

**TOBB EKONOMİ VE TEKNOLOJİ ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**METEOROLOJİ RADAR VERİLERİNDEN OPTİMAL HAVA DURUMU  
TESPİTİ İÇİN ÖZNETELİK SEÇİMİ VE YENİ YÖNTEMLERİN  
GELİŞTİRİLMESİ**

**YÜKSEK LİSANS TEZİ**

**Eren HAMURCU**

**Elektrik ve Elektronik Mühendisliği Anabilim Dalı**

**Tez Danışmanı: Doç. Dr. İmam Şamil YETİK**

**NİSAN 2018**



Fen Bilimleri Enstitüsü Onayı

.....  
**Prof. Dr. Osman EROĞUL**  
Müdür

Bu tezin Yüksek Lisans derecesinin tüm gereksinimlerini sağladığını onaylarım.

.....  
**Doç. Dr. Tolga GİRİCİ**  
Anabilim dalı Başkanı

TOBB ETÜ, Fen Bilimleri Enstitüsü'nün 151211046 numaralı Yüksek Lisans Öğrencisi **Eren HAMURCU**'nun ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı "**METEOROLOJİ RADAR VERİLERİNDEN OPTİMAL HAVA DURUMU TESPİTİ İÇİN ÖZNİTELİK SEÇİMİ VE YENİ YÖNTEMLERİN GELİŞTİRİLMESİ**" başlıklı tezi **04.04.2017** tarihinde aşağıda imzaları olan jüri tarafından kabul edilmiştir.

**Tez Danışmanı :** **Doç. Dr. İmam Şamil YETİK** .....  
TOBB Ekonomi ve Teknoloji Üniversitesi

**Jüri Üyeleri :** **Doç. Dr. Cem İYİGÜN (Başkan)** .....  
Orta Doğu Teknik Üniversitesi

**Dr. Öğr. Üyesi Ahmet Murat ÖZBAYOĞLU** .....  
TOBB Ekonomi ve Teknoloji Üniversitesi



## TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, alıntı yapılan kaynaklara eksiksiz atıf yapıldığını, referansların tam olarak belirtildiğini ve ayrıca bu tezin TOBB ETÜ Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırlandığını bildiririm.

Eren HAMURCU



## ÖZET

Yüksek Lisans

METEOROLOJİ RADAR VERİLERİNDEN OPTİMAL HAVA DURUMU

TESPİTİ İÇİN ÖZNİTELİK SEÇİMİ VE YENİ YÖNTEMLERİN

GELİŞTİRİLMESİ

Eren HAMURCU

TOBB Ekonomi ve Teknoloji Üniversitesi  
Fen Bilimleri Enstitüsü  
Elektrik ve Elektronik Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. İmam Şamil YETİK

Tarih: Nisan 2018

Özellikle son yıllarda, meteorolojik radar verilerinin işlenmesi ve bu veriler doğrultusunda optimal hava durumu tahminleri önemli bir araştırma alanı olmuştur. Ayrıca yine bu radar verileri kullanılarak kuş,böcek ve kargaşa gibi meteorolojik olmayan hedeflerin tespiti üzerine de yoğunlaşmıştır. Uzaktan algılama sistemleri ile meteorolojik tespitlerde uyduların yanı sıra radarlar da kullanılmaya başlanmıştır. Özellikle polarimetrik mikro doppler radarlar ile ölçümlerle bölgedeki hidrometeorların tespiti mümkündür. Uyduların yerine bu radarların tercih edilmesinin en önemli sebebi hem radarlarla daha küçük alanlar hakkında daha detaylı bilgiler toplanabilmesi, hem de kısa vadeli ve anlık tespitler ile bölgedeki meteorolojik duruma göre hızlı önlemler alınabilmesidir. Bu tez kapsamında Hatay Meteoroloji Radar verileri kullanılarak bu bölgedeki hidrometeorların tespiti üzerine bir sınıflandırıcı oluşturulmuş ve bu sınıflandırıcının performansını ve başarısını artırmaya yönelik araştırmalar yapılmıştır. İlk aşamada Hatay Radar'ından alınan verilerin formatı

çalışmalara uygun hale getirilmiş ve çıkarılan polarimetrik radar öznitelikleri kullanılarak bir destek vektör makinesi sınıflandırıcısı oluşturulmuştur. Sınıflandırıcı iki aşamada çalışmaktadır; öncelikle radar görüntülerinde yağış tespiti yapılmıştır, daha sonra ise yağış tespit edilemeyen bölgelerde kuş-böcek ve kargaşa tespit edilmiştir. Radar verilerinde sınıflandırıcı eğitimi için yersel gerçeklik bilgisi olmadığı için radar öznitelikleri incelenip hidrometeor sınıfları gözle tespit edilebilen bölgeler taranıp, eğitim için bir yersel gerçeklik seti oluşturulmuştur. Yersel gerçeklik seti kullanılarak sınıflandırıcı eğitimi yapılmıştır. Daha sonra radardan gelen sekiz öznitelik için bir öznitelik seçimi yapılmış ve her iki sınıflandırma aşaması için etkili olan öznitelikler belirlenmiştir. Radar verilerinde hatalı ve gürültülü ölçüm alınan bölgeler, bir maskeleyme metodu kullanılarak temizlenmiş ve seçilen öznitelikler ile sınıflandırma sonuçları kıyaslanmıştır. Son olarak da hatalı yağış tespitlerini minimuma indirmek için radardan ölçülen spektral özniteliklerin yanı sıra sınıflandırma sonuçları kullanılarak yeni doku öznitelikleri çıkarılmış ve bu öznitelikler kullanılarak tekrar sınıflandırmalar yapılmıştır. Doku öznitelikleri olarak, sınıflandırma sonuçlarından elde edilen doku üzerinde, sınıflar arasındaki komşuluk ilişkileri kullanılarak hesaplanan enerji ve entropi değerleri kullanılmıştır. Tezin sonunda ise elde edilen doku öznitelikleri kullanılarak yapılan sınıflandırma işleminde, sınıflandırıcı performansının yağış tespitinde başarımın arttığı görülmüş ve özellikle yağışsız tarihlerde ölçülen hatalı yağış sınıflandırma sonuçları büyük ölçüde giderilmiştir.

**Anahtar Kelimeler:** Radar, Sinyal işleme, Meteoroloji, Destek vektör makineleri, Sınıflandırma, Doku bazlı öznitelik çıkarımı, Öznitelik seçimi.



## **ABSTRACT**

Master of Science

# **FEATURE SELECTION FOR OPTIMAL WEATHER DETECTION FROM METEOROLOGICAL RADAR DATA AND DEVELOPMENT OF NEW METHODS**

Eren HAMURCU

TOBB University of Economics and Technology  
Institute of Natural and Applied Sciences  
Electrical and Electronics Engineering Science Programme

Supervisor: Associate Professor İmam Şamil YETİK

Date: April 2018

Especially in recent years, meteorological radar data processing and optimal weather forecasts in the direction of these data, have become an important research area. It is also focused on the detection of non-meteorological targets such as birds, insects and clutter using these radar data. Remote sensing systems as well as satellites have begun to be used in meteorological detection. Especially with polarimetric micro doppler radar, it is possible to detect the hydrometeors in the region by measurements. The most important reasons for choosing these radars instead of satellites can be gathered more detailed information about smaller areas and and quick measures can be taken according to the meteorological situation in the region with short term and instant detections. Within the scope of the thesis, a classifier on the detection of the hydrometeors in this region was constructed by using Hatay Meteorology Radar data and studies were carried out to improve the performance and the success of this

classifier. In the first step, the data obtained from Hatay Radar were adapted to the formative studies and a support vector machine classifier was created using the extracted polarimetric radar features. The classifier works in two stages; firstly rainfall detection in radar images, then birds-bugs and clutter detection in regions where rainfall could not be detected. Since there is no ground truth information for classifier training in radar data, radar features are examined, regions visually detectable in hydrometeor classes are scanned, and a ground truth dataset for training is created. Classifier training was done using the ground truth dataset. Then a feature selection was made for the eight features from the radar and the features required for both classification stages were determined. Erroneous and noisy measurements in the radar data were taken using a masking method and the classification results were compared with the selected features. Finally, in order to minimize false precipitation detections, new texture features were extracted by using the spectral features measured from the radar, as well as the classification results, and they were reclassified using these features. As texture features, were used on the texture obtained from the classification results, energy and entropy values calculated using neighborhood relations between the classes. At the end of the thesis, in the classification process using the obtained texture features, the performance of the classifier performance in the precipitation detection was increased and the results of faulty rainfall classification, which was measured especially in the precipitation without precipitation, were largely eliminated.

**Keywords:** Radar, Signal processing, Meteorology, Support vector machines, Classification, Texture based feature extraction, Feature selection.

## TEŞEKKÜR

Öncelikle, yüksek lisans çalışmalarım boyunca tecrübesi, vizyonu ve anlayışıyla bana yol gösteren ve bu süreç boyunca değerli katkı ve emekleriyle verimli bir lisansüstü eğitimi geçirmemi sağlayan Doç. Dr. İmam Şamil Yetik'e teşekkür ederim.

Araştırmalarım boyunca karşılıklı fikir alışverişinde bulunduğumuz bütün laboratuvar arkadaşlarıma teşekkürlerimi sunarım. Ayrıca, bu sürecin hem başında hem de sonunda bilgi, birikim, tecrübelerinden faydalandığım arkadaşlarım Mehmet Saygın Seyfioğlu ve Doğançan Büyükçolak'a destek ve ilgilerinden dolayı teşekkürü borç bilirim. Ayrıca tez çalışmalarında kullanılan veri setinin temini konusunda yardımlarından dolayı Dr. Kurtuluş Öztürk'e teşekkürlerimi sunarım.

