

T.C.  
DICLE ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

SAR UYDU İMGELERİ KULLANILARAK YARI DENEYSEL VE  
MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE TOPRAK NEMİNİN  
TAHMİNİ: KARŞILAŞTIRMALI BİR SAHA ÇALIŞMASI

Hüseyin ACAR

DOKTORA TEZİ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

DIYARBAKIR

Aralık – 2020

T.C.  
DİCLE ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

SAR UYDU İMGELERİ KULLANILARAK YARI DENEYSEL VE  
MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE TOPRAK NEMİNİN  
TAHMİNİ: KARŞILAŞTIRMALI BİR SAHA ÇALIŞMASI

Hüseyin ACAR

DOKTORA TEZİ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

DIYARBAKIR

Aralık – 2020

## TEŐEKKÜR

Bu alıŐma, TUBİTAK (No. 114E543), DUBAP ve TARBİL projeleri kapsamında desteklenmiŐtir. Desteklerinden oturu TUBİTAK'a, TARBİL'e ve Dicle Üniversitesi Bilimsel AraŐtırma Projeleri Koordinatörluđüne teŐekkür ederim.

alıŐmalarımı yönlendirmesinde, araŐtırmalarımın her aŐamasında bilgi, öneri ve yardımlarını esirgemeyen danıŐman hocam Prof. Dr. Mehmet Sıra ÖZERDEM'e, Tez İzleme Komitesi üyeleri Prof. Dr. Zeynel Fuat TOPRAK ve Dr. Öğr. Üyesi Muhammet Ali ARSERİM'e ve alıŐmalarım boyunca her konuda destek veren ArŐ. Gör. Cem HAYDAROĞLU'na teŐekkür ederim.

Akademik alıŐmalarım süresince maddi ve manevi desteđini esirgemeyen aileme ayrıca teŐekkür ederim.

## İÇİNDEKİLER

	Sayfa
<b>TEŞEKKÜR</b> .....	I
<b>İÇİNDEKİLER</b> .....	II
<b>ÖZET</b> .....	IV
<b>ABSTRACT</b> .....	VI
<b>ÇİZELGE LİSTESİ</b> .....	VIII
<b>ŞEKİL LİSTESİ</b> .....	IX
<b>KISALTMA VE SİMGELER</b> .....	XII
<b>1. GİRİŞ</b> .....	1
1.1 Tezin Hedefi .....	1
1.2. Tezin İçeriği .....	2
<b>2. KAYNAK ÖZETLERİ</b> .....	3
2.1. Toprak Neminin Tahmini ve Önemi .....	3
2.2. Yersel Ölçümler ile Toprak Neminin Tahmini .....	5
2.3. Uzaktan Algılama ile Toprak Neminin Tahmini .....	6
2.4. Farklı Modeller ile Toprak Nem Tahmini .....	10
2.4.1. Deneysel, Yarı Deneysel ve Teorik Modeller ile Toprak Nem Tahmini..	10
2.4.2. Makine Öğrenmesi Modelleri ile Toprak Nem Tahmini .....	12
<b>3. MATERYAL ve METOT</b> .....	19
3.1. Çalışma Alanı ve Çalışmada Kullanılan Veriler .....	19
3.1.1. Çalışma Alanı .....	19
3.1.2. Yersel Toprak Nem Ölçümleri .....	19
3.1.3. Uzaktan Algılama Verisi .....	20
3.1.4. Radarsat-2 Verisinin Ön İşlenmesi .....	21
3.1.4.1. Radyometrik Kalibrasyon .....	22
3.1.4.2. Çoklu-bakış .....	22
3.1.4.3. Benek Filtreleme .....	22

3.1.4.4.	Arazi Düzeltme ve Coğrafi Kodlama .....	23
3.2.	Polarimetrik Ayırıştırma Modelleri .....	28
3.2.1.	Freeman-Durden Ayırıştırma Modeli .....	29
3.2.2.	Yamaguchi Ayırıştırma Modeli .....	34
3.2.3.	Van Zyl Ayırıştırma Modeli .....	36
3.2.4.	Cloude-Pottier (H/A/ $\alpha$ ) Ayırıştırma Modeli .....	39
3.2.5.	Cloude Ayırıştırma Modeli .....	41
3.3.	Radar İmgelerinden Özellik Çıkarma .....	41
3.4.	Toprak Nem Tahminini Etkileyen Parametreler .....	42
3.4.1.	SAR Sensör Parametreleri .....	42
3.4.2.	Hedef Parametreleri .....	43
3.5.	Yarı Deneysel Modeller ile Toprak Neminin Tahmini .....	45
3.5.1.	Oh Modelleri .....	45
3.5.2.	Dubois Modeli .....	48
3.6.	Makine Öğrenmesi Yöntemleri ile Toprak Neminin Tahmini .....	48
3.6.1.	En Küçük Kareler Destek Vektör Makineleri (LS-SVM) .....	48
3.6.2.	Genelleştirilmiş Regresyon Sinir Ağı (GRNN) .....	51
3.6.3.	Aşırı Öğrenme Makineleri (ELM) ve Kernel ELM .....	52
3.6.4.	Adaptif Sinirsel Bulanık Çıkarım Sistemi (ANFIS) .....	54
3.7.	Tez Kapsamında Önerilen Modeller .....	57
<b>4.</b>	<b>BULGULAR VE TARTIŞMA</b> .....	<b>59</b>
<b>5.</b>	<b>SONUÇLAR ve ÖNERİLER</b> .....	<b>83</b>
<b>6.</b>	<b>KAYNAKLAR</b> .....	<b>85</b>
	<b>ÖZGEÇMİŞ</b> .....	<b>94</b>

## ÖZET

### SAR UYDU İMGELERİ KULLANILARAK YARI DENEYSSEL VE MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE TOPRAK NEMİNİN TAHMİNİ: KARŞILAŞTIRMALI BİR SAHA ÇALIŞMASI

DOKTORA TEZİ

Hüseyin ACAR

DİCLE ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ  
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

2020

Uzaktan algılama teknolojisi, geniş bir aralıkta gözlem yapabilme, zamanında ve daha az kısıtla veri toplama yeteneği sayesinde birçok alanda yaygın olarak kullanılmaktadır. Tarım, uzaktan algılamanın uygulanması ve araştırılması için en önemli alanlardan biridir. Aktif mikrodalga SAR sensörleri, yüksek çözünürlük sağlamaları, hava şartlarından etkilenmemeleri ve toprak nemine olan duyarlılıkları nedeniyle büyük ölçekli toprak nem tahmini için uygundur. Son yıllarda uzaktan algılama alanında doğrusal olmayan makine öğrenme teknikleri toprak nem tahmini için önerilmektedir.

Bu çalışmada yüzey toprak nemi, Radarsat-2 ve polarimetrik hedef ayrıştırma verisi kullanılarak yarı deneysel modeller ve makine öğrenmesi yöntemleri ile tahmin edilmeye çalışılmıştır. Oh (1992), Dubois (1995) ve Oh (2004) yarı deneysel modelleri ve Genelleştirilmiş Regresyon Sınır Ağı (GRNN), En Küçük Kareler Destek Vektör Makineleri (LS-SVM), Aşırı Öğrenme Makinesi (ELM), Kernel tabanlı Aşırı Öğrenme Makinesi (KELM), Adaptif Sinirsel Bulanık Çıkarım Sistemi (ANFIS) makine öğrenmesi yöntemleri kullanılmıştır.

Bu çalışmada Yamaguchi, van Zyl, Freeman-Durden, H/A/α ve Cloude polarimetrik hedef ayrıştırma yöntemleri kullanılmıştır. Toprak neminin inversiyonu için ilk olarak yalın ve orta seviyede bitki örtülü toprak için iki farklı tarihe ait Radarsat-2 imgesine ön işlemler uygulanmıştır. Sonra sigma geri saçılma katsayıları ve polarimetrik ayrıştırma katsayıları özellik vektörü olarak kullanılmak üzere ön işlemleri tamamlanan ve yersel ölçüm noktalarına karşılık gelen SAR imge piksellerinden çıkarılmıştır. Son olarak, elde edilen sigma geri saçılma katsayıları yarı deneysel modellerde kullanılmıştır. Makine öğrenmesi yöntemlerinde ise sigma geri saçılma katsayıları ve polarimetrik ayrıştırma bileşenleri giriş olarak kullanılmıştır.

Yarı deneysel modeller ile yalın ve orta seviyede bitki örtülü toprak için en iyi doğruluk sonuçları kare ortalamalarının karekökü hatası (RMSE) olarak sırasıyla 13.01 ve 17.91 olarak elde edilmiştir. Makine öğrenmesi teknikleri ile en iyi doğruluk sonuçları RMSE cinsinden sırasıyla 4.04 ve 2.72 olarak elde edilmiştir. Sonuçlar, makine öğrenmesi tekniklerinin yarı deneysel modellerden çok daha iyi performansa sahip olduğunu göstermiştir.

**Anahtar Kelimeler:** Toprak Nem İncersiyonu, Radarsat-2 Verisi, Uzaktan Algılama, Polarimetrik Hedef Ayrıştırma, Yarı Deneysel Modeller, Makine Öğrenmesi



## ABSTRACT

### ESTIMATION OF SOIL MOISTURE VIA SEMIEMPIRICAL AND MACHINE LEARNING METHODS USING SAR SATELLITE IMAGES: A COMPARATIVE FIELD STUDY

PhD THESIS

Hüseyin ACAR

DEPARTMENT OF ELECTRICAL-ELECTRONICS ENGINEERING  
INSTITUTE OF NATURAL AND APPLIED SCIENCES  
UNIVERSITY OF DICLE

2020

Remote sensing technology is widely used in many fields thanks to its ability to observe in a wide range and to collect data on time and with less constraints. Agriculture is one of the most important areas for the application and research of remote sensing. Active microwave SAR sensors are suitable for large-scale soil moisture estimation due to their high resolution, not affected by weather conditions and sensitivity to soil moisture. In recent years, in the field of remote sensing nonlinear machine learning techniques have been recommended for soil moisture estimation.

In this study, surface soil moisture was retrieved from Radarsat-2 and polarimetric target decomposition data by using semiempirical models and machine learning methods. The semiempirical models and machine learning techniques employed were Oh (1992), Dubois (1995), Oh (2004) and Generalized Regression Neural Network (GRNN), Least Squares – Support Vector Machine (LS-SVM), Extreme Learning Machine (ELM), Kernel based Extreme Learning Machine (KELM), Adaptive Neuro-Fuzzy Inference System (ANFIS), respectively.

In addition, Yamaguchi, van Zyl, Freeman-Durden, H/A/ $\alpha$  and Cloude polarimetric target decomposition methods were used in this study. For soil moisture inversion, firstly, preprocessing was applied to the Radarsat-2 image of two different dates with bare and moderately vegetated soil. Then, sigma nought coefficients and the polarimetric decomposition components were extracted as feature vector from preprocessed SAR image pixels corresponding to ground measured points. Lastly, sigma nought coefficients were used in semiempirical inversion models, and sigma nought coefficients and polarimetric decomposition components were used as input to machine learning methods.

The best accuracy results for semiempirical models were 13.01 and 17.91 Root Mean Square Error (RMSE) for bare and moderately vegetated soil, respectively. The best accuracy for machine learning techniques were 4.04 and 2.72 RMSE for two dates, respectively. The results indicated that the machine learning techniques performed much better than the semiempirical models.

**Key Words:** Soil Moisture Inversion, Radarsat-2 Imagery, Remote Sensing, Polarimetric Target Decomposition, Semiempirical Models, Machine Learning



## ÇİZELGE LİSTESİ

<b><u>Çizelge No</u></b>	<b><u>Sayfa</u></b>
<b>Çizelge 3.1.</b> Yersel toprak nem ölçümleri	20
<b>Çizelge 3.2.</b> Radarsat-2 imgelerine ait bilgiler	21
<b>Çizelge 3.3.</b> Polarimetrik ayrıştırma yöntemleri ve bileşenleri	28
<b>Çizelge 4.1.</b> Toprak neminin inversiyonu için kullanılan farklı yaklaşımların karşılaştırılması	82



## ŞEKİL LİSTESİ

<u>Şekil No</u>		<u>Sayfa</u>
Şekil 2.1.	Toprak nem tahmini için literatürde önerilen temel yaklaşımların sınıflandırılması	5
Şekil 2.2.	Aktif SAR uzaktan algılama verisi ile toprak neminin tahmini için literatürde önerilen temel yaklaşımların sınıflandırılması	17
Şekil 3.1.	Çalışma alanını gösteren harita, (a) RGB Radarsat-2 imgesi, (b) örnek alınan noktalar Google Earth imgesinde kırmızı noktalar ile gösterilmiştir	20
Şekil 3.2.	Radarsat-2 verisine uygulanan ön işlemleri gösteren akış şeması	21
Şekil 3.3.	SAR geometrik bozulmalar (a) kısaltım, (b) örtüşme ve (c) gölgeleme	24
Şekil 3.4.	Radarsat-2 SLC imgeleri (a) 10 Haziran 2015 ve (b) 3 Mart 2016	25
Şekil 3.5.	Ön işlemleri tamamlanmış Radarsat-2 verilerinden elde edilen RGB imgeleri (a) 10 Haziran 2015, (b) 3 Mart 2016 sigma tekniği <sup>1</sup> ; (c) 10 Haziran 2015 ve (d) 3 Mart 2016 Yamaguchi ayrıştırması metodu <sup>2</sup>	27
Şekil 3.6.	Temel saçılma mekanizmaları (a) Yüzey saçılması, (b) Çift sıçrama saçılması, (c) Hacimsel saçılma ve (d) Helis saçılması	29
Şekil 3.7.	Çalışmanın akış şeması	42
Şekil 3.8.	GRNN mimarisi	51
Şekil 3.9.	ANFIS mimarisi	55
Şekil 4.1.	Sigma tekniği kullanılarak türetilen ve çalışma alanını içeren ön işlemi tamamlanmış 10 Haziran 2015 tarihli Radarsat-2 SAR verisine ait RGB görüntüsü (R=HH, G=HV ve B=HH/HV)	60
Şekil 4.2.	Yamaguchi ayrıştırma tekniği kullanılarak türetilen ve çalışma alanını içeren ön işlemi tamamlanmış 10 Haziran 2015 tarihli Radarsat-2 SAR verisine ait RGB görüntüsü (R=Çift sıçrama saçılması, G=Hacimsel saçılma ve B=Yüzey saçılması)	60
Şekil 4.3.	van Zyl ayrıştırma tekniği kullanılarak türetilen ve çalışma alanını içeren ön işlemi tamamlanmış 10 Haziran 2015 tarihli Radarsat-2 SAR verisine ait RGB görüntüsü (R=Çift sıçrama saçılması, G=Hacimsel saçılma ve B=Yüzey saçılması)	61
Şekil 4.4.	Freeman-Durden ayrıştırma tekniği kullanılarak türetilen ve çalışma alanını içeren ön işlemi tamamlanmış 10 Haziran 2015 tarihli Radarsat-2 SAR verisine ait RGB görüntüsü (R=Çift sıçrama saçılması, G=Hacimsel saçılma ve B=Yüzey saçılması)	61
Şekil 4.5.	H/A/α ayrıştırma tekniği kullanılarak türetilen ve çalışma alanını içeren ön işlemi tamamlanmış 10 Haziran 2015 tarihli Radarsat-2 SAR verisine ait RGB görüntüsü (R=Entropi, G=Anizotropi ve B=α)	62

<b>Şekil 4.6.</b>	Cloude ayrıştırma tekniği kullanılarak türetilen ve çalışma alanını içeren ön işlemi tamamlanmış 10 Haziran 2015 tarihli Radarsat-2 SAR verisine ait RGB görüntüsü (R=Çift sıçrama saçılması, G=Hacimsel saçılma ve B=Yüzey saçılması)	62
<b>Şekil 4.7.</b>	Sigma tekniği kullanılarak türetilen ve çalışma alanını içeren ön işlemi tamamlanmış 3 Mart 2016 tarihli Radarsat-2 SAR verisine ait RGB görüntüsü (R=HH, G=HV ve B=HH/HV)	63
<b>Şekil 4.8.</b>	Yamaguchi ayrıştırma tekniği kullanılarak türetilen ve çalışma alanını içeren ön işlemi tamamlanmış 3 Mart 2016 tarihli Radarsat-2 SAR verisine ait RGB görüntüsü (R=Çift sıçrama saçılması, G=Hacimsel saçılma ve B=Yüzey saçılması)	63
<b>Şekil 4.9.</b>	van Zyl ayrıştırma tekniği kullanılarak türetilen ve çalışma alanını içeren ön işlemi tamamlanmış 3 Mart 2016 tarihli Radarsat-2 SAR verisine ait RGB görüntüsü (R=Çift sıçrama saçılması, G=Hacimsel saçılma ve B=Yüzey saçılması)	64
<b>Şekil 4.10.</b>	Freeman-Durden ayrıştırma tekniği kullanılarak türetilen ve çalışma alanını içeren ön işlemi tamamlanmış 3 Mart 2016 tarihli Radarsat-2 SAR verisine ait RGB görüntüsü (R=Çift sıçrama saçılması, G=Hacimsel saçılma ve B=Yüzey saçılması)	64
<b>Şekil 4.11.</b>	H/A/ $\alpha$ ayrıştırma tekniği kullanılarak türetilen ve çalışma alanını içeren ön işlemi tamamlanmış 3 Mart 2016 tarihli Radarsat-2 SAR verisine ait RGB görüntüsü (R=Entropi, G=Anizotropi ve B= $\alpha$ )	65
<b>Şekil 4.12.</b>	Cloude ayrıştırma tekniği kullanılarak türetilen ve çalışma alanını içeren ön işlemi tamamlanmış 3 Mart 2016 tarihli Radarsat-2 SAR verisine ait RGB görüntüsü (R=Çift sıçrama saçılması, G=Hacimsel saçılma ve B=Yüzey saçılması)	65
<b>Şekil 4.13.</b>	Oh (1992) yarı deneysel modeli ile 10 Haziran 2015 Radarsat-2 verilerinden toprak nemi inversiyonu	67
<b>Şekil 4.14.</b>	Dubois (1995) yarı deneysel modeli ile 10 Haziran 2015 Radarsat-2 verilerinden toprak nemi inversiyonu	67
<b>Şekil 4.15.</b>	Oh (2004) yarı deneysel modeli ile 10 Haziran 2015 Radarsat-2 verilerinden toprak nemi inversiyonu	68
<b>Şekil 4.16.</b>	Oh (1992) yarı deneysel modeli ile 3 Mart 2016 Radarsat-2 verilerinden toprak nemi inversiyonu	68
<b>Şekil 4.17.</b>	Dubois (1995) yarı deneysel modeli ile 3 Mart 2016 Radarsat-2 verilerinden toprak nemi inversiyonu	69
<b>Şekil 4.18.</b>	Oh (2004) yarı deneysel modeli ile 3 Mart 2016 Radarsat-2 verilerinden toprak nemi inversiyonu	69
<b>Şekil 4.19.</b>	Yarı deneysel modeller kullanılarak toprak nemi inversiyonu (a) 10 Haziran 2015 Radarsat-2 verileri, (b) 3 Mart 2016 Radarsat-2 verileri	70

<b>Şekil 4.20.</b>	10 Haziran 2015 tarihli tüm örnekler için sigma geri saçılma katsayılarından oluşan özellik vektörünü kullanan GRNN makine öğrenmesi yöntemi ile toprak nemi inversiyonu	72
<b>Şekil 4.21.</b>	10 Haziran 2015 tarihli tüm örnekler için Yamaguchi ayrıştırma bileşenlerinden oluşan özellik vektörünü kullanan LS-SVM makine öğrenmesi yöntemi ile toprak nemi inversiyonu	72
<b>Şekil 4.22.</b>	10 Haziran 2015 tarihli tüm örnekler için Freeman-Durden ayrıştırma bileşenlerinden oluşan özellik vektörünü kullanan ELM makine öğrenmesi yöntemi ile toprak nemi inversiyonu	73
<b>Şekil 4.23.</b>	10 Haziran 2015 tarihli tüm örnekler için van Zyl ayrıştırma bileşenlerinden oluşan özellik vektörünü kullanan KELM makine öğrenmesi yöntemi ile toprak nemi inversiyonu	73
<b>Şekil 4.24.</b>	10 Haziran 2015 tarihli tüm örnekler için H/A/α ayrıştırma bileşenlerinden oluşan özellik vektörünü kullanan ANFIS makine öğrenmesi yöntemi ile toprak nemi inversiyonu	74
<b>Şekil 4.25.</b>	3 Mart 2016 tarihli tüm örnekler için sigma geri saçılma katsayılarından oluşan özellik vektörünü kullanan GRNN makine öğrenmesi yöntemi ile toprak nemi inversiyonu	74
<b>Şekil 4.26.</b>	3 Mart 2016 tarihli tüm örnekler için Yamaguchi ayrıştırma bileşenlerinden oluşan özellik vektörünü kullanan LS-SVM makine öğrenme yöntemi ile toprak nemi inversiyonu	75
<b>Şekil 4.27.</b>	3 Mart 2016 tarihli tüm örnekler için Freeman-Durden ayrıştırma bileşenlerinden oluşan özellik vektörünü kullanan ELM makine öğrenme yöntemi ile toprak nemi inversiyonu	75
<b>Şekil 4.28.</b>	3 Mart 2016 tarihli tüm örnekler için van Zyl ayrıştırma bileşenlerinden oluşan özellik vektörünü kullanan KELM makine öğrenme yöntemi ile toprak nemi inversiyonu	76
<b>Şekil 4.29.</b>	3 Mart 2016 tarihli tüm örnekler için H/A/α ayrıştırma bileşenlerinden oluşan özellik vektörünü kullanan ANFIS makine öğrenme yöntemi ile toprak nemi inversiyonu	76
<b>Şekil 4.30.</b>	10 Haziran 2015 tarihli imgeden makine öğrenmesi modellerini kullanarak toprak nem inversiyonunun hesaplanan RMSE değerleri. Özellik vektörü olarak (a) Sigma değerleri, (b) Yamaguchi ayrıştırma bileşenleri, (c) Genelleştirilmiş Freeman-Durden ayrıştırma bileşenleri, (d) van Zyl ayrıştırma bileşenleri, (e) Cloude ayrıştırma bileşenleri, (f) H/A/α ayrıştırma bileşenleri kullanılmıştır	78
<b>Şekil 4.31.</b>	3 Mart 2016 tarihli imgeden makine öğrenmesi modellerini kullanarak toprak nem inversiyonunun hesaplanan RMSE değerleri. Özellik vektörü olarak (a) Sigma değerleri, (b) Yamaguchi ayrıştırma bileşenleri, (c) Genelleştirilmiş Freeman-Durden ayrıştırma bileşenleri, (d) van Zyl ayrıştırma bileşenleri, (e) Cloude ayrıştırma bileşenleri, (f) H/A/α ayrıştırma bileşenleri kullanılmıştır	80

## KISALTMA VE SİMGELER

A	: Anizotropi
AIEM	: Gelişmiş İntegral Eşitlik Modeli
ANFIS	: Adaptif Sinirsel Bulanık Çıkarım Sistemi
BPNN	: Geri Yayılımlı Sinir Ağı
DEM	: Dijital Yükseklik Modeli
$\delta p$	: Penetrasyon derinliği
ELM	: Aşırı Öğrenme Makinesi
$\epsilon_r$	: Bağlı dielektrik sabiti
ESA	: Avrupa Uzay Ajansı
FDR	: Frekans Alanı Reflektometri
GOM	: Geometrik Optik Modeli
GRNN	: Genelleştirilmiş Regresyon Sinir Ağı
H	: Entropi
HH	: Yatay-yatay polarizasyon
HV	: Yatay-dikey polarizasyon
IEM	: İntegral Eşitlik Modeli
KA	: Kirchhoff Yaklaşımı
KELM	: Kernel tabanlı Aşırı Öğrenme Makinesi
L	: Korelasyon uzunluğu
LAI	: Bitki Yaprak Alanı İndeksi
$\lambda$	: Dalga boyu
LS-SVM	: En Küçük Kareler Destek Vektör Makinesi
LST	: Kara Yüzeyi Sıcaklığı
LUT	: Arama Tablosu (Look-Up Table)
MF	: Üyelik Fonksiyonları
MLP	: Çok Katmanlı Algılayıcı
MLR	: Çok Değişkenli Doğrusal Regresyon
MMSE	: Minimum Ortalama Kare Hata
MPDI	: Mikrodalga Polarizasyon Fark İndeksi
$m_v$	: Volümetrik toprak nemi
NDVI	: Normalize Edilmiş Fark Bitki Örtüsü İndeksi
NN	: Sinir Ağları
p	: Eş-polarizasyon oranı
POM	: Fiziksel Optik Modeli
q	: Çapraz-polarizasyon oranı
r	: Korelasyon katsayısı
RMSE	: Kare Ortalamalarının Karekökü Hatası
s	: Yüzey yüksekliğinin standart sapması

SAR	: Sentetik Açıklıklı Radar
$\sigma^{\circ}$	: Sigma geri saçılma katsayısı
SLC	: Tek Görünümlü Kompleks
SPM	: Küçük Pertürbasyon Yöntemi
SVM	: Destek Vektör Makineleri
SVR	: Destek Vektör Regresyonu
TDR	: Zaman Alanı Reflektometri
$\theta$	: Gelme açısı
VI	: Bitki Örtüsü İndeksi
VH	: Dikey-yatay polarizasyon
VV	: Dikey-dikey polarizasyon
YSA	: Yapay Sinir Ağı



## 1. GİRİŞ

### 1.1. Tezin Hedefi

Toprak nemi tarım, hidroloji ve iklim çalışmaları gibi birçok uygulamada çok önemli bir parametre olup toprak neminin doğru ve hassas uzamsal tahminleri gereklidir (Xing ve ark. 2019). Toprak suyu içeriği olarak da bilinen toprak nemi, genellikle toprak parçacıkları arasında bulunan su miktarı olarak tanımlanır. Toprak nemi, toprak ve atmosfer etkileşimini analiz etmede yaygın olarak kullanılan bir ölçüdür (Shang ve ark. 2007). Tarımdaki toprak nemi bitki büyümesi ile yakından ilişkilidir. Toprak neminin doğru ve güvenilir bir şekilde ölçülmesi, su kaynaklarının kullanımında ve toprak yönetiminde yararlıdır (Verhoest ve ark. 2008).

Toprak nemini belirlemek için kullanılan geleneksel ölçüm yöntemleri; zaman, finansal maliyet ve işçilik konularında dezavantajlara sahiptir. Ayrıca düz homojen arazilerde bile toprak neminin yüksek lokal mekânsal değişkenliği nedeniyle dağılımını yeterince karakterize etmek için çok sayıda alan örneği gerekmektedir. Bu lojistik kısıtlama, uzaktan algılanmış iyi çözünürlüğe sahip imgeler kullanılarak çözülebilir. Mikrodalga (radar) ile uzaktan algılama, hidrolojik uygulamaları için özel olarak kullanılmaktadır. Radara geri yansıyan enerji, yüzeydeki toprak nemi içeriğindeki değişikliklere duyarlı olduğundan (Kornelsen ve Coulibaly 2013), toprak nemini tahmin etmek için son yıllarda özellikle aktif mikrodalga sensörleri ile uzaktan algılama teknolojileri kullanılarak çok sayıda araştırma yapılmıştır (Baghdadi ve ark. 2012, Kumar ve ark. 2019, Ezzahar ve ark. 2020).

Bu tez çalışması ile hedeflenen, Sentetik Açıklıklı Radar (SAR) uydu imgelerinden elde edilen öznelikler ile volümetrik toprak nemini tahmin etmektir. Bu amaçla, toprak nemini tahmin etmek için yarı deneysel nem tahmin modelleri ve beş farklı makine öğrenme yöntemi kullanılmıştır. Bu çalışmanın literatüre katkıları ve diğer çalışmalara göre farklı yönleri şöyle özetlenebilir:

- 1) Toprak nem tahmini, yarı deneysel nem tahmin modelleri ve farklı makine öğrenme modelleri ile gerçekleştirilmiştir.

## 1. GİRİŞ

---

- 2) Makine öğrenmesi modellerine girdi olarak SAR imgesinden elde edilen farklı polarimetrik ayrıştırma katsayıları özellik vektörü olarak kullanılmıştır.
- 3) Önerilen yaklaşım ile ön işlemler tamamlanmış Radarsat-2 imgesinden elde edilen Yamaguchi polarimetrik ayrıştırma katsayıları, toprak nemini tahmin etmek için ilk kez kullanılmıştır.

### 1.2. Tezin İçeriği

Tezin birinci bölümünde tezin hedefi ve tezin içeriği açıklanmıştır. Tezin kapsadığı diğer bölümler aşağıdaki gibi organize edilmiştir.

İkinci bölümde; toprak nemi tahmininin önemi, toprak nemi tahmini için kullanılan geleneksel ölçüm ve uzaktan algılama yöntemleri, deneysel, yarı deneysel, teorik modeller ve makine öğrenmesi modelleri ile toprak nem tahmini ile ilgili literatürde yapılan çalışmalar sunulmuştur.

Üçüncü bölümde; çalışma alanı, çalışmada kullanılan verilerin (Radarsat-2 imgeleri ve yersel toprak nem ölçümleri) özellikleri ve Radarsat-2 imgelerine uygulanan ön işlemler, polarimetrik ayrıştırma yöntemleri, Radarsat-2 imgelerinden özellik çıkarma, toprak nem tahminini etkileyen parametreler, çalışmada kullanılan yarı deneysel modeller ile makine öğrenmesi yöntemleri anlatılmıştır.

Dördüncü bölümde; toprak neminin tahmin edilmesi için yarı deneysel modeller ve makine öğrenmesi yöntemleriyle elde edilen bulgular ile birlikte bulguların tartışılması yer almaktadır. Ayrıca elde edilen sonuçlar literatürdeki diğer çalışmalar ile karşılaştırılmıştır.

Son bölümde ise tez çalışması ile literatüre yapılan katkılardan ve ileride yapılabilecek çalışmalardan söz edilmiştir.

## 2. KAYNAK ÖZETLERİ

Bu tez kapsamında SAR uydu imgelerinden elde edilen öznelikler ile volümetrik toprak neminin tahmini amaçlanmıştır. Bu bölümde, tez konusunun önemi ve konuyla ilişkili literatür çalışmalarına yer verilmiştir.

### 2.1. Toprak Neminin Tahmini ve Önemi

Tarımsal verimlilik büyük ölçüde suyun varlığına bağlıdır. Bundan dolayı su kaynaklarının yönetimi, ele alınması gereken son derece önemli bir konudur. Toprak nemi hakkında kesin bilgi edinmek, uygun bir su kaynağı yönetim şemasının hazırlanmasını etkileyen ana faktördür (Petropoulos ve ark. 2018). Ayrıca yüzey toprak nemi, buharlaşma hızı ve dolayısıyla mikro-meteoroloji üzerinde etkilidir ve dolayısıyla enerji ve karbon döngülerine etkisi bulunmaktadır (Walker ve Houser 2004). Toprak nemi; iklim tahmini, hava tahmini (Koster ve ark. 2011) ve hidrolojik modelleme (Chen ve ark. 2011) gibi uygulamalarla birçok disiplinde farklı uzamsal ve zamansal ölçeklerde kullanılmaktadır. Özellikle toprak neminin doğru tahmin edilmesinin uzamsal/zamansal değişikliklerine ve anormalliklerine ilişkin haritalarının oluşturulması, dünyanın birçok bölgesinde ciddi sorunlar olarak görülen kuraklık (Martínez-Fernández ve ark. 2016) ve sel riskini (Brocca ve ark. 2017) izleme olanağını artırabilir.