Eğitim ve öğrenim hayatım boyunca beni koşulsuz şekilde destekleyen ve her türlü imkânı sunan aile bireylerime başta annem Mürşide Hamurcu ve babam Muharrem Hamurcu olmak üzere şükranlarımı sunarım.

Son olarak, TOBB Ekonomi ve Teknoloji Üniversitesi Elektrik ve Elektronik Mühendisliği Bölümü öğretim üyelerine, bana bu seçkin ve güzide üniversitede yüksek lisans yapma fırsatı verdikleri için teşekkür ederim. Ayrıca yüksek lisans eğitimim boyunca bana burs sağladığı için TOBB ETÜ'ye teşekkür ederim.



## İÇİNDEKİLER

sayfa

<b>TEZ BİLDİRİMİ</b> .....	<b>iii</b>
<b>ÖZET</b> .....	<b>iv</b>
<b>ABSTRACT</b> .....	<b>vi</b>
<b>TEŞEKKÜR</b> .....	<b>viii</b>
<b>ŞEKİL LİSTESİ</b> .....	<b>xi</b>
<b>ÇİZELGE LİSTESİ</b> .....	<b>xii</b>
<b>KISALTMALAR</b> .....	<b>xiii</b>
<b>SEMBOL LİSTESİ</b> .....	<b>xiv</b>
<b>1.GİRİŞ</b> .....	<b>1</b>
1.1 Tez Konusunun Tanımı ve Motivasyon.....	1
1.2 Radar Temelleri.....	2
1.3 Tez İçeriği.....	5
<b>2.POLARİMETRİK DOPPLER METEOROLOJİ RADARLARI VE RADAR ÜRÜNLERİ</b> .....	<b>7</b>
2.1 Fiziksel Öznitelikler.....	7
2.2 Doku (Texture) Öznitelikleri.....	9
2.2.1 Doku öznitelik çıkarımı.....	10
2.2.2 Doku özniteliklerinin destek vektörleri skor hesaplama doğrultusunda öznitelik uzayına eklenmesi.....	11
<b>3. TEZ ÇALIŞMALARINDA KULLANILAN VERİ SETİ</b> .....	<b>15</b>
3.1 Veri Setinin Temini.....	15
3.2 Ham Verinin İşlenmesi ve Çalışmalarda Kullanılması.....	16
<b>4.METEOROLOJİK RADAR VERİLERİNİN SINIFLANDIRILMASI</b> .....	<b>21</b>
4.1 Destek Vektör Makineleri.....	21
4.2 Meteoroloji Verilerini SVM ile Sınıflandırma.....	22
4.3 Sınıflandırma Sonuçları Doğrultusunda Gürültülü Verinin Tespiti ve Temizlenmesi.....	26
<b>5. METEOROLOJİK RADAR VERİLERİNİ SINIFLANDIRMA İÇİN ÖZNİTELİK SEÇİMİ</b> .....	<b>29</b>
<b>6. DOKU ÖZNİTELİKLERİ EKLENMİŞ ÖZNİTELİK UZAYI İLE SINIFLANDIRMA</b> .....	<b>35</b>

<b>7.SONUÇLAR .....</b>	<b>39</b>
<b>KAYNAKLAR.....</b>	<b>41</b>
<b>ÖZGEÇMİŞ.....</b>	<b>45</b>



## ŞEKİL LİSTESİ

sayfa

Şekil 1.1: Basit radar formu .....	3
Şekil 1.2: Darbe radar güç şeması.....	3
Şekil 1.3: Darbe radar menzil şeması.....	3
Şekil 2.1: Doku öznelikleri çıkarılmış radar görüntüleri.....	11
Şekil 2.2: $T_1$ (Enerji) ve $T_2$ (Entropi) özneliklerinin sınıf saçımları.....	13
Şekil 3.1: Hatay Radarı Google Maps uydu görüntüsü.....	15
Şekil 3.2: 22 Mart 2015 saat 22:53 tarihine ait Hatay Radarı görüntüleri.....	16
Şekil 3.3: 28 Mart 2015 saat 12:30 tarihine ait Hatay Radarı görüntüleri.....	17
Şekil 3.4: 4 Nisan 2015 saat 18:00 tarihine ait Hatay Radarı görüntüleri.....	18
Şekil 4.1: Destek vektör makineleri.....	19
Şekil 4.2: Radar görüntülerinden yersel gerçeklik toplanmış bölgeler.....	21
Şekil 4.3: Doğrusal destek vektör makineleri kullanılarak yapılan sınıflandırma sonuçları.....	22
Şekil 4.4: Şekil 3.3'e ait radar verilerinin sınıflandırma sonucu.....	23
Şekil 4.5: Şekil 3.4'e ait radar verilerinin sınıflandırma sonucu.....	23
Şekil 4.6: Filtrelenmiş ve filtrelenmemiş yansıtıcılık.....	25
Şekil 4.7: Şekil 3.3'e ait verinin Hydroclass bileşeni görüntüsü.....	25
Şekil 4.8: Şekil 4.4'e ait veriye gürültü filtremesi yapılmış sınıflandırma sonucu ....	26
Şekil 4.9: Şekil 4.5'e ait veriye gürültü filtremesi yapılmış sınıflandırma sonucu ....	26
Şekil 5.1: Farklı tarihlerdeki radar görüntülerinin öznelik seçimi ile sınıflandırma sonuçları .....	31
Şekil 6.1: 28 Mart 2015 12:30 tarihine ait veri için öznelik seçimi sonrası sınıflandırma sonuçları ve doku öznelikleri eklendikten sonra sınıflandırma sonuçları.....	32
Şekil 6.2: 4 Nisan 2015 18:00 tarihine ait veri için öznelik seçimi sonrası sınıflandırma sonuçları ve doku öznelikleri eklendikten sonra sınıflandırma sonuçları.....	33
Şekil 6.3: 22 Mart 2015 22:53 tarihine ait veri için öznelik seçimi sonrası sınıflandırma sonuçları ve doku öznelikleri eklendikten sonra sınıflandırma sonuçları.....	33
Şekil 6.4: Yakınlaştırılmış görüntü (A) Doku öznelikleri ile beraber sınıflandırma sonuçları (B) Sadece fiziksel öznelikler ile sınıflandırma sonucu.....	34





## ÇİZELGE LİSTESİ

sayfa

Çizelge 5.1: Fischer Skor [19].....27

Çizelge 5.2: Tekli öznitelik sınıflandırma başarımları [19].....28

Çizelge 5.3: Toplu başarımlar sonuçları [19].....29





## KISALTMALAR

<b>RCS</b>	: Radar Cross Section
<b>SVM</b>	: Support Vector Machines
<b>Z<sub>dr</sub></b>	: Diferansiyel Yansıtıcılık
<b><math>\rho_{hv}</math></b>	: Yatay ve dikey sinyallerin arasındaki ilinti katsayısı
<b><math>\Phi_{DP}</math></b>	: Radar ile aydınlanan hacim arasında gidiş-dönüşte yaşanan toplam diferansiyel faz
<b>K<sub>DP</sub></b>	: Spesifik Diferansiyel Faz
<b>V<sub>RAD</sub></b>	: Radyal Hız
<b>W<sub>RAD</sub></b>	: Doppler Spektrum Genişliği
<b>Z<sub>h</sub></b>	: Yatay eksende görülen yansıtıcılık
<b>SQI</b>	: Normalize Güç
<b>Z<sub>v</sub></b>	: Dikey eksen görülen yansıtıcılık
<b><math>\Phi_{HH}</math></b>	: Yatay faz
<b><math>\Phi_{VV}</math></b>	: Dikey faz



## SEMBOL LİSTESİ

Bu çalışmada kullanılmış olan simgeler açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler	Açıklama
$G$	Anten Kazancı
$c$	Işık Hızı
$v$	Hedef hızı
$P_t$	Gönderilen sinyal gücü
$P_r$	Alınan sinyal gücü
$P_n$	Sinyalin gürültü gücü
$H$	Hacimsel yansıtıcılık katsayısı
$\lambda$	Dalga boyu
$L_s$	Sistemsal Kayıplar
$L_a$	Atmosferik Kayıplar
$R$	Radar uzaklığı
$f_r$	Alınan sinyal frekansı
$f_t$	Gönderilen sinyal frekansı
$k$	Boltzman sabiti
$T_0$	Gürültü referans sıcaklığı (290 K)
$T_s$	Alınan gürültü sıcaklığı
$B$	Sinyal bant genişliği
$S$	Polarimetrik Saçılma matrisi
$S_v$	Dikey saçılma indisi
$S_h$	Yatay saçılma indisi
$\mu$	Ortalama değer
$\sigma$	Varyans



# 1.GİRİŞ

## 1.1 Tez Konusunun Tanımı ve Motivasyon

Hava durumu tespitinde ve hidrometeorolojik sınıflandırmada meteoroloji uydularının yanı sıra radarların kullanımı da gün geçtikçe artmaktadır. Meteoroloji Genel Müdürlüğü'nden alınan bilgilere göre, meteorolojik tahminler için radarların kullanımı 1950'li yıllarda başlamıştır. Doppler radarların bu alanda kullanımı ise 1970'li denk gelmektedir. Hava durumu tespiti ve hidrometeor sınıflandırma için radarların tercih edilmesinin önemli sebeplerinden birisi; radarların diğer uzaktan algılama teknolojilerine göre küçük bölgelerde daha detaylı ve anlık bilgi verebilmesidir.

Dünyada ve Türkiye'de meteorolojik radar sayısı gün geçtikçe artmaktadır. Bu radarlardan gelen bilgilerin işlenmesi ve bu alandaki bilgi birikimin artması önemli bir hal almaya başlamıştır. Meteoroloji Genel Müdürlüğüne ait toplamda 18 meteoroloji radarı bulunmaktadır. Bu radarlar; Afyonkarahisar, Ankara, Antalya, Hatay, Balıkesir, Bursa, Erzurum, Gaziantep, İstanbul (Avr.), İstanbul (Asya), İzmir, Karaman, Muğla, Samsun, Sivas, Şanlıurfa, Trabzon, Zonguldak illerimizde bulunmaktadır. Bu radarların büyük bir kısmı son yıllarda hizmete girmiştir ve yeni meteoroloji radarlarının da hizmete girip bu sayıyı artırması muhtemeldir. Ülkemizde ve dünyada meteoroloji radarlarının sayısı ve hizmet kapasitesi arttıkça, bu radarlardan elde edilen sinyallerin işlenmesi ve kullanılması da önem kazanmaktadır.

Meteorolojik uydulardan ve radarlardan alınan veriler doğrultusunda yapılan tahminlerde meteorolojik ve biyolojik hedeflerin ayrımının yapılmaması durumunda hatalı sonuçlar elde edilebilir. Özellikle göç dönemlerindeki yoğun kuş sürüleri yağmur ve yağmur bulutu olarak algılanabilir veya yersel ve deniz kargaşaları meteorolojik veri olarak algılanıp hatalı sonuçlar doğurabilir.

Bu tezde meteorolojik radarlardan alınan veriler doğrultusunda bölgede hava durumu ve hidrometeor tespiti yapılması hedeflenmektedir. Ancak genel olarak bu radar veri

setlerinde bir yersel gerçeklik (ground truth) bilgisi olmadığı için optimal bir sınıflandırıcı eğitmek mümkün değildir. Bu durumda literatürde geçen radar öznitelik değerleri doğrultusunda, gözle yersel gerçeklik bilgisi toplamak mümkündür. Dolayısıyla toplanan bu yersel gerçeklik verileri doğrultusunda bir sınıflandırıcı eğitmek mümkündür.

Meteoroloji radarlarından alınan bilgiler doğrultusunda hava durumu tespiti ve hidrometeorolojik sınıflandırma üzerine birçok çalışma yapılmıştır [1-3]. Sadece kargaşa veya kuş tespitleri üzerine de çalışmalar yapılmıştır [4]. Yine bu radarlardan elde edilen bilgiler doğrultusunda yapılan sınıflandırmalar için yeni öznitelikler ve farklı hesaplamalar doğrultusunda sınıflandırmalar yapılmıştır [5,6]. Radardan elde edilen fiziksel öznitelikler dışında doku (texture) öznitelikler kullanılarak da radar verileri sınıflandırılmıştır [7-9]. Ayrıca Türkiye'ye ait meteorolojik verilerin iyileştirilmesi üzerine de çalışmalarda yapılmıştır [10].

Yapılan çalışmalarda, radar verileri sınıflandırılırken matematiksel bir öznitelik seçimi yapılmamıştır. Ancak literatürde geçen özniteliklerin özellikleri incelendiğinde yağış tespiti için ve biyolojik hedefleri ayırt etmek için belirli özniteliklerin kullanılması daha faydalı olacaktır. Ayrıca radardan gelen özniteliklerle beraber doku (texture) öznitelikler birleştirilerek hem fiziksel (spektral) hem de doku odaklı (spatial) bir sınıflandırma metodu kullanılmamıştır. Bu tezin amacı literatürdeki bu boşlukları doldurmaktır.

## **1.2 Radar Temelleri**

Radar kelimesi “Radio Detection and Ranging” teriminin kısaltılması sonucu oluşmuştur. Temel olarak radarın çalışma prensibi; gönderdiği elektromanyetik sinyalin çarptığı hedeften yansıtılarak geri dönmesi sonucunda sinyalin şiddeti (genliği), yönü ve geri gelme süresi ile hedef hakkında bilgi vermesidir. Radarlar genellikle askeri alanlarda kullanılmaktadır. Bunun yanı sıra sivil alanlarda da kullanımları artmaktadır. Meteorolojik radarlar da sivil alanlarda kullanılan radarlara bir örnektir. Şekil 1.1’de basit bir yapıyla radar formu görülebilir.



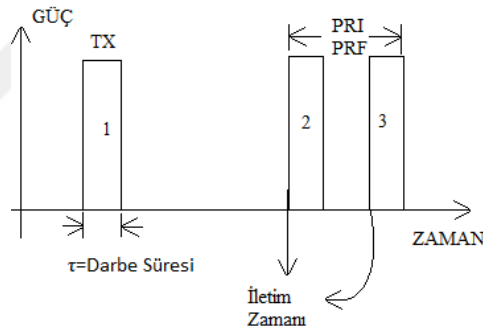


Şekil 1.1: Basit radar formu.

Genel olarak iki tip radar vardır; (i) darbe radarları ve (ii) sürekli radarlar. Darbe radarları anlık darbeler yollayarak hedeften yansıma alma metodu ile çalışmaktadır. Yollanan darbelerin tekrarlanma frekansına Darbe Tekrarlanma Frekansı (Pulse Repetition Frequency (PRF)), periyoduna ise Darbe Tekrarlanma Süresi (Pulse Repetition Interval (PRI)) denir. Şekil 1.2’de darbe radarlara ait güç şeması gösterilmiştir. Darbe radarlara ait ortalama güç Denklem(1.1)’deki gibi hesaplanabilir:


$$\text{Ortalama Güç; } P_{\text{avg}} = P_t \cdot \tau \cdot \text{PRF} \quad (1.1)$$

$$2 * R = c * t_d \text{ ve } R = \frac{c * t_d}{2} \quad (1.2)$$



Şekil 1.2: Darbe radar güç şeması.

Denklem(1.2)’de  $t_d$ , TX ve RX (gönderilen ve alınan sinyaller) arasındaki gecikmeyi,  $c$  ışık hızını ifade etmektedir. Şekil 1.3’te darbe radar menzil şeması gösterilmiştir.



Şekil 1.3: Darbe radar menzil şeması.

Denklem(1.2)'deki parametreler üzerinden devam edersek maksimum ve minimum radar menzili şu şekilde hesaplanır:

$$R_{\min} = \frac{c(\tau+ts)}{2} \text{ ve } R_{\max} = \frac{c*PRI}{2} \quad (1.3)$$

Doppler etkisiyle, radardan gönderilen ve alınan sinyalin frekans bilgileri sayesinde hedefteki cismin hızı tespit edilebilir.

$$f_r = \left( \frac{1+v/c}{1-v/c} \right) * f_t \quad (1.4)$$

Denklem (1.4)'te görüldüğü gibi alınan ve gönderilen sinyallerin bilgisiyle hedefteki cismin radyal hızı tespit edilebilir. Denklemde  $v$  cismin hızını,  $c$  ışık hızını ifade etmektedir.  $f_t$  ve  $f_r$  ise gönderilen ve alınan sinyallerin frekanslarıdır.

Sürekli radarlarda ise, radar darbe yollamak yerine belirli salınım ve şekillerde sürekli sinyaller yollar. Yolladığı ve aldığı sinyal şekilleri ve çalışma mekanizması dışında darbe radarlarla benzer amaçlar için kullanılmaktadır. Bu radarlara ait güç şu şekilde hesaplanabilir:

$$P_r = \frac{P_t * G^2 * RCS * \lambda^2}{(4\pi)^3 * R^4 * L_s * L_a(R)} \quad (1.5)$$

Denklem(1.5) noktasal bir hedef için radara ait menzil ve güç ilişkisini ifade etmektedir. Denklemde  $L_s$  sistemsel kayıpları,  $L_a$  atmosferik kayıpları,  $\lambda$  Dalga boyunu,  $G$  anten kazancını,  $P_t$  gönderilen sinyal gücünü,  $P_r$  alınan sinyal gücünü ifade etmektedir. Alınan ve gönderilen sinyal güç değerleri ve diğer radar bileşenleri ile menzil hesabı yani hedefin radara olan uzaklığı tespit edilir. Alınan sinyaldeki gürültünün gücü ise Denklem(1.8) ile hesaplanır. Denklem(1.6) ve Denklem(1.7)'de,  $B$  sinyal bant genişliğini,  $k$  Boltzman sabitini,  $T_0$  ve  $T_s$  referans ve alınan gürültü sıcaklığını (Kelvin) ifade etmektedir. RCS ifadesi ise radar kesiti değerini ifade etmektedir (Radar Cross Section) .

$$P_n = k * T_0 * B + k * T_s * B \quad (1.6)$$

$$F = \frac{SNR_{input}}{SNR_{output}} = \frac{P_s / k T_0 B}{P_s / (k T_0 B + k T_s B)} = 1 + \frac{T_s}{T_0} \quad (1.7)$$

$$P_n = k T_0 B F \quad (1.8)$$

Gürültü katsayısı F alınan sinyal ve gönderilen sinyallerin oranıyla hesaplanır. Bu katsayı ile alınan ve gönderilen sinyallerin gürültü oranı hesaplanır. Gürültü bilgisini de radar menzil denklemine eklersek. Noktasal bir cisim için radar menzil denklemi Denklem(1.9)'deki gibi olur. Maksimum menzil ise Denklem (1.10) ile ifade edilir.

$$\frac{Pr}{Pn} = \frac{Pt * G^2 * RCS * \lambda^2}{(4\pi)^3 * R^4 * Ls * La(R) * k * To * B * F} \quad (1.9)$$

$$R_{max} = \left( \frac{Pt * G^2 * RCS * \lambda^2}{(4\pi)^3 * Ls * La(R) * k * To * B * F * \left(\frac{Pr}{Pn}\right)} \right)^{1/4} \quad (1.10)$$

Ancak gerçek hayatta noktasal saçılım yerine belirli bir hacmi olan saçılımlar üzerine çalışılmaktadır ve radarlar bu hedefleri tespit etmektedir. Şekil ve boyutlar da önem kazanmaktadır. Hacimsel bir saçılım için diferensiyel RCS değeri hesaplanır ve hacimsel yansıma değeri kullanmak gerekmektedir. Bu değer, cismin üç boyutta diferansiyel parçaları alınarak elde edilir.

$$dRCS = \eta * dV = \eta * R^2 * dR * d\theta * d\phi \quad (1.11)$$

Denklem (1.11)'deki RCS (radar kesiti) katsayısı  $\eta * \Lambda R$  ile ifade edilir, “ $\eta$ ” sembolü hacimsel yansıtıcılık katsayısını ifade etmektedir. Hacimsel bir hedef için G (Gain) parametresi hesaplanırken de çözünürlük için 3dB sinyal limitli açı değerleri bilgisi ( $\theta_3$ ,  $\phi_3$ ) kullanılır. Hacimsel bir saçılım için menzil denklemi aşağıda Denklem(1.12)'deki gibi olur:

$$Pr = \frac{Pt * G^2 * \lambda^2 * \eta * \Lambda R * \theta_3 * \phi_3}{(4\pi)^3 * R^2 * Ls * La(R)} \quad (1.12)$$

Radarlar sayesinde elde edilen bu bilgilerle hedefteki cismin şekli, hızı, büyüklüğü vb. özellikleri tespit edilir ve askeri veya askeri olmayan alanlarda bu bilgiler ile radarlar üzerinde çalışmalar yapılır.