Toprak neminin tahmini, geleneksel olarak doğrudan topraktan örnek alınması ve içeriğindeki su miktarının belirlenmesinden oluşan saha çalışması ile gerçekleştirilir. Bu tür ölçüm toprak neminin doğrudan ve doğru bir şekilde belirlenmesi için en güvenilir araç olarak kabul edilmekle birlikte bu tür yöntemlerin uygulanması zaman alıcı, zahmetli ve pahalıdır (Zhang ve ark. 2014). Modern problemler ile yapılabilen toprak nem ölçümü daha kolay olmasına rağmen, bu problemleri kullanarak toprak nemini ölçmek hala hem zaman hem de finansal açıdan maliyetlidir. Ayrıca doğrudan gravimetrik yöntemle problemlerin kalibrasyonuna ihtiyaç duyulmaktadır. Kalıcı problemler ile sensör ağlarının kurulması, toprak nem bilgilerinin toplanması için gereken çabayı azaltmaya yardımcı olabilir, ancak bu geniş alanlar için pratik bir yöntem değildir. Ayrıca sözü edilen bu yöntemlerle oluşturulacak toprak nem haritaları küçük alanlar için bilgi sağlarken, daha geniş alanları temsil edecek büyük ölçekli toprak nem haritalarının oluşturulması zordur.

## 2. KAYNAK ÖZETLERİ

---

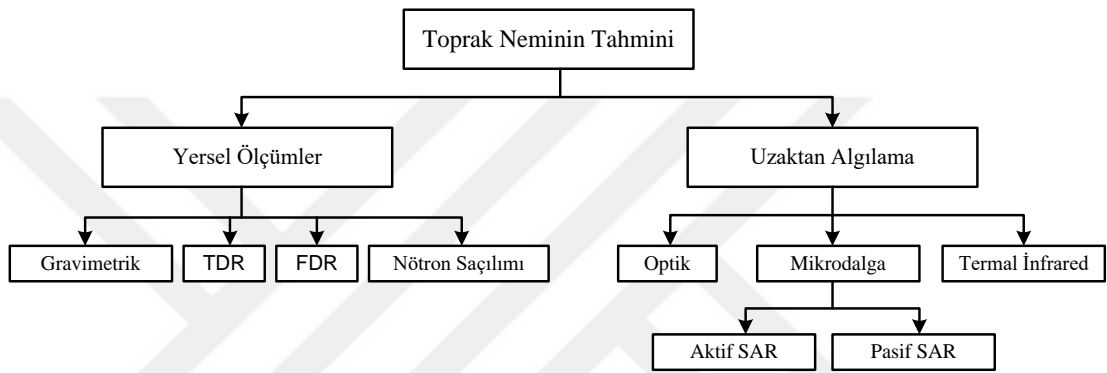
Geleneksel ölçüm yöntemleri ile toprak neminin belirlenmesinde karşılaşılan zorluklar ve son yirmi yılda birçok uydunun faaliyete geçmesiyle birlikte dünya yüzeyinin tam, periyodik ve kapsamlı uzaktan algılama verilerinin artması, toprak nem tahmininde uzaktan algılamanın kullanılmasına yönelik araştırmaların yoğun bir şekilde artmasını sağlamıştır (Baghdadi ve Zribi 2006, Wang ve Qu 2009). Uzaktan algılama verisini kullanarak toprak nemi ile ilgili araştırmalar 1970'lerde başlamıştır (Schmugge 1974) ve halen aktif bir araştırma alanıdır. Uzaktan algılama, benzersiz veri toplama özellikleri nedeniyle yüzey toprak nemini tahmin etmek için umut verici görünmektedir. Özellikle, radyometreler gibi mikrodalga uzaktan algılama sensörleri, saçılımölçerler ve SAR, mikrodalga elektromanyetik dalgaların toprağın dielektrik özelliklerine (Topp ve ark. 1980) (ve dolayısıyla su içeriğine) hassasiyeti sayesinde toprak nem içeriğini tahmin etmek için yoğun bir şekilde kullanılır.

Günümüzde yersel, hava ve uzay kaynaklı uzaktan algılama teknikleri, büyük ölçekli yakın zemin toprak özelliklerinin makul zamansal ve uzamsal çözünürlüklerde karakterizasyonu ve izlenmesi için son derece etkili bir yol sunmaktadır. Toprak neminin tahmini için optik ve mikrodalga uzaktan algılama verisini içeren elektromanyetik radyasyonun yansıtma ve/veya emisyonuna dayalı çok sayıda çalışma yapılmıştır. Optik tabanlı uzaktan algılama yöntemleri olarak Landsat (Sadeghi ve ark. 2017), MODIS (Piles ve ark. 2011), Hyperion (Song ve ark. 2014) ve HyMap (Haubrock 2008) gibi geniş bant ve dar bant optik uydu ve hava kaynaklı sensörler; mikrodalga tabanlı uzaktan algılama yöntemleri olarak aktif ve pasif sensörler (Walker ve ark. 2004, Liu ve ark. 2012) toprak nem tahmininde kullanılmaktadır.

Uzaktan algılama sensörleri ile toprak nemi tahmin işlemi zorlu bir işittir. Çünkü uzaktan algılama sensörüne topraktan geri yansıyan sinyal; toprak nemi, toprak yüzey pürüzlülüğü, bitki örtüsü, topoğrafya ve arazi kullanım heterojenliğine karşı duyarlıdır (Ulaby ve ark. 1982, Pasolli ve ark. 2012). Ayrıca sensörün algıladığı sinyalde bitki örtüsünün etkisi nedeniyle toprağın katkısı net değildir. Toprak nemi tahmininde bitki örtüsü tabakasının katkısını etkili bir şekilde gidermek için, birçok bilim adamı polarimetrik ayrışma yöntemlerine dayanan çalışmalar yapmıştır (Jaghuber ve ark. 2013, Huang ve ark. 2016). SAR polarimetrisi, saçılma matrisinin kanonik saçılma bileşenlerine ayrışmasına ve miktarlarının belirlenmesine izin vermektedir. Ekili

alanlardaki ana saçılma türleri, ekili alanlardaki saçılma süreçlerini modellemek ve yorumlamak için kullanılabilen yüzey, çift sıçrama ve volümetrik saçılma mekanizmalarıdır. Sensöre geri gelen toplam saçılma yerine yalın ve seyrek bitki örtülü araziler için yüzey geri saçılma katsayılarının kullanılmasıyla, toprak nemi tahminlerinde bir iyileşme gözlenmiştir.

Yukarıda sözü edilen bilgiler çerçevesinde, toprak neminin tahminine ilişkin önerilen yaklaşımlar Şekil 2.1.'de gösterilmiştir. Şekilde gösterilen temel yaklaşımların detayları alt bölümlerde açıklanmıştır.



**Şekil 2.1.** Toprak nem tahmini için literatürde önerilen temel yaklaşımların sınıflandırılması

## 2.2. Yersel Ölçümler ile Toprak Neminin Tahmini

Yersel ölçümler ile toprak nemi ölçümü; gravimetrik yöntem ile doğrudan ya da dielektrik sabiti kullanımı ve nötron saçılımı tespiti gibi elektromanyetik teknikler ile dolaylı olarak ölçülebilir (Schmugge ve ark. 1980). Doğrudan tahmin yöntemi olan gravimetrik yöntemde, topraktan alınan numuneler önce bir fırında kurutulur. Toprak örneğinin ağırlığı kurutma işleminden önce ve sonra elde edilebilir. İki ağırlık arasındaki fark, buharlaşan su içeriğini gösterir ve ayrıca su ağırlığının toplam ağırlığa oranı, toprak nem yüzdesinin hesabı için kullanılabilir. Toprağın hacmi göz önüne alındığında, volümetrik toprak nemi hesaplanabilir.

Toprağın çeşitli özelliklerini algılayarak ve daha sonra bu özellikleri toprak nemi ile ilişkilendirerek, toprak nem değerlerini dolaylı olarak hesaplamak mümkündür. Bu özelliklerden ikisi toprağın dielektrik sabiti ve hidrojen içeriğidir. Bağlı geçirgenlik olarak da bilinen dielektrik sabiti, bir dielektrik malzemenin bir elektriksel alana maruz kaldığında nasıl davrandığını tanımlayan bir parametredir. Bu parametre toprak için iki

## 2. KAYNAK ÖZETLERİ

---

yolla ölçülebilir: Zaman Alanı Reflektometri (TDR) ve Frekans Alanı Reflektometri (FDR). TDR, elektromanyetik dalgaları topraktan ileterek çalışır. Toprakta iletilen elektromanyetik dalganın hızı, dalganın toprakta yayılması için gereken sürenin ölçülmesiyle hesaplanır. Hız, toprağın dielektrik sabiti ile ilgilidir, bu da hacimsel toprak suyunun içeriğine bağlıdır (Dalton ve Van Genuchten 1986). Daha hızlı geçiş süresi daha az toprak nemi anlamına gelmektedir. FDR, bir devrenin parçası olarak düzenlenmiş olan toprağın kapasitansının hesaplanmasına dayanmaktadır (Dean ve ark. 1987). Toprağın kapasitansı, toprağın elektrik yükünü nasıl koruyabildiğini gösteren ve dielektrik sabitinin bir fonksiyonu olan bir özelliktir. Bu nedenle, kapasitans miktarının saptanması toprak nem miktarını verebilir.

Nötron saçılma olayına dayanan başka bir toprak nem sensörü sınıfı vardır. Özel radyoaktif maddeler tarafından gönderilen yüksek enerjili nötronlar, hidrojen atomları ile çarpışma sonucu yavaşlar ve bir nötron bulutu oluşturur. Cihazda algılanan bu bulutun yoğunluğu, topraktaki hidrojen veya su miktarı ile ilişkilidir (Chanasyk ve Naeth 1996).

Daha önce de değinildiği gibi yersel yöntemler ile toprak neminin ölçümü en doğru sonuçlar veren teknikler olmasına rağmen, bu yöntemler zamansal açıdan maliyetli ve uzamsal kapsamları sınırlıdır.

### **2.3. Uzaktan Algılama ile Toprak Neminin Tahmini**

Uzaktan algılama teknolojisi; geniş bir aralıkta gözlem yapabilme, zamanında ve daha az kısıtla veri toplama yeteneği sayesinde birçok alanda yaygın olarak kullanılmaktadır. Tarım, uzaktan algılamanın uygulanması ve araştırılması için en önemli alanlardan biridir. Uzaktan algılamanın tarımdaki uygulamalarına verilebilecek örnekler; toprak nemi ve yüzey pürüzlülüğünün tahmini, ürün verimi tahmini, bitki parametrelerinden bitki uzunluğu tahmini, bitki yaprak alanı indeksi (LAI) ve bitki biyokütlesinin tahminidir (Liu ve ark. 2019). Toprak neminin uzaktan ölçümleri ve izlenmesi için optik, termal ve mikrodalga uzaktan algılama teknikleri kullanılmaktadır.

Optik uzaktan algılama tekniğinde farklı dalga boylarına sahip VIS, NIR ve SWIR elektromanyetik radyasyon bantları kullanılarak, spektral yüzey yansımaya bilgisi ile toprak nemi tahminleri yapılabilmektedir. Şu anda yörüngede çok sayıdaki optik sensör olmasına rağmen, toprak nemi tahmini için uzaktan optik algılama ile yapılan gözlem

tabanlı literatür çalışmaları sınırlı sayıdadır. Bu kısmen optik sinyallerin bulutlara ve bitki örtüsüne nüfuz edememesinden ve toprak neminin optik verilerden doğru tahmin edilmesi için üzerinde uzlaşılan fiziksel tabanlı bir modelin bulunmamasından kaynaklanmaktadır (Sadeghi ve ark. 2017). Toprağın sahip olduğu nem, renk, tuzluluk, doku, bitki örtüsü ve pürüzlülük gibi çeşitli özellikleri, yüzey yansımalarını etkileyerek uzaktan algılama ile elde edilen spektral ölçümlerde değişkenliğe neden olmaktadır (Ben-Dor ve ark. 2002). Bu da büyük ölçekli uygulamaların doğruluğunu etkilemektedir. Bu sınırlamalara rağmen tarımsal uygulamalardaki önemi nedeniyle yüksek uzamsal çözünürlüğe sahip optik uzaktan algılanan ürünlerin varlığı toprak nem tahminine olan ilgiyi artırmaktadır.

Termal kızılötesi uzaktan algılama tekniğinde, termal eylemsizlik yöntemiyle veya bitki örtüsü indeksleri (VI) ile belirlenen kara yüzeyi sıcaklığından (LST) toprak neminin elde edilmesi için elektromanyetik dalga bandının 3.5 – 14  $\mu\text{m}$  arasını kullanır (Claps ve Laguardia 2004). Son otuz yıldır, LST - VI konsepti, toprak neminin tahmini için yaygın olarak uygulanmıştır (Gillies ve ark. 1997, Mallick ve ark. 2009). Termal eylemsizlik kullanan yöntemler, bitki örtüsüne karşı çok hassas olmalarından dolayı sadece yalın arazilere veya az bitki örtüsüne sahip arazilere uygulanabilirler (Wang ve Qu 2009).

Sahada kullanılan elektromanyetik toprak nem sensörlerinde olduğu gibi, su, hava ve katıların dielektrik geçirgenliğindeki büyük farklılıklar da mikrodalga uzaktan algılama için kullanılmaktadır (Ulaby ve ark. 1982). Toprak fazlarının (yani su, hava ve katıların) dielektrik özellikleri, mikrodalgaların toprak yüzeyindeki emisyonunu ve geri saçılmasını etkiler. Toprak nemi L-bandı, C-bandı ve X-bandı dahil olmak üzere düşük frekanslı mikrodalga verilerinden alınabilmektedir. Pasif ve aktif mikrodalga uzaktan algılama, şu anda toprak nemini küresel ölçekte izleme için kullanılabilecek en umut verici tekniklerdir. Büyük ölçekli veri ürünlerinin sürekli kullanılabilirliği açısından, mikrodalga tabanlı teknikler, optik ve termal kızılötesi tabanlı ürünlerden önemli ölçüde daha ileridir.

Pasif mikrodalga sensörleri, yüzey sıcaklığı ve emisyonun çarpımı olan parlaklık sıcaklığı ile orantılı olarak topraktan gelen mikrodalga emisyonunun yoğunluğunu ölçer. Gözlenen bu emisyon, kuru toprak ve suyun dielektrik sabitindeki büyük farklılıklar nedeniyle nem içeriğiyle ilişkilidir (Moran ve ark. 2004). Pasif toprak nemi tahmini için

## 2. KAYNAK ÖZETLERİ

---

kara yüzeyinin fiziksel sıcaklığı hakkında bilgi gereklidir. Yüzey emisyon modeli, yalın veya bitki örtülü yüzeylerde toprak neminin mikrodalgada uzaktan algılanması uygulamalarında temel bileşenlerden biridir. Kara yüzeyinden mikrodalga emisyonunun hesaplanması için özel uygulama ve frekans aralığına bağlı olarak, ışıma transfer denklemindeki önemli süreçlerin farklı yaklaşımları ve parametrelendirmeleri ile bir dizi model geliştirilmiştir (Ulaby ve ark. 1986, Njoku ve Entekhabi 1996). Toprak nemini mikrodalga radyometrik ölçümlerden elde etmek için istatistiksel teknikler ve ileri model inversiyonu şeklinde iki ana kategoriye ayrılabilen birçok yaklaşım geliştirilmiştir.

İstatistiksel yaklaşımlar genellikle ölçülen parlaklık sıcaklığı ve yüzey toprak nemi arasındaki regresyon analizine dayanır. Her bir uzay-kaynaklı gözlem grubu için, ölçülen parlaklık sıcaklığı ve fiziksel parametreler arasında regresyon ilişkileri kurulur. Regresyon ilişkileri daha sonra yardımcı verilerden tahmin edilebilecek fiziksel değişkenler ve parametreler açısından analiz edilir (Wigneron ve ark. 2003). İstatistiksel yaklaşımlar basit ve verimlidir. Bununla birlikte, bu yöntemler sahaya özeldir, çünkü sadece kalibre edildikleri benzer koşullar için kullanılabilirken, kalibrasyon alanının dışındaki eğilimleri izlemek için geçerli değildir. İleri model inversiyonu yaklaşımında, ilk önce ilgili arazi yüzey parametrelerine dayanarak mikrodalga radyometrik ölçümlerini simüle etmek için bir radyasyon transfer modeli seçilir ve daha sonra simüle edilmiş model ve uzaktan mikrodalga algılama ile ölçülen parlaklık sıcaklık değerleri arasında kalan hatayı en aza indirerek modeli tersine çevirmek için bir yöntem geliştirilir.

Bitki örtüsüyle kaplı alanlarda toprak nemini elde etmek için kullanılan istatistiksel teknikler, parlaklık sıcaklığı ve toprak nemi arasındaki ilişkiye bitki örtüsünün etkileri açısından yaklaşımda farklılık göstermektedir. Genellikle, yüzey toprak nemi istatistiksel olarak toprak pürüzlülüğü ve bitki örtüsü etkilerini düzeltmek için kullanılan mikrodalga emisyonu ve bitki örtüsü indekslerinin bir kombinasyonu ile ilişkilidir (Wigneron ve ark. 2003). Jackson ve ark. (1982) ve Theis ve ark. (1984)'te, mikrodalga polarizasyon fark indeksi (MPDI) ve normalize edilmiş fark bitki örtüsü indeksi (NDVI) gibi bitki örtüsü indeksleri, regresyon fonksiyonunda mikrodalga emisyonunu toprak nemi ile ilişkilendirmek için kullanılmıştır.

Pasif mikrodalga ölçümlerinin küresel tahmin için kullanımı, uzamsal çözünürlüğün iyi olmaması, uydulardan elde edilebilen dalga boylarının tüm bitki örtüsü

türleri ve seviyeleri için yeterli toprak nemi duyarlılığı sağlayamaması (Wang ve Qu 2009) gibi nedenlerden dolayı sınırlıdır. Pasif mikrodalga sistemleri (radyometreler) kara yüzeyinden zayıf doğal mikrodalga emisyonlarını yakalarken, aktif mikrodalga yöntemlerinde, bir mikrodalga sinyali iletilir ve en yaygın aktif mikrodalga görüntüleme konfigürasyonu olan SAR işleminden sonra pasif sistemlerle elde edilenlerden daha yüksek uzamsal çözünürlükler sağlayan normalize edilmiş geri saçılmış sinyal kaydedilir. Kara yüzeylerinden geri saçılan mikrodalga enerjisi, toprak özellikleri ve bitki örtüsü ile belirlenmektedir. Örneğin, toprak yüzey pürüzlülüğü arttıkça yüzey saçılması artar, bu da sensöre geri dönen geri saçılımı artırır (Ulaby ve ark. 1982). Bitki örtüsü toprak nem tahmininin kalitesini düşürebilir ve toprak nem tahminindeki en iyi doğruluklar yalın veya seyrek bitkili topraklar için elde edilebilir. Bitki örtüsünün toprak nemi tahmini üzerindeki etkisini hafifletmek için önerilen yöntemler arasında toprak ve bitki örtüsünün geri saçılmış sinyale katkısını ayırmak için polarimetrik hedef ayrıştırma teknikleri (Hajnsek ve ark. 2009) ve çoklu gelme açılı SAR verileri (Srivastava ve ark. 2009) kullanılması bulunmaktadır.

Aktif mikrodalga SAR sensörü, toprağın dielektrik sabitindeki değişikliklere duyarlıdır ve kuru bir toprağın dielektrik sabiti (yaklaşık 5) suyun dielektrik sabitinden (yaklaşık 80) çok farklıdır. Dielektrik sabitinin değeri, bir dielektrik karışım modeli kullanılarak toprak nem değerine dönüştürülebilir. Bu nedenle, toprak nem seviyesinin bir mikrodalga sensörü olan SAR tarafından ölçülmesi optik bir sensörden daha doğru gibi görünmektedir. Zemin yüzeyi, toprak nemi miktarına bağlı olarak sensör tarafından yayılan sinyalin genliğini değiştirir ve değişim miktarı, diğer parametrelerin yanı sıra toprağın dielektrik özellikleri ile ilişkilidir.

Son yıllarda SAR sensörü konusunda büyük ilerlemeler kaydedilmiştir. Tek polarizasyona sahip Seasat, ERS-1/2, JERS-1, Radarsat-1 ve çoklu-bant, çoklu-polarizasyon özellikli ENVISAT/ASAR, SIR-C/X-SAR, ALOS/PALSAR, Sentinel-1, Radarsat-2, TerraSAR-X, Cosmo-SkyMed, GF-3, ALOS-2 uydu sensörleri geliştirilmiştir (Liu ve ark. 2019). SAR tekniği tarımsal uzaktan algılama alanında önemli bir rol oynamaktadır, çünkü şu anda oldukça fazla veri kaynağı sunmaktadır. Ayrıca bu SAR uydu sistemleri toprak neminin elde edilmesi için uygun frekanslara sahiptir.

### 2.4. Farklı Modeller ile Toprak Nem Tahmini

Bu kısımda, SAR verisinden toprak nemi tahmini için kullanılan modeller iki grupta ele alınmıştır. Birinci grupta; deneysel, yarı deneysel ve teorik modeller yer alırken, ikinci grupta ise makine öğrenmesi tabanlı yöntemler yer almaktadır.

#### 2.4.1. Deneysel, Yarı Deneysel ve Teorik Modeller ile Toprak Nem Tahmini

Radar uzaktan algılama, uzun yıllardır yüzey toprak nemini tahmin etmek ve haritalamak için kullanılmaktadır. SAR geri saçılma katsayısını toprak nemi ile ilişkilendirmek amacıyla SAR çalışmalarının başlangıcından bu yana birçok deneysel (Hallikainen ve ark. 1985, Shoshany ve ark. 2000), teorik (Fung ve ark. 1992, Huang ve ark. 2010) ve yarı deneysel (Oh ve ark. 1992, Dubois ve ark. 1995, Shi ve ark. 1995) model geliştirilmiştir.

Deneysel modeller, geri saçılma gözlemlerinden toprak neminin elde edilebilmesi için deneysel ölçümlerden türetilen yararlı ampirik ilişkiler kurar (Walker ve ark. 2004). Deneysel geri saçılma modellerinin teorik geri saçılma modellerine göre ana avantajı, birçok doğal yüzeyin teorik geri saçılma modellerinin geçerlilik bölgeleri dışında kalması ve geçerlilik bölgelerinde olsa bile, mevcut geri saçılma modellerinin deneysel gözlemlerle iyi uyum sağlayamamasıdır (Oh ve ark. 1992, Walker ve ark. 2004). Deneysel yöntemler genellikle doğru toprak nemi sonuçları verir, ancak model geliştirme sürecinde deneysel ölçümlerle benzer toprak parametrelerine ve radar konfigürasyonlarına sahip hedef bölgelerle sınırlıdır (Chen ve ark. 1995, Dubois ve ark. 1995). Çünkü genelleme yapmak için çok sayıda deneysel ölçüm gereklidir ancak mevcut ampirik modeller genellikle sınırlı sayıda gözlemden türetilir.

Teorik yaklaşımlar, genellikle elektromanyetik dalgaların kırınım teorisinden türetilir. Dalga boyuna ve yüzey pürüzlülüğü aralığına bağlı olarak farklı geçerlilik aralıklarına sahiptir (Fung ve ark. 1992). Radar geri saçılımı ile yüzey parametreleri arasındaki fiziksel etkileşimi teorik geri saçılım modellemesi yoluyla anlamak için birçok çaba gösterilmiştir. İntegral Eşitlik Modeli (IEM), geniş pürüzlülük geçerlilik alanı sayesinde yalın toprak yüzeyleri için en yaygın olarak kullanılan nümerik geri saçılma modellerinden biridir. Chen ve ark. (2003), orijinal IEM'yi genişletmiş ve gelişmiş integral eşitlik modelini (AIEM) geliştirmiştir. IEM inversiyon modeli için ve sigma geri

saçılma katsayılarını hem çıplak hem de seyrek bitki örtülü topraklar üzerindeki model tahminleriyle doğrudan ilişkilendirmek için, çeşitli toprak nemi ve pürüzlülük koşulları için IEM nümerik simülasyonlarının uyumuna dayanan çeşitli algoritmalar geliştirilmiştir. Bunlar arasında arama tabloları (look-up table (LUT)) (Thoma ve ark. 2006), sinir ağları (NN) (Baghdadi ve ark. 2002, Notarnicola ve ark. 2008), Bayesci yaklaşımlar (Paloscia ve ark. 2004) ve minimizasyon teknikleri (Nelder ve Mead 1965, Paloscia ve ark. 2008) bulunmaktadır. Santi ve ark. (2004), bu yaklaşımlardan Bayes, Sinir Ağları ve Nelder-Mead minimizasyonunun performansını karşılaştırmıştır. Bu yöntemlerden Nelder-Mead minimizasyonu, toprak nemi değerlerini biraz fazla tahmin etme eğiliminde olmasına rağmen diğerleri daha yakın sonuçlar vermiştir. Benzer şekilde, Paloscia ve ark. (2008) aynı üç yaklaşımı deneysel verilerle karşılaştırmış ve yine üçünün de ölçülenlere çok yakın toprak nemi değerleri ürettiğini bulmuşlardı. Ancak NN'nin doğruluk ve hesaplama hızı açısından en uygun olduğu ifade edilmiştir.

Diğer teorik modeller arasında küçük pertürbasyon yöntemi (SPM), Kirchhoff yaklaşımı (KA), geometrik optik modeli (GOM) ve fiziksel optik modeli (POM) bulunmaktadır (Ulaby ve ark. 1986). Bu modeller spesifik pürüzlülük koşulları durumunda uygulanabilir ve rms yüksekliğinin, korelasyon uzunluğunun ve dielektrik sabitinin bilindiği varsayılır. Genellikle, çok pürüzlü yüzeyler için geometrik optik modeli, orta pürüzlü yüzeyler için fiziksel optik modeli ve çok az pürüzlü yüzeyler için küçük pertürbasyon modeli en uygun olanıdır.

Teorik modeller, geri saçılma katsayısının pürüzlülük veya toprak nemi içeriğindeki değişikliklere tepkisindeki genel eğilimi oldukça iyi tahmin edebilir (Dubois ve van Zyl 1994). Bununla birlikte, bu modellerin karmaşıklıkları, bitki örtüsü ve toprak yüzey tabakasının parametreleştirilmesi için kısıtlayıcı gereklilik, toprak neminin tahminindeki etkili uygulanabilirliklerini engellemektedir (Ulaby ve ark. 1986).

Teorik ve deneysel yaklaşımlar arasında bir yerde bulunan yarı deneysel geri saçılma modelleri, deneysel verilerden elde edilen model parametreleri ile teorik bir temele dayanılarak geliştirilmiştir. Polarimetrik radar verileriyle toprak neminin tahmini için kullanılan yarı deneysel modellerin ilki Oh ve ark. (1992), tarafından geliştirilen modeldir. Bu model, çapraz polarizasyon oranının toprak nemine karşı çok hassas olduğunu ve farklı pürüzlülük koşullarına sahip yalın toprak yüzeylerinin saçılmölçer

## 2. KAYNAK ÖZETLERİ

---

verileri ile ampirik bağlantılarına dayandığını ifade etmektedir. Dubois ve ark. (1995) ile önerilen modelde; eş polarizasyon geri saçılma katsayıları, yüzey dielektrik sabiti, gelme açısı, dalga boyu ve yüzey pürüzlülüğünün doğrusal olmayan fonksiyonları olarak ifade edilir. Daha sonra sunulan ve orijinal modelden daha geniş yüzey pürüzlülüğü aralığına sahip Oh (2002) modelinin deneysel gözlemlerle ve sınırlı model geçerlilik aralığı içinde IEM ile iyi bir uyum gösterdiği gösterilmiştir. Oh (1992) modeli, kamyonu monte edilmiş saçılımölçer gözlemlerine dayanmasına rağmen, hava ve uzay kaynaklı SAR ölçümlerine başarıyla uygulanmıştır (Zribi ve ark. 1997). Ji ve ark. (1996) tarafından Dubois modelinin hem C-bandında hem de L-bandında Oh veya IEM modellerinden daha iyi sonuçların elde edildiği, Baghdadi ve Zribi (2006) tarafından ise Oh, Dubois ve IEM modellerinin radar tepkisini daha büyük tahmin etme eğiliminde oldukları tespit edilmiştir. Bu geri saçılma modellerinin temel avantajı, deneysel modellerle yaygın olarak ilişkilendirilen sahaya özgü problemlere sahip olmalarının beklenmemesidir. Yalnız toprak çalışmalarında Oh ve Dubois tarafından geliştirilen yarı deneysel modeller, yaygın olarak kullanılmıştır.

### 2.4.2. Makine Öğrenmesi Modelleri ile Toprak Nem Tahmini

Son yıllarda uzaktan algılama alanında artan bir ilgi yaratan ve toprak nem tahmini için önerilen oldukça güçlü regresyon yöntemleri, doğrusal olmayan makine öğrenme teknikleri ile temsil edilmektedir. Gelişmiş öğrenme stratejileri sayesinde, bu teknikler bir dizi referans örnek bilgiyi kullanarak karmaşık ve doğrusal olmayan eşleşmeleri bile öğrenebilir ve yaklaşık olarak tahmin edebilir. Yapay sinir ağı (YSA), tarımsal değişkenlerin tahmininde sık kullanılan tekniklerden birisidir ve birçok uygulama alanında geniş çapta araştırılmıştır (Wasserman 1993). Toprak neminin tahmini için kullanılan sinir ağı model inversiyonu, Bayes yöntemi ve simpleks algoritmaları gibi iyi bilinen inversiyon stratejileri ile karşılaştırılmıştır (Notarnicola ve ark. 2008, Paloscia ve ark. 2008). Bu çalışmalarda YSA'ların incelenen diğer stratejilere göre doğruluk, kararlılık ve hesaplama hızı açısından daha üstün olduğu değerlendirilmiştir. Destek vektör regresyonu (SVR), son birkaç yılda tarımsal parametrelerin tahmininde kullanılan bir başka yaklaşımdır. Araştırmalar ile elde edilen sonuçlar, bu yöntemin iyi bir genelleme kabiliyeti ve referans örneklerin sınırlı bulunabilirliği durumunda gürültüye karşı gürbüzlük gibi umut verici özelliklerini göstermektedir (Durbha ve ark. 2007).

Notarnicola ve ark. (1995), IEM gibi teorik bir geri saçılma modelini tersine çevirmek için, polarizasyon ve gelme açısı bakımından farklı konfigürasyonlarda YSA kullanılmasını önermiştir. Dawson ve ark. (1997), çok katmanlı algılayıcı (MLP) ağının geliştirilmiş bir versiyonunu IEM ile birleştirerek yalın topraktan geri saçılma katsayılarının simülasyonu için uygun bir elektromanyetik model tasarlamıştır. Bu model polarimetrik saçılmölçer verisine uygulanmış ve toprak nemi tahmini için sistem performansının RMSE değeri  $0.034 \text{ m}^3/\text{m}^3$  olarak elde edilmiştir.