### 1.3 Tez İçeriği

Bu tezin kapsamında, Meteoroloji Genel Müdürlüğünden alınan ve Hatay Çift Kutuplu Doppler Radar'ına ait olan radar veri seti aracılığıyla hidrometeor sınıflandırılma yapılmıştır. Bu veri setinde 28 Mart 2015 ve 5 Nisan 2015 tarihleri arasında farklı

zamanlarda alınmış 40 adet radar görüntüsü bulunmaktadır. Her bir radar görüntüsünde 8 adet öznitelik bulunmaktadır ve bu öznitelikler üzerinden çalışmalar yürütülmüştür.

Kullanılan veri seti üzerinden bir destek vektör makinesi algoritması kullanılarak sınıflandırılma yöntemi geliştirilmiştir. Sınıflandırma iki aşamadan oluşmaktadır; ilk önce yağış bölgede yağış tespiti yapılmaktadır; ve yağış tespit edilemeyen ve ölçüm alınan bölgelerde kuş/böcek veya kargaşa (yersel,deniz) tespiti yapılmıştır. Literatürde kullanılan öznitelikler üzerinden her aşamada kullanılması gereken öznitelikler için bir öznitelik seçimi yapılmıştır [11]. Öznitelik seçiminden sonra ise yapılan yağış tespiti sınıflandırma sonuçlarına göre doku bazlı öznitelikler çıkarılıp hatalı sınıflandırma durumu tespiti için bu öznitelikler de destek vektör uzayına eklenip sınıflandırma tekrarlanmıştır. Hem fiziksel (spektral) hem doku bazlı (spatial) öznitelikler birleştirilerek optimal bir meteorolojik radar sınıflandırıcısı oluşturulmuştur. Hava durumu tespiti ve hidrometeor sınıflandırma için yeni ve geliştirilmiş bir metot oluşturulup, bu metot sonucunda meteorolojik radar verilerinden elde edilen sınıflandırma sonuçları iyileştirilmiştir.

## 2.POLARİMETRİK DOPPLER METEOROLOJİ RADARLARI VE RADAR ÜRÜNLERİ

Polarimetrik radarlar, normal radarların aksine tek polarizasyonda sinyal göndermek yerine çift polarizasyonlu sinyaller gönderirler. Radarlar genellikle yatay polarizasyonlu sinyaller göndermektedir ancak polarimetrik radarlar hem yatay hem de dikey polarizasyonlu sinyalleri arka arkaya gönderirler . Böylece sadece hedefin var olup olmadığına dair bilginin yanı sıra hedefin şekline ait bilgi de elde edilebilir.

### 2.1 Fiziksel Öznitelikler

Polarimetrik radarların gönderdiği elektromanyetik dalgalar sonucunda elde edilen genlik bilgisi “Polimetrik Saçılma matrisi” ile ifade edilir

$$\text{Polarimetrik saçılma matrisi } S = \begin{bmatrix} S_{hh} & S_{hv} \\ S_{vh} & S_{vv} \end{bmatrix} \quad (2.1)$$

Denklem (2.1) 'de verilen saçılma matrisi değerleri ile literatürde bu radarlara ait bazı öznitelikler hesaplanmıştır. Yukarıdaki saçılma matrisindeki  $S_{hh}$ ,  $S_{hv}$ ,  $S_{vh}$ ,  $S_{vv}$  (yatay, yatay-dikey, dikey-yatay, dikey) saçılma katsayılarından bazı öznitelikler hesaplanmıştır

$Z_{dr}$  (Diferansiyel Yansıtıcılık) katsayısı, polarimetrik radardan gönderilen dikey ve yatay sinyaller arasındaki oranı ifade etmektedir. Saçılma matrisinden elde edilen dikey ve yatay saçılma değerleri ile hesaplanır.

$$Z_{dr} = 10 \log \left( \frac{|S_{hh}|^2}{|S_{vv}|^2} \right) \quad (2.2) \quad Z_{dr} = 10 \log \left( \frac{Z_H}{Z_V} \right) \text{ dB} \quad (2.3) \text{ olarak tanımlanmaktadır.}$$

Bu oran doğrultusunda  $Z_{dr}$  hedefteki hidrometeorun şekli hakkında bilgi vermektedir.  $Z_{dr}$  değeri pozitif ise hedefteki cismin uzunluğu eninden büyüktür, eğer negatif bir değer ise tam tersidir ve yaklaşık olarak sifıra yakınsa hedefteki cisim homojen bir şekle sahiptir. Yağmur damlalarında yer çekimi etkisinden dolayı düşüş esnasında bu değer pozitif olması beklenmektedir. Ancak daha küçük yağmur damlalarında bu

oranın da damla boyutuyla beraber düşmesi beklenmektedir. Yağış tespiti için önemli bir bilgi de gökten serbest düşme yapan bir yağmur damlasının eninin boyundan büyük olmasının fiziksel olarak zor olması ve  $Z_{dr}$  negatif bir değer alıyorsa bu noktada yağmur dışı bir biyolojik ekonun olması muhtemeldir. Ayrıca 2003 yılında yapılan bir çalışmada alınan sonuçlar incelendiğinde yersel kargaşanın  $Z_{dr}$  değerinin negatif olduğu ve biyolojik hedeflerde ise (kuş/böcek) bu değer çok yüksek olduğu söylenmiştir [12].

$\rho_{hv}$  (Yatay ve Dikey Sinyallerin Arasındaki İlinti) katsayısı, polarimetrik saçılma matrisinden elde edilen yatay ve dikey sinyaller arasındaki ilintiyle hesaplanır.

$$\rho_{hv} = | \langle S_{hh}^* S_{vv} \rangle | / ( \langle |S_{hh}|^2 \rangle \langle |S_{vv}|^2 \rangle )^{1/2} \quad (2.4)$$

Eğer yansıyan cisim çoğunlukla homojen bir hidrometeordan oluşuyorsa ilinti genelde yüksektir.

$\Phi_{DP}$  (Radar ile Aydınlanan Hacim Arasında Gidiş-Dönüşte Yaşanan Toplam Diferansiyel Faz), gönderilen sinyalin cisimden geçerken yavaşlaması yatay ve dikey sinyallerin arasında bir faz farkına sebep olur, bu faz farkı genel olarak menzile de artmaktadır.

$$\Phi_{DP} = \Phi_{HH} - \Phi_{VV} \quad (2.5)$$

Sinyaller yağmur damlaları içinden geçerken yavaşlamaktadır. Yağmur damlaları büyüdükçe yatay ekseni, dikey eksenine göre daha genişler. Bu yüzden, yatay ekseni gönderilen sinyal, dikey ekseni sinyale göre daha geç gelir.

KDP (Spesifik Diferansiyel Faz) ise diferansiyel fazın menzile bağlı olarak değişimini ifade etmektedir. Genellikle bu öznelik yağış hızını ve zayıflama derecesini tespit etmek için kullanılır [13]. Denklem (2.6)'de  $r_2$  ve  $r_1$  menzile ait diferansiyel fazı tespit edilen iki farklı noktanın radar olan uzaklığını temsil etmektedir.

$$K_{DP} = \frac{\Phi_{DP}(r_2) - \Phi_{DP}(r_1)}{r_2 - r_1} \quad (2.6)$$

$V_{RAD}$  (Radyal Hız), hedefteki cismin radarın bulunduğu konuma göre bağlı hızını ifade etmektedir. Radyal hız bileşeni, doppler radar hız denklemi ile hesaplanmaktadır.

Genellikle biyolojik hedefler (kuş/böcek), hareketsiz olan deniz ve karasal kargaşalara göre daha yüksek radyal hıza sahip olmalıdır. Ayrıca yağmur damlları sadece yatay hareket ettiği için radyal hız değerleri yine kuş ve böceklere göre oldukça düşüktür.

$W_{RAD}$  (Doppler Spektrum Genişliği), mikro doppler radarlar sayesinde hedefteki cismin doppler hız bileşine kullanılarak doppler spektrum genişliğini elde etmek mümkündür. Biyolojik cisimlerin doppler spektrum genişliği, yağış gibi meteorolojik cisimlere göre daha yüksektir. Yoğun kuş sürülerinin yağış olarak algılanmaması konusunda oldukça belirleyici bir özneliktir.

$Z_h$  (Yatay Eksende Görülen Yansıtıcılık), yatay eksende gönderilen sinyal ile gelen yansıtıcılık değeridir. Saçılma matrisinde  $S_{hh}$  değerinden elde edilir:

$$Z_h = |S_{hh}|^2 \quad (2.7)$$

SQI (NCP, Normalized Coherent Power), hedeften gelen gecikmiş sinyalin ve toplam alınan sinyalin enerjileri oranını ifade eder. Sinyalin cisimden dönerken bozulma seviyesini veya nasıl bir gecikmeye uğradığını gösterir:

$$NCP = \frac{|R_{hh}(1)|}{|R_{hh}(0)|}, \quad NCP = \frac{|R_{vv}(1)|}{|R_{vv}(0)|} \quad (2.8)$$

## 2.2 Doku (Texture) Öznitelikleri

Meteorolojik radar verileri sınıflandırılırken önemli bir metrik de ölçüm alınan pikseller arasındaki komşuluk ilişkileridir. Doğanın kanunlarından ötürü küçük bir alan yağış görüp etrafında yağışsız bir durum gözlemek mümkün değildir. Ayrıca yine yağışlı havalarda göçmen kuşların uçuşu nadir görülen bir durumdur. Bu gerçekler göz önünde alındığında tek bir pikselde yağış tespit edilip komşu piksellerde ise yağışsız hava tespit etmek doğru bir sonuç değildir. Çalışmanın bu kısmına kadar kullanılan öznitelikler sadece belirli bir pikselden (hedeften) alınan ölçümler üzerinden çıkarılmış ve çevresel faktörler hesaba katılmamıştır. Literatürdeki çalışmalarda da meteorolojik radar verileri sınıflandırılırken doku bazlı öznitelikler ile birlikte öznitelik seçimi yapılmış radar verileri sınıflandırma için beraber kullanılmamıştır. Doku analizi ile elde edilen sonuçlar genellikle sınıflandırma sonuçlarının doğruluk oranını takip etmek amacıyla kullanılmıştır. Tez kapsamındaki çalışmalarda elde edilen doku özniteliklerinin, destek vektör makineleri eğitim

sürecine öznitelik olarak eklenmesi ve seçilen özniteliklerle beraber tekrar bir sınıflandırıcı eğitimi ile sınıflandırmadaki bu hataların önüne geçmesi hedeflenmektedir.

### 2.2.1 Doku öznitelik çıkarımı

Veriler arasındaki komşuluk ilişkilerinden bağımsız olarak sadece radar verileri ile elde edilen sınıflandırma sonuçları doğrultusunda doku öznitelikleri çıkarılmıştır. Doku öznitelikleri olarak komşu pikseller arasındaki eşitlik üzerinden enerji ve entropi momentleri hesaplanmıştır [14]. Hesaplanan bu enerji ve entropi değerleri ile tekrar bir destek vektör makinesi sınıflandırıcı eğitilmiş ve radar verileri ile doku verileri birleştirilmiş sınıflandırılma sonuçları oluşturulmuştur.

Enerji ve entropi değerlerini hesaplamak için öncelikle pikseller arasındaki komşuluk ilişkileri kullanılarak eşdizimlik matrisi ( $C_o$ ) oluşturulmuştur [15].

$$C_o = \sum_m \sum_n \sum_{i=0}^2 \sum_{j=0}^2 \begin{cases} 0, & \text{eğer } C(m \pm i, n \pm j) = C(m, n) \\ 1, & \text{diğer} \end{cases} \quad (2.9)$$

Denklem (2.9)'de,  $C(m,n)$  eşdizimlilik matrisi değeri hesaplanan noktayı temsil etmektedir,  $C_o$  matrisi hesaplanırken  $m$  ve  $n$  indisleri görüntüdeki piksellerin yerini temsil etmektedir. Komşuluk ilişkileri bağlantısını ifade etmek için  $i$  ve  $j$  indisleri kullanılmıştır ve  $C_o$  matrisi hesaplanırken piksele maksimum yatay ve dikey uzaklığı ikişer piksel olan bölgelerle hesaplama yapılmıştır. Elde edilen eşdizimlik matrisi daha sonra normalize edilip 1'den çıkarılarak  $N_d$  (normalize edilmiş eşdizimlik matrisi) hesaplanmıştır.  $N_d$  bileşeni kullanılarak da radar görüntüsüne ait enerji ve entropi momentleri edilmiştir:

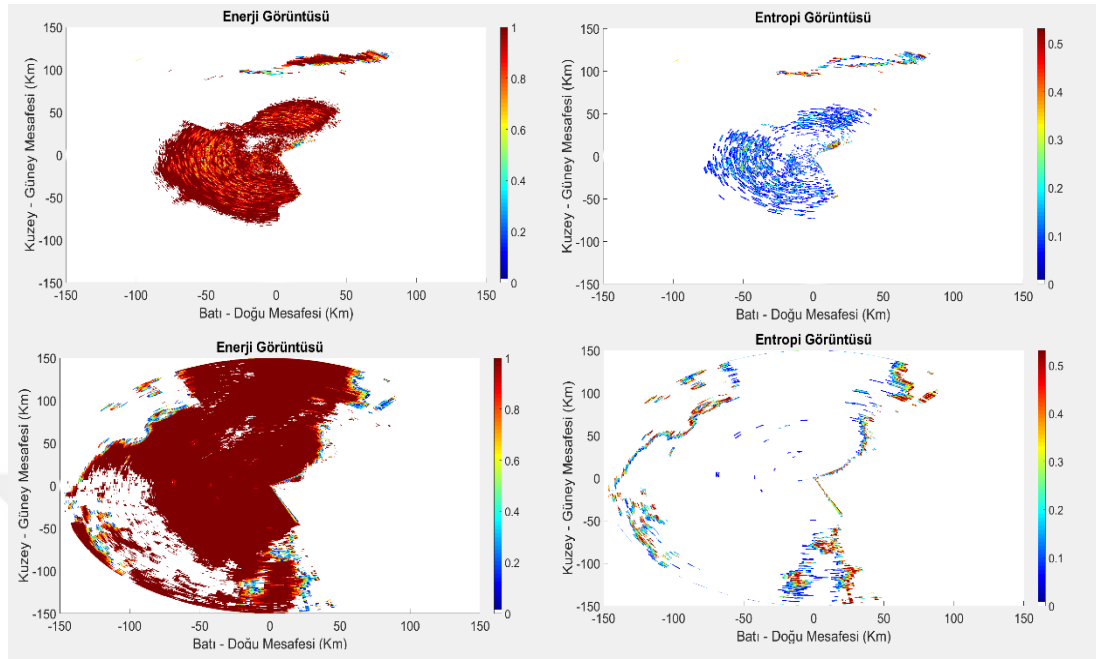
$$\text{Enerji} = N_d^2 \quad (2.10)$$

$$\text{Entropi} = N_d * \log_2 N_d \quad (2.11)$$

Doku öznitelikleri özellikle yağış tespiti sırasında oluşan hataları engellemek için kullanılmıştır. Çünkü kuş/böcek ve kargaşa sınıflandırma aşamasında yukarıda bahsedilen pikseller arasındaki ilişkilerle bir bağlantı kurmak mümkün değildir. Bu yüzden ilk sınıflandırma aşaması sonuçları ele alınarak doku öznitelikleri elde edilmiş



ve bu öznitelikler, öznitelik uzayına eklenerek yağış tespiti için yapılan sınıflandırma aşaması tekrarlanmıştır.



Şekil 2.1: Doku öznitelikleri çıkarılmış radar görüntüleri.

Doku öznitelikleri incelenirse, enerji bileşeni ve entropi bileşenleri ters orantılı iki bileşendir. Eğer bölgede homojen dağılımlı bir sınıflandırma varsa komşu pikseller arasındaki sınıflandırma sonuçları benzer ise bölgede enerji momenti yüksektir. Aynı şekilde bu benzerlik ve homojenlik entropi değerini ise ters orantıyla etkilemektedir, entropi farklılığın yüksek ve homojenliğin düşük bölgelerde yüksektir.

### 2.2.2 Doku özniteliklerinin destek vektörleri skor hesaplama doğrultusunda öznitelik uzayına eklenmesi

Radar görüntülerinden elde edilen sınıflandırma sonuçlarından çıkarılan doku özniteliklerinin yanı sıra bu görüntülerdeki her bir piksele ait doğruluk derecelerinin bilinmesi gerekmektedir. Ancak elimizdeki radar görüntülerinde yersel gerçeklik bilgisi olmadığı için sınıflandırma sonuçları üzerinden bir metrik hesaplama ihtiyacı doğmuştur. Literatürde destek vektör makineleri üzerinden yapılan sınıflandırmalarda hata payı hesaplanmasına yönelik çeşitli yöntemler vardır [16, 17]. Genellikle fiziksel (spektral) ve bölgesel (spatial) durumların birleştirilmesi üzerine yapılan çalışmalarda destek vektör makinelerinin spektral özniteliklerden gelen skorları ve doku bazlı

spatial olasılıklar birleştirilip görüntülerde sınıflandırma yapılmıştır [17]. Tez kapsamında ise radar ölçümlerinden elde edilen öznelikler ile yapılan destek vektör makinesi sınıflandırma (spektral sınıflandırma) hata skorları kullanılarak doku öznelikleri (spatial condition), radar öznelik uzayına eklenmiştir.

Yağış tespiti için kullanılan öznelik uzayı ile eğitilen destek vektör makineleri parametreleri ve sınıflandırma sonuçları kullanılarak bir destek vektör makineleri skorlama metodu geliştirilmiştir. Eğitilen destek vektörleri ve hiperdüzleme ele alınarak çıkarılan sınıflandırma sonuçlarının bu hiperdüzleme olan uzaklığı ve destek vektör parametreleri ile ayırt edilebilirliği üzerinden bir skorlama amaçlanmıştır.

$$S(x)=(x/s)'\beta+b \quad (2.12)$$

Denklem (2.12)'de  $\beta$  parametresi destek vektörlerine ait beta değerlerini b parametresi destek vektör sabitini (bias), s parametresi ise destek vektör makinesi için kullanılan kernel fonksiyonu parametrelerini ifade etmektedir. Skor hesaplaması yapılırken skor bilgisi içinde sınıf bilgisi de bulundurmak amacıyla elde edilen skorlar yağış var ve yok tespiti üzerine [-1 1] değerleriyle çarpılmıştır. S(x) vektörüne kaydedilen skorlar en ayırık veriye ait skor doğrultusunda normalize edilmiştir ve  $S_n(x)$  vektörü elde edilmiştir.  $S_n$  normalize skor vektörü kullanılarak da doku öznelikleri, öznelik uzayına Denklem(2.13) ve Denklem(2.14) kullanılarak eklenmiştir.