Satalino ve ark. (2002), ERS veri setlerini kullanarak toprak nemi tahmini için bir YSA yaklaşımı kullanmıştır. Bu yaklaşımda YSA, IEM modelinden simüle edilmiş veriler kullanılarak eğitilmiştir. Tahmin edilen volümetrik toprak nemi için toplam RMSE değeri yaklaşık 6 olarak bulunmuştur. Sonuçlar, ERS gibi tek bir konfigürasyona sahip bir sensör için tahmin hatasının toprak nem katsayısı ile radar geri saçılma katsayısı arasında ilişkiyi etkileyen pürüzlülük koşullarındaki değişikliklerden kaynaklandığını göstermiştir.

Paloscia ve ark. (2008), iki gizli katmanı bulunan bir ileri beslemeli YSA'nın ENVISAT/ASAR imgelerinden toprak nemi inversiyon performansını Nelder-Mead simpleks algoritması ve Bayes yöntemi tabanlı bir istatistiksel yaklaşım ile elde edilen sonuçlarla karşılaştırmıştır. Karşılaştırma hem IEM'den elde edilen simüle edilmiş veriler hem de deneysel veriler kullanılarak gerçekleştirilmiştir. Test edilen tüm yaklaşımların ölçülen toprak nem içeriği değerlerine çok yakın değerler ürettiğini göstermiştir. Bununla birlikte, YSA ile elde edilen tahminler kullanılarak makul sürede nem haritaları oluşturmanın diğer yöntemlerden biraz daha uygun olduğu, YSA'nın elektromanyetik modellerin ters çevrilmesinde etkin olduğu ve toprak neminin uzaktan algılama verisinden elde edilmesinde başarılı olduğu belirtilmiştir.

Prasad ve ark. (2009), simüle edilmiş ek veriler olmadan sadece deneysel veriler kullanarak bir YSA yaklaşımı sunmuştur. Bu çalışmada X-bandı yersel saçılmölçer ölçümlerinden toprak nemini, bitki biyokütlesini ve LAI'yi tahmin etmek için radyal temelli YSA kullanılmıştır. Ölçülen volümetrik toprak nem değerleri yaklaşık  $0.22 - 0.27 \text{ cm}^3/\text{cm}^3$  arasındadır. Toprak nemi tahmini için elde edilen RMSE değeri yaklaşık  $0.03 \text{ cm}^3/\text{cm}^3$  olarak verilmiştir.

## 2. KAYNAK ÖZETLERİ

---

Lakhankar ve ark. (2009), Radarsat-1 veri setlerinden yararlanarak toprak nemini tahmin etmek için çoklu değişkenli regresyonlar, YSA ve bulanık mantığı karşılaştırmıştır. Sonuçlar, YSA ve bulanık mantık modellerinin çoklu değişkenli regresyona göre daha iyi performansa sahip olduğunu göstermiştir. Ayrıca, toprak neminin tahmini için mikrodalga gözlemlerine ek olarak NDVI ve toprak özelliklerinin bu modellere eklenmesi sonucunda elde edilen RMSE'yi yaklaşık %30 oranında azaltmıştır. Bu modeller ile en iyi konfigürasyonlarında (geri saçılma katsayıları ile birlikte NDVI ve toprak özellikleri kullanılarak) YSA ile 3.39, bulanık mantık ile 3.45 ve çoklu değişken analizi ile 4.48 RMSE değerleri hesaplanmıştır.

Ahmad ve ark. (2010), uzaktan algılama verisinden toprak nemi tahmini için Destek Vektör Makinesi (SVM) modelini 10 bölgeye uygulamıştır. SVM modeli 1998-2002 yıllarını kapsayan 5 yıllık veri ile eğitilmiş ve 2003-2005 yıllarını kapsayan 3 yıllık veri ile test edilmiştir. Toprak nemi tahmini için elde edilen sonuçlar korelasyon katsayılarının 0.34-0.77 arasında değiştiğini ve RMSE değerinin seçilen tüm bölgeler için 2'den daha az olduğunu göstermiştir. Sonuçlar SVM modelinin ölçülen toprak nemindeki değişimi yakalayabildiğini göstermiştir. SVM ile elde edilen sonuçlar, ileri beslemeli geri yayımlı YSA ve çok değişkenli doğrusal regresyon (MLR) modeli ile elde edilen tahminler sonuçları ile karşılaştırılmıştır ve SVM modelinin toprak nemi tahmini için YSA ve MLR modellerine göre daha iyi performans gösterdiği belirtilmiştir. Bu çalışmada, tüm veri ile elde edilen RMSE değeri SVM için 1.98, YSA için 2.79 ve MLR için 2.854 şeklindedir.

Pasolli ve ark. (2011), C-band saçılmölçer verilerini kullanarak yalın topraktan toprak neminin tahmini için YSA'yı SVR ile karşılaştırmıştır. SVR'nin, veri setinde aykırı değerlerin varlığında daha gürbüz olmasına ve daha az sayıda referans eğitim verisi varlığında daha yüksek kararlılık göstermesine rağmen, iki yöntemle elde edilen iyi ve benzer tahmin performanslarına dikkat çekilmiştir. Bu da YSA'nın eğitimi için sağlam ve kapsamlı bir referans veri setinin önemini göstermektedir. Pasolli ve ark. (2012), dağlık alana ait tam polarimetrik Radarsat-2 imgelerinden SVR ve yenilikçi çok amaçlı model seçim stratejisini birleştirerek toprak nem tahmini yapmıştır. Yatay-yatay (HH) ve yatay-dikey (HV) kanalları gibi polarimetrik özelliklerin kullanımı ile dağlık alandaki toprak nem içeriği  $0.0485 \text{ m}^3/\text{m}^3$  RMSE değeri ile tahmin edilmiştir. HV kanalı ile elde

edilen sonuçlar, bu kanalın radar sinyali üzerindeki bitki örtüsünün etkisini çözme kabiliyetini göstermiştir.

Baghdadi ve ark. (2012), radar tepkisini etkileyen toprak nemi ve yüzey pürüzlülüğü parametrelerinin tahmini için YSA'yı kullanmıştır. YSA, yalın topraklar için çok çeşitli yüzey pürüzlülüğü ve toprak nemi içeren, IEM'den üretilen gürültülü bir veri seti ile eğitilmiş ve doğrulanmıştır. YSA'nın toprak nemi ve yüzey pürüzlülüğünü tahmin etme performansları, toprak parametreleri hakkında uzman bilgisi kullanılarak veya kullanılmadan çeşitli inversiyon durumları için test edilmiştir. İnversiyon yaklaşımı daha sonra polarimetrik Radarsat-2 imgeleri kullanılarak doğrulanmıştır. Toprak nemi (kuru, ıslak veya çok ıslak topraklar) hakkında uzman bilgisinin sunulması, toprak nemi tahminlerini iyileştirirken, yüzey pürüzlülüğü tahminindeki doğruluk değişmemiştir. Ayrıca, toprak parametrelerinin tahminini iyileştirmek için polarimetrik parametreler ve anizotropi kullanılmıştır. Bu çalışmada toprak nemi tahmininin sinir ağları tekniği kullanılarak C-bandı SAR verilerinden doğru bir şekilde alınabileceği ifade edilmiştir. Toprak nemi tahminindeki RMSE değeri; toprak parametreleri hakkında uzman bilgisi olmadan yaklaşık  $0.098 \text{ cm}^3/\text{cm}^3$  ve toprak nemi hakkında uzman bilgisi sağlanarak  $0.065 \text{ cm}^3/\text{cm}^3$  olarak hesaplanmıştır.

Paloscia ve ark. (2013), ASAR ve Radarsat-2 görüntülerinden toprak nemi tahmini için farklı YSA konfigürasyonlarını ve AIEM elektromanyetik modelini kullanmıştır. Dikey-dikey (VV) polarizasyonu, VV ve dikey-yatay (VH) polarizasyonu, bitki örtüsünün katkısını hesaba katmak için kullanılan NDVI parametresi ile birlikte VV polarizasyonunu içeren farklı konfigürasyonları dikkate almıştır. Volümetrik toprak nem içeriği için tahmin doğruluğu  $\leq 0.05 \text{ m}^3/\text{m}^3$  olarak elde edilmiş olup tahminlerin birçoğu buna uymaktadır.

Xie ve ark. (2014), toprak nemi tahmini için geri yayımlı sinir ağı (BPNN) kullanmıştır. Toprak nemi tahmini için AMSR-E ölçümleri kullanılarak 18 çeşit BPNN modeli geliştirilmiştir. 6.9 GHz ve 10.7 GHz veri setleri ile eğitilen BPNN modelinin, 0.5 korelasyon değeri ve 10.3 RMSE değeri ile tüm BPNN modelleri arasında en iyi performansa sahip olduğu, BPNN modelinin doğrusal olmayan ilişkileri yakalama yeteneği nedeniyle toprak nemi tahmini için uygun olduğu ifade edilmiştir.

## 2. KAYNAK ÖZETLERİ

---

Rodríguez-Fernández ve ark. (2015), giriş verisi ve referans toprak nemi veri seti arasında istatistiksel ilişkiyi bulmak için YSA kullanmıştır. Giriş verisi; L-bant SMOS parlaklık sıcaklığı pasif mikrodalga verisi ve C-bant aktif mikrodalga ASCAT verisi ve MODIS NDVI verisinin birleştirilmesiyle oluşturulmuştur. YSA'yı eğitmek için kullanılan referans toprak nemi verileri, Avrupa Orta Menzilli Hava Tahminleri Merkezine ilişkin model tahminleridir. Toprak nemi tahmini için YSA kullanılarak SMOS verilerinin en iyi konfigürasyonu, 25° ile 60° arasındaki gelme açıları için hem H hem de V polarizasyonu ile ölçülen parlaklık sıcaklığı verilerini kullanmaktır. Toprak nemi inversiyonu, MODIS NDVI ve ASCAT geri saçılma verileri eklenerek yaklaşık %10 iyileştirilebilmiştir.

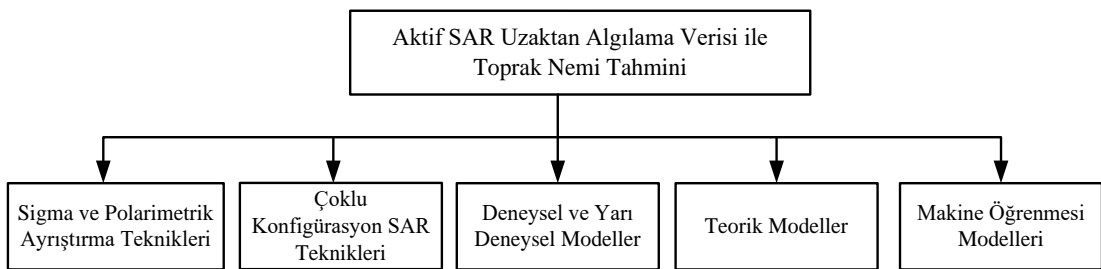
Özerdem ve ark. (2017) tarafından yapılan çalışma ile, yalın ve bitki örtülü tarım alanlarında toprak nemini tahmin etmek için, polarimetrik ayrıştırma modelleri ve geliştirilmiş regresyon sinir ağı (GRNN) kullanılarak Radarsat-2 verileri ve yersel toprak nemi arasında bir ilişki kurulmuştur. Araştırma, Dicle Üniversitesi'nde bulunan iki tarım alanı üzerinde gerçekleştirilmiştir. Ön işlemi tamamlanan Radarsat-2 imgelerinden elde edilen standart sigma ( $\sigma^\circ$ ) geri saçılma katsayıları, Freeman-Durden ve H/A/ $\alpha$  polarimetrik ayrıştırma katsayılarını içeren özellik vektörleri GRNN ile toprak neminin tahmini için kullanılmıştır. Üç farklı dönem için toprak neminin tahmini için, RMSE değerleri 2.84, 2.65 ve 2.77 olarak hesaplanmıştır. Sonuçlar, radarın toprak nemi tahmini için güçlü bir uzaktan algılama aracı olduğunu göstermiştir.

Santi ve ark. (2019), C-bandı SAR verilerinden yüzey toprak nem içeriğinin tahminini iyileştirmek için makine öğrenmesi ve polarimetrenin ortak kullanımından faydalanmayı amaçlamıştır. Çalışma Kanada'daki iki tarım alanında gerçekleştirilmiş ve alandaki nem ölçüm istasyonlarından yüzey toprak nem içeriğinin doğrudan ölçümleri ile birlikte bir dizi Radarsat-2 imgesi toplanmıştır. Analizler uydu imgesinden elde edilen geri saçılma katsayılarının toprak nem içeriğine duyarlı olduğunu göstermiştir. Yüzey toprak nemi tahmini için mevcut veriler üzerinde YSA algoritması uygulanmıştır. Algoritma, sigma geri saçılma katsayıları ve Radarsat-2 imgesinden kompakt polarimetri (CP) veri simülatörü ile hesaplanan CP parametresinden oluşan kombinasyonlar kullanılarak uygulanmıştır. Algoritmanın yersel ölçümlerle doğrulanan sonuçları, makine öğrenmesi tekniklerinin yüzey toprak neminin izlenmesi için umut verici yeteneklerini

doğrulamıştır. Ayrıca, sonuçlar CP verisinin  $\sigma^0$  ile birlikte kullanılmasının yüzey toprak nemi tahmin hassasiyetini artırma potansiyelini göstermiştir. Dikkate alınan giriş kombinasyonuna bağlı olarak, YSA algoritması toprak nemi tahminini 3 – 7 RMSE değeri ile tahmin edebilmiştir.

Ezzahar ve ark. 2020, Fas'ın Tensfit havzasındaki yalın tarım toprağına ait Sentinel-1 uydu imgelerinden elde edilen geri saçılma katsayılarının kullanıldığı IEM saçılma modelini ve SVR tekniğini kullanarak yüzey toprak nemini tahmin etmeyi amaçlamışlardır. Tahmin edilen toprak nemi yersel toprak nemi ölçümleriyle karşılaştırılarak SVR sonuçlarının IEM modeli ile elde edilen sonuçlara yakın olduğu bulunmuştur. Elde edilen RMSE değerleri SVR için 2.77 ve IEM için 2.71 olarak hesaplanmıştır. Bununla birlikte, büyük ölçekli alanlarda pürüzlülük parametresini elde etmenin zor olduğu göz önüne alındığında, SVR tekniği ile toprak nemi tahmin etmenin yararlı bir araç olduğu ve bu nedenle bu tür ölçeklerde haritalar oluşturmak için kullanılabileceği sonucuna varılmıştır.

Aktif SAR uzaktan algılama verisi ile toprak neminin tahmini için literatürde önerilen temel yaklaşımların sınıflandırılmasına göre tez çalışmasının bulunduğu konum Şekil 2.2.'de gösterilmiştir. Buna göre, tez çalışmasında sigma ve polarimetrik ayrıştırma teknikleri ile özellik vektörü elde edilmiş olup, toprak neminin inversiyonu için yarı deneysel modeller ve makine öğrenmesi modelleri kullanılmıştır.



**Şekil 2.2.** Aktif SAR uzaktan algılama verisi ile toprak neminin tahmini için literatürde önerilen temel yaklaşımların sınıflandırılması

Bu tez çalışmasında SAR verilerinden yüzey toprak neminin tahmini amaçlanmıştır. Bu amaç doğrultusunda tez kapsamında yapılan uygulamalar aşağıda listelenmiştir.

## 2. KAYNAK ÖZETLERİ

---

- C-bandı SAR sensörü Radarsat-2 verisi kullanılarak Oh (1992), Dubois (1995) ve Oh (2004) yarı deneysel modelleri ile yüzey toprak nemi tahmin performansının değerlendirilmesi,
- Polarimetrik hedef ayrıştırma modelleri ile Radarsat-2 imgesinden elde edilecek yeni özellikler ve sigma geri saçılma verilerinin, makine öğrenme teknikleri (En Küçük Kareler Destek Vektör Makinesi (LS-SVM), Genelleştirilmiş Regresyon Sinir Ağı (GRNN), Aşırı Öğrenme Makinesi (ELM), Kernel tabanlı Aşırı Öğrenme Makinesi (KELM), Adaptif Sinirsel Bulanık Çıkarım Sistemi (ANFIS)) ile toprak nem tahmini için kullanılmasına yönelik bir yaklaşım geliştirmek.

### 3. MATERYAL ve METOT

Bu tez kapsamında SAR uydu imgelerinden elde edilen öznitelikler ile yarı deneysel modeller ve makine öğrenmesi yöntemleri kullanılarak volümetrik toprak neminin tahmini amaçlanmıştır. Bu bölümde; çalışma alanı, çalışmada kullanılan yersel toprak nem ölçümleri ve uzaktan algılama verileri, Radarsat-2 imgelerine uygulanan ön işlemler, polarimetrik ayrıştırma modelleri, toprak nemini etkileyen sensör ve hedef parametreleri, çalışmada kullanılan yarı deneysel modeller ve makine öğrenmesi yöntemleri hakkında detaylı bilgi verilmiştir.

#### 3.1. Çalışma Alanı ve Çalışmada Kullanılan Veriler

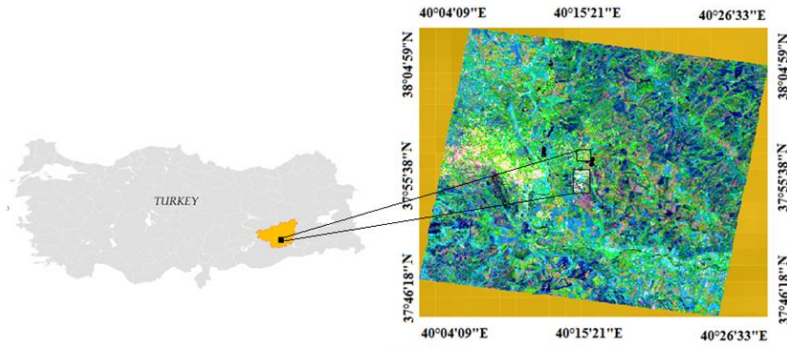
##### 3.1.1. Çalışma Alanı

Çalışma alanı Türkiye'nin güneydoğusunda bulunan Diyarbakır ilindeki Dicle Üniversitesi'nin tarımsal alanlarında yer almaktadır ( $40^{\circ}04' - 40^{\circ}26'E$ ,  $37^{\circ}46' - 38^{\circ}04'N$ ) ve toplam  $22 \text{ km}^2$ 'lik iki alandan oluşmaktadır. Çalışma alanının ortalama yüksekliği  $650 \text{ m}$ 'dir. Mart ve Haziran aylarına ait ortalama yağış sırasıyla  $65 \text{ mm}$  ve  $8 \text{ mm}$  ve ortalama sıcaklık sırasıyla  $8 \text{ }^{\circ}\text{C}$  ve  $26 \text{ }^{\circ}\text{C}$ 'dir. Bu tarım alanlarında çoğunlukla buğday ve mısır yetiştirilmektedir. Çalışma alanını gösteren harita Şekil 3.1.'de verilmiştir. Her iki çalışma alanı Şekil 3.1. (a)'da Freeman-Durden ayrıştırma metodu ile elde edilen katsayılardan oluşturulan RGB Radarsat-2 imgesinde siyah dikdörtgenlerle gösterilmiştir (RGB imgesinde kırmızı renk çift sıçrama, yeşil renk hacim saçılması ve mavi renk ise yüzey saçılma bileşenleri için kullanılmıştır).

##### 3.1.2. Yersel Toprak Nem Ölçümleri

Yersel toprak nem ölçümleri 10 Haziran 2015 ve 3 Mart 2016 tarihlerinde Radarsat-2 veri toplama ile eş zamanlı olarak yapılmıştır. Toprak örnekleri 3-5 cm derinlikten alınmıştır ve her bir yersel ölçüm arasındaki mesafe yaklaşık  $100 \text{ m}$ 'dir. Toprak nem içeriği, Dicle Üniversitesi araştırma laboratuvarlarında gravimetrik yöntemlerle ölçülmüştür. 10 Haziran 2015 ve 3 Mart 2016 tarihlerinde çalışma alanından sırasıyla 272 ve 156 adet toprak örneği alınmıştır. Bu tarihlerde yapılan toprak nemi ölçümleri ile ilgili diğer bilgiler Çizelge 3.1.'de verilmiştir.

### 3. MATERYAL VE METOT



(a)



(b)

**Şekil 3.1.** Çalışma alanını gösteren harita, (a) RGB Radarsat-2 imgesi, (b) örnek alınan noktalar Google Earth imgesinde kırmızı noktalar ile gösterilmiştir

**Çizelge 3.1.** Yersel toprak nem ölçümleri

Ölçüm tarihi	Arazi durumu	Örnek sayısı	Minimum (%)	Maksimum (%)	Ortalama (%)	Standart Sapma (%)	Değişim Katsayısı
10 Haziran 2015	Yalın toprak	272	0.79	44.73	7.46	7.01	0.94
3 Mart 2016	Orta seviyede bitki örtüsü	156	25.38	43.20	34.45	2.89	0.08

#### 3.1.3. Uzaktan Algılama Verisi

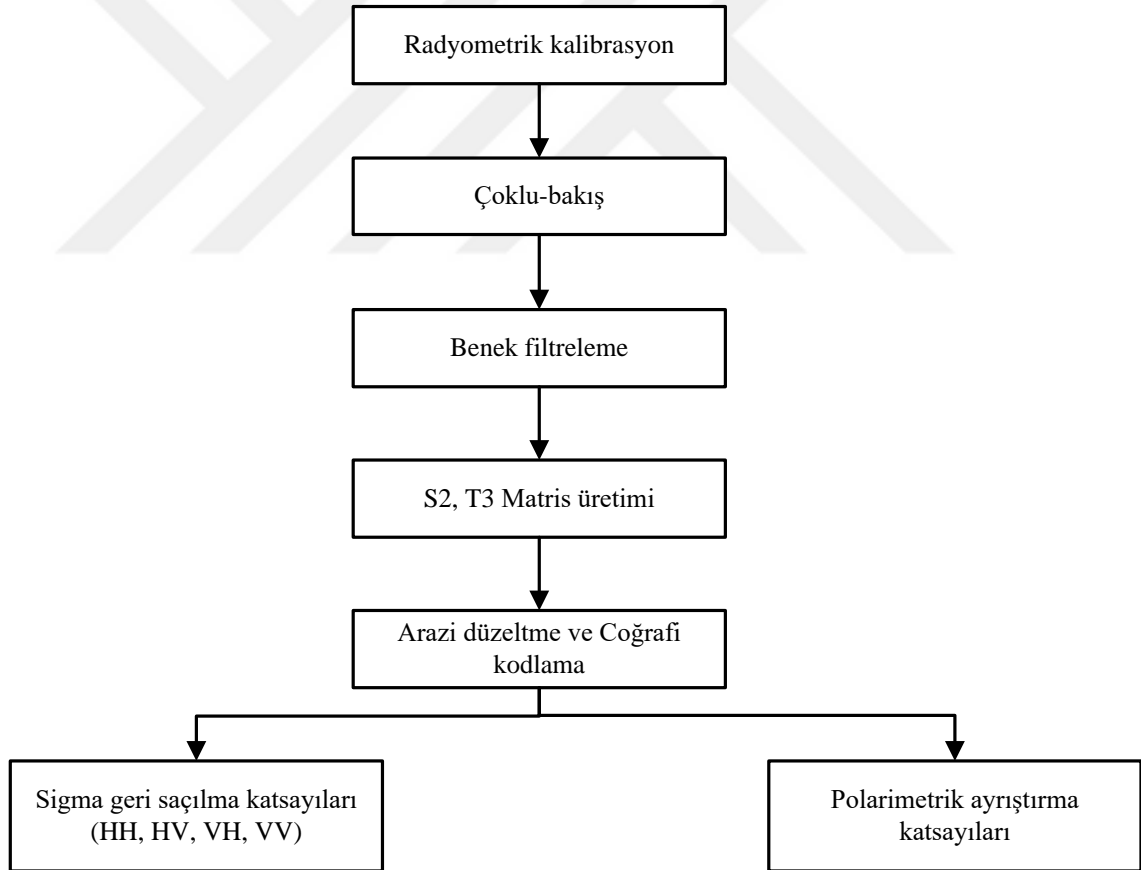
Radarsat-2, Kanada Uzay Ajansı tarafından 2007 yılında başlatılan ve C-band mikrodalga SAR sensörlerine sahip bir radar uydusudur. Bu çalışmada, toprak nemini tahmin etmek için iki adet Radarsat-2 tam polarimetrik tek görünümlü kompleks (SLC) ürünü kullanılmıştır. Radarsat-2 imgelerine ait bilgiler Çizelge 3.2.'de verilmiştir.

**Çizelge 3.2.** Radarsat-2 imgelerine ait bilgiler

Tarih	Yörünge yönü	Demet modu	Gelme açısı
10 Haziran 2015	Descending	Q29	46.8° – 48°
3 Mart 2016	Descending	Q13	32.39° – 34.04°

### 3.1.4. Radarsat-2 Verisinin Ön İşlenmesi

SAR ürünlerinin ön işlenmesi için SNAP Sentinel-1 yazılımı kullanılmıştır. Ön işlemler; radyometrik kalibrasyon, çoklu bakış, benek filtreleme, arazi düzeltme ve coğrafi kodlama adımlarından oluşmaktadır. Radarsat-2 verisine uygulanan ön işlemleri gösteren akış şeması Şekil 3.2.'de verilmiştir. Radyometrik kalibrasyon, çoklu bakış, benek filtreleme, arazi düzeltme ve coğrafi kodlama adımları aşağıda açıklanmıştır.



**Şekil 3.2.** Radarsat-2 verisine uygulanan ön işlemleri gösteren akış şeması

#### 3.1.4.1. Radyometrik Kalibrasyon

SAR imgelerinde topoğrafya nedeniyle oluşan radyometrik distorsiyonların kalibrasyonu gerekmektedir. Böylece SAR imgelerinin piksel değerleri yansıtıcı yüzeyin radar geri saçılımını gerçekten temsil eder. Radyometrik kalibrasyon,  $i$  pikseli için  $DN_i$  geri saçılmış sinyalin genliği olmak üzere her pikselin 8 bitten oluşan dijital sayısını sigma geri saçılma katsayısına ( $\sigma_i^0$ ) dönüştürmek için ürün dosyasındaki bir LUT kullanılarak gerçekleştirilir (Koppe ve ark. 2012). Sigma geri saçılma katsayısı desibel cinsinden denklem (3.1) ile hesaplanabilir. Burada  $A_0$  ve  $A_1$  otomatik kazanç kontrol katsayıları ve  $\theta$  ise gelme açısıdır.

$$\sigma_i^0 = 10 \times \log\left[\left(\frac{DN_i^2 + A_0}{A_1}\right) \times \sin(\theta)\right] \quad (3.1)$$

#### 3.1.4.2. Çoklu-bakış

SAR orijinal imgesi genellikle, doğal benek gürültüsü içermektedir. İmgenin doğal benekli görünümünü azaltmak için, birkaç imge aynı sahnenin farklı görünümüne karşılık gelmiş gibi koherent olmayan bir şekilde birleştirilir. Bu işlem genel olarak çoklu-bakış işleme olarak bilinmektedir. Sonuç olarak, çoklu-bakış işlemi uygulanmış imge daha iyi yorumlanabilir. Çoklu-bakış işlemeyi uygulamanın iki yolu vardır:

- Çoklu-bakışlı imgeler, tek bakışlı bir imgenin konvolüsyon yoluyla ortalaması alınarak üretilebilir.
- Çoklu-bakışlı imgeler, alt spektral bant genişliği kullanılarak frekans-alanı yöntemi ile üretilebilmektedir.

#### 3.1.4.3. Benek Filtreleme

SAR imgeleri, imgenin kalitesini düşüren ve özelliklerinin yorumlanmasını zorlaştıran benek denilen tuz ve biber gürültüsü benzeri bir dokuya sahiptir. Benek gürültüsü rastgele yapıcı ve yıkıcı girişimlerden kaynaklanır. Benek gürültüsünü azaltmak için, uzamsal filtreleme veya çoklu-bakış işlemi uygulanabilir. Benek gürültüsü, imgeden çıkarılan hedef ayrıştırma parametrelerinin doğruluğunu da önemli ölçüde etkiler. Benek gürültüsünün hedef ayrıştırma parametreleri üzerindeki etkisini araştırmak için birçok çalışma yapılmıştır (López-Martínez ve ark. 2005, Touzi 2007).

SAR imgesinde benek gürültüsünün giderilmesi önemli bir sorundur. SAR imgesinde benek gürültüsünü giderme ile ilgili birçok çalışma bulunmaktadır. Benek filtreleme algoritmalarının çoğunda, küçük pencerede görüntünün tekdüze (sabit gri) veya doku (yoğunluğun değiştiği bölgeler) olduğu varsayılır. Touzi (2007), işlem penceresi boyutunun koherent olmayan ayırıştırma parametrelerinden türetilen tahminlerin doğruluğunu önemli ölçüde etkilediğini göstermiştir.

Refined Lee filtresi, minimum ortalama karesel hata (MMSE) kriterine ve imgenin istatistiksel parametrelerinin hesaplanmasına dayanan adaptif bir filtredir. Bu filtre benekleri, imgeden istatistiksel olarak bağımsız bir çarpımsal gürültü olarak kabul eder. Filtrelenmiş pikselin tahmini değeri  $\tilde{X}$ , filtrelenmemiş piksellerin lokal ortalaması  $\bar{Y}$  olmak üzere Refined Lee filtresi (3.2) ile verilmiştir.


$$\tilde{X} = \bar{Y} + k(Y - \bar{Y}) \quad (3.2)$$

$$k = \frac{\text{var}(X)}{\text{var}\langle Y \rangle} = \frac{\text{var}\langle Y \rangle - E^2(\langle Y \rangle)\sigma_n^2}{\text{var}\langle Y \rangle[1 + \sigma_n^2]} \quad (3.3)$$

Burada,  $k$  adaptif filtreleme katsayısı ve  $\sigma_n^2$  benek varyansdır.

#### 3.1.4.4. Arazi Düzeltme ve Coğrafi Kodlama

Düzeltilmemiş, ham bir görüntüyü keyfi bir koordinat sisteminden bir coğrafi veya harita projeksiyon koordinat sistemine dönüştürme işlemidir. Bu işlemde, imge pikselleri gerçek dünya harita koordinatlarına hizalanacak ve sığacak şekilde konumlandırılır ve düzeltilir. Arazi düzeltme ve coğrafi kodlama ile imgelerde topoğrafyadaki değişimlerden ve uydu sensörünün eğiminden kaynaklanan geometrik bozulmalar düzeltilir ve bilinen bir harita koordinat sistemi ile ilişkilendirilir. SAR geometrik bozulmalar; kısaltım (foreshortening), örtüşme (layover) ve gölgeleme (shadowing) gibi bozulmaları içermektedir ve Şekil 3.3.'te gösterilen bu geometrik bozulmalar bir Dijital Yükseklik Modeli (DEM) kullanılarak düzeltilebilir.