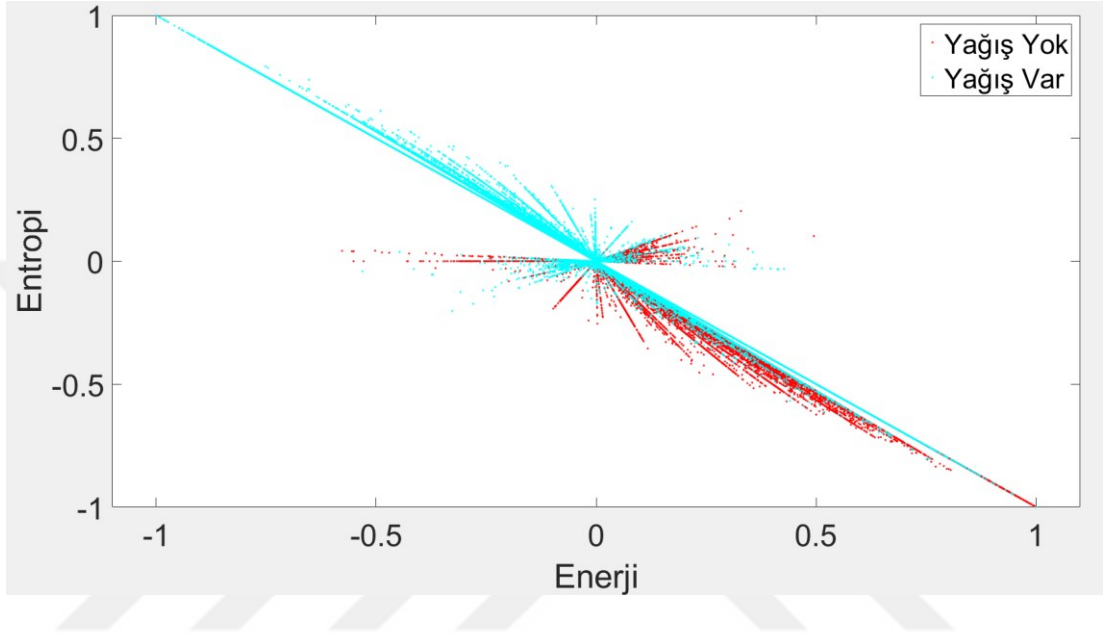
$$T_1=(2*Enerji-1)*S_n \quad (2.13)$$

$$T_2=(2*Entropi-1)*S_n \quad (2.14)$$

Normalize edilmiş skor vektörü hem verinin eşleştirildiği sınıfa ait olasılığını hem de pozitif ve negatif olma durumuna göre sınıf bilgisini tutmaktadır. Enerji ve entropi değerleriyle oranlanan skor bilgisi ile skor ve doku bazlı aynı öznelikler elde edilmiştir.

$T_1$  ve  $T_2$  özneliklerinin radar verilerine göre sınıfları ayırması için saçılımları incelendiğinde oldukça ayırt edici iki öznelik elde edildiği görülmüştür. Şekil 2.2 görüldüğü gibi doğrusal bir destek vektör makinesi kullanılarak bu iki özneliğin büyük ölçüde veriyi sınıflandırmada başarılı olması beklenmektedir.

Sonuç olarak veri setindeki fiziksel öznitelikler kullanılarak elde edilen sınıflandırma sonuçlarının, radar görüntüsü üzerinde komşuluk ilişkileri kullanılarak entropi ve enerji değerleri hesaplanmıştır. Hesaplanan bu enerji ve entropi değerleri sınıflandırma skorlama yöntemiyle birleştirilip, fiziksel özniteliklerin yanı sıra doku bazlı öznitelikler elde edilmiştir ve Şekil 2.2'den de görüldüğü üzere bu öznitelikler yağış tespiti için oldukça ayrık bir saçılım göstermiştir.



Şekil 2.2:  $T_1$  (Enerji) ve  $T_2$  (Entropi) özniteliklerinin sınıf saçılımları.



### **3. TEZ ÇALIŞMALARINDA KULLANILAN VERİ SETİ**

Çalışmalarda kullanılan veri seti Meteoroloji Genel Müdürlüğü Uzaktan Algılama Şube Müdürlüğü'nden temin edilmiştir. Veri seti temin edilirken tezin amacına yönelik radar görüntüleri ve görüntüleme tarihleri seçilmiştir.

#### **3.1 Veri Setinin Temini**

Meteoroloji Genel Müdürlüğü'nden alınan veri seti çerçevesinde tez çalışmalarına başlanmıştır. Meteorolojik radar verileri seçilirken tezin amacına uygun esaslar göz önünde bulundurulmuştur. Öncelikle tezde kullanılan metod ve tezin amacına uygun olması için hem yağış görülebilecek hem de yoğun miktarda kuş popülasyonu olabilecek tarihler araştırıldı. Hatay'da bulunan meteoroloji radarı verileri bu esaslara göre seçildi. Yapılan literatür araştırmaları ve gözlemler sonucu Mart ayı başında Kudüs civarından Avrupaya göç eden kuşlar ve böcekler, Mart sonunda ve Nisan başında Hatay ilimizden geçmektedir [18]. Aynı zamanda Meteoroloji Genel Müdürlüğü'ne ait arşivlere göre bölgede ilkbaharda yağmur yağışları da gözlenmektedir. Çalışmalarda kullanılan veriler de bu faktörler göz önünde bulundurularak 27 Mart 2015- 5 Nisan 2015 tarihleri arasında alınmış radar görüntülerinden oluşturulmuştur.

Hatay'da bulunan Meteorolojik Radar, C band Çift Kutuplu (Dual-Pol) Doppler bir meteorolojik radardır. Domuz Burnu mevkiindeki radarın coğrafik konumundan dolayı Güneydoğu kısmından veri almak mümkün değildir. Bunun sebebi, bölge hem dağlık bir bölge olmakla beraber hem de Suriye sınırına yakın olduğu için bu kısımdan veri alınamamıştır.

Şekil 3.1'deki haritalardan da görülebileceği gibi, hatay radarı özellikle zor bir yerdedir. Güney batıya doğru potansiyel deniz kargaşası ve doğuya doğru dağlar kaplıdır.



Şekil 3.1: Hatay Radarı Google Maps uydu görüntüsü.

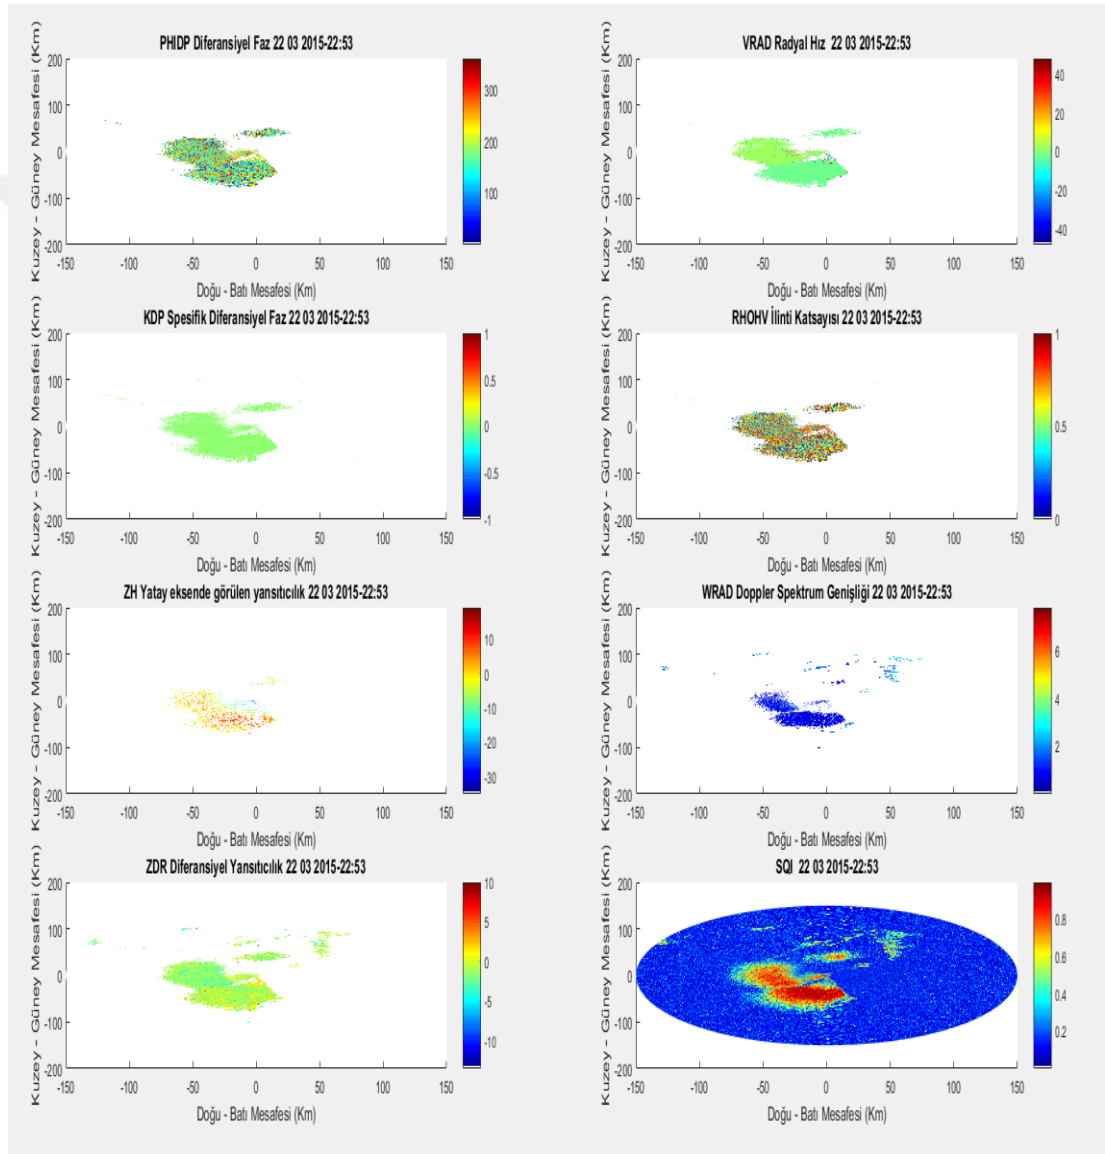
### 3.2 Ham Verinin İşlenmesi ve Çalışmalarda Kullanılması

Türk Meteoroloji Servisi tarafından sağlanan veriler IRIS formatındadır. Bu formattaki veri setinin kullanılması ve işlenmesinde büyük zorluklar yaşanmıştır. 2016 Nisan ayında Finlandiya Meteoroloji Enstitüsüne yapılan akademik ziyarette enstitü çalışanlarının python proglama dilince yazdığı bir dönüşüm kodu ile veriler HDF5 formatına çevrilmiştir [19].