**Şekil 3.3.** SAR geometrik bozulmalar (a) kısaltım, (b) örtüşme ve (c) gölgeleme (Anonim 2020)


İki farklı noktadan alınan radar ekoları arasındaki zaman gecikmesi, imgedeki mesafelerini belirlemektedir. Şekil 3.3 (a)'da imgede a'-b' noktaları arasındaki mesafe, a-b noktalarının yerdeki dikey projeksiyonları arasındaki mesafeden daha kısadır. Çünkü b noktası a noktasından daha yüksekte olduğundan dolayı radar sensörüne daha yakın konumdadır. Bu bozulma kısaltım (foreshortening) olarak adlandırılır. Şekil 3.3 (b)'de,  $\alpha$  açısı gelme açısından daha büyük olması durumunda b noktasındaki dönüş a noktasındaki dönüşten daha önce gerçekleşmektedir ve a-b noktası, imgeye b'- a' olarak yansımıştır (örtüşme). Şekil 3.3 (c)'de ise büyüyen radar geliş açılarına bağlı olarak arazi tepeleri gölgeleme etkisine sebep olmaktadır.

İlk olarak, Radarsat-2 SLC ürününe, piksel değerlerinin radar geri saçılımıyla doğrudan ilişkili olabileceği görüntüler sağlamak için radyometrik kalibrasyon uygulanmıştır. Sonra, imgeye çoklu-bakış işlemi ve ardından benek filtreleme adımı ile benek gürültüsünü gidermek için 7x7 boyutunda kayan pencere kullanan Refined-Lee filtresi uygulanmıştır. Daha sonra; sigma geri saçılma katsayıları için Sinclair (S2), polarimetrik ayrıştırma bileşenleri için koherent (T3) matrisleri oluşturulmuştur. Son olarak; arazi düzeltilmesi adımı, SRTM-3 DEM ve WGS84 harita projeksiyonu kullanılarak gerçekleştirilmiştir. Bu adımlar uygulandıktan sonra, sigma radar saçılma katsayıları ve polarimetrik ayrıştırma bileşenleri SAR verilerinden elde edilebilmiştir.

Her iki döneme ait Radarsat-2 SLC imgeleri Şekil 3.4.'te ve ön işlemleri tamamlanmış olan örnek Radarsat-2 imgeleri Şekil 3.5.'te verilmiştir.




(a)




(b)


**Şekil 3.4.** Radarsat-2 SLC imgeleri  
(a) 10 Haziran 2015 ve  
(b) 3 Mart 2016




(a)



(b)



(c)



(d)

**Şekil 3.5.** Ön işlemleri tamamlanmış Radarsat-2 verilerinden elde edilen RGB imgeleri (a) 10 Haziran 2015, (b) 3 Mart 2016 sigma tekniği<sup>1</sup>; (c) 10 Haziran 2015 ve (d) 3 Mart 2016 Yamaguchi ayrıştırması metodu<sup>2</sup>

<sup>1</sup> RGB imgesinde kırmızı HH, yeşil HV, mavi HH/HV polarizasyonları için kullanılmıştır.

<sup>2</sup> RGB imgesinde kırmızı renk çift sıçrama, yeşil renk hacim saçılması ve mavi renk ise yüzey saçılma bileşenleri için kullanılmıştır.

#### 3.2. Polarimetrik Ayırıştırma Modelleri


Polarimetrik ayırıştırma esas olarak, radar hedeflerinin veya yer yüzeyindeki nesnelerin elektromanyetik enerjiyi nasıl dağıttığını açıklayan saçılma matrisine dayanmaktadır. Hedef ayırıştırma yöntemlerinin temel amacı, ölçülen polarimetrik matrisi bir dizi temel saçılma mekanizmasının bir toplamına ayırmaktır. Her saçılma mekanizması fiziksel bir mekanizmaya karşılık gelir ve baskın saçılma mekanizması belirlenebilmektedir. Böylece polarimetrik hedef ayırıştırma yöntemleri saçılma işleminin yorumlanmasını basitleştirmektedir.

Polarimetrik ayırıştırma yöntemleri koherent ve koherent olmayan hedef ayırıştırma yöntemleri olarak ikiye ayrılır. Koherent ayırıştırma S saçılma matrisine dayanmaktadır (Pauli, Touzi, Cameron ayırıştırma yöntemleri). Koherent olmayan polarimetrik ayırıştırma şu şekilde sınıflandırılabilir: koherent (T3) ve kovaryans (C3) matrislerinin model tabanlı ayırıştırması (Yamaguchi, Freeman-Durden ayırıştırma yöntemleri), T3 ve C3 matrislerinin özdeğer veya özvektör tabanlı ayırıştırması (H/A/ $\alpha$ , van Zyl, Cloude ayırıştırma yöntemleri). Koherent olmayan ayırıştırma yöntemleri, yer yüzeyindeki hedeflerin çoğunlukla heterojen dağılmasından dolayı daha iyi sonuç vermektedir. Ayrıca model tabanlı ayırıştırma yöntemleri, fiziksel yapılar ile doğrudan ilişkili olan saçılma mekanizmalarını yorumlayabilmelerinin avantajlarına sahiptir.

Bu çalışmada kullanılan polarimetrik ayırıştırma modelleri ve bileşenleri Çizelge 3.3.'te ve saçılma mekanizmaları Şekil 3.6.'da gösterilmiştir.

**Çizelge 3.3.** Polarimetrik ayırıştırma yöntemleri ve bileşenleri

Polarimetrik ayırıştırma	Bileşenler
Freeman Durden	Yüzey saçılması, Çift sıçrama saçılması, Hacimsel saçılma
Yamaguchi	Yüzey saçılması, Çift sıçrama saçılması, Hacimsel saçılma ve Helis saçılması
van Zyl	Yüzey saçılması, Çift sıçrama saçılması, Hacimsel saçılma
Cloude	Yüzey saçılması, Çift sıçrama saçılması, Hacimsel saçılma
Cloude-Pottier (H/A/ $\alpha$ )	Entropi, Anizotropi, Alfa



**Şekil 3.6.** Temel saçılma mekanizmaları (a) Yüzey saçılması, (b) Çift sıçrama saçılması, (c) Hacimsel saçılma ve (d) Helis saçılması (Zou ve ark. 2015)

### 3.2.1. Freeman-Durden Ayırıştırma Modeli

Freeman-Durden ilk üç bileşenli koherent olmayan model tabanlı ayırıştırma yöntemlerinden birisidir. Üç bileşenli saçılma mekanizması, pürüzlü bir yüzeyden yüzey saçılması, dihedral yüzeyden çift sıçrama saçılması ve rastgele yönlendirilmiş dipollerden hacim saçılmasını içermektedir. Freeman-Durden ayırıştırması, çapraz korelasyon ve eş-polarizasyon yansıma simetri koşulunun her zaman sıfır olduğunu varsaymaktadır. Freeman-Durden ayırıştırması, dielektrik yüzeyli saçılma örüntüleri kullandığından daha gerçekçi bir temsil sağlamaktadır (Dasari ve ark. 2016).

Freeman-Durden ayırıştırmasının ilk bileşeni, çapraz polarize bileşenin ihmal edilebilir olduğu hafif pürüzlü yüzey saçılımını modelleyen birinci dereceden Bragg yüzey saçılımından oluşur. Bragg yüzeyi için saçılma  $\mathbf{S}$  matrisi (3.4) ile tanımlanmıştır:

$$\mathbf{S} = \begin{bmatrix} R_H & 0 \\ 0 & R_V \end{bmatrix} \quad (3.4)$$

Yatay ve dikey polarize dalgalar için yansıma katsayıları  $R_H$  ve  $R_V$ ,  $\theta$  lokal gelme açısı ve  $\epsilon_r$  yüzeyin bağlı dielektrik sabiti olmak üzere şu şekilde verilmiştir.

$$\begin{aligned}
 R_H &= \frac{\cos \theta - \sqrt{\varepsilon_r - \sin^2 \theta}}{\cos \theta + \sqrt{\varepsilon_r - \sin^2 \theta}} \\
 R_V &= \frac{(\varepsilon_r - 1)\{\sin^2 \theta - \varepsilon_r(1 + \sin^2 \theta)\}}{(\varepsilon_r \cos \theta + \sqrt{\varepsilon_r - \sin^2 \theta})^2}
 \end{aligned} \tag{3.5}$$

Bu saçılma matrisi yüzey saçılma kovaryans matrisini ( $\mathbf{C}_{3S}$ ) vermektedir. Burada  $f_S$  tek-sıçrama saçılımının  $|S_{VV}|^2$  bileşenine karşılık gelen katkısıdır.

$$\mathbf{C}_{3S} = \begin{bmatrix} |R_H|^2 & 0 & R_H R_V^* \\ 0 & 0 & 0 \\ R_V R_H^* & 0 & |R_V|^2 \end{bmatrix} = f_S \begin{bmatrix} |\beta|^2 & 0 & \beta \\ 0 & 0 & 0 \\ \beta^* & 0 & 1 \end{bmatrix} \tag{3.6}$$

$$f_S = |R_V|^2 \text{ ve } \beta = \frac{R_H}{R_V} \tag{3.7}$$

Çift sıçrama saçılma bileşeni, reflektör yüzeylerinin farklı dielektrik malzemelerden yapılabileceği yer-ağaç gövdesi geri saçılması gibi bir dihedral köşe reflektörden saçılmasıyla modellenmektedir. Dikey gövde yüzeyi, yatay ve dikey polarizasyonlar için sırasıyla  $R_{TH}$  ve  $R_{TV}$  yansımaya katsayılarından oluşmaktadır. Yatay yer yüzeyinin Fresnel yansımaya katsayıları  $R_{GH}$  ve  $R_{GV}$ 'dir. Model,  $e^{2j\gamma_H}$  ve  $e^{2j\gamma_V}$  yayılım faktörleri dahil edilerek daha genel hale getirilebilir, burada  $\gamma_H$  ve  $\gamma_V$  kompleks katsayıları herhangi bir yayılım zayıflatma ve faz değişim etkisini temsil etmektedir. Bu durumda çift sıçrama saçılması için  $\mathbf{S}$  saçılma matrisi,

$$\mathbf{S} = \begin{bmatrix} e^{2j\gamma_H} R_{TH} R_{GH} & 0 \\ 0 & e^{2j\gamma_V} R_{TV} R_{GV} \end{bmatrix} \tag{3.8}$$

Bu saçılma matrisi, çift sıçrama saçılma kovaryans matrisi  $\mathbf{C}_{3D}$  matrisini vermektedir. Burada  $f_D$  çift sıçrama saçılımının  $|S_{VV}|^2$  bileşenine karşılık gelen katkısıdır.

$$\begin{aligned}
C_{3D} &= \begin{bmatrix} |R_{TH}R_{GH}|^2 & 0 & e^{2j(\gamma_H-\gamma_V)}R_{TH}R_{GH}R_{TV}^*R_{GV}^* \\ 0 & 0 & 0 \\ e^{2j(\gamma_V-\gamma_H)}R_{TV}R_{GV}R_{TH}^*R_{GH}^* & 0 & |R_{TV}R_{GV}|^2 \end{bmatrix} \\
&= f_D \begin{bmatrix} |\alpha|^2 & 0 & \alpha \\ 0 & 0 & 0 \\ \alpha^* & 0 & 1 \end{bmatrix}
\end{aligned} \tag{3.9}$$

$$f_D = |R_{TV}R_{GV}|^2 \quad \text{ve} \quad \alpha = e^{2j(\gamma_H-\gamma_V)} \frac{R_{TH}R_{GH}}{R_{TV}R_{GV}} \tag{3.10}$$

Bir bitki kanopisinin hacimsel saçılması, rastgele yönlendirilmiş silindir benzeri saçılma bulutunun katkısı olarak modellenmektedir. Ortogonal doğrusal  $(\hat{x}, \hat{y})$  bazında yatay olarak yönlendirilmiş bir temel dipolün saçılma matrisi (3.11) ile ifade edilmiştir.

$$\mathbf{S} = \begin{bmatrix} a & 0 \\ 0 & b \end{bmatrix}_{a \gg b} \tag{3.11}$$

Burada a ve b, parçacık karakteristik koordinat sistemindeki karmaşık saçılma katsayılarıdır.

Yatay dipolün saçılma matrisi, radar görüş hattı etrafında bir  $\theta$  açısı ile döndürüldüğünde (3.12) ile ifade edilmektedir.

$$\begin{aligned}
\mathbf{S}(\theta) &= \begin{bmatrix} \cos \theta & \sin \theta \\ -\sin \theta & \cos \theta \end{bmatrix} \begin{bmatrix} a & 0 \\ 0 & b \end{bmatrix} \begin{bmatrix} \cos \theta & -\sin \theta \\ \sin \theta & \cos \theta \end{bmatrix} \\
&= \begin{bmatrix} a \cos^2 \theta + b \sin^2 \theta & (b-a) \sin \theta \cos \theta \\ (b-a) \sin \theta \cos \theta & a \sin^2 \theta + b \cos^2 \theta \end{bmatrix}
\end{aligned} \tag{3.12}$$

İnce silindir benzeri saçıcıların radar bakış yönüne rastgele yönlendirildiği varsayılarak, elde edilen kovaryans matrisi  $\mathbf{C}_{3V}$ 'nin ikinci dereceden istatistikleri şu şekilde verilmektedir:

$$\begin{aligned}
 \langle S_{HH} S_{HH}^* \rangle &= |a|^2 I_1 + |b|^2 I_2 + 2 \operatorname{Re}(ab^*) I_4 \\
 \langle S_{HH} S_{HV}^* \rangle &= (b-a)^* (a I_5 + b I_6) \\
 \langle S_{HV} S_{HV}^* \rangle &= |b-a|^2 I_4 \\
 \langle S_{HH} S_{VV}^* \rangle &= (|a|^2 + |b|^2) I_4 + ab^* I_1 + a^* b I_2 \\
 \langle S_{VV} S_{VV}^* \rangle &= |a|^2 I_2 + |b|^2 I_1 + 2 \operatorname{Re}(ab^*) I_4 \\
 \langle S_{HV} S_{VV}^* \rangle &= (b-a)(a^* I_6 + b^* I_5)
 \end{aligned} \tag{3.13}$$

$$\begin{aligned}
 I_1 &= \int_{-\pi}^{\pi} \cos^4 \theta p(\theta) d\theta & I_2 &= \int_{-\pi}^{\pi} \sin^4 \theta p(\theta) d\theta \\
 I_3 &= \int_{-\pi}^{\pi} \sin^2 2\theta p(\theta) d\theta \equiv 4I_4 & I_4 &= \int_{-\pi}^{\pi} \sin^2 \theta \cos^2 \theta p(\theta) d\theta \\
 I_5 &= \int_{-\pi}^{\pi} \cos^3 \theta \sin(\theta) p(\theta) d\theta & I_6 &= \int_{-\pi}^{\pi} \sin^3 \theta \cos \theta p(\theta) d\theta
 \end{aligned} \tag{3.14}$$

Yönlendirme açısının olasılık yoğunluk fonksiyonunun üniform olduğu ( $p(\theta) = \frac{1}{2\pi}$ ) varsayılırsa, (3.15) ve (3.16) ifadeleri elde edilir.

$$I_1 = I_2 = \frac{3}{8}, \quad I_3 = \frac{1}{2}, \quad I_4 = \frac{1}{8}, \quad I_5 = I_6 = 0 \tag{3.15}$$

$$\begin{aligned}
 \langle S_{HH} S_{HH}^* \rangle &= \frac{1}{4} (|a|^2 + |b|^2) + \frac{1}{8} (|a+b|^2) \\
 \langle S_{HH} S_{HV}^* \rangle &= 0 \\
 \langle S_{HV} S_{HV}^* \rangle &= \frac{1}{8} |b-a|^2 \\
 \langle S_{HH} S_{VV}^* \rangle &= \frac{1}{8} (|a|^2 + |b|^2) + \frac{3}{4} \operatorname{Re}(ab^*) \\
 \langle S_{HV} S_{VV}^* \rangle &= 0 \\
 \langle S_{VV} S_{VV}^* \rangle &= \frac{1}{4} (|a|^2 + |b|^2) + \frac{1}{8} (|a+b|^2)
 \end{aligned} \tag{3.16}$$

Silindir benzeri saçıcılar bulutunun rastgele yönlendirilmiş ve çok ince yatay ( $b \mapsto 0$ ) olduğunu varsayarsak, hacimsel saçılım ortalama kovaryans matrisi  $\langle C_{3V} \rangle_\theta$  ile verilmektedir.

$$\langle C_{3V} \rangle_\theta = \frac{f_V}{8} \begin{bmatrix} 3 & 0 & 1 \\ 0 & 2 & 0 \\ 1 & 0 & 3 \end{bmatrix} \quad (3.17)$$

Burada  $f_V$  hacimsel saçılım bileşeninin katkısına karşılık gelmektedir. Hacimsel, çift- sıçrama ve yüzey saçılması bileşenlerinin ilişkisiz olduğu varsayılarak toplam ikinci dereceden istatistikler, tek mekanizmalar için yukarıdaki istatistiklerin toplamıdır. Böylece toplam geri saçılma modeli,

$$\begin{aligned} C_3 &= C_{3S} + C_{3D} + \langle C_{3V} \rangle_\theta \\ &= \begin{bmatrix} f_S |\beta|^2 + f_D |\alpha|^2 + \frac{3f_V}{8} & 0 & f_S \beta + f_D \alpha + \frac{f_V}{8} \\ 0 & \frac{2f_V}{8} & 0 \\ f_S \beta^* + f_D \alpha^* + \frac{f_V}{8} & 0 & f_S + f_D + \frac{3f_V}{8} \end{bmatrix} \end{aligned} \quad (3.18)$$

Bu model, beş bilinmeyenli dört denklem vermektedir. Bununla birlikte hacim katkısı  $\frac{f_V}{8}$ ,  $\frac{2f_V}{8}$  veya  $\frac{3f_V}{8}$ ,  $|S_{HH}|^2$ ,  $|S_{VV}|^2$  ve  $S_{HH} S_{VV}^*$  terimlerinden çıkarılarak geriye dört bilinmeyenli üç denklem kalmaktadır:

$$\begin{aligned} \langle S_{HH} S_{HH}^* \rangle &= f_S |\beta|^2 + f_D |\alpha|^2 \\ \langle S_{HH} S_{VV}^* \rangle &= f_S \beta + f_D \alpha \\ \langle S_{VV} S_{VV}^* \rangle &= f_S + f_D \end{aligned} \quad (3.19)$$

Genel olarak, bilinmeyenlerden biri sabitse bir çözüm bulunabilir.  $\langle S_{HH} S_{VV}^* \rangle$  gerçek kısmının işaretine dayanarak çift sıçrama veya yüzey saçılması baskın katkı olarak kabul edilmektedir (van Zyl 1989). Eğer  $\text{Re}(\langle S_{HH} S_{VV}^* \rangle) \geq 0$  ise yüzey saçılması baskın kabul edilir ve  $\alpha = -1$ 'e sabitlenmiştir. Eğer  $\text{Re}(\langle S_{HH} S_{VV}^* \rangle) \leq 0$  ise çift sıçrama saçılması baskın kabul edilir ve  $\beta = +1$  değerine sabitlenmiştir. Daha sonra,  $f_S$  ve  $f_D$  katkısı ve  $\alpha$  veya  $\beta$  parametreleri, artık radar ölçümlerinden tahmin edilebilir. Son olarak, her saçılma mekanizmasının katkısı tahmin edilebilir (Lee ve Pottier 2017).

$$\begin{aligned} \text{Span} &= |S_{\text{HH}}|^2 + 2|S_{\text{HV}}|^2 + |S_{\text{VV}}|^2 \\ &= P_{\text{S}} + P_{\text{D}} + P_{\text{V}} \end{aligned} \quad (3.20)$$

$$\begin{aligned} P_{\text{S}} &= f_{\text{S}}(1 + |\beta|^2) \\ P_{\text{D}} &= f_{\text{D}}(1 + |\alpha|^2) \\ P_{\text{V}} &= f_{\text{V}} \end{aligned} \quad (3.21)$$

### 3.2.2. Yamaguchi Ayırıştırma Modeli

Yamaguchi ve ark. (2005), üç bileşenli saçılma modeli yaklaşımına dayanarak helis saçılma terimini de içeren dört bileşenli bir saçılma modeli önermiştir. Helis saçılma modeli, yansıma simetri varsayımını ortadan kaldırmaktadır. Çünkü bu varsayım insan yapımı yapılar ve karmaşık şekilli hedefler dışında çeşitli araziler için her zaman geçerli değildir.

Helis saçılması mekanizmasının fikri, Krogager ve Freeman (1994) tarafından koherent hedef ayırıştırma teoreminde geliştirilmiştir. Bir helis hedefi sol-el ve sağ-el dairesel polarizasyonlar üretmektedir. Bir sol-helis hedefe veya bir sağ-helis hedefe karşılık gelen saçılma matrisleri şu şekildedir:

$$S_{\text{LH}} = \frac{1}{2} \begin{bmatrix} 1 & j \\ j & -1 \end{bmatrix} \text{ ve } S_{\text{RH}} = \frac{1}{2} \begin{bmatrix} 1 & -j \\ -j & -1 \end{bmatrix} \quad (3.22)$$

Bu iki matris, sol ve sağ helis kovaryans matrislerini (3.23)'de ifade edildiği gibi vermektedir. Burada  $f_{\text{C}}$ , helis saçılma bileşeninin katkısına karşılık gelmektedir.

$$C_{\text{3LH}} = \frac{f_{\text{C}}}{4} \begin{bmatrix} 1 & -j\sqrt{2} & -1 \\ j\sqrt{2} & 2 & -j\sqrt{2} \\ -1 & j\sqrt{2} & 1 \end{bmatrix} \text{ ve } C_{\text{3RH}} = \frac{f_{\text{C}}}{4} \begin{bmatrix} 1 & j\sqrt{2} & -1 \\ -j\sqrt{2} & 2 & j\sqrt{2} \\ -1 & -j\sqrt{2} & 1 \end{bmatrix} \quad (3.23)$$

Dört bileşenli ayırıştırma modeli yaklaşımında Yamaguchi ve arkadaşlarının önerdiği ikinci önemli katkı,  $\langle |S_{\text{HH}}|^2 \rangle$  ve  $\langle |S_{\text{VV}}|^2 \rangle$ 'nin bağıl geri saçılım büyüklüklerine göre, ayırıştırmadaki hacimsel saçılma matrisinin modifikasyonu ile ilgilidir (Yamaguchi ve ark. 2005). Hacimsel saçılmanın teorik modellemesinde, yönlendirme açıları için

üniform bir olasılık fonksiyonu ile rastgele yönlendirilmiş bir dipol bulutu uygulanmaktadır. Bununla birlikte, dikey yapının oldukça baskın olduğu bitki örtülü alanlar için, ağaç gövdelerinden ve dallardan saçılma üniform olmayan bir açı dağılımı sergiler. Önerilen yeni olasılık dağılımı (3.24) ile verilmektedir.

$$p(\theta) = \begin{cases} \frac{1}{2} \cos \theta, & |\theta| < \pi/2 \\ 0, & |\theta| > \pi/2 \end{cases} \quad (3.24)$$

Burada  $\theta$  radardan görülen yatay eksen den alınmaktadır. Bu durumda denklem 3.14'te tanımlanan integraller denklem (3.25)'te verilenlere eşit olmaktadır.

$$I_1 = \frac{8}{15}, I_2 = \frac{3}{15}, I_3 = \frac{8}{15}, I_4 = \frac{2}{15}, I_5 = I_6 = 0 \quad (3.25)$$

Silindir benzeri saçıcılar bulutunun rastgele yönlendirilmiş ve çok ince yatay ( $b \mapsto 0$ ) olduğu varsayılırsa, hacimsel saçılım ortalama kovaryans matrisi  $\langle C_{3V} \rangle_\theta$  ile verilmektedir.

$$\langle C_{3V} \rangle_\theta = \frac{f_V}{15} \begin{bmatrix} 8 & 0 & 2 \\ 0 & 4 & 0 \\ 2 & 0 & 3 \end{bmatrix} \quad (3.26)$$

Eğer silindir benzeri saçıcılar bulutunun rastgele yönlendirilmiş ve çok ince dikey ( $a \mapsto 0$ ) olduğu varsayılırsa, hacimsel saçılım ortalama kovaryans matrisi  $\langle C_{3V} \rangle_\theta$  ile verilmektedir.

$$\langle C_{3V} \rangle_\theta = \frac{f_V}{15} \begin{bmatrix} 3 & 0 & 2 \\ 0 & 4 & 0 \\ 2 & 0 & 8 \end{bmatrix} \quad (3.27)$$

Her iki durumda da  $f_V$  hacimsel saçılma bileşeninin katkısına karşılık gelmektedir.

Hacimsel, çift sıçrama, yüzey ve helis saçılması bileşenlerinin ilişkisiz olduğu varsayılarak toplam ikinci dereceden istatistikler, tek mekanizmalar için yukarıdaki istatistiklerin toplamıdır. Böylece toplam geri saçılma modeli,

$$C_3 = C_{3S} + C_{3D} + C_{3LH/RH} + \langle C_{3V} \rangle_\theta$$

$$= \begin{bmatrix} f_s |\beta|^2 + f_D |\alpha|^2 + \frac{f_C}{4} & \pm j \frac{\sqrt{2} f_C}{4} & f_s \beta + f_D \alpha - \frac{f_C}{4} \\ \pm j \frac{\sqrt{2} f_C}{4} & \frac{f_C}{2} & \pm j \frac{\sqrt{2} f_C}{4} \\ f_s \beta^* + f_D \alpha^* - \frac{f_C}{4} & \pm j \frac{\sqrt{2} f_C}{4} & f_s + f_D + \frac{f_C}{4} \end{bmatrix} + f_v \begin{bmatrix} a & 0 & d \\ 0 & b & 0 \\ d & 0 & c \end{bmatrix} \quad (3.28)$$

Bu model, altı bilinmeyenli ( $\alpha, \beta, f_s, f_D, f_C$  ve  $f_v$ ) beş denklem vermektedir. Seçilen hacim saçılması ortalama kovaryans matrisi  $\langle C_{3V} \rangle_\theta$  için  $a, b, c$  ve  $d$  parametreleri sabittir. Her bir saçılma mekanizmasının ölçülen toplam güce katkısı şu şekilde tahmin edilebilir:

$$\text{Span} = |S_{HH}|^2 + 2|S_{HV}|^2 + |S_{VV}|^2 = P_S + P_D + P_C + P_V \quad (3.29)$$

$$\begin{aligned} P_S &= f_s (1 + |\beta|^2) & P_D &= f_D (1 + |\alpha|^2) \\ P_C &= f_C & P_V &= f_v \end{aligned} \quad (3.30)$$

Freeman-Durden ve Yamaguchi ayrıştırmaları basitlik, fiziksel yorumlamanın kolaylığı, hesaplama verimliliği ve nispeten daha iyi performans gibi avantajlara sahiptir. Bununla birlikte, yaygın olarak kullanılan hacimsel saçılma modellerinin dinamik aralıkları çok sınırlı olduğundan hacimsel saçılma katkısı daha yüksek tahmin edilmektedir.

### 3.2.3. Van Zyl Ayrıştırma Modeli

Van Zyl ayrıştırması, özvektör-tabanlı bir ayrıştırma yöntemidir (van Zyl ve ark. 2011) ve bu ayrıştırmanın ana fikri fiziksel olmayan negatif gücün ortaya çıkmasını önlemektir. Freeman-Durden ve Yamaguchi ayrıştırma modellerinde, yüzey ve çift sıçrama saçılma bileşenleri için kovaryans matrisinin negatif özdeğerleri üretilebilmektedir. Bu nedenle, bu ayrıştırmanın negatif sonuçları fiziksel olarak yanlıştır. van Zyl polarimetrik ayrıştırması yüzey saçılması, çift sıçrama saçılması ve hacim saçılması bileşenlerinden oluşmaktadır.

Van Zyl ayrıştırması ilk olarak, monostatik durumda azimutal simetrik doğal arazi için 3x3 C3 kovaryans matrisi kullanılarak önerilmiştir (van Zyl 1993). Yansıma simetri hipotezi ile toprak ve orman gibi doğal bir ortam söz konusu olduğunda, eş-polarize ve çapraz-polarize kanallar arasındaki korelasyonun sıfır olduğu varsayılmaktadır. C3 ortalama kovaryans matrisi şu şekildedir:

$$C_3 = \begin{bmatrix} \langle |S_{HH}|^2 \rangle & 0 & \langle S_{HH}S_{VV}^* \rangle \\ 0 & \langle 2|S_{HV}|^2 \rangle & 0 \\ \langle S_{VV}S_{HH}^* \rangle & 0 & \langle |S_{VV}|^2 \rangle \end{bmatrix} = \alpha \begin{bmatrix} 1 & 0 & \rho \\ 0 & \eta & 0 \\ \rho^* & 0 & \mu \end{bmatrix} \quad (3.31)$$

$$\begin{aligned} \alpha &= \langle S_{HH}S_{HH}^* \rangle & \rho &= \langle S_{HH}S_{VV}^* \rangle / \langle S_{HH}S_{HH}^* \rangle \\ \eta &= 2 \langle S_{HV}S_{HV}^* \rangle / \langle S_{HH}S_{HH}^* \rangle & \mu &= \langle S_{VV}S_{VV}^* \rangle / \langle S_{HH}S_{HH}^* \rangle \end{aligned} \quad (3.32)$$

$\alpha, \rho, \eta$  ve  $\mu$  parametrelerinin tümü saçıcıların boyutuna, şekline ve elektriksel özelliklerine ve bunların istatistiksel açısal dağılımına bağlıdır. Böyle bir durumda, van Zyl (1993) tarafından verilen özdeğerlere karşılık gelen analitik ifadeleri türetmek mümkündür.

$$\begin{aligned} \lambda_1 &= \frac{\alpha}{2} \left\{ 1 + \mu + \sqrt{(1 - \mu)^2 + 4|\rho|^2} \right\} \\ \lambda_2 &= \frac{\alpha}{2} \left\{ 1 + \mu - \sqrt{(1 - \mu)^2 + 4|\rho|^2} \right\} \\ \lambda_3 &= \alpha\eta \end{aligned} \quad (3.33)$$

Buna karşılık gelen üç özvektör ise:

$$\begin{aligned}
 \underline{u}_1 &= \sqrt{\frac{\mu-1+\sqrt{\Delta}}{(\mu-1+\sqrt{\Delta})^2+4|\rho|^2}} \begin{bmatrix} \frac{2\rho}{\mu-1+\sqrt{\Delta}} \\ 0 \\ 1 \end{bmatrix} \\
 \underline{u}_2 &= \sqrt{\frac{\mu-1-\sqrt{\Delta}}{(\mu-1-\sqrt{\Delta})^2+4|\rho|^2}} \begin{bmatrix} \frac{2\rho}{\mu-1-\sqrt{\Delta}} \\ 0 \\ 1 \end{bmatrix} \\
 \underline{u}_3 &= \begin{bmatrix} 0 \\ 1 \\ 0 \end{bmatrix}
 \end{aligned} \tag{3.34}$$

Burada  $\Delta = (1-\mu)^2 + 4|\rho|^2$ , dir. 3x3 Hermit C3 ortalama kovaryans matrisi ařağıdaki řekilde ifade edilebilir:

$$\begin{aligned}
 C_3 &= \sum_{i=1}^3 \lambda_i \underline{u}_i \underline{u}_i^{*T} \\
 &= \Lambda_1 \begin{bmatrix} |\alpha|^2 & 0 & \alpha \\ 0 & 0 & 0 \\ \alpha^* & 0 & 1 \end{bmatrix} + \Lambda_2 \begin{bmatrix} |\beta|^2 & 0 & \beta \\ 0 & 0 & 0 \\ \beta^* & 0 & 1 \end{bmatrix} + \Lambda_3 \begin{bmatrix} 0 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix}
 \end{aligned} \tag{3.35}$$

Burada,

$$\begin{aligned}
 \Lambda_1 &= \lambda_1 \left[ \frac{(\mu-1+\sqrt{\Delta})^2}{(\mu-1+\sqrt{\Delta})^2+4|\rho|^2} \right] & \alpha &= \frac{2\rho}{\mu-1+\sqrt{\Delta}} \\
 \Lambda_2 &= \lambda_2 \left[ \frac{(\mu-1-\sqrt{\Delta})^2}{(\mu-1-\sqrt{\Delta})^2+4|\rho|^2} \right] & \beta &= \frac{2\rho}{\mu-1-\sqrt{\Delta}} \\
 \Lambda_3 &= \lambda_3
 \end{aligned} \tag{3.36}$$

ile tanımlanmaktadır. Van Zyl ayrıştırması, ilk iki özvektörün tek ve çift sayıda yansıma olarak yorumlanabilen eşdeğer saçılma matrislerini temsil ettiğini göstermektedir.

### 3.2.4. Cloude-Pottier (H/A/ $\alpha$ ) Ayırıştırma Modeli

H/A/ $\alpha$  ayrışması olarak da adlandırılan Cloude-Pottier ayrıştırma modeli, koherent matrisinin özvektör-tabanlı ayrıştırmasına dayanmaktadır. Bu yöntem karmaşık saçılmayı; entropi (H), anizotropi (A) ve ortalama alfa açısı ( $\alpha$ ) olarak üç polarimetrik parametreye ayırştırmaktadır. Düşük entropi değerleri genellikle baskın saçılma mekanizmalarını tanımlarken, yüksek entropi değerleri farklı saçılma mekanizmalarının rastgele kombinasyonlarını tanımlamaktadır (Ustuner ve Sanli 2019). Alfa açısının sırasıyla yüzey saçılması, hacim saçılması ve çift sıçrama saçılması nedeniyle  $\alpha = 0^\circ, 45^\circ$  ve  $90^\circ$  olarak üç spesifik durumu vardır. Anizotropi, saçılma mekanizmalarını ayırt etmek, ikinci ve üçüncü özdeğerlerin nispi önemini tanımlamak için kullanılan yararlı bir parametredir.

Bu modelde,  $3 \times 3$  Hermit koherent matrisi  $\mathbf{T}$  denklem (3.37)'de verildiği gibi ayrıştırılır (Cloude ve Pottier 1997).

$$\mathbf{T} = \mathbf{U}_3 \mathbf{\Sigma} \mathbf{U}_3^{-1} \quad (3.37)$$

Burada  $\mathbf{\Sigma}$ ,  $3 \times 3$  boyutunda reel değerli bir diyagonal matris olup  $\mathbf{T}$  matrisinin özdeğerlerini içermektedir.

$$\mathbf{\Sigma} = \begin{bmatrix} \lambda_1 & 0 & 0 \\ 0 & \lambda_2 & 0 \\ 0 & 0 & \lambda_3 \end{bmatrix} \quad (3.38)$$

Burada  $\lambda_1 > \lambda_2 > \lambda_3 > 0$  olarak verilmektedir.  $3 \times 3$  birim matris  $\mathbf{U}_3$ ,  $\mathbf{T}$  matrisinin  $i = 1, 2, 3$  için  $u_i$  özvektörlerinden oluşmaktadır.

$$\mathbf{U}_3 = [u_1 \quad u_2 \quad u_3] \quad (3.39)$$

$\mathbf{T}$  matrisinin  $u_i$  özvektörleri denklem (3.40)'taki gibi formülize edilebilir:

$$u_i = [\cos \alpha_i \quad \sin \alpha_i \cos \beta_i e^{j\delta_i} \quad \sin \alpha_i \cos \beta_i e^{j\gamma_i}]^T \quad (3.40)$$

### 3. MATERYAL VE METOT

---

Denklem (3.38) ve (3.39) göz önüne alınarak  $\mathbf{T}$  matrisinin öz ayrıştırması (3.41) ifadesi ile yazılabilir.

$$\mathbf{T} = \sum_{j=1}^3 \lambda_j \mathbf{u}_j \mathbf{u}_j^{*T} \quad (3.41)$$

Rankı 3 olan  $\mathbf{T}$  matrisi, rankı 1 olan üç adet koherent matrisin kombinasyonu olarak ayrıştırılabilir.

$$\mathbf{T} = \mathbf{T}_{01} + \mathbf{T}_{02} + \mathbf{T}_{03} \quad (3.42)$$

Elde edilen özdeğerler ve özvektörler  $\mathbf{T}$ 'nin öz ayrıştırmasının birincil parametreleri olarak kabul edilmektedir. Bu öz ayrıştırması tarafından sağlanan fiziksel bilgilerin analizini basitleştirmek için,  $\mathbf{T}$ 'nin özdeğerlerinin ve özvektörlerinin bir fonksiyonu olarak üç adet ikincil parametre tanımlanmıştır (Cloude 1992). Bu parametreler entropi, anizotropi ve alfa açısıdır.

Entropi (H), hedef saçılmasının rastgelelik derecesini tanımlamaktadır. Hedef koherent matrisinin özdeğerlerinden denklem (3.43) ile hesaplanmaktadır. Entropi değeri 0 ile 1 arasındadır.

$$H = \sum_{i=1}^3 -P_i \log_n(P_i) \quad (3.43)$$

$$P_i = \frac{\lambda_i}{\sum_{k=1}^3 \lambda_k} \quad (3.44)$$

Anizotropi (A), entropiyi tamamlayıcı bir parametredir. Anizotropi, öz ayrıştırmasının ikinci ve üçüncü özdeğerlerinin önemini ölçmektedir. Hedef koherent matrisinin özdeğerlerinden elde edilmektedir.

$$A = \frac{\lambda_2 - \lambda_3}{\lambda_2 + \lambda_3} \quad (3.45)$$

Alfa açısı ( $\alpha$ ), baskın saçılma mekanizması hakkında bilgi sağlamaktadır ve denklem (3.46) ile hesaplanabilmektedir.

$$\alpha = \sum_{i=1}^3 p_i \alpha_i \quad (3.46)$$

### 3.2.5. Cloude Ayırıştırma Modeli

Cloude ayırıştırması, koherent matrisinin en büyük özdeğerini ( $\lambda_1$ ) elde ederek baskın saçılma mekanizmasını tanımlamak için bir algoritmaya dayanan özvektör tabanlı ayırıştırma modelidir (Lee ve Pottier 2017). Bu ayırıştırmanın bileşenleri, yüzey saçılması, çift sıçrama saçılması ve hacimsel saçılmadır.

$\mathbf{T}_{01}$  koherent matrisi, tek bir hedef vektörü  $\underline{k}_1$  'in dış çarpımı olarak ifade edilebilir.

$$\mathbf{T}_{01} = \lambda_1 \underline{u}_1 \underline{u}_1^{*T} = \underline{k}_1 \underline{k}_1^{*T} \quad (3.47)$$

Sıfıra eşit olmayan özdeğer  $\lambda_1$ , hedef vektör  $\underline{k}_1$  'in Frobenius normunun karesidir ve ilişkili saçılma matrisine karşılık gelmektedir. Cloude ayırıştırması sonucunda elde edilen hedef vektörü  $\underline{k}_1$  denklem (3.48) ile ifade edilebilir:

$$\underline{k}_1 = \sqrt{\lambda_1} \underline{u}_1 = \frac{e^{j\phi}}{\sqrt{2A_0}} \begin{bmatrix} 2A_0 \\ C + jD \\ H - jG \end{bmatrix} = e^{j\phi} \begin{bmatrix} \sqrt{2}A_0 \\ \sqrt{B_0} + Be^{j\arctan(D/C)} \\ \sqrt{B_0} - Be^{-j\arctan(G/H)} \end{bmatrix} \quad (3.48)$$

Hedef vektörü  $\underline{k}_1$  üç saçılma bileşeninin kombinasyonundan oluşmaktadır:

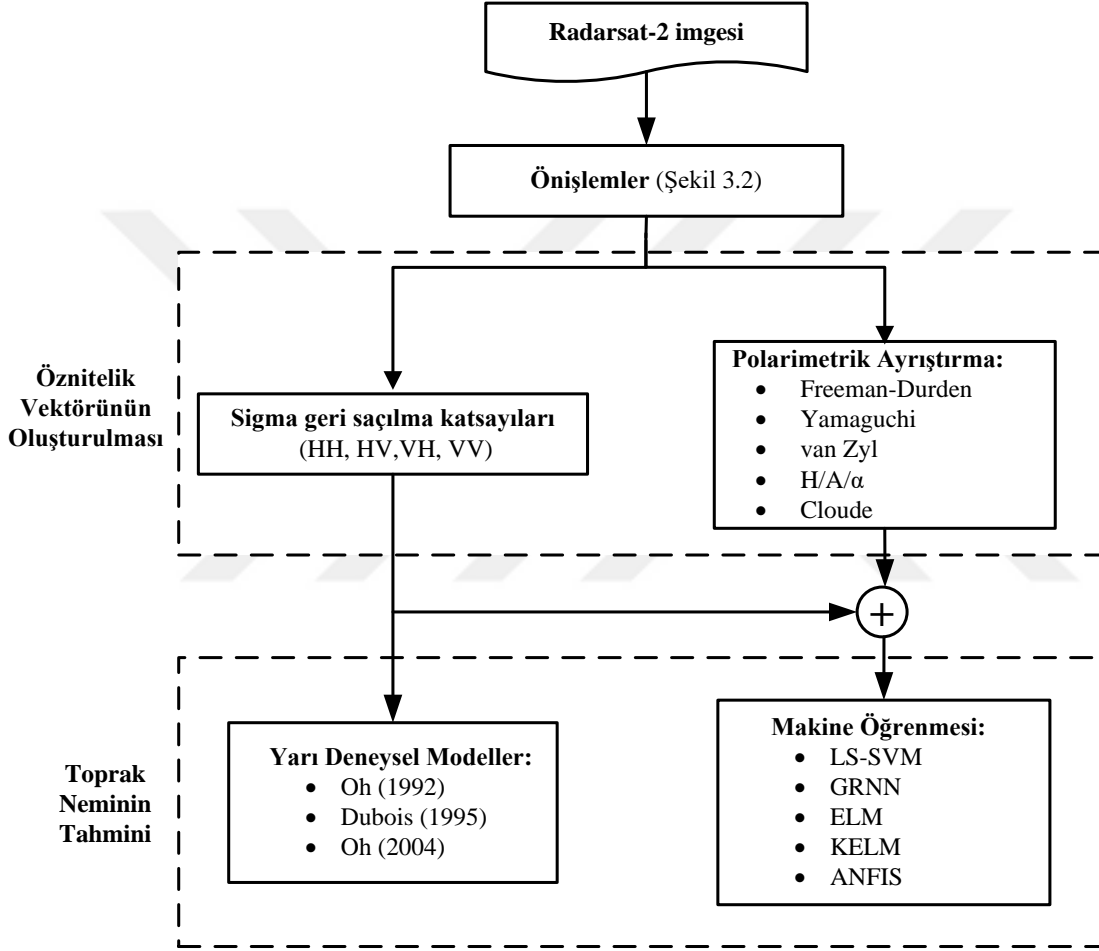
- Yüzey saçılması:  $A_0 \gg B_0 + B, B_0 - B$
- Çift sıçrama saçılması:  $B_0 + B \gg A_0, B_0 - B$
- Hacimsel saçılma:  $B_0 - B \gg A_0, B_0 + B$

### 3.3. Radar İmgelerinden Özellik Çıkarma

Bu çalışmada, yarı deneysel modeller ve makine öğrenmesi yöntemleri ile ön işlemleri tamamlanmış 10 Haziran 2015 ve 3 Mart 2016 Radarsat-2 imgelerinden toprak

### 3. MATERYAL VE METOT

neminin inversiyonu için sigma radar geri saçılma katsayıları ve Yamaguchi, van Zyl, Freeman-Durden, H/A/ $\alpha$  ve Cloude polarimetrik hedef ayrıştırma katsayıları özellik vektörleri olarak çıkarılmıştır. Radar geri saçılma katsayıları ( $\sigma_{HH}^o, \sigma_{HV}^o, \sigma_{VH}^o, \sigma_{VV}^o$ ) yarı deneysel modellerde tahmin için kullanılırken, polarimetrik ayrıştırma bileşenleri ve radar geri saçılma katsayıları inversiyon işlemi için makine öğrenme modellerinin girdisi olarak kullanılmıştır. Bu tez çalışmasının akış şeması Şekil 3.7.'de verilmiştir.



Şekil 3.7. Çalışmanın akış şeması

### 3.4. Toprak Nem Tahminini Etkileyen Parametreler

#### 3.4.1. SAR Sensör Parametreleri

Radar gelme açısı ve sensör dalga boyu, penetrasyon derinliğini ve radar tarafından algılanan yüzey pürüzlülüğünü etkilemektedir. Daha uzun dalga boyları ve daha dik gelme açıları (radar ışını ile normal arasındaki açı) genellikle penetrasyon derinliğinin artmasına neden olmaktadır ve toprak nemi haritalaması için 10 ila 20

derecelik gelme açıları önerilmektedir (Ulaby ve ark. 1982). Radar geri saçılması, bitki örtüsünün depolarize edici etkisi nedeniyle polarizasyon konfigürasyonuna göre değişmektedir. Toprak nemi, HH ve VV polarizasyon konfigürasyonlarında geri saçılma ile güçlü bir şekilde ilişkilidir (Sokol ve ark. 2004).

### 3.4.2. Hedef Parametreleri

#### a) Toprak Yüzey Pürüzlülüğü

Toprak nemi bilgisinin radar geri saçılımından doğru şekilde tahmin edilmesinin önündeki en büyük engel yüzey pürüzlülüğüdür. Çünkü geri saçılımın pürüzlülüğe olan duyarlılığı toprak neminden daha büyüktür (Álvarez-Mozos ve ark. 2009). Yüzey pürüzlülüğünün yüksek uzamsal değişkenliği, geniş alanlarda doğru ölçümün yapılmasını zorlaştırmaktadır (Verhoest ve ark. 2008). Pürüzlülük aynı zamanda toprak tipi, toprak işleme uygulamaları ve yağış olaylarıyla da bağlantılıdır. Toprak nemi tahminlerindeki bağıl değişiklikler göz önüne alındığında yüzey pürüzlülüğünün etkileri ortadan kaldırılrsa da deneysel, yarı deneysel ve fiziksel modellerde mutlak değerleri tahmin etmeye çalışırken dikkate alınmaları gerekmektedir.

#### b) Toprağın Dielektrik Sabiti

Toprağın dielektrik özellikleri toprak nem içeriği ile yakından ilişkilidir ve geri saçılmayı kontrol eden ikinci en önemli faktördür. Dielektrik özellikler, bir dalgaın bir materyal boyunca yayılma yeteneğini tarif etmektedir. Genel olarak, dielektrik sabiti faz farkını temsil edebilmek için karmaşık bir sayı olarak ele alınmaktadır:

$$\varepsilon_r = \varepsilon' - j\varepsilon'' \quad (3.49)$$

Çünkü karmaşık bir sayı hem genliği hem de fazı göstermek için kullanılabilir. Dielektrik sabitinin gerçek kısmı ( $\varepsilon'$ ), ortamdaki depolanmış enerjiyi yansıtır ve imajiner kısım ( $\varepsilon''$ ), enerji kaybı miktarıyla ilişkilidir. Çeşitli çalışmalar, dielektrik sabitinin gerçek kısmının toprak nemindeki değişikliklere duyarlılığının imajiner kısımdan çok daha yüksek olduğunu göstermiştir (Schmugge ve ark. 1980, Hallikainen ve ark. 1985, Ulaby ve ark. 1986). Bu nedenle, toprak nemi tahmininde toprağın dielektrik sabitinin gerçek bir sayı olduğu varsayılabilir.

### 3. MATERYAL VE METOT

---

Dielektrik sabiti için değerler tipik olarak 0 ila 80 arasındadır, su için dielektrik sabitinin değeri 80'e yaklaşmaktadır. Bu nedenle, dielektrik sabitinin değeri, daha yüksek nem içeriğine sahip topraklarda daha yüksek değerlere yol açan su içeriğinden büyük ölçüde etkilenmektedir. TDR prensiplerine göre çalışan toprak nemi problemleri, dielektrik geçirgenliğini doğrudan  $\pm\%1$ 'lik bir doğrulukla ölçmektedir. Buna dielektrik sabitinden volümetrik toprak nemine dönüşümde  $\%3-4$ 'lük bir hata eklenir (Topp ve ark. 1980). Bu ilişki, gelen enerjinin dalga boyundan bağımsız olarak  $\%40-55$ 'in altındaki volümetrik toprak nem içeriği için geçerlidir. Bu aralığın dışında, dönüşüm modeli toprak nemini  $\%10$  veya üzerinde daha düşük tahmin edebilir ve bir şekilde frekansa bağımlı hale gelmektedir (Topp ve ark. 1980).

Toprağın dielektrik özellikleri, radar sinyalinin penetrasyon derinliğini ( $\delta_p$ ) etkilemektedir ve denklem (3.50) ile hesaplanabilmektedir:

$$\delta_p \approx \frac{1}{k} \cdot \frac{\sqrt{\epsilon''}}{\epsilon''} \quad (3.50)$$

Burada  $k$  dalga sayısı,  $\epsilon''$  ortamdaki dalga zayıflamasının ölçüsüdür. Çok kuru ve kumlu topraklarda C-bandı penetrasyonu 0.52 m derinliklere yaklaşabilir, ancak ekim yapmaya elverişli çoğu toprakta ise penetrasyon derinliği 1 – 5 cm arasındadır (Bruckler ve ark. 1988). Bu da göstermektedir ki radar dönüş sinyali, sadece yüzeye yakın koşulları temsil etmektedir (Dobson ve Ulaby 1986).

#### c) Toprak Bileşenleri

Toprak, katı parçacıklar (mineraller ve organik madde), hava ve su karışımından oluşan doğal katmanların birleşimi olarak düşünülebilir. Katı parçacıklar, boyutlarına göre kum, silt ve kil olarak sınıflandırılabilir. Bu üç tip parçacık, toprakta eşit olarak bulunabilir veya toprak bunlardan birinden yüksek oranda ve diğerlerinin küçük yüzdelerinden oluşabilir. Toprağın dokusu bu üç parçacık türünün oranına göre sınıflandırılmaktadır (Behari 2006). Toprak dokusu toprağın dielektrik sabitini ve dolayısıyla uzaktan algılama ölçümlerini etkileyebilir. Eşit dielektrik sabit değerlerine sahip ancak farklı miktarlarda kum, silt ve kil karışımı olan topraklar farklı nem değerlerine sahip olabilir (Wang ve Schmutge 1980).

#### d) Bitki Örtüsü

Bitki örtüsünün varlığı radar geri saçılmasını etkilemektedir. Radar geri saçılması, bitki kanopisi ile alttaki toprak arasındaki karmaşık çoklu-sıçrama etkileşimleri nedeniyle toprak nemi ile doğrusal olarak ilişkili değildir. Bitki örtüsünün varlığında, toprak nemi yalın toprak nemi inversiyon modelleri ile olduğu değerler altında tahmin edilmektedir. Ayrıca bitki örtüsünün yüksekliği ve yoğunluğu da toprak nemi tahmininde doğrudan etkiye sahiptir ve bazen toprak nemi tahmin modelleri doğruluklarında başarısız olmaktadır.

### 3.5. Yarı Deneysel Modeller ile Toprak Neminin Tahmini

#### 3.5.1. Oh Modelleri

Oh ve ark. (1992) ve Oh (2004), yalın toprak yüzeyleri için teorik model, geri saçılma ve SAR ölçümlerini kullanarak yarı deneysel geri saçılma modelleri önermiştir. Bu modeller, eş-polarizasyon oranı (p) ve çapraz-polarizasyon oranını (q) gelme açısı ( $\theta$ ), dalga sayısı (k), yüzey yüksekliğinin standart sapması (s) ve volümetrik toprak nemine ( $m_v$ ) bağlı olarak tanımlamaktadır. Oh ve ark. (1992), modeli ilk olarak (3.51) ve (3.52) denklemlerinde gösterildiği gibi sunmuştur. Model yalın topraklar içindir ve  $0.1 \leq ks \leq 2.5$ ,  $0.09 \leq m_v \leq 0.31$  ve  $10^\circ \leq \theta \leq 70^\circ$  için geçerlidir.

$$p = \sigma_{HH}^0 / \sigma_{VV}^0 = [1 - (\frac{2\theta}{\pi})^{1/(3\Gamma_0)} e^{-ks}]^2 \quad (3.51)$$

$$q = \sigma_{HV}^0 / \sigma_{VH}^0 = 0.23\sqrt{\Gamma_0}[1 - e^{-ks}] \quad (3.52)$$

$$\Gamma_0 = \left| \frac{1 - \sqrt{\epsilon_r}}{1 + \sqrt{\epsilon_r}} \right|^2 \quad (3.53)$$

Uzaktan algılanan imgeden Oh (1992) modelini kullanarak toprak nemi tahmini yapabilmek için, geri saçılma katsayıları ( $\sigma_{HH}^0$ ,  $\sigma_{HV}^0$  ve  $\sigma_{VV}^0$ ),  $\theta$  ve dalga boyu ( $\lambda$ ) bilinmelidir. p ve q denklemleri  $e^{-ks}$  terimi yok edilecek bir şekilde düzenlenirse denklem (3.54) elde edilir. Bu denklem iteratif bir şekilde  $\Gamma_0$  (Fresnel yansıması) için çözüldüğünde, dielektrik sabiti denklem (3.53) ile hesaplanabilir ve daha sonra

### 3. MATERYAL VE METOT

volümetrik toprak nemi Topp ve ark. (1980) tarafından önerilen polinom (3.55) ile elde edilebilir.

$$\left(\frac{2\theta}{\pi}\right)^{1/3\Gamma_0} \cdot \left[1 - \frac{q}{0.23\sqrt{\Gamma_0}}\right] + \sqrt{p} - 1 = 0 \quad (3.54)$$

$$m_v = -5.3 + 2.92(\varepsilon_r') + 0.055(\varepsilon_r')^2 + 0.0043(\varepsilon_r')^3 \quad (3.55)$$

Oh ve ark. (2002), eş-polarizasyon ve çapraz-polarizasyon oranlarını modifiye ederek (3.56) ve (3.57) denklemleriyle ifade etmiştir ve ek olarak çapraz-polarize geri saçılma katsayısı için yeni bir denklem (denklem (3.58)) sunmuştur.

$$p = 1 - \left(\frac{\theta}{90^\circ}\right)^{0.35m_v - 0.65} e^{-0.4(ks)^{1.4}} \quad (3.56)$$

$$q = 0.1\left(\frac{s}{L} + \sin 1.3\theta\right)^{1.2} (1 - e^{-0.9(ks)^{0.8}}) \quad (3.57)$$

$$\sigma_{VH}^0 = 0.11m_v^{0.7} \cos^{2.2} \theta (1 - e^{-0.32(ks)^{1.8}}) \quad (3.58)$$

Korelasyon uzunluğunun ölçülmesinin kesin olmadığı (Oh ve Kay 1998) ve q oranının pürüzlülük parametresine (s/L) duyarlı olduğu göz önüne alındığında, Oh (2004)'te q için korelasyon uzunluğunu ihmal eden yeni bir formülasyon (denklem (3.59)) önermiştir. Oh (2004) modeli yalnız topraklar içindir ve  $0.13 \leq ks \leq 6.98$ ,  $0.04 \leq m_v \leq 0.291$  ve  $10^\circ \leq \theta \leq 70^\circ$  için geçerlidir.

$$q = 0.095(0.13 + \sin 1.5\theta)^{1.4} (1 - e^{-1.3(ks)^{0.9}}) \quad (3.59)$$

Oh (2004) modelinden toprak nemini tahmin etmek için bir inversiyon modeli oluşturulmuştur. Bu amaçla, denklem (3.58) ks için aşağıdaki gibi düzenlenmiştir:

$$ks = \left[ -3.125 \ln \left( \frac{\sigma_{VH}^0}{0.11m_v^{0.7} (\cos \theta)^{2.2}} \right) \right]^{5/9} \quad (3.60)$$

Denklem (3.60) denklem (3.59)'da yerine yazılır ve  $m_v$  için doğrusal olmayan bir denklem (3.61) elde edilir. Bu denklem  $m_v = 0.5$  başlangıç değeri için nümerik yöntemlerle iteratif olarak çözülür.

$$1 - \left( \frac{\theta}{90^\circ} \right)^{0.35m_v^{-0.65}} \cdot \exp \left( -0.4 \left\{ \left[ -3.125 \ln \left( \frac{\sigma_{vH}^0}{0.11m_v^{0.7} (\cos \theta)^{2.2}} \right) \right]^{5/9} \right\}^{1.4} \right) - p = 0 \quad (3.61)$$

$ks$ 'nin ilk tahmini,  $m_v$ 'nin ilk tahmininin denklem (3.60)'da yerine yazılmasıyla elde edilir. Denklem (3.59)'dan  $ks$ 'nin ikinci tahmini türetilir:

$$ks = \left[ \ln \left( 1 - \frac{q}{0.095(0.13 \sin(1.5\theta))^{1.4}} \right) / -1.3 \right]^{10/9} \quad (3.62)$$

Bu ikinci  $ks$  tahmini kullanılarak,  $m_v$ 'nin iki tahmini daha (3.56) ve (3.58) denklemlerinden türetilir:

$$m_v = \left[ \frac{\sigma_{vH}^0}{0.11(\cos \theta)^{2.2} \cdot [1 - \exp(-0.32(ks)^{1.8})]} \right]^{10/9} \quad (3.63)$$

$$m_v = \left[ \ln \left( \frac{1-p}{\exp(-0.4(ks)^{1.4}) / 0.35 \ln \theta} \right) \right]^{-20/13} \quad (3.64)$$

Bu işlem iki  $s$  tahmini ve üç  $m_v$  tahmini ile sona ermektedir.  $s$  ve  $m_v$ 'nin ağırlıklı ortalamaları (3.65) ve (3.66) denklemleriyle elde edilir.

$$s = \frac{s_1 * w_1 + s_2 * 0.25w_2}{w_1 + 0.25w_2} \quad (3.65)$$

$$m_v = \frac{m_{v1} * w_3 + m_{v2} * w_4 + m_{v3} * w_5}{w_3 + w_4 + w_5} \quad (3.66)$$

Son aşamada, üretilen tahminlerin model geçerlilik aralıkları içerisinde olup olmadığı teyit edilir. Önceki aşamadaki ortalama alma işlemi nedeniyle, tahminlerin model geçerlilik aralığının dışında olması muhtemeldir.

#### 3.5.2. Dubois Modeli

Dubois ve ark. (1995),  $\sigma_{HH}^0$  ve  $\sigma_{VV}^0$  radar geri saçılma katsayılarını modellemek için yarı deneysel bir yaklaşım önermiştir.  $\sigma_{HH}^0$  ve  $\sigma_{VV}^0$  gelme açısı, dielektrik katsayısı, yüzey yüksekliğinin standart sapması ve dalga boyuyla ifade edilir. Dubois (1995) modeli yalnız topraklar içindir ve  $k.s \leq 2.5$ ,  $m_v \leq \%35$  ve  $\theta \geq 30^\circ$  için geçerlidir.

$$\sigma_{HH}^0 = 10^{-2.75} \left( \frac{\cos^{1.5} \theta}{\sin^5 \theta} \right) 10^{0.028 \cdot \varepsilon_r \cdot \tan \theta} (k.s. \sin \theta)^{1.4} \lambda^{0.7} \quad (3.67)$$

$$\sigma_{VV}^0 = 10^{-2.35} \left( \frac{\cos^3 \theta}{\sin^3 \theta} \right) 10^{0.046 \cdot \varepsilon_r \cdot \tan \theta} (k.s. \sin \theta)^{1.1} \lambda^{0.7} \quad (3.68)$$

Dubois (1995) inversiyon modeli için, (3.67) ve (3.68) ile verilen denklemlerden biri  $\varepsilon_r \tan \theta$  için çözülmüş ve diğer denklemde yerine yazılmıştır. Elde edilen denklem, yüzey pürüzlülüğünü ( $ks$ ) elde etmek için çözülmür. Elde edilen  $ks$ , denklem (3.67)'de yerine yazılarak dielektrik sabiti tahmin edilir.

$$\varepsilon_r = \frac{\log_{10}(\sigma_{HH}^0) 10^{2.75} (\cos \theta)^{-1.5} (\sin \theta)^5 (k.s. \sin \theta)^{-1.4} \lambda^{-0.7}}{0.028 \tan \theta} \quad (3.69)$$

Son olarak, tahmin edilen dielektrik sabiti deneysel olarak türetilmiş 3. dereceden polinom (3.55) kullanılarak volümetrik toprak nemi tahminine dönüştürülür.

### 3.6. Makine Öğrenmesi Yöntemleri ile Toprak Neminin Tahmini

#### 3.6.1. En Küçük Kareler Destek Vektör Makineleri (LS-SVM)

Vapnik (1995), YSA'nın dezavantajlarını en aza indirmek için makine öğrenme teorisine ve kuadratik programlama çözümüne dayanan SVM yöntemini önermiştir. Bir destek vektör makinesi, verileri iki kategoriye ayıran en uygun hiper düzlemi oluşturur. SVM regresyonunda, en uygun ayırıcı hiper düzlem ile destek vektörleri arasında bir marjin yerine bir yaklaşım hatası kullanılmaktadır (Ceryan ve ark. 2013).

Suykens ve Van Gestel (2002), geleneksel SVM'yi basitleştirmek için LS-SVM'nin kullanılmasını önermiştir. LS-SVM, çeşitli örüntü tanıma alanlarında sınıflandırma için kullanılmış ve son zamanlarda regresyon problemlerini başarıyla ele

almıştır. LS-SVM, SVM ile benzer avantajlara sahiptir, ancak ek avantajı, hesaplamada çok daha kolay ve daha basit olan bir dizi doğrusal denklemin çözülmesini gerektirmesidir.