HDF5 formatında çevrilen veriler daha sonra işlenerek radar görüntüleri elde edilmiştir. Ancak önceden de bahsedildiği üzere radar görüntüleri alanın yaklaşık 270 derecelik bir bölümü hakkında bilgi vermektedir. Radarın Kuzey Doğu bölgesindeki coğrafik oluşumlar (dağlar) sadece yersel kargaşaya sebep verdiği için bu bölge filtrelenerek temizlenmiş herhangi bir ölçüm kaydedilmemiştir. Ayrıca radara ait veriler 150 km'lik bir maksimum menzille alınmıştır. Bu menzil radar için güvenilir sınır olarak kullanılmıştır. Veri seti kullanılarak yapılan sınıflandırma çalışmalarında da, belirlenen güvenilir radar menzili içindeki veriler baz alınmıştır. Radara 150

km'den daha uzak noktalardan alınan ölçümler, doğruluk oranı düşük olduğu için çalışmalarda kullanılmamıştır.

Iris formatından Hdf5 formatına çevrilen radar görüntüleri polar koordinat düzlemi üzerine çizdirilip, radar görüntülerine ait öznelik değerleri ve dağılımları üzerinden bölgesel kuş/böcek, yağış, kargaşa (yersel ve deniz kargaşası) tespiti yapılmıştır. Tez çalışmalarında kullanılan veri setinde yersel gerçeklik bilgisi olmadığı için görüntüler üzerinden yersel gerçeklik tahmini ve tespiti üzerine bilgiler edinilmiştir.



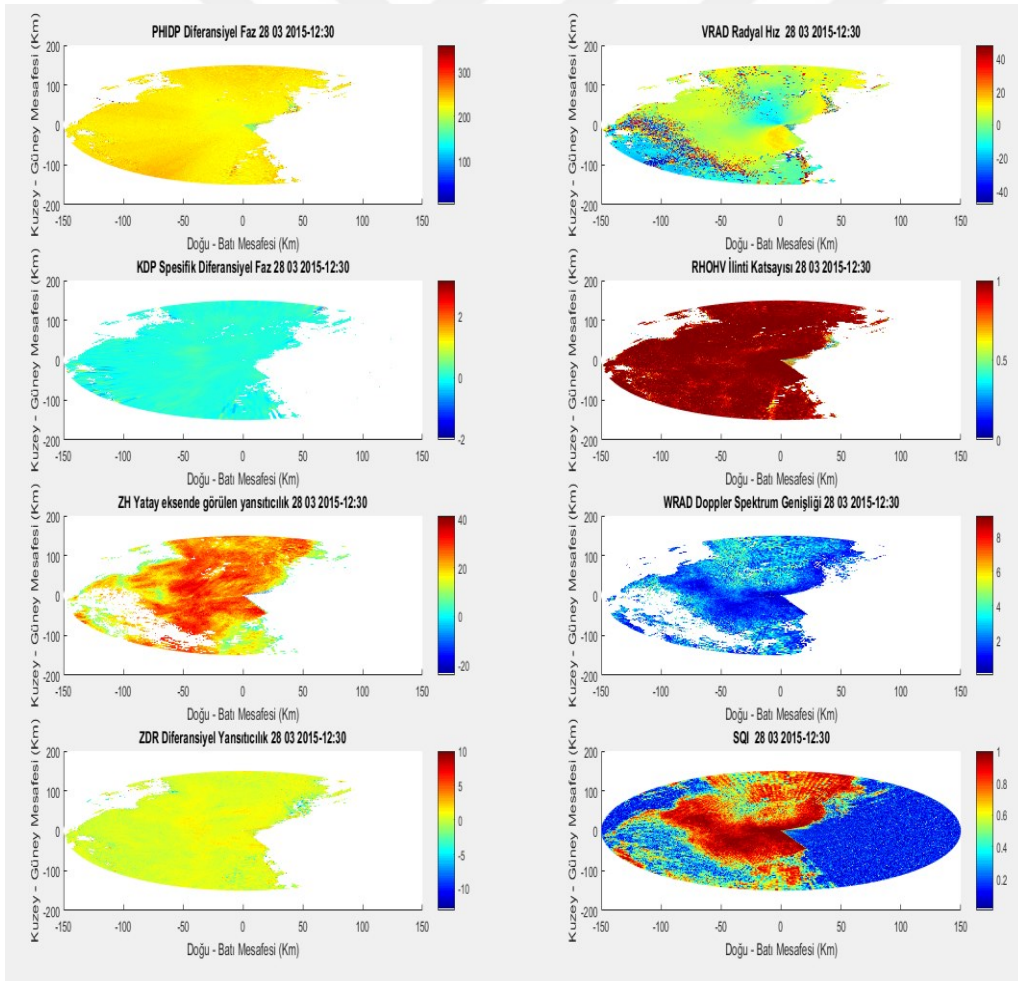
Şekil 3.2: 22 Mart 2015 saat 22:53 tarihine ait Hatay Radarı görüntüleri.

İncelenen radar verileri üzerinden edinilen bilgiler sayesinde hem sınıflandırıcı eğitimi için gerekli bir eğitim seti hem de sınıflandırma sonuçlarındaki hataların tespiti



mümkün olmuştur. Şekil 3.2, 22 Mart akşamına ait bir radar görüntüsüdür. Radar öznelik görüntüleri incelendiğinde, radarın güneybatısında yoğun bir deniz kargaşası görülebilir. Bu tahmin şu öznelik değerleri yorumlamalarıyla doğrulanabilir. SQI değeri bu bölgede yüksek olarak görülmektedir. Ayrıca radyal hız bileşeni ise oldukça düşüktür ve ilinti katsayısı ( $\rho_{hv}$ ) bölgedeki piksellerde çeşitlilik göstermektedir. Ayrıca radara yakın mesafede uçan kuş/böcek sürüleri de görülmektedir. Beklediği gibi kuş ve böceklerin radyal hızları diğer hidrometeorlardan oldukça yüksektir. Ayrıca bölgede herhangi bir yağış görülememektedir.

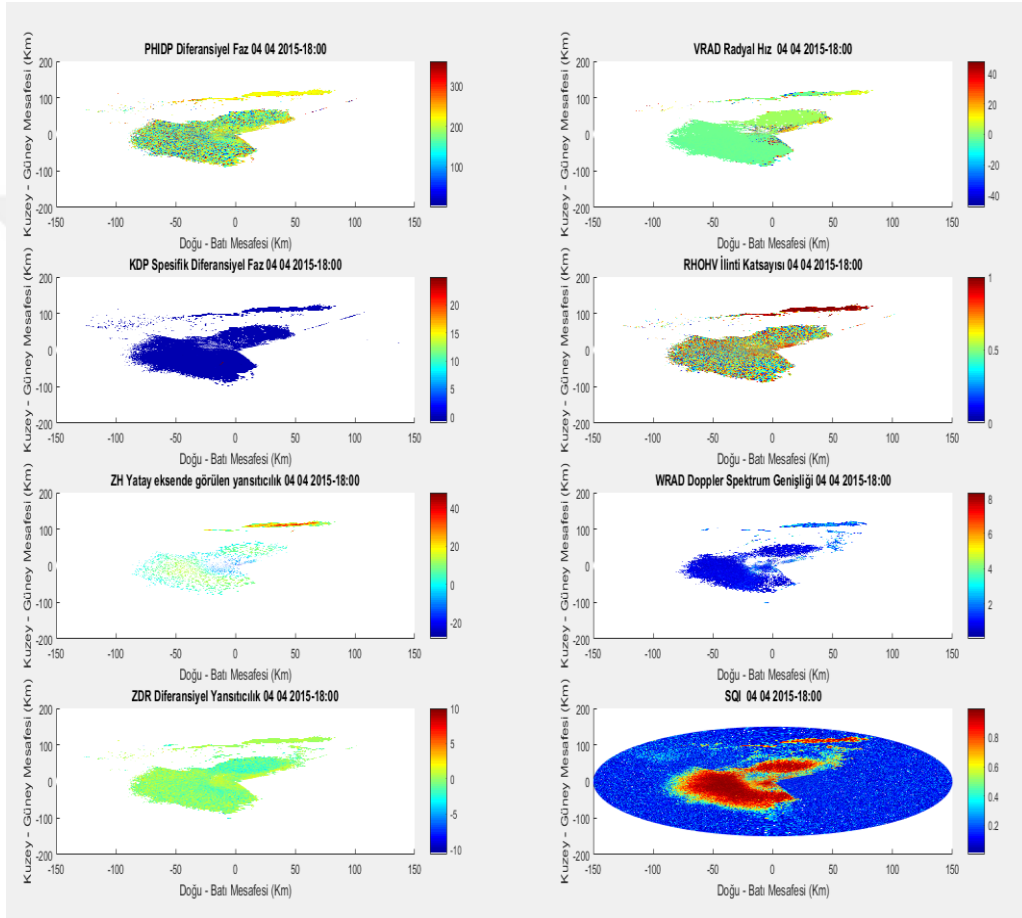
Şekil 3.3 ise yağışlı bir zaman aralığına ait radar öznelik görüntülerini içermektedir. Öznelik değerlerinden görüldüğü gibi bölgede yoğun bir yağış görülebilir.  $\rho_{hv}$  değeri, görüntünün büyük bir bölümünde genellikle 1 değerine çok yakındır, ayrıca  $Z_{dr}$  değerinde de homojen bir yağış olduğu görülebilir



Şekil 3.3: 28 Mart 2015 saat 12:30 tarihine ait Hatay Radarı görüntüleri.