LS-SVM'nin formülasyonu için,  $x_i$  giriş ve  $y_i$  çıkış verisi olmak üzere  $\{x_i, y_i\} \in \mathfrak{R}^2$ ,  $i = 1, 2, \dots, N$  eğitim seti verilsin. Regresyon modeli denklem (3.70)'te verildiği gibi doğrusal olmayan haritalama fonksiyonu  $\phi(\cdot)$  kullanılarak oluşturulabilir.

$$y = w^T \phi(x) + b \quad (3.70)$$

Burada  $w$  ağırlık vektörü ve  $b$  bias terimidir. SVM'de olduğu gibi, cezalandırılmış bir regresyon hatası içeren bir maliyet fonksiyonu  $C$ 'yi aşağıdaki gibi en aza indirmek gerekmektedir:

$$\min C(w, e) = \frac{1}{2} w^T w + \frac{1}{2} \gamma \sum_{i=1}^N e_i^2 \quad (3.71)$$

$$y = w^T \phi(x_i) + b + e_i, \quad i = 1, 2, \dots, N \quad (3.72)$$

Denklem (3.71) ile verilen maliyet fonksiyonunun ilk kısmı, ağırlıkları regüle etmek ve büyük ağırlıkları cezalandırmak için kullanılmaktadır. Bu regülarizasyondan dolayı, ağırlıklar benzer değere yaklaşmaktadır. Büyük ağırlıklar, aşırı varyansa neden olabilmelerinden dolayı LS-SVM'nin genelleme yeteneğini bozmaktadır. Maliyet fonksiyonunun ikinci kısmı eğitim verisinin regresyon hatasını içermektedir. Kullanıcı tarafından optimize edilmesi gereken  $\gamma$  parametresi, bu parçanın birinci kısma kıyasla nispi ağırlığını vermektedir. Denklem (3.72) tarafından sağlanan kısıtlama, regresyon hatasının tanımını vermektedir. Bu optimizasyon problemini çözmek için Lagrange fonksiyonu şu şekilde oluşturulur:

$$L_{LS-SVM} = \frac{1}{2} \|w\|^2 + \frac{1}{2} \gamma \sum_{i=1}^N e_i^2 - \sum_{i=1}^N \alpha_i \{w^T \phi(x_i) + b + e_i - y_i\} \quad (3.73)$$

Burada,  $\alpha_i$  Lagrange çarpanlarıdır. Bu fonksiyonun çözümü  $w, b, e_i$  ve  $\alpha_i$ 'ye göre kısmi türev alınarak elde edilebilir.

$$w = \sum_{i=1}^N \alpha_i \phi(x_i) = \sum_{i=1}^N \gamma e_i \phi(x_i) \quad (3.74)$$

Burada kullanılan pozitif tanımlı Kernel denklem (3.75) ile verilmiştir.

$$K(x_i, x_j) = \phi(x_i)^T \phi(x_j) \quad (3.75)$$

Bu yaklaşımın önemli bir sonucu, ağırlıkların Lagrange çarpanlarının doğrusal kombinasyonları olarak yazılabilesidir. Denklem (3.74)'teki sonuç denklem (3.70)'te yerine yazılırsa denklem (3.76) elde edilmektedir.

$$y_i = \sum_{i=1}^N \alpha_i \phi(x_i)^T \phi(x_j) + b \quad (3.76)$$

Bir doğrusal denklemler setinin çözülmesiyle,

$$A \begin{bmatrix} \alpha \\ b \end{bmatrix} = \begin{bmatrix} y \\ 0 \end{bmatrix}, \quad A = \begin{bmatrix} K + \frac{1}{\gamma} I_N & \\ & I_N^T & 0 \end{bmatrix} \quad (3.77)$$

Burada  $K$  kernel matrisi ve  $I$  ise birim matrisi göstermektedir.

$$\begin{bmatrix} \alpha \\ b \end{bmatrix} = A^{-1} \begin{bmatrix} y \\ 0 \end{bmatrix} \quad (3.78)$$

Buradan görüleceği gibi, genellikle Lagrange çarpanları (destek vektörleri) sıfırdan farklıdır, yani tüm eğitim nesnelere çözüme katkıda bulunur. Doğrusal olmayan regresyon içeren uygulamalarda,  $\langle \phi(x_i), \phi(x_j) \rangle$  iç çarpımını bir kernel fonksiyonuyla değiştirmek yeterlidir. Bu durumda (3.79) ile verilen doğrusal olmayan regresyon fonksiyonu elde edilir.

$$y = \sum_{i=1}^N \alpha_i K(x_i, x) + b \quad (3.79)$$

LS-SVM ile kullanılan doğrusal, polinom, radyal tabanlı fonksiyon, spline ve sigmoid gibi birçok kernel fonksiyonu bulunmaktadır. Bu çalışmada kernel fonksiyonu olarak radyal tabanlı fonksiyon (RBF) tercih edilmiştir.

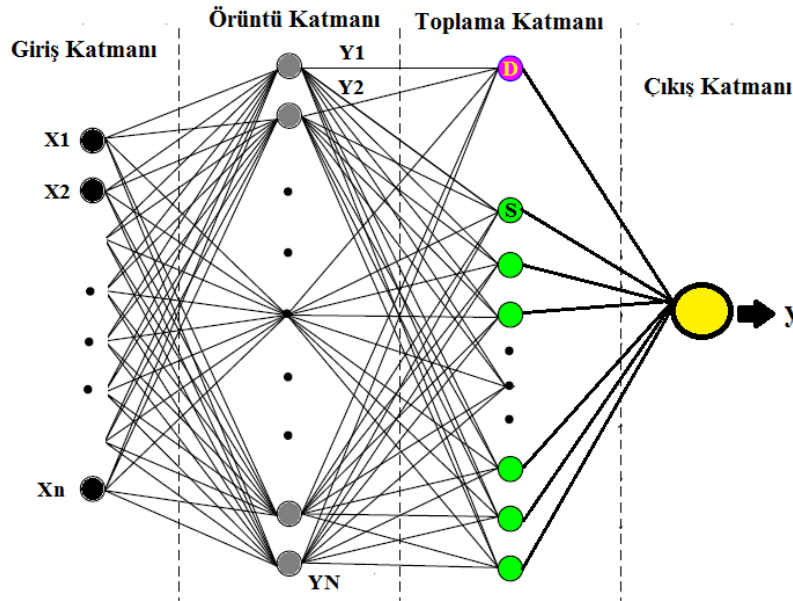
### 3.6.2. Genelleştirilmiş Regresyon Sinir Ağı (GRNN)

Specht (1991), regresyon problemleri için yeni bir sinir ağı modeli sunmuştur. GRNN, sürekli değişkenlerin tahminlerini sağlayan ve mevcut veri setiyle aranan fonksiyon yüzeyini parametrik olmayan bir şekilde oluşturan, hafıza tabanlı bir sinir ağıdır. Regresyon problemleri için yararlı bir yöntem olan GRNN, paralel bir yapıya sahiptir ve öğrenme süreci için sadece bir iterasyon kullanmaktadır. GRNN, her biri bir sonraki katmanla ilişkili dört katmandan oluşmaktadır. Bunlar giriş katmanı, örüntü katmanı, toplama katmanı ve çıkış katmanıdır. GRNN mimarisi Şekil 3.8.'de verilmiştir.

GRNN, olasılık dağılım fonksiyonunu içeren olasılıksal bir sinir ağıdır. Eğitim veri seti, GRNN regresyon modelinin her  $y$  çıkışına karşılık gelen  $x$  girişinden oluşmaktadır.

$$E[(y|x)] = \frac{\int_{-\infty}^{\infty} yf(x,y)dy}{\int_{-\infty}^{\infty} f(x,y)dy} \quad (3.80)$$

Burada  $E[(y|x)]$ , verilen  $x$  giriş vektörü için  $y$  çıkışının beklenen değeridir.  $f(x,y)$  ise  $x$  ve  $y$ 'nin olasılık yoğunluk fonksiyonudur.



Şekil 3.8. GRNN mimarisi (Acar 2017)

Genel regresyon yöntemi ile bir tahmin elde etmek için denklem (3.81)'de verilen formül kullanılmaktadır.

$$\hat{y}(x) = \frac{\sum_{i=1}^n y^i \exp\left(-\frac{C_i}{\zeta}\right)}{\sum_{i=1}^n \exp\left(-\frac{C_i}{\zeta}\right)}, \quad C_i = \sum_{j=1}^p |x_j - x_j^i| \quad (3.81)$$

Burada  $n$  eğitim örneklerinin sayısı,  $\zeta$  yayılma parametresidir ve  $C_i$ ,  $x$  giriş vektörü ile  $x^i$  eğitim vektörü arasındaki mesafedir.

### 3.6.3. Aşırı Öğrenme Makineleri (ELM) ve Kernel ELM

Huang ve ark. (2006) tarafından önerilen ve hızlı bir öğrenme yöntemi olan Aşırı Öğrenme Makineleri, Tek Gizli Katmanlı İleri Beslemeli Sinir Ağları için geliştirilmiştir. Giriş ağırlıkları ve bias gibi tüm parametreler rastgele üretilmektedir. Geri Yayılma (BP) yönteminde olduğu gibi parametrelerin ayarlanması gerekmemektedir. ELM yönteminin  $N$  tane eğitim örneği için çıkış fonksiyonu,

$$y(x) = \sum_{i=1}^m \beta_i g(w_i, b_i, x_i) = H(x)\beta \quad (3.82)$$

şekindedir. Burada  $x$  girişleri,  $w$  giriş ağırlıklarını,  $b$  bias parametresini ve  $H(x)$  gizli katmanın çıkış matrisini temsil etmektedir. Gizli katman ve çıkış katmanı arasındaki ağırlıklar  $\beta_i = \{\beta_1, \beta_2, \dots, \beta_m\}$ 'dir. Herhangi bir  $g(\cdot)$  fonksiyonu için çıkış katmanının girişi

$$H_{n \times m} = \begin{bmatrix} g(w_{1,1}x_1 + b_1) & \dots & g(w_{1,m}x_m + b_m) \\ \vdots & \ddots & \vdots \\ g(w_{n,1}x_n + b_1) & \dots & g(w_{n,m}x_m + b_m) \end{bmatrix} \quad (3.83)$$

şekindedir. ELM, çıkış ağırlığının en küçük normu ile eğitim hatasını en aza indirmeyi amaçlamaktadır (Huang ve ark. 2006).

$$\text{Min} : \|H\beta - T\|^2 \text{ ve } \|\beta\| \quad (3.84)$$

Denklem (3.82) ile çıkış ağırlığı en küçük kareler yöntemi kullanılarak elde edilebilmektedir.

$$\beta = H^+T \quad (3.85)$$

Burada,  $H^+$  genelleştirilmiş Moore-Penrose matrisinin tersidir (Rao ve Mitra 1972). Kısıtlı optimizasyon tabanlı ELM şu şekilde verilmektedir:

$$\text{Min} : m = \frac{1}{2}\|\beta\|^2 + C\frac{1}{2}\|\xi\|^2, \quad H\beta = T - \xi \quad (3.86)$$

Dual optimizasyon yöntemi kullanılarak denklem (3.86) çözüldüğünde,

$$m = \frac{1}{2}\|\beta\|^2 + C\frac{1}{2}\|\xi\|^2 - \alpha(\xi - T + H\beta) \quad (3.87)$$

elde edilir. Burada  $\alpha$  Lagrange çarpanıdır. Eğitim setinin boyutuna bağlı olarak farklı çözümler elde edilmektedir:

1. Eğer  $n \gg m$  ise

$$\beta = \left( \frac{I}{C} + H^+H \right)^{-1} H^+T \quad (3.88)$$

denklem (3.82) ile verilen çıkış fonksiyonu şu şekilde verilmektedir:

$$y(x) = H(x) \left( \frac{I}{C} + H^+H \right)^{-1} H^+T \quad (3.89)$$

2. Eğer  $n < m$  ise

$$\beta = H^T \left( \frac{I}{C} + HH^T \right)^{-1} T \quad (3.90)$$

durumunda ise çıkış fonksiyonu şu şekildedir:

$$y(x) = H(x)H^T \left( \frac{I}{C} + HH^T \right)^{-1} T \quad (3.91)$$

### 3. MATERYAL VE METOT

ELM'ye bir çekirdek fonksiyonu dahil edilerek ağırlıktaki hatalar azaltılabilir. Ek olarak sistemin gürbüzlüğü ve genelleme yeteneği artırılabilir. Denklem (3.91)'deki özellik haritalama matrisi  $H(x)$  bilinmediğinde, KELM yöntemi Mercer koşulları kullanılarak tanımlanır.

$$\phi_{ELM} = H(x_i).H(x_j) = K(x_i, x_j) \quad (3.92)$$

KELM için çıkış fonksiyonu denklem (3.93) ile verilmektedir.

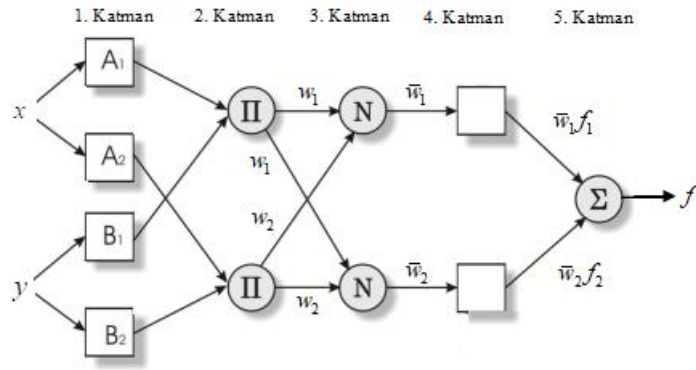
$$y(x) = \begin{bmatrix} K(x, x_1) \\ \vdots \\ K(x, x_n) \end{bmatrix}^T \left( \phi_{ELM} + \frac{I}{C} \right)^{-1} T \quad (3.93)$$

Sadece  $K(x_i, x_j)$  ile ilgili bilgi gereklidir,  $H(x)$  bilinmeyebilir.

#### 3.6.4. Adaptif Sinirsel Bulanık Çıkarım Sistemi (ANFIS)

Jang (1993), Adaptif Sinirsel Bulanık Çıkarım Sistemi (ANFIS) önermiştir. Jang'a göre ANFIS, işlevsel olarak Takagi-Sugeno tipi çıkarım modeliyle aynı olan bir sinir ağıdır. ANFIS, yapay sinir ağlarının öğrenme yeteneğini ve bulanık mantığın çıkarım ilkelerini birleştiren çok katmanlı bir uyarlanabilir ağıdır. Bulanık çıkarım sistemleri, bulanık mantık teorisinin en iyi bilinen uygulamalarından biridir. Bulanık çıkarım sistemlerinde, üyelik fonksiyonlarının tipik olarak deneme yanılma yoluyla manuel olarak ayarlanması gerekmektedir. Bulanık bir modelin parametreleri YSA tekniği sayesinde eğitim veri setinden öğrenilmesine olanak tanımaktadır. Aynı zamanda bulanık modelde haritalanan çözüm, dilsel terimlerle "eğer – o halde" kuralları olarak açıklanabilmektedir.

ANFIS modelinin mimarisi Şekil 3.9.'da verilmiştir. Bu model beş katmandan oluşmaktadır. Her katman, düğüm fonksiyonu tarafından tanımlanan birkaç düğüm içermektedir. Karelerle gösterilen adaptif düğümler, bu düğümlerde ayarlanabilen parametreleri temsil etmektedir. Tersine, dairelerle gösterilen sabit düğümler, modelde sabitlenmiş parametre setlerini temsil etmektedir. ANFIS modelinin yapısını açıklamak için bu bölümde giriş olarak iki değişken ( $x$  ve  $y$ ) ve bir çıkış ( $f$ ) kullanan basit bir örnek ANFIS mimarisi açıklanacaktır.



**Şekil 3.9.** ANFIS mimarisi

İlk katman, girdileri Üyelik Fonksiyonları (MF) aracılığıyla bulanık bir kümeye dönüştüren bulanık katmandır. Bu katman şu şekilde tanımlanan düğüm fonksiyonlarına sahip adaptif düğümler içermektedir:

$$\begin{aligned} O_{1,i} &= \mu_{A_i}(x), & i &= 1, 2 \\ O_{1,i} &= \mu_{B_{i-2}}(y), & i &= 3, 4 \end{aligned} \quad (3.94)$$

Burada  $x$  ve  $y$  giriş düğümü,  $A$  ve  $B$  bu düğümle ilişkili dilsel etiketler,  $\mu(x)$  ve  $\mu(y)$  üyelik fonksiyonlarıdır. Kullanılabilecek birçok üyelik fonksiyonu tipi mevcuttur. Bununla birlikte, genellikle maksimum ve minimumu 1 ve 0'a eşit olan Gauss şekilli bir fonksiyon benimsenmektedir. Bu katmandaki parametreler öncül parametreler olarak tanımlanır.

İkinci katmandaki her düğüm, bir daire ile işaretlenmiş ve  $\Pi$  ile etiketlenmiş sabit bir düğümdür. Düğüm fonksiyonu, çıkış sinyali olarak görev yapmak üzere giriş sinyalleri ile çarpılır.

$$O_{2,i} = w_i = \mu_{A_i}(x) \cdot \mu_{B_{i-2}}(y), \quad i = 1, 2 \quad (3.95)$$

Burada  $O_{2,i}$  ikinci katmanın çıkışıdır. Çıkış sinyali  $w_i$ , kuralın ateşleme gücünü temsil etmektedir.

Üçüncü katmandaki her düğüm,  $i$ 'nci düğüm ateşleme gücünün tüm kuralların ateşleme gücünün toplamına oranını hesaplayarak ateşleme gücünü normalize eden

### 3. MATERYAL VE METOT

---

düğüm fonksiyonuna sahip, bir daire ile gösterilen ve N ile etiketlenmiş sabit bir düğümdür. Burada  $O_{3,i}$  üçüncü katmanın çıkışıdır.

$$O_{3,i} = \bar{w} = \frac{w_i}{w_1 + w_2}, \quad i = 1, 2 \quad (3.96)$$

Dördüncü katmandaki her düğüm, (3.97)'deki gibi düğüm fonksiyonuna sahip, bir kare ile gösterilen ayarlanabilir bir düğümdür:

$$O_{4,i} = \bar{w}_i \cdot f_i, \quad i = 1, 2 \quad (3.97)$$

Burada  $f_1$  ve  $f_2$ , aşağıdaki gibi bulanık “eğer – o halde” kuralları ve  $p_i$ ,  $q_i$  ve  $r_i$  kural parametreleridir:

Kural 1. Eğer  $x$  A<sub>1</sub> ve  $y$  B<sub>1</sub> ise, o halde  $f_1 = p_1x + q_1y + r_1$

Kural 2. Eğer  $x$  A<sub>2</sub> ve  $y$  B<sub>2</sub> ise, o halde  $f_2 = p_2x + q_2y + r_2$

Beşinci katmandaki her düğüm, bir daire ile gösterilen ve  $\Sigma$  ile etiketlenen sabit bir düğümdür. Genel çıkış (3.98) ile hesaplanmaktadır:

$$O_{5,i} = \sum_i \bar{w}_i \cdot f_i = \frac{\sum_i w_i f_i}{w_i} = f \quad (3.98)$$

ANFIS'in en basit öğrenme kuralı, hata sinyallerini çıkış katmanından (Katman 5) geriye doğru giriş düğümlerine (Katman 1) özyinelemeli olarak hesaplayan geri yayılımadır. Bu öğrenme kuralı, yaygın ileri beslemeli sinir ağlarında kullanılan geri yayılma öğrenme kuralıyla tamamen aynıdır (Guillaume 2001). Bu yöntem bir ANFIS ağındaki parametreleri tanımlamak için uygulanabilmesine rağmen genellikle yavaştır ve lokal minimumda sıkışıp kalması olasıdır (Jang 1993). Hibrit öğrenme algoritması veya genetik algoritma gibi farklı öğrenme teknikleri bu eğitim problemini çözmek için kullanılabilir (Soto ve ark. 2016). Parametreleri optimize etmek için dereceli azalma yöntemi ve en küçük kareler yöntemini entegre eden hızlı bir hibrit öğrenme yöntemi kullanılarak ANFIS modellerinin daha iyi performansı gösterilmiştir (Guillaume 2001,

Soto ve ark. 2018). Bu nedenle bu tezde, önerilen ANFIS modelinde hibrit öğrenme yöntemi kullanılmıştır.

### 3.7. Tez Kapsamında Önerilen Modeller

Tez kapsamında iki farklı tarihe ait Radarsat-2 imgelerinden Oh (1992), Dubois (1995) ve Oh (2004) yarı deneysel modelleri ile birlikte LS-SVM, GRNN, ELM, KELM ve ANFIS makine öğrenmesi yöntemleri ile toprak nemi tahmin edilmiştir. Tahmin edilen toprak nemi ile yersel ölçülmüş toprak nemi arasındaki korelasyon tespit edilmeye çalışılmıştır. Bunun için özellik vektörü olarak kullanılmak üzere, Radarsat-2 imgelerinden elde edilen sigma geri saçılma katsayıları ve Freeman-Durden, Yamaguchi, van Zyl, Cloude ve Cloude-Pottier polarimetrik ayrıştırma bileşenleri elde edilmiştir.

Yarı deneysel modeller ile toprak nemi tahminini gerçekleştirmek için, PolSARpro yazılımının içerdiği yarı deneysel inversiyon modelleri kullanılmıştır. Oh (1992) modeline Radarsat-2 imgelerinden elde edilen  $\sigma_{HH}^0, \sigma_{HV}^0, \sigma_{VV}^0$  sigma geri saçılma katsayıları ve  $\theta$  lokal gelme açısı, Dubois (1995) modeline  $\sigma_{HH}^0, \sigma_{VV}^0$  ve  $\theta$  giriş olarak uygulanmıştır. Modeller ile toprağın dielektrik katsayısı tahmin edilmiş olup denklem (3.55) ile volümetrik toprak nemine dönüştürülmüştür. Oh (2004) modeline  $\sigma_{HH}^0, \sigma_{HV}^0, \sigma_{VV}^0$  ve  $\theta$  giriş olarak uygulanmış olup doğrudan toprak nemi tahmin edilmiştir. Oh (1992) ve Oh (2004) inversiyon modelleri Newton-Ralphson yöntemiyle iteratif olarak çözülmüştür. Oh (1992) modelinde Fresnel yansımaları elde etmek için başlangıç değeri 2, Oh (2004) modelinde ilk toprak nemi tahmini için 0.5 değeri kullanılmıştır.

Makine öğrenmesi modelleri için parametre seçimleri şöyledir. LS-SVM regresyon modelinde regülarizasyon katsayısı ve RBF kernel fonksiyonunun genişliği parametreleri simpleks algoritması ile optimize edilerek belirlenmiştir. Burada çapraz doğrulama için 10-katlı çapraz doğrulama tekniği kullanılmıştır. GRNN regresyon modelinde yayılma parametresi 1, ELM regresyon modelinde gizli nöron sayısı 20, aktivasyon fonksiyonu radyal tabanlı fonksiyon seçilmiştir. KELM regresyon modelinde gizli nöron sayısı 10, aktivasyon fonksiyonu kernel RBF, kernelin genişliği ise 1 olarak seçilmiştir. ANFIS modelinde ise MF sayısı 2 ve MF tipi olarak 'gbell' kullanılmıştır. Bu parametreler deneme yanılma yöntemi kullanılarak belirlenmiştir.



#### 4. BULGULAR VE TARTIŞMA

Bu bölümde, Radarsat-2 imgelerinden toprak nemi inversiyonunun bulguları sunulmaktadır. Bu amaçla iki farklı dönem için kullanılan yarı deneysel ve makine öğrenmesi modellerinin analiz sonuçları verilmiştir.


Radarsat-2 SAR verilerinden toprak neminin tahmininde kullanılacak sigma geri saçılma değerlerini ve polarimetrik ayrıştırma parametrelerini elde etmek için öncelikle ham Radarsat-2 imgesi ön işlemden geçirilmiştir. İmgelere uygulanan ön işlem adımları Bölüm 3.1.4.'te detaylı bir şekilde verilmiştir. Yersel toprak nemi ölçüm noktalarına karşılık gelen GPS verileri, ön işlemleri tamamlanan imgeye aktarılmıştır. Bir sonraki adımda yersel ölçüm noktası çevresinde imgenin 3x3 piksellerinden oluşan bir hücrenin ortalaması alınmıştır. Son aşamada ise ortalaması alınan hücrelerden sigma ve polarimetrik parametre değerleri çıkarılmıştır ve bu değerler kaydedilerek yarı deneysel ve makine öğrenmesi modelleri için giriş olarak kullanılmıştır. Radarsat-2 imgelerinden her bir yersel ölçüm noktası için çıkarılan özellikler şu şekildedir: 4 tane sigma geri saçılma katsayısı, 4 tane Yamaguchi ayrıştırma bileşeni, 3 tane van Zyl ayrıştırma bileşeni, 3 tane Freeman-Durden ayrıştırma bileşeni, 3 tane Cloude-Pottier ayrıştırma bileşeni ve 3 tane Cloude ayrıştırma bileşenine ait değerler. Bu işlemin sonunda her hücre için toplam 20 özellik oluşturulmuştur. Bu işlem 10 Haziran 2015 Radarsat-2 imgesindeki 272 ve 3 Mart 2016 imgesindeki 156 örnek noktası için tekrarlanmıştır. Polarimetrik ayrıştırma yöntemleri için imgelerden çıkarılan parametreler Çizelge 3.3.'te özetlenmiştir. Sigma ve polarimetrik ayrıştırma teknikleri kullanılarak her iki dönem için elde edilen ve çalışma alanını içine alan Radarsat-2 SAR verilerine ait RGB görüntüleri Şekil 4.1. – Şekil 4.12.'de verilmiştir.

Model tahminlerinin performans ölçümü, kare ortalamalarının karekökü hatası (RMSE) ile yapılmıştır. RMSE, bir model tarafından tahmin edilen değerler ile ölçülen değerler arasındaki farkı ölçmek için kullanılan yaygın bir araçtır. RMSE (4.1) ile verilen formül ile hesaplanmaktadır.


$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (e_i - m_i)^2} \quad (4.1)$$

#### 4. BULGULAR VE TARTIŞMA


Burada  $N$  örnek sayısı,  $m_i$  volümetrik toprak neminin  $i$ . örneğinin ölçülen değeri ve  $e_i$  örnek  $i$ 'nin tahmini değeridir. Ölçülen ve tahmin edilen toprak nem değerleri, volümetrik yüzde (vol. %) olarak ifade edilmiştir.




**Şekil 4.1.** Sigma tekniği kullanılarak türetilen ve çalışma alanını içeren ön işleme tamamlanmış 10 Haziran 2015 tarihli Radarsat-2 SAR verisine ait RGB görüntüsü (R=HH, G=HV ve B=HH/HV)




**Şekil 4.2.** Yamaguchi ayrıştırma tekniği kullanılarak türetilen ve çalışma alanını içeren ön işleme tamamlanmış 10 Haziran 2015 tarihli Radarsat-2 SAR verisine ait RGB görüntüsü (R=Çift sıçrama saçılması, G=Hacimsel saçılma ve B=Yüzey saçılması)




**Şekil 4.3.** van Zyl ayrıştırma tekniği kullanılarak türetilen ve çalışma alanını içeren ön işleme tamamlanmış 10 Haziran 2015 tarihli Radarsat-2 SAR verisine ait RGB görüntüsü (R=Çift sıçrama saçılması, G=Hacimsel saçılma ve B=Yüzey saçılması)




**Şekil 4.4.** Freeman-Durden ayrıştırma tekniği kullanılarak türetilen ve çalışma alanını içeren ön işleme tamamlanmış 10 Haziran 2015 tarihli Radarsat-2 SAR verisine ait RGB görüntüsü (R=Çift sıçrama saçılması, G=Hacimsel saçılma ve B=Yüzey saçılması)




**Şekil 4.5.** H/A/ $\alpha$  ayrıştırma tekniği kullanılarak türetilen ve çalışma alanını içeren ön işleme tamamlanmış 10 Haziran 2015 tarihli Radarsat-2 SAR verisine ait RGB görüntüsü (R=Entropi, G=Anizotropi ve B= $\alpha$ )




**Şekil 4.6.** Cloude ayrıştırma tekniği kullanılarak türetilen ve çalışma alanını içeren ön işleme tamamlanmış 10 Haziran 2015 tarihli Radarsat-2 SAR verisine ait RGB görüntüsü (R=Çift sıçrama saçılması, G=Hacimsel saçılma ve B=Yüzey saçılması)




**Şekil 4.7.** Sigma tekniği kullanılarak türetilen ve çalışma alanını içeren ön işleme tamamlanmış 3 Mart 2016 tarihli Radarsat-2 SAR verisine ait RGB görüntüsü (R=HH, G=HV ve B=HH/HV)




**Şekil 4.8.** Yamaguchi ayrıştırma tekniği kullanılarak türetilen ve çalışma alanını içeren ön işleme tamamlanmış 3 Mart 2016 tarihli Radarsat-2 SAR verisine ait RGB görüntüsü (R=Çift sıçrama saçılması, G=Hacimsel saçılma ve B=Yüzey saçılması)




**Şekil 4.9.** van Zyl ayrıştırma tekniği kullanılarak türetilen ve çalışma alanını içeren ön işlemi tamamlanmış 3 Mart 2016 tarihli Radarsat-2 SAR verisine ait RGB görüntüsü (R=Çift sıçrama saçılması, G=Hacimsel saçılma ve B=Yüzey saçılması)



**Şekil 4.10.** Freeman-Durden ayrıştırma tekniği kullanılarak türetilen ve çalışma alanını içeren ön işlemi tamamlanmış 3 Mart 2016 tarihli Radarsat-2 SAR verisine ait RGB görüntüsü (R=Çift sıçrama saçılması, G=Hacimsel saçılma ve B=Yüzey saçılması)



**Şekil 4.11.** H/A/ $\alpha$  ayrıştırma tekniği kullanılarak türetilen ve çalışma alanını içeren ön işlemi tamamlanmış 3 Mart 2016 tarihli Radarsat-2 SAR verisine ait RGB görüntüsü (R=Entropi, G=Anizotropi ve B= $\alpha$ )



**Şekil 4.12.** Cloude ayrıştırma tekniği kullanılarak türetilen ve çalışma alanını içeren ön işlemi tamamlanmış 3 Mart 2016 tarihli Radarsat-2 SAR verisine ait RGB görüntüsü (R=Çift sıçrama saçılması, G=Hacimsel saçılma ve B=Yüzey saçılması)


#### 4. BULGULAR VE TARTIŞMA

---

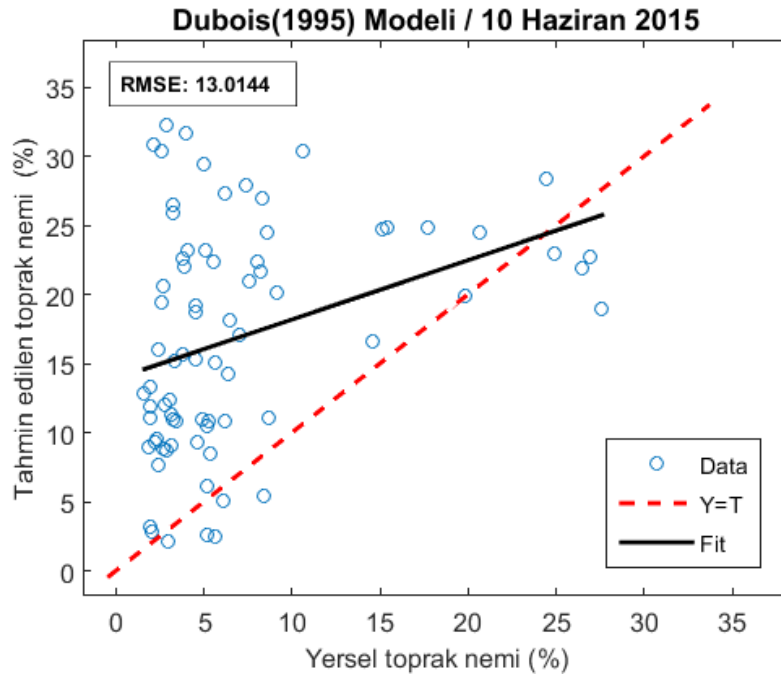
Yarı deneysel Oh (1992), Dubois (1995) ve Oh (2004) modelleri yüzey toprak nem içeriğini elde etmek için kullanılmıştır. Bu yarı deneysel modeller teorik modeller kadar karmaşık olmayıp deneysel modeller kadar basit de değildir. Yarı deneysel modeller ile toprak nemi inversiyonları, bu modeller için PolSARpro yazılımının içerdiği kaynak kodu kullanılarak ön işleme tamamlanmış imgelere uygulanarak hesaplanmıştır. PolSARpro, Avrupa Uzay Ajansı (ESA) tarafından oluşturulan açık kaynak SAR analiz yazılımıdır. Bu üç yüzey inversiyon modelleri için oluşturulan kaynak kodları, dielektrik sabiti ve volümetrik toprak nemini tahmin etmek için kullanılmıştır. Oh (1992) ve Dubois (1995) modelleri dielektrik sabitini tahmin etmektedir. Oh (2004) modeli ise doğrudan volümetrik toprak nemini tahmin etmektedir.

Yarı deneysel modellerin doğruluğu örneğin, Dubois (1995) modeli kullanılarak 10 Haziran 2015 verisi için RMSE değeri 13.01 ve Oh (1992) modeli kullanılarak 3 Mart 2016 verisi için RMSE değeri 22.93 olarak elde edilmiştir. Şekil 4.13. – Şekil 4.18.’de verilen saçılma grafikleri, sırasıyla 10 Haziran 2015 Radarsat-2 verileri için Oh (1992), Dubois (1995) ve Oh (2004) modelleri ve 3 Mart 2016 Radarsat-2 verileri için Oh (1992), Dubois (1995) ve Oh (2004) modelleri ile tahmin edilen ve yersel (ölçülen) toprak nemi arasındaki ilişkiyi göstermektedir. 10 Haziran 2015 Radarsat-2 verileri için Oh (1992), Dubois (1995) ve Oh (2004) modelleri ile tahmin edilen ve yersel toprak nemi arasındaki  $r$  (korelasyon katsayısı) değeri sırasıyla 0.06, 0.34 ve 0.30’dur. 3 Mart 2016 Radarsat-2 verileri için Oh (1992), Dubois (1995) ve Oh (2004) modelleri ile tahmin edilen ve yersel toprak nemi arasındaki  $r$  değeri sırasıyla 0.42, 0.05 ve 0.08’dir. Her iki dönem için tüm yarı deneysel modeller ile elde edilen sonuçlar Şekil 4.19.’da sunulmuştur.

10 Haziran 2015 ve 3 Mart 2016 tarihli veri setleri için yarı deneysel yaklaşımla yapılan toprak nem tahminlerinin çoğunun modellerin geçerlilik aralıklarının dışında kaldığı görülmektedir. Oh (1992), Dubois (1995) ve Oh (2004) ile 10 Haziran 2015 veri seti için yapılan toprak nemi tahminlerinde sırasıyla 74, 74 ve 11 tahmin ve 3 Mart 2016 veri seti için 54, 106, 16 tahmin model geçerlilik aralıklarında yer almaktadır.

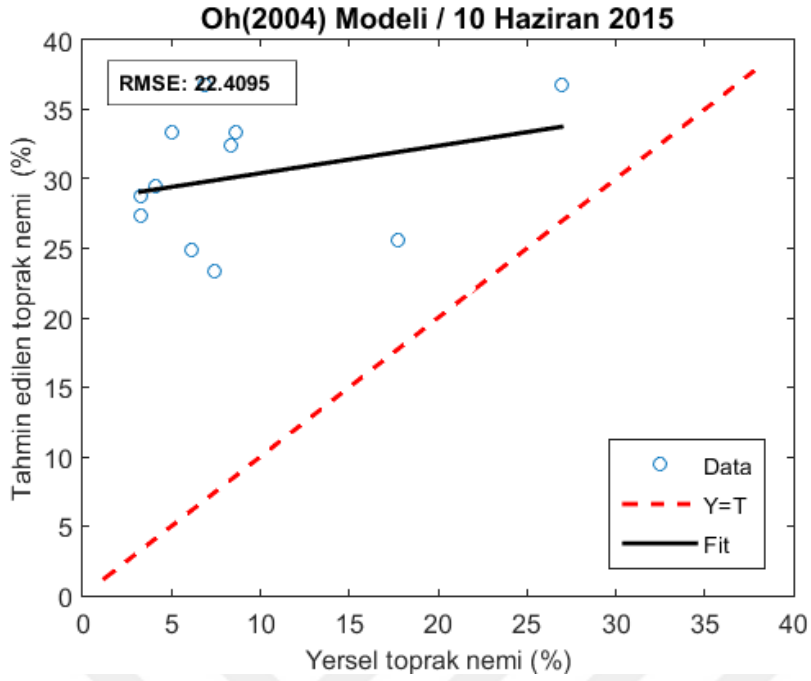


**Şekil 4.13.** Oh (1992) yarı deneysel modeli ile 10 Haziran 2015 Radarsat-2 verilerinden toprak nemi inversiyonu

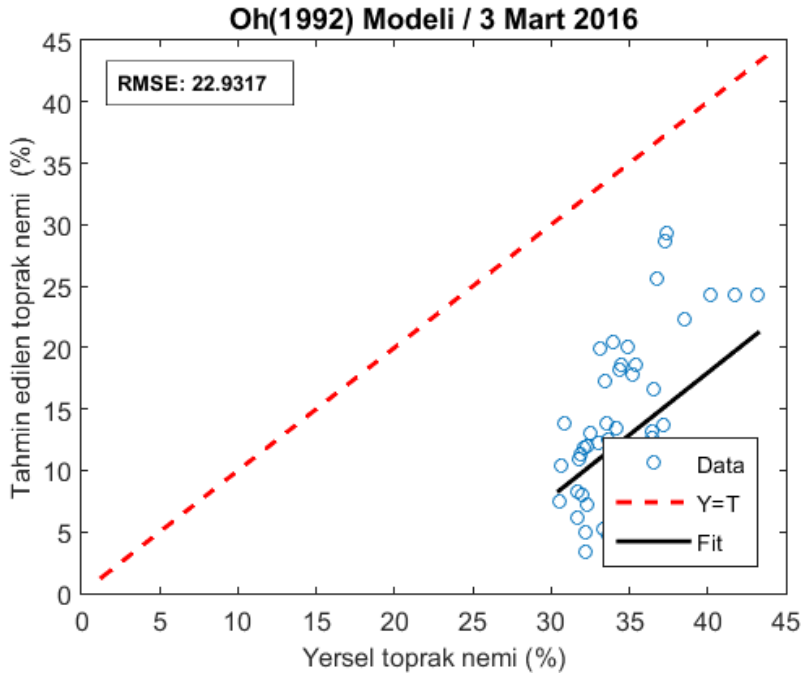


**Şekil 4.14.** Dubois (1995) yarı deneysel modeli ile 10 Haziran 2015 Radarsat-2 verilerinden toprak nemi inversiyonu


#### 4. BULGULAR VE TARTIŞMA



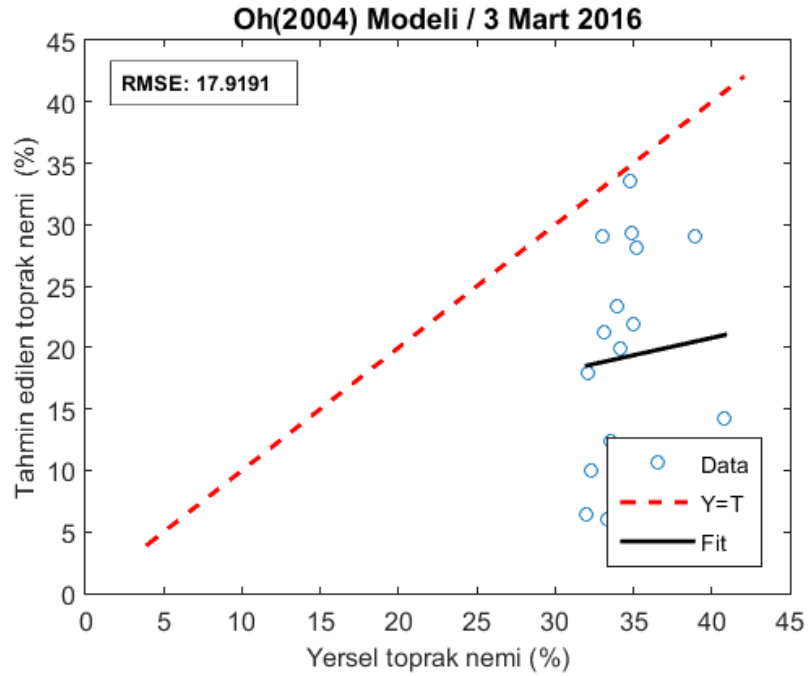
**Şekil 4.15.** Oh (2004) yarı deneysel modeli ile 10 Haziran 2015 Radarsat-2 verilerinden toprak nemi inversiyonu



**Şekil 4.16.** Oh (1992) yarı deneysel modeli ile 3 Mart 2016 Radarsat-2 verilerinden toprak nemi inversiyonu

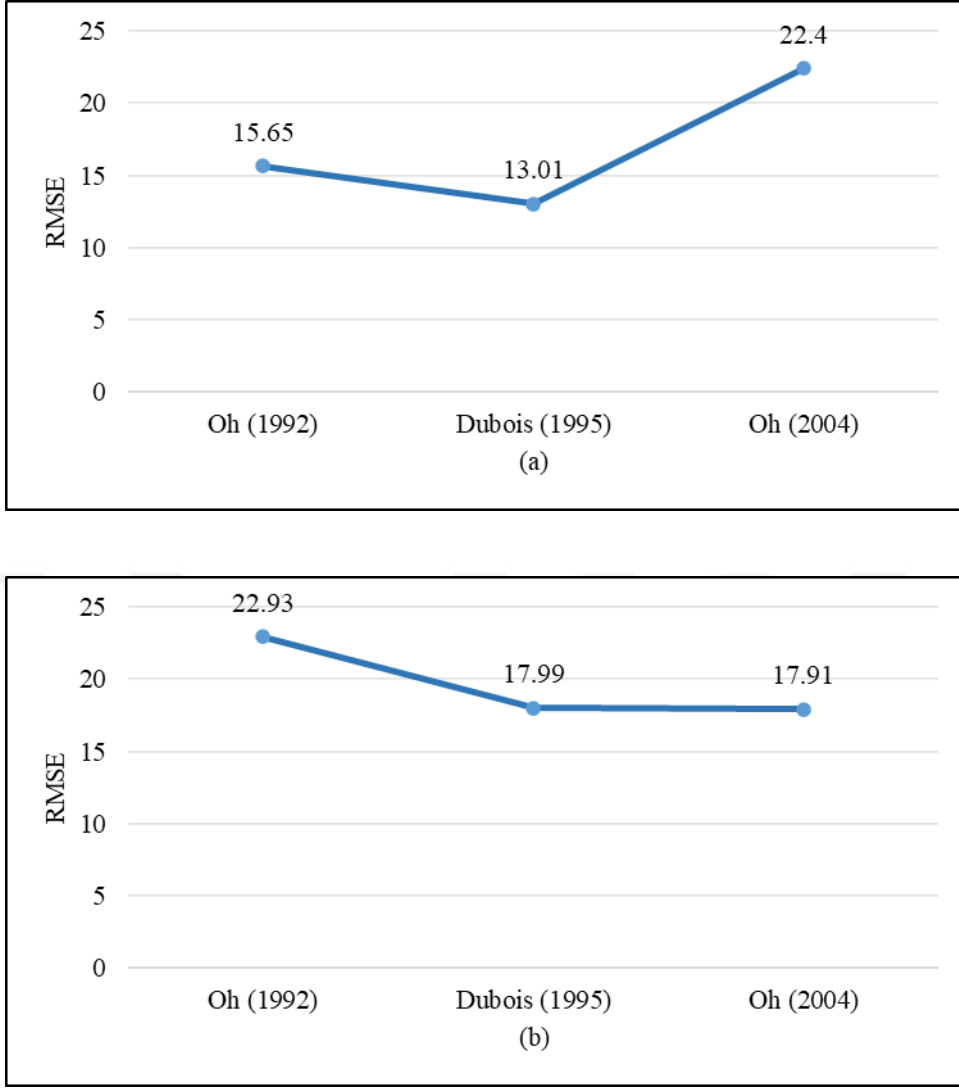


**Şekil 4.17.** Dubois (1995) yarı deneysel modeli ile 3 Mart 2016 Radarsat-2 verilerinden toprak nemi inversiyonu



**Şekil 4.18.** Oh (2004) yarı deneysel modeli ile 3 Mart 2016 Radarsat-2 verilerinden toprak nemi inversiyonu

#### 4. BULGULAR VE TARTIŞMA




**Şekil 4.19.** Yarı deneysel modeller kullanılarak toprak nemi inversiyonu (a) 10 Haziran 2015 Radarsat-2 verileri, (b) 3 Mart 2016 Radarsat-2 verileri

Makine öğrenmesi yaklaşımında, toprak neminin inversiyonu LS-SVM, GRNN, ELM, KELM ve ANFIS olmak üzere 5 farklı yöntem kullanılarak gerçekleştirilmiştir. Bu yöntemlerin başarısını hesaplamak için eğitim ve test setleri oluşturulmuştur. Yersel toprak nemi ölçümleri, makine öğrenmesi yöntemleri için hedef vektör olarak tanımlanmıştır. Test aşamasında, sistemin başarısını doğrulamak için 10-katlı çapraz doğrulama yöntemi kullanılmıştır. k-katlı çapraz doğrulama yönteminde, veri seti rastgele k parçaya bölünür (Sengur 2009). Her seferinde, bu veri setinin bir parçası test için kullanılırken geri kalanı eğitim için kullanılmaktadır. k deneme sonunda verinin her bir


parçası test için kullanılır ve sistemin doğruluğu tüm veri parçaları için elde edilen hatanın ortalaması olarak hesaplanmaktadır.

Makine öğrenmesi modelleri ile tahmin edilen toprak nemi değerleri ile ölçülen yersel toprak nem değerleri arasındaki ilişki Şekil 4.20. - Şekil 4.29.'da verilen örnek saçılma grafikleri ile gösterilmiştir. 10 Haziran 2015 tarihli Radarsat-2 imgesinden elde edilen özellik vektörleri (sigma, Yamaguchi, Freeman-Durden, van Zyl, H/A/α ve Cloude) için makine öğrenmesi yöntemleri kapsamında tahmin edilen toprak nem değerleri ile ölçülen yersel toprak nem değerleri arasındaki korelasyon değerleri; sigma için 0.49 – 0.60, Yamaguchi için 0.58 – 0.72, Freeman-Durden için 0.77 – 0.81, van Zyl için 0.51 – 0.60, H/A/α için 0.11 – 0.26 ve Cloude için 0.39 – 0.48 arasındadır. 3 Mart 2016 tarihli Radarsat-2 imgesinden elde edilen özellik vektörleri (sigma, Yamaguchi, Freeman-Durden, van Zyl, H/A/α ve Cloude) için makine öğrenmesi yöntemleri kapsamında tahmin edilen toprak nemi değerleri ile ölçülen yersel toprak nem değerleri arasındaki korelasyon değerleri; sigma için 0.19 – 0.56, Yamaguchi için 0.25 – 0.53, Freeman-Durden için 0.14 – 0.55, van Zyl için 0.17 – 0.52, H/A/α için 0.02 – 0.13 ve Cloude için 0.13 – 0.53 arasındadır.


Makine öğrenmesi modellerinin doğruluğu, örneğin LS-SVM modeli kullanılarak 10 Haziran 2015 verisindeki tüm örnekler için RMSE değeri 4.89 ve 3 Mart 2016 verisi için RMSE değeri 3.13 olarak elde edilmiştir. Bu model, giriş olarak Yamaguchi ayrıştırma katsayılarını içeren veri seti ile eğitilmiştir. Çalışmamızda kullanılan makine öğrenmesi yaklaşımları arasında LS-SVM, GRNN, ELM ve KELM genellikle her iki dönem için de en iyi RMSE sonuçlarını vermiştir. ANFIS modeli ile RMSE değerleri çoğunlukla daha yüksek elde edilmiştir. Her iki dönem için giriş olarak farklı özellik vektörlerini kullanan tüm makine öğrenme modelleri için hesaplanan RMSE değerleri Şekil 4.30. ve Şekil 4.31.'de sunulmuştur.




**Şekil 4.20.** 10 Haziran 2015 tarihli tüm örnekler için sigma geri saçılma katsayılarından oluşan özellik vektörünü kullanan GRNN makine öğrenmesi yöntemi ile toprak nemi inversiyonu




**Şekil 4.21.** 10 Haziran 2015 tarihli tüm örnekler için Yamaguchi ayrıştırma bileşenlerinden oluşan özellik vektörünü kullanan LS-SVM makine öğrenmesi yöntemi ile toprak nemi inversiyonu




**Şekil 4.22.** 10 Haziran 2015 tarihli tüm örnekler için Freeman-Durden ayrıştırma bileşenlerinden oluşan özellik vektörünü kullanan ELM makine öğrenmesi yöntemi ile toprak nemi inversiyonu




**Şekil 4.23.** 10 Haziran 2015 tarihli tüm örnekler için van Zyl ayrıştırma bileşenlerinden oluşan özellik vektörünü kullanan KELM makine öğrenmesi yöntemi ile toprak nemi inversiyonu




**Şekil 4.24.** 10 Haziran 2015 tarihli tüm örnekler için H/A/a ayrıştırma bileşenlerinden oluşan özellik vektörünü kullanan ANFIS makine öğrenmesi yöntemi ile toprak nemi inversiyonu




**Şekil 4.25.** 3 Mart 2016 tarihli tüm örnekler için sigma geri saçılma katsayılarından oluşan özellik vektörünü kullanan GRNN makine öğrenmesi yöntemi ile toprak nemi inversiyonu




**Şekil 4.26.** 3 Mart 2016 tarihli tüm örnekler için Yamaguchi ayrıştırma bileşenlerinden oluşan özellik vektörünü kullanan LS-SVM makine öğrenme yöntemi ile toprak nemi inversiyonu




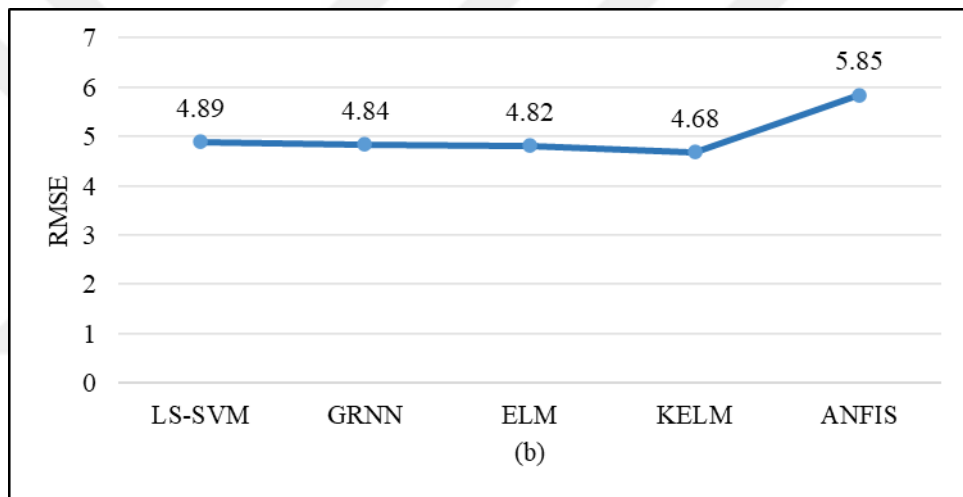

**Şekil 4.27.** 3 Mart 2016 tarihli tüm örnekler için Freeman-Durden ayrıştırma bileşenlerinden oluşan özellik vektörünü kullanan ELM makine öğrenme yöntemi ile toprak nemi inversiyonu




Şekil 4.28. 3 Mart 2016 tarihli tüm örnekler için van Zyl ayrıştırma bileşenlerinden oluşan özellik vektörünü kullanan KELM makine öğrenme yöntemi ile toprak nemi inversiyonu






Şekil 4.29. 3 Mart 2016 tarihli tüm örnekler için H/A/ $\alpha$  ayrıştırma bileşenlerinden oluşan özellik vektörünü kullanan ANFIS makine öğrenme yöntemi ile toprak nemi inversiyonu



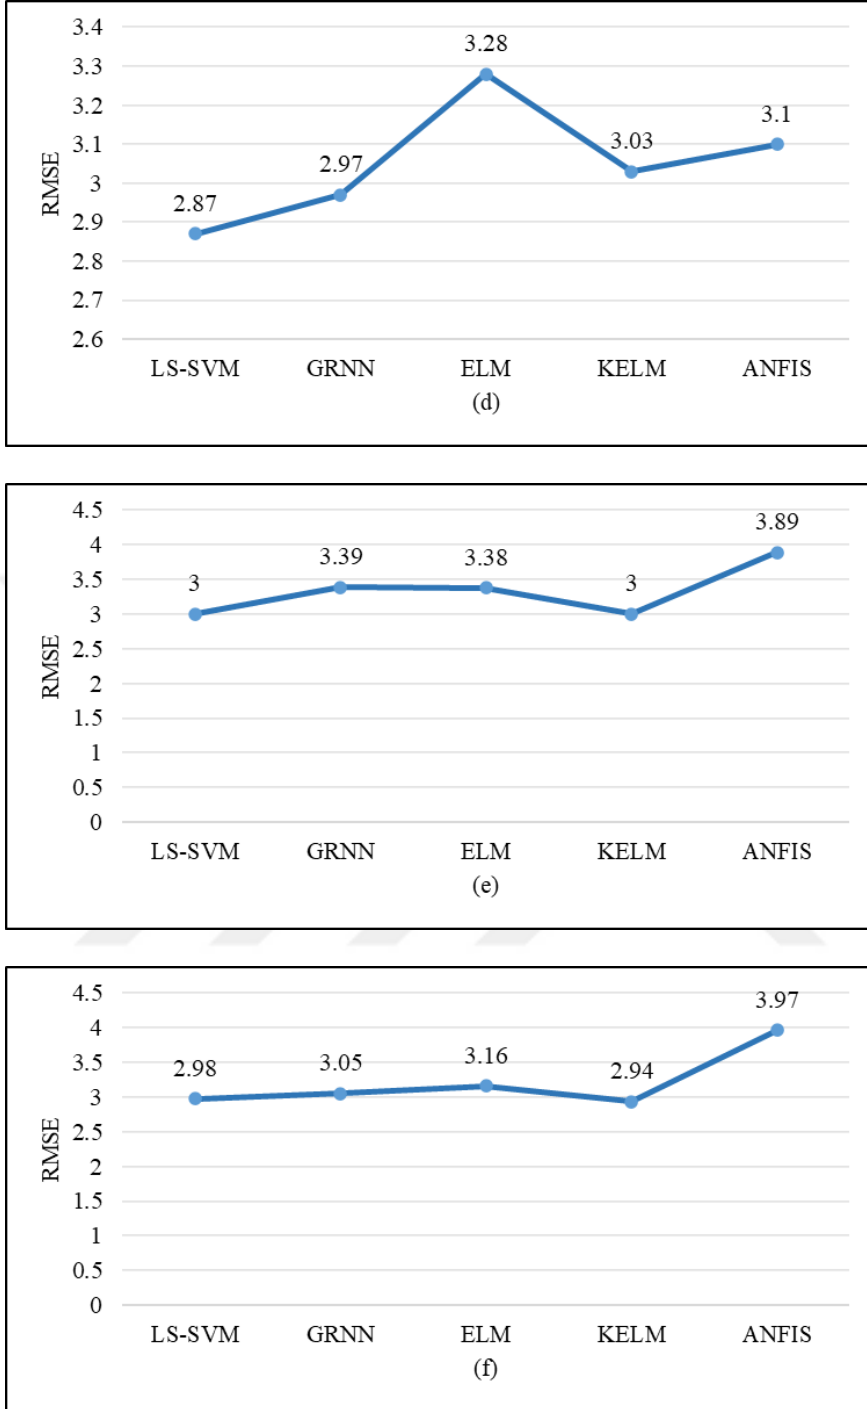
#### 4. BULGULAR VE TARTIŞMA



**Şekil 4.30.** 10 Haziran 2015 tarihli imgeden makine öğrenmesi modellerini kullanarak toprak nem inversiyonunun hesaplanan RMSE değerleri. Özellik vektörü olarak (a) Sigma değerleri, (b) Yamaguchi ayrıştırma bileşenleri, (c) Genelleştirilmiş Freeman-Durden ayrıştırma bileşenleri (d) van Zyl ayrıştırma bileşenleri, (e) Cloude ayrıştırma bileşenleri, (f) H/A/ $\alpha$  ayrıştırma bileşenleri kullanılmıştır



#### 4. BULGULAR VE TARTIŞMA



**Şekil 4.31.** 3 Mart 2016 tarihli imgeden makine öğrenmesi modellerini kullanarak toprak nem inversiyonunun hesaplanan RMSE değerleri. Özellik vektörü olarak (a) Sigma değerleri, (b) Yamaguchi ayrıştırma bileşenleri, (c) Genelleştirilmiş Freeman-Durden ayrıştırma bileşenleri (d) van Zyl ayrıştırma bileşenleri, (e) Cloude ayrıştırma bileşenleri, (f) H/A/ $\alpha$  ayrıştırma bileşenleri kullanılmıştır

Oh (1992), Dubois (1995) ve Oh (2004) yarı deneysel modelleri için yüksek RMSE değerleri hesaplanmıştır. Ayrıca, bu modellerle 10 Haziran 2015 Radarsat-2 imgesinden toprak nem tahmini için genel olarak daha yüksek tahminler üretilirken, 3 Mart 2016 Radarsat-2 imgesi için daha düşük tahmin sonuçları üretilmiştir. Yarı deneysel modeller ile yapılan toprak nem tahminleri, yersel toprak nemi ölçümlerinden büyük ölçüde sapma göstermiştir. Bu nedenle, model tahminleri ile yersel ölçümler arasındaki korelasyon çok düşük olarak elde edilmiştir. Bu sonuçların çoğunun istatistiksel olarak anlamsız olduğu saptanmıştır.

Tüm sonuçlar karşılaştırıldığında, toprak neminin yarı deneysel modellerle inversiyonu, makine öğrenmesi yaklaşımından çok daha kötü sonuçlar vermiştir. Bunun nedeni, çalışma alanına ilişkin yüzeyinin bitki örtüsü ile kaplı olması olabilir (Liu ve ark. 2019). Ayrıca yarı deneysel modellerle toprak nemini tahmin etmek için toprak nemi, radar geliş açısı ve yüzey pürüzlülüğü parametrelerinin model geçerlilik aralıklarında olması gerekmektedir, aksi takdirde yarı deneysel modeller doğru sonuçlar üretmez ve bu da yarı deneysel modellerin kullanımını kısıtlamaktadır.

Makine öğrenmesi yaklaşımı, toprak nemi inversiyonu için yarı deneysel modellerden daha iyi sonuçlar vermesine rağmen, bazı dezavantajları vardır. Makine öğrenmesi yaklaşımının temel dezavantajlarından biri, sonuçların kabul edilebilir doğruluğu için çok sayıda örnek toplamaya ihtiyaç duymasıdır. Bu çalışmada kullanılan makine öğrenmesi yöntemlerine bakıldığında, modelin eğitimi sırasında GRNN, ELM ve KELM yöntemlerinin LS-SVM ve ANFIS yöntemlerinden çok daha hızlı olduğu tespit edilmiştir.

Farklı yaklaşımlarla toprak neminin inversiyonu ile ilgili diğer birçok literatür çalışması Çizelge 4.1.'de verilmiştir. Bu çalışmada önerilen modellerin de literatürdeki diğer çalışmalara göre iyi sonuçlar verdiği söylenebilir.

#### 4. BULGULAR VE TARTIŞMA

**Çizelge 4.1.** Toprak neminin inversiyonu için kullanılan farklı yaklaşımların karşılaştırılması

<b>Kaynak</b>	<b>Alan</b>	<b>Veri seti</b>	<b>Performans</b>	<b>Yöntem</b>
<b>Önerilen Yöntem</b>	Yalın ve Bitki örtülü arazi	Radarsat-2 verisi ve yersel ölçümler	Yarı deneysel yöntemler için RMSE = 13.01, Makine öğrenmesi için RMSE = 2.72	Yarı deneysel yöntemler, Polarimetrik ayrıştırma, Makine öğrenmesi
<b>Senyurek ve ark. (2020)</b>	Bitki örtülü arazi	CYGNSS verisi ve yersel ölçümler	RMSE = 5.12	Makine öğrenmesi tabanlı algoritma
<b>Satalino ve ark. (2002)</b>	Yalın toprak	ERS-SAR ve yersel ölçümler	RMSE = 6	YSA
<b>Wang ve ark. (2016)</b>	Bitki örtülü arazi	UAVSAR ve SMAP verileri	RMSE = 6 –12	Polarimetrik ayrıştırma
<b>Baghdadi ve ark. (2012)</b>	Yalın toprak	Radarsat-2 ve IEM verileri	RMSE = 6.5 – 9.8	YSA
<b>Xie ve ark. (2017)</b>	Bitki örtülü arazi	Radarsat-2 ve yersel ölçümler	RMSE = 1.76 – 2.81	Polarimetrik ayrıştırma, Bragg, X-Bragg, ISSM
<b>Zhang ve ark. (2016)</b>	Yalın toprak	TerraSAR-X, Radarsat-2 ve yersel ölçümler	RMSE = 2.2 – 3	SVR, Modifiye Dubois modeli
<b>Lakhankar ve ark. (2009)</b>	Yalın ve Bitki Örtülü arazi	Landsat, Radarsat-1 ve yersel ölçümler	RMSE = 3.39 – 8.29	Çoklu regresyon, Sinir Ağları, Bulanık mantık
<b>Pasolli ve ark. (2012)</b>	Bitki örtülü arazi	Radarsat-2 verisi ve yersel ölçümler	RMSE = 4.85	SVR, Polarimetrik ayrıştırma
<b>Xing ve ark. (2019)</b>	Bitki örtülü arazi	Radarsat-2 ve yersel ölçümler	RMSE = 4.43	Modifiye Su Bulutu Modeli (MWCM)

## 5. SONUÇLAR ve ÖNERİLER

Tarım, hidroloji ve iklim çalışmaları gibi birçok uygulamada toprak neminin çok önemli bir parametre olduğu kabul edilmekle birlikte, toprak neminin doğru ve hassas uzamsal tahminlerinin gerekli olduğu görülmektedir.

Toprak nemini belirlemek için kullanılan geleneksel ölçüm yöntemlerinin maliyetinin yüksek olması ve düz homojen arazilerde bile toprak neminin yüksek lokal mekânsal değişkenliği nedeniyle dağılımını yeterince karakterize etmek için çok sayıda alan örneği gerektiği bilinmektedir. Bu lojistik kısıtlama, radar gibi uzaktan algılama teknolojileri ile elde edilen iyi çözünürlüğe sahip imgeler kullanılarak çözülebileceği yapılan çalışmalardan görülmektedir. Ayrıca uzaktan algılama sensörleri, yüksek çözünürlük sağlamaları, hava şartlarından etkilenmemeleri ve toprak nemine olan duyarlılıkları nedeniyle büyük ölçekli toprak nem tahmini için uygundur. Literatürde farklı sahaların yalın ve bitki örtülü yüzeyleri için toprak nem tahminlerinde hem uzaktan algılama ve hem de yersel ölçümler çerçevesinde çeşitli yöntemler kullanılarak belirlenmeye çalışılmıştır. Bu çalışmalara ek bir saha çalışması katarak, düşünülen kavramların desteklemek amacıyla bu tez çalışması gerçekleştirilmiştir. Bu tez çalışmasında, Radarsat-2 SAR imgelerinden elde edilen özellikler kullanılarak yarı deneysel ve makine öğrenmesi modellerinin toprak nemi tahmin performansı değerlendirilmiştir.

Tez kapsamında yapılan çalışmalar sonucunda elde edilen bulgular aşağıda listelenmiştir:

- 1) Elde edilen sonuçlar, makine öğrenmesi modellerinin toprak neminin inversiyonu için yarı deneysel modellere kıyasla çok daha iyi performansa sahip olduğunu göstermiştir. Çünkü yarı deneysel modeller toprak nemi, radar geliş açısı ve yüzey pürüzlülüğü parametrelerine bağlı olarak sadece model geçerlilik aralıklarında doğru sonuçlar vermektedir. Dolayısıyla bu durum yarı deneysel modellerin kullanım alanını sınırlamaktadır.
- 2) Bu çalışmada kullanılan makine öğrenmesi yöntemleri göz önüne alındığında modellerin eğitimi aşamasında GRNN, ELM ve KELM yöntemlerinin LS-

## 5. SONUÇ VE ÖNERİLER

---

SVM ve ANFIS yöntemlerine göre çok daha az hesaplama süresine sahip olduğu saptanmıştır.

- 3) SAR uzaktan algılama verilerinden toprak neminin elde edilmesi için makine öğrenmesi yaklaşımının hızlı ve kabul edilebilir doğrulukla uygulanabileceği saptanmıştır.
- 4) Nem tahmin çalışmasının yarı deneysel nem tahmin modelleri ve farklı makine öğrenme modelleri ile gerçekleştirilmesi, literatürde öncü bir çalışma olarak görülebilir.
- 5) SAR imgesinden elde edilen farklı polarimetrik ayrıştırma katsayılarının, makine öğrenmesi modellerinin eğitiminde kullanılması, konuya farklı bir bakış açısı kazandırdığı şeklinde değerlendirilebilir.
- 6) Önerilen yaklaşım ile ön işlemi tamamlanmış Radarsat-2 imgesinden elde edilen Yamaguchi polarimetrik ayrıştırma katsayıları, toprak nemini tahmin etmek için ilk kez kullanılmıştır ve elde edilen başarımın kabul edilebilir sınırlar içinde olduğu saptanmıştır.
- 7) Tezde gerçekleştirilen yazılımların yeniden kodlanmış olması, özgün bir çalışmanın gerçekleştirildiği olarak kabul edilebilir.

Bu çalışmanın sonucu olarak yapılabilecek çalışmalar ve öneriler aşağıda listelenmiştir:

- 1) Önerilen yaklaşımı iyileştirmek için aktif ve pasif sensör verileri ve daha fazla yersel ölçümlerin kombinasyonu ile toprak nemi inversiyonu için kapsamlı bir analiz yapılabilecektir.
- 2) Bu çalışmada elde edilen özellik vektörlerinin farklı kombinasyonları, makine öğrenmesi yöntemlerinin eğitilmesi için kullanılabilir.
- 3) Özellik seçme yöntemleri kullanılarak özellik vektörleri yeniden oluşturulabilir ve elde edilen özellik vektörlerinin makine öğrenmesi yöntemlerinin performansına etkisi analiz edilebilir.

## 6. KAYNAKLAR

- Acar, E. 2017. Dicle nehri havzasında toprak nem ölçümleri ile SAR imgeleri arasındaki ilişkiyi saptama ve bu ilişkiye dayalı toprak neminin tahmini, Doktora tezi, Dicle Üniversitesi Fen Bilimleri Enstitüsü, Diyarbakır. 121.
- Ahmad, S., Kalra, A., Stephen, H. 2010. Estimating soil moisture using remote sensing data: A machine learning approach. *Advances in Water Resources*, 33(1), 69-80.
- Álvarez-Mozos, J., Verhoest, N. E. C., Larrañaga, A., Casali, J., González-Audícana, M. 2009. Influence of surface roughness spatial variability and temporal dynamics on the retrieval of soil moisture from SAR observations. *Sensors*, 9(1), 463-489.
- Anonim, 2020. Synthetic aperture radar: Land applications tutorial part 1: Background and theory. Erişim: [[https://earth.esa.int/documents/10174/2700124/sar\\_land\\_apps\\_1\\_theory.pdf](https://earth.esa.int/documents/10174/2700124/sar_land_apps_1_theory.pdf)]. Erişim Tarihi : 08.11.2020
- Baghdadi, N., Cresson, R., El Hajj, M., Ludwig, R., La Jeunesse, I. 2012. Estimation of soil parameters over bare agriculture areas from C-band polarimetric SAR data using neural networks. *Hydrology and Earth System Sciences*, 16(6), 1607-1621.
- Baghdadi, N., Gaultier, S., King, C. 2002. Retrieving surface roughness and soil moisture from synthetic aperture radar (SAR) data using neural networks. *Canadian Journal of Remote Sensing*, 28(5), 701-711.
- Baghdadi, N., Zribi, M. 2006. Evaluation of radar backscatter models IEM, OH and Dubois using experimental observations. *International Journal of Remote Sensing*, 27(18), 3831-3852.
- Behari, J. 2006. Microwave dielectric behaviour of wet soils (Vol. 8). Springer Science & Business Media.
- Ben-Dor, E., Patkin, K., Banin, A., Karnieli, A. 2002. Mapping of several soil properties using DAIS-7915 hyperspectral scanner data - A case study over soils in Israel. *International Journal of Remote Sensing*, 23(6), 1043-1062.
- Brocca, L., Ciabatta, L., Massari, C., Camici, S., Tarpanelli, A. 2017. Soil moisture for hydrological applications: Open questions and new opportunities. *Water*, 9, 140.
- Bruckler, L., Witono, H., Stengel, P. 1988. Near surface soil moisture estimation from microwave measurements. *Remote Sensing of Environment*, 26(2), 101-121.
- Ceryan, N., Okkan, U., Samui, P., Ceryan, S. 2013. Modeling of tensile strength of rocks materials based on support vector machines approaches. *International Journal for Numerical and Analytical Methods in Geomechanics*, 37(16), 2655-2670.
- Chanasyk, D. S., Naeth, M. A. 1996. Field measurement of soil moisture using neutron probes. *Canadian Journal of Soil Science*, 76(3), 317-323.
- Chen, F., Crow, W. T., Starks, P. J., Moriasi, D. N. 2011. Improving hydrologic predictions of a catchment model via assimilation of surface soil moisture. *Advances in Water Resources*, 34(4), 526-536.

- Chen, K. S., Wu, T. D., Tsang, L., Li, Q., Shi, J., Fung, A. K. 2003. Emission of rough surfaces calculated by the integral equation method with comparison to three-dimensional moment method simulations. *IEEE Transactions on Geoscience and Remote Sensing*, 41(1), 90-101.
- Chen, K. S., Yen, S. K., Huang, W. P. 1995. A simple model for retrieving bare soil moisture from radar-scattering coefficients. *Remote Sensing of Environment*, 54(2), 121-126.
- Claps, P., Laguardia, G. 2004. Assessing spatial variability of soil water content through thermal inertia and NDVI. *Remote Sensing for Agriculture, Ecosystems, and Hydrology V*, 5232, 378.
- Cloude, S. R. 1992. Uniqueness of Target Decomposition Theorems in Radar Polarimetry. Editörler: Boerner, W. M., Brand, H., Cram, L. A., Holm, W. A., Stein, D. E., Wiesbeck, W., Keydel, W., Giuli, D., Gjessing, D. T., Molinet, F. A., *Direct and Inverse Methods in Radar Polarimetry*, 267-296, Springer, Netherlands.
- Cloude, S. R., Pottier, E. 1997. An entropy based classification scheme for land applications of polarimetric SAR. *IEEE Transactions on Geoscience and Remote Sensing*, 35(1), 68-78.
- Dalton, F. N., Van Genuchten, M. T. 1986. The time-domain reflectometry method for measuring soil water content and salinity. *Geoderma*, 38(1-4), 237-250.
- Dasari, K., Lokam, A., Jayasri, P. V. 2016. A Study on Utilization of Polarimetric SAR Data in Planning a Smart City. *Procedia Computer Science*, 93(September), 967-974.
- Dawson, M. S., Fung, A. K., Manry, M. T. 1997. A robust statistical-based estimator for soil moisture retrieval from radar measurements. *IEEE Transactions on Geoscience and Remote Sensing*, 35(1), 57-67.
- Dean, T. J., Bell, J. P., Baty, A. J. B. 1987. Soil moisture measurement by an improved capacitance technique, Part I. Sensor design and performance. *Journal of Hydrology*, 93(1-2), 67-78.
- Dobson, M. C., Ulaby, F. T. 1986. Active Microwave Soil Moisture Research. *IEEE Transactions on Geoscience and Remote Sensing*, GE-24(1), 23-36.
- Dubois, P. C., van Zyl, J., Engman, T. 1995. Measuring soil moisture with imaging radars. *IEEE Transactions on Geoscience and Remote Sensing*, 33(4), 915-926.
- Dubois, P. C., van Zyl, J. 1994. Empirical soil moisture estimation algorithm using imaging radar. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 3, 1573-1575.
- Durbha, S. S., King, R. L., Younan, N. H. 2007. Support vector machines regression for retrieval of leaf area index from multiangle imaging spectroradiometer. *Remote Sensing of Environment*, 107(1-2), 348-361.
- Ezzahar, J., Ouaadi, N., Zribi, M., Elfarkh, J., Aouade, G., Khabba, S., Er-Raki, S., Chehbouni, A., Jarlan, L. 2020. Evaluation of backscattering models and support vector machine for the retrieval of bare soil moisture from sentinel-1 data. *Remote Sensing*, 12(1), 1-20.

- Fung, A. K., Li, Z., Chen, K. S. 1992. Backscattering from a randomly rough dielectric surface. *IEEE Transactions on Geoscience and Remote Sensing*, 30(2), 356-369.
- Gillies, R. R., Carlson, T. N., Cui, J., Kustas, W. P., Humes, K. S. 1997. A verification of the “triangle” method for obtaining surface soil water content and energy fluxes from remote measurements of the normalized difference vegetation index (NDVI) and surface  $\epsilon$ . *International Journal of Remote Sensing*, 18(15), 3145-3166.
- Guillaume, S. 2001. Designing fuzzy inference systems from data: An interpretability-oriented review. *IEEE Transactions on Fuzzy Systems*, 9(3), 426-443.
- Hajnsek, I., Jagdhuber, T., Schön, H., Papathanassiou, K. P. 2009. Potential of estimating soil moisture under vegetation cover by means of PolSAR. *IEEE Transactions on Geoscience and Remote Sensing*, 47(2), 442-454.
- Hallikainen, M. T., Ulaby, F. T., Dobson, M. C., El-Rayes, M. A., Wu, L. K. 1985. Microwave Dielectric Behavior of Wet Soil-Part I: Empirical Models and Experimental Observations. *IEEE Transactions on Geoscience and Remote Sensing*, GE-23(1), 25-34.
- Haubrock, S. N. 2008. Surface soil moisture quantification and validation based on hyperspectral data and field measurements. *Journal of Applied Remote Sensing*, 2(1), 1-26.
- Huang, G. B., Zhu, Q. Y., Siew, C. K. 2006. Extreme learning machine: Theory and applications. *Neurocomputing*, 70(1-3), 489-501.
- Huang, S., Tsang, L., Njoku, E. G., Chan, K. S. 2010. Backscattering coefficients, coherent reflectivities, and emissivities of randomly rough soil surfaces at L-band for SMAP applications based on numerical solutions of maxwell equations in three-dimensional simulations. *IEEE Transactions on Geoscience and Remote Sensing*, 48(6), 2557–2568.
- Huang, X., Wang, J., Shang, J. 2016. An Integrated Surface Parameter Inversion Scheme over Agricultural Fields at Early Growing Stages by Means of C-Band Polarimetric RADARSAT-2 Imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 54(5), 2510-2528.
- Jackson, T. J., Schmugge, T. J., Wang, J. R. 1982. Passive microwave sensing of soil moisture under vegetation canopies. *Water Resources Research*, 18(4), 1137–1142.
- Jagdhuber, T., Hajnsek, I., Bronstert, A., Papathanassiou, K. P. 2013. Soil moisture estimation under low vegetation cover using a multi-angular polarimetric decomposition. *IEEE Transactions on Geoscience and Remote Sensing*, 51(4), 2201-2215.
- Jang, J. S. R. 1993. ANFIS: Adaptive-Network-Based Fuzzy Inference System. *IEEE Transactions on Systems, Man and Cybernetics*, 23(3), 665-685.
- Ji, J., van der Keur, P., Thomsen, A., Skriver, H. 1996. Soil moisture retrieval using the Danish L- & C-band polarimetric SAR. International Geoscience and Remote Sensing Symposium (IGARSS), 2, 1300-1302.
- Koppe, W., Gnyp, M. L., Hütt, C., Yao, Y., Miao, Y., Chen, X., Bareth, G. 2012. Rice monitoring with multi-temporal and dual-polarimetric Terrasar-X data. *International Journal of Applied Earth Observation and Geoinformation*, 21(1), 568–576.

- Kornelsen, K. C., Coulibaly, P. 2013. Advances in soil moisture retrieval from synthetic aperture radar and hydrological applications. *Journal of Hydrology*, 476, 460-489.
- Koster, R. D., Mahanama, S. P. P., Yamada, T. J., Balsamo, G., Berg, A. A., Boissarie, M., Dirmeyer, P. A., Doblas-Reyes, F. J., Drewitt, G., Gordon, C. T., Guo, Z., Jeong, J. H., Lee, W. S., Li, Z., Luo, L., Malyshev, S., Merryfield, W. J., Seneviratne, S. I., Stanelle, T., Wood, E. F. 2011. The second phase of the global land-atmosphere coupling experiment: Soil moisture contributions to subseasonal forecast skill. *Journal of Hydrometeorology*, 12(5), 805-822.
- Krogager, E., Freeman, A. 1994. Three component break-downs of scattering matrices for radar target identification and classification. Proc. PIERS'94, 391.
- Kumar, P., Prasad, R., Choudhary, A., Gupta, D. K., Mishra, V. N., Vishwakarma, A. K., Singh, A. K., Srivastava, P. K. 2019. Comprehensive evaluation of soil moisture retrieval models under different crop cover types using C-band synthetic aperture radar data. *Geocarto International*, 34(9), 1022–1041.
- Lakhankar, T., Ghedira, H., Temimi, M., Sengupta, M., Khanbilvardi, R., Blake, R. 2009. Non-parametric methods for soil moisture retrieval from satellite remote sensing data. *Remote Sensing*, 1(1), 3-21.
- Lee, J. S., Pottier, E. 2017. Polarimetric radar imaging: from basics to applications. CRC press.
- Liu, C. A., Chen, Z. X., Yun, S. H. A. O., Chen, J. S., Hasi, T., Pan, H. Z. 2019. Research advances of SAR remote sensing for agriculture applications: A review. *Journal of Integrative Agriculture*, 18(3), 506-525.
- Liu, Y. Y., Dorigo, W. A., Parinussa, R. M., de Jeu, R. A., Wagner, W., McCabe, M. F., Van Dijk, A. I. J. M. 2012. Trend-preserving blending of passive and active microwave soil moisture retrievals. *Remote Sensing of Environment*, 123, 280-297.
- López-Martínez, C., Pottier, E., Cloude, S. R. 2005. Statistical assessment of eigenvector-based target decomposition theorems in radar polarimetry. *IEEE Transactions on Geoscience and Remote Sensing*, 43(9), 2058-2074.
- Mallick, K., Bhattacharya, B. K., Patel, N. K. 2009. Estimating volumetric surface moisture content for cropped soils using a soil wetness index based on surface temperature and NDVI. *Agricultural and Forest Meteorology*, 149(8), 1327-1342.
- Martínez-Fernández, J., González-Zamora, A., Sánchez, N., Gumuzzio, A., Herrero-Jiménez, C. M. 2016. Satellite soil moisture for agricultural drought monitoring: Assessment of the SMOS derived Soil Water Deficit Index. *Remote Sensing of Environment*, 177, 277–286.
- Moran, M. S., Peters-Lidard, C. D., Watts, J. M., Mc Elroy, S. 2004. Estimating soil moisture at the watershed scale with satellite-based radar and land surface models. *Canadian Journal of Remote Sensing*, 30(5), 805-826.
- Nelder, J. A., Mead, R. 1965. A Simplex Method for Function Minimization. *The Computer Journal*, 7(4), 308-313.
- Njoku, E. G., Entekhabi, D. 1996. Passive microwave remote sensing of soil moisture. *Journal of Hydrology*, 184(1-2), 101-129.

- Notarnicola, C., Casarano, D., Posa, F., Refice, A., Satalino, G. 1995. Stima di parametri geofisici a partire da dati SAR polarimetrici multifrequenza. In Proceedings of Atti del VII Convegno Nazionale dell'Associazione Italiana di Telerilevamento (AIT), Chieri, Italy, 443–448.
- Notarnicola, Claudia, Angiulli, M., Posa, F. 2008. Soil moisture retrieval from remotely sensed data: Neural network approach versus Bayesian method. *IEEE Transactions on Geoscience and Remote Sensing*, 46(2), 547-557.
- Oh, Y. 2004. Quantitative retrieval of soil moisture content and surface roughness from multipolarized radar observations of bare soil surfaces. *IEEE Transactions on Geoscience and Remote Sensing*, 42(3), 596-601.
- Oh, Y., Kay, Y. 1998. Condition for precise measurement of soil surface roughness. *IEEE Transactions on Geoscience and Remote Sensing*, 36, 691-695.
- Oh, Y., Sarabandi, K., Ulaby, F. T. 1992. An Empirical Model and an Inversion Technique for Radar Scattering from Bare Soil Surfaces. *IEEE Transactions on Geoscience and Remote Sensing*, 30(2), 370–381.
- Oh, Y., Sarabandi, K., Ulaby, F. T. 2002. Semi-empirical model of the ensemble-averaged differential Mueller matrix for microwave backscattering from bare soil surfaces. *IEEE Transactions on Geoscience and Remote Sensing*, 40(6), 1348-1355.
- Özerdem, M. S., Acar, E., Ekinci, R. 2017. Soil Moisture Estimation over Vegetated Agricultural Areas: Tigris Basin, Turkey from Radarsat-2 Data by Polarimetric Decomposition Models and a Generalized Regression Neural Network. *Remote Sensing*, 9(4), 395.
- Paloscia, S., Pettinato, S., Santi, E., Notarnicola, C., Pasolli, L., Reppucci, A. 2013. Soil moisture mapping using Sentinel-1 images: Algorithm and preliminary validation. *Remote Sensing of Environment*, 134, 234–248.
- Paloscia, S., Santi, E., Pettinato, S., Angiulli, M. 2004. Soil properties estimates from SAR data by using a Bayesian approach combined with IEM. International Geoscience and Remote Sensing Symposium (IGARSS), 2, 819-822.
- Paloscia, S., Pampaloni, P., Pettinato, S., Santi, E. 2008. A comparison of algorithms for retrieving soil moisture from ENVISAT/ASAR images. *IEEE Transactions on Geoscience and Remote Sensing*, 46(10), 3274-3284.
- Pasolli, L., Notarnicola, C., Bruzzone, L., Bertoldi, G., Della Chiesa, S., Niedrist, G., Tappeiner, U., Zebisch, M. 2012. Polarimetric RADARSAT-2 imagery for soil moisture retrieval in alpine areas. *Canadian Journal of Remote Sensing*, 37(5), 535-547.
- Pasolli, L., Notarnicola, C., Bruzzone, L. 2011. Estimating soil moisture with the support vector regression technique. *IEEE Geoscience and Remote Sensing Letters*, 8(6), 1080-1084.
- Petropoulos, G. P., Srivastava, P. K., Piles, M., Pearson, S. 2018. Earth Observation-Based Operational Estimation of Soil Moisture and Evapotranspiration for Agricultural Crops in Support of Sustainable Water Management. *Sustainability*, 10(1), 181.
- Piles, M., Camps, A., Vall-llossera, M., Corbella, I., Panciera, R., Rudiger, C., Kerr, Y. H., Walker, J. 2011. Downscaling SMOS-Derived Soil Moisture Using MODIS

- Visible/Infrared Data. *IEEE Transactions on Geoscience and Remote Sensing*, 49(9), 3156-3166.
- Prasad, R., Kumar, R., Singh, D. 2009. A radial basis function approach to retrieve soil moisture and crop variables from X-band scatterometer observations. *Progress In Electromagnetics Research*, 12, 201-217.
- Rao, C. R., Mitra, S. K. 1972. Generalized Inverse of Matrices and Its Applications. *Operational Research Quarterly* (1970-1977), 23(4), 598.
- Rodríguez-Fernández, N. J., Aires, F., Richaume, P., Kerr, Y. H., Prigent, C., Kolassa, J., Cabot, F., Jiménez, C., Mahmoodi, A., Drusch, M. 2015. Soil moisture retrieval using neural networks: Application to SMOS. *IEEE Transactions on Geoscience and Remote Sensing*, 53(11), 5991-6007.
- Sadeghi, M., Babaeian, E., Tuller, M., Jones, S. B. 2017. The optical trapezoid model: A novel approach to remote sensing of soil moisture applied to Sentinel-2 and Landsat-8 observations. *Remote Sensing of Environment*, 198, 52–68.
- Santi, E., Paloscia, S., Pampaloni, P., Pettinato, S., Poggi, P. 2004. Retrieval of soil moisture from ENVISAT ASAR images: a comparison of inversion algorithms. In Proceedings of the 2004 Envisat & ERS Symposium (ESA SP-572), 6-10.
- Santi, E., Dabboor, M., Pettinato, S., Paloscia, S. 2019. Combining Machine Learning and Compact Polarimetry for Estimating Soil Moisture from C-Band SAR Data. *Remote Sensing*, 11(20), 2451.
- Satalino, G., Mattia, F., Davidson, M. W. J., Le Toan, T., Pasquariello, G., Borgeaud, M. 2002. On current limits of soil moisture retrieval from ERS-SAR data. *IEEE Transactions on Geoscience and Remote Sensing*, 40(11), 2438-2447.
- Schmugge, T. 1974. Remote sensing of soil moisture with microwave radiometers. *Transactions - American Society of Agricultural Engineers*, 26(3), 748–753.
- Schmugge, T. J., Jackson, T. J., McKim, H. L. 1980. Survey of methods for soil moisture determination. *Water Resources Research*, 16(6), 961-979.
- Sengur, A. 2009. Multiclass least-squares support vector machines for analog modulation classification. *Expert Systems with Applications*, 36(3, Part 2), 6681-6685.
- Senyurek, V., Lei, F., Boyd, D., Kurum, M., Gurbuz, A. C., Moorhead, R. 2020. Machine learning-based CYGNSS soil moisture estimates over ISMN sites in CONUS. *Remote Sensing*, 12(7), 1–24.
- Shang, K. Z., Wang, S. G., Ma, Y. X., Zhou, Z. J., Wang, J. Y., Liu, H. L., Wang, Y. Q. 2007. A scheme for calculating soil moisture content by using routine weather data. *Atmospheric Chemistry and Physics Discussions*, 7(3), 7451-7472.
- Shi, J., Wang, J., Hsu, A., O'Neill, P., Engman, E. T. 1995. Estimation of soil moisture and surface roughness parameters using L-band SAR measurements. International Geoscience and Remote Sensing Symposium (IGARSS), 1, 507-509.
- Shoshany, M., Svoray, T., Curran, P. J., Foody, G. M., Perevolotsky, A. 2000. The relationship between ERS-2 SAR backscatter and soil moisture: generalization from a humid to semi-arid transect. *International Journal of Remote Sensing*, 21(11), 2337-2343.

- Sokol, J., Nc Nairn, H., Pultz, T. J. 2004. Case studies demonstrating the hydrological applications of C-band multipolarized and polarimetric SAR. *Canadian Journal of Remote Sensing*, 30(3), 470-483.
- Song, X., Ma, J., Li, X., Leng, P., Zhou, F., Li, S. 2014. First results of estimating surface soil moisture in the vegetated areas using ASAR and Hyperion data: The Chinese heihe river basin case study. *Remote Sensing*, 6(12), 12055-12069.
- Soto, J., Melin, P., Castillo, O. 2016. Time series prediction using ensembles of ANFIS models with genetic optimization of interval type-2 and type-1 fuzzy integrators. *International Journal of Hybrid Intelligent Systems*, 11(3), 211-226.
- Specht, D. F. 1991. A general regression neural network. *IEEE Transactions on Neural Networks*, 2(6), 568-576.
- Srivastava, H. S., Patel, P., Sharma, Y., Navalgund, R. R. 2009. Large-area soil moisture estimation using multi-incidence-angle RADARSAT-1 SAR data. *IEEE Transactions on Geoscience and Remote Sensing*, 47(8), 2528-2535.
- Suykens, J., Van Gestel, J. De Brabanter, B. De Moor, and J. Vandewalle. 2002. Least squares support vector machines. *Neurocomputing*, 48, 85-105.
- Theis, S. W., Blanchard, B. J., Newton, R. W. 1984. Utilization of vegetation indices to improve microwave soil moisture estimates over agricultural lands. *IEEE Transactions on Geoscience and Remote Sensing*, (6), 490-496.
- Thoma, D. P., Moran, M. S., Bryant, R., Rahman, M., Holifield-Collins, C. D., Skirvin, S., Sano, E. E., Slocum, K. 2006. Comparison of four models to determine surface soil moisture from C-band radar imagery in a sparsely vegetated semiarid landscape. *Water Resources Research*, 42(1).
- Topp, G. C., Davis, J. L., Annan, A. P. 1980. Electromagnetic determination of soil water content: Measurements in coaxial transmission lines. *Water Resources Research*, 16(3), 574-582.
- Touzi, R. 2007. Speckle effect on polarimetric target scattering decomposition of SAR imagery. *Canadian Journal of Remote Sensing*, 33(1), 60-68.
- Ulaby, F. T., Moore, R. K., Fung, A. K. 1982. Microwave remote sensing: Active and passive. Volume 2-Radar remote sensing and surface scattering and emission theory.
- Ulaby, F. T., Moore, R. K., Fung, A. K. 1986. Microwave remote sensing: Active and passive, vol. iii, volume scattering and emission theory, advanced systems and applications. Inc., Dedham, Massachusetts, 1797-1848.
- Ustuner, M., Sanli, F. B. 2019. Polarimetric target decompositions and light gradient boosting machine for crop classification: A comparative evaluation. *ISPRS International Journal of Geo-Information*, 8(2).
- van Zyl, J. J., Arii, M., Kim, Y. 2011. Model-Based Decomposition of Polarimetric SAR Covariance Matrices Constrained for Nonnegative Eigenvalues. *IEEE Transactions on Geoscience and Remote Sensing*, 49(9), 3452-3459.
- van Zyl, J. J. 1989. Unsupervised classification of scattering behavior using radar polarimetry data. *IEEE Transactions on Geoscience and Remote Sensing*, 27(1), 36-45.

- van Zyl, J. J. 1993. Application of Cloude's target decomposition theorem to polarimetric imaging radar data. *Radar Polarimetry*, 1748, 184.
- Vapnik, V. N. 1995. The Nature of Statistical Learning Theory. Springer-Verlag.
- Verhoest, N. E. C., Lievens, H., Wagner, W., Álvarez-Mozos, J., Moran, M. S., Mattia, F. 2008. On the soil roughness parameterization problem in soil moisture retrieval of bare surfaces from synthetic aperture radar. *Sensors*, 8(7), 4213-4248.
- Walker, J. P., Houser, P. R. 2004. Requirements of a global near-surface soil moisture satellite mission: accuracy, repeat time, and spatial resolution. *Advances in Water Resources*, 27(8), 785-801.
- Walker, J. P., Houser, P. R., Willgoose, G. R. 2004. Active microwave remote sensing for soil moisture measurement: A field evaluation using ERS-2. *Hydrological Processes*, 18(11), 1975-1997.
- Wang, H., Magagi, R., Goita, K., Jagdhuber, T., Hajnsek, I. 2016. Evaluation of simplified polarimetric decomposition for soil moisture retrieval over vegetated agricultural fields. *Remote Sensing*, 8(2), 1-24.
- Wang, J. R., Schmugge, T. J. 1980. An empirical model for the complex dielectric permittivity of soils as a function of water content. *IEEE Transactions on Geoscience and Remote Sensing*, GE-18(4), 288-295.
- Wang, L., Qu, J. J. 2009. Satellite remote sensing applications for surface soil moisture monitoring: A review. *Frontiers of Earth Science in China*, 3(2), 237-247.
- Wasserman, P. D. 1993. Advanced Methods in Neural Computing. John Wiley & Sons, Inc.
- Wigneron, J. P., Calvet, J. C., Pellarin, T., Van de Griend, A. A., Berger, M., Ferrazzoli, P. 2003. Retrieving near-surface soil moisture from microwave radiometric observations: current status and future plans. *Remote Sensing of Environment*, 85(4), 489-506.
- Xie, Q., Meng, Q., Zhang, L., Wang, C., Sun, Y., Sun, Z. 2017. A soil moisture retrieval method based on typical polarization decomposition techniques for a maize field from full-polarization Radarsat-2 data. *Remote Sensing*, 9(2).
- Xie, X. M., Xu, J. W., Zhao, J. F., Liu, S., Wang, P. 2014. Soil moisture inversion using AMSR-E remote sensing data: An artificial neural network approach. *Applied Mechanics and Materials*, 501, 2073-2076.
- Xing, M., He, B., Ni, X., Wang, J., An, G., Shang, J., Huang, X. 2019. Retrieving surface soil moisture over wheat and soybean fields during growing season using modified water cloud model from RADARSAT-2 SAR data. *Remote Sensing*, 11(16).
- Yamaguchi, Y., Moriyama, T., Ishido, M., Yamada, H. 2005. Four-component scattering model for polarimetric SAR image decomposition. *IEEE Transactions on Geoscience and Remote Sensing*, 43(8), 1699-1706.
- Zhang, F., Zhang, L. W., Jing-Jing, S. H. I., Huang, J. F. 2014. Soil moisture monitoring based on land surface temperature-vegetation index space derived from MODIS data. *Pedosphere*, 24(4), 450-460.

Zhang, X., Chen, B., Fan, H., Huang, J., Zhao, H. 2016. The potential use of multi-band SAR data for soil moisture retrieval over bare agricultural areas: Hebei, China. *Remote Sensing*, 8(1), 1-14.

Zou, B., Zhang, Y., Cao, N., Minh, N. P. 2015. A Four-Component Decomposition Model for PolSAR Data Using Asymmetric Scattering Component. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(3), 1051-1061.

Zribi, M., Taconet, O., Hégarat-Masclé, S. Le, Vidal-Madjar, D., Emblanch, C., Loumagne, C., Normand, M. 1997. Backscattering behavior and simulation comparison over bare soils using SIR-C/X-SAR and ERASME 1994 data over Orgeval. *Remote Sensing of Environment*, 59(2), 256-266.