Ayrıca radar görüntülerinde tüm alanda olmamak kaydıyla bölgesel yağışlar da görülebilmektedir. Şekil 3.4'te kuzeydoğu bölgesinde yağış olmakla beraber yine radar yakınlarında göçmen kuşlar tespit edilebilir. Kuzey doğu kısmında ölçüm alınan bölgede  $\rho_{hv}$  değerinin yüksek olması bu bölgede yağış olduğu anlamına gelmektedir.  $Z_h$  değeri de bu bölgedeki hidrometeorların yatay bileşenlerinin diğer bölgelere göre yüksek olduğunu göstermektedir. Radar yakınlarındaki göçmen biyolojik canlıların (kuş,böcek) radyal hızları da diğer hidrometeorlara göre yüksektir.



Şekil 3.4: 4 Nisan 2015 saat 18:00 tarihine ait Hatay Radarı görüntüleri.

Radar görüntüleri incelendikten sonra Finlandiya Meteoroloji Enstitüsü çalışanları tarafından hazırlanan bir Naive Bayesian sınıflandırıcı, Türkiye Meteoroloji Genel Müdürlüğü'nden alınan Hatay radarı verilerine uygulanmış ve sınıflandırma sonuçları üzerine araştırmalar yapılmıştır [20]. Bu çalışmada bir amaç da tek bir sınıflandırma algoritmasının dünya üzerinde farklı coğrafik özelliklere ait bölgelerden alınan veriler üzerinden performansını tespit etmektir.

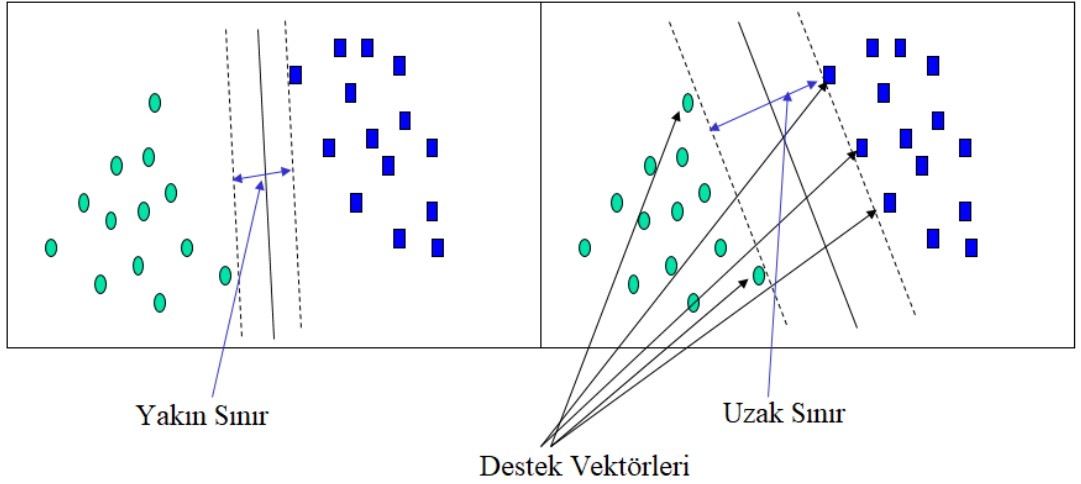


## 4.METEOROLOJİK RADAR VERİLERİNİN SINIFLANDIRILMASI

### 4.1 Destek Vektör Makineleri

Destek vektör makineleri, doğrusal ve doğrusal olmayan verileri sınıflandırmak için kullanılan bir makine öğrenme tekniğidir. Eğitim setini yüksek boyutlu bir haritalama metodu ile sınıflara ayırmaktadır. Çok boyutlu uzayda verisini ayıran doğrusal veya doğrusal olmayan sınırlar çizer ve bu sınıflar doğrultusunda verinin sınıfına karar verir. Bu ayırma işlemini hiperdüzlem denilen doğrular aracılığıyla yapar. Destek vektör makineleri hiperdüzlemleri, destek vektörleri ve sınır değerleri hesaplayarak tespit eder [21].

Destek vektör makineleri numerik verileri sınıflandırmak için kullanışlı bir metottur. Veri集中的 öznelikler kullanılarak eğitilen destek vektör makinelerinde diğer sınıflandırma metotlarına oranla sınıflandırıcı eğitim daha yavaştır ancak yüksek bir başarımla elde edilebilmektedir.



Şekil 4.1: Destek vektör makineleri.

Şekil 4.1’de görüldüğü gibi öznitelik değerleri birbirine yakın bir şekilde de uzak bir şekilde de sınırlandırılabilir. Destek vektör makinelerinin eğitilmesinde bu hiperdüzlemlerden en uygunu seçilmelidir. Destek vektör makineleri bu hiperdüzlemler içinde en genişini tespit edip edim maksimum sınırlı hiperdüzlemi bulur [21].

$$\mathbf{W}^* \mathbf{x} + \mathbf{b} = 0 \quad \mathbf{W} = \{w_1, w_2, \dots, w_n\} \text{ ve } \mathbf{b} \text{ (sabit değer) kayma oranı} \quad (4.1)$$

Hiperdüzlemler Denklem(1.13)’de belirtildiği gibi ifade edilir. Öznitelik uzayı boyutuna göre  $\mathbf{W}$  ağırlık vektörleri sayısı belirlenir ve hiperdüzlemler hesaplanır. Hesaplanan hiperdüzlemler üzerindeki değerler destek vektörlerini belirler ve bu destek vektörleri ile veri seti sınıflandırılır.

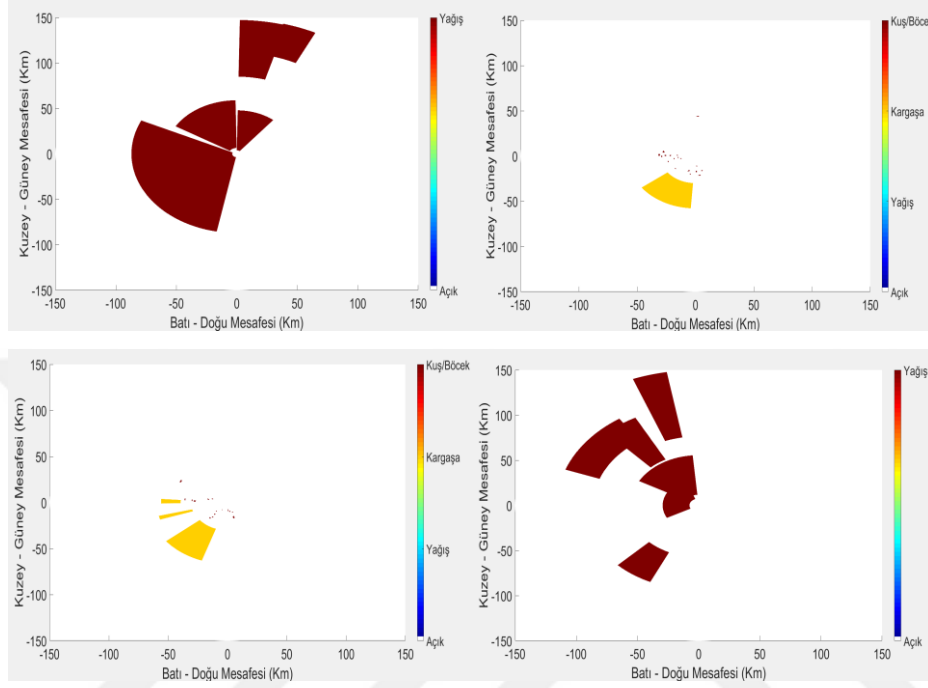
Destek vektör makineleri yüksek boyutlu veri setlerinde etkili bir şekilde çalışır. Doğrusal olan öznitelik uzaylarının yanı sıra doğrusal olmayan verilerde de kullanılabilir. Doğrusal olmayan destek vektör makineleri ve doğrusal destek vektör makineleri eğitilirken farklı kernel fonksiyonları kullanılır. Bu çalışmada doğrusal destek vektör makineleri kullanıldığı için doğrusal kernel fonksiyonu kullanılmıştır. Bu kernel dışında; polinomal, gaussian, sigmoid, kuadratik kernel fonksiyonları da kullanılmaktadır.

#### **4.2 Meteoroloji Verilerini SVM ile Sınıflandırma**

Tez kapsamında kullanılmak üzere farklı saat ve tarihlerde 40 radar görüntüsü seçilmiş ve çalışmalar bu radar görüntüleri kullanılarak devam ettirilmiştir. Radar görüntüsü seçilirken; verilerdeki ölçümlerin kaliteli ve temiz olması, veri setinde çeşitlilik kriterleri göz önünde bulundurulmuştur.

Radar veri seti sınıflandırılması için destek vektör makineleri ile sınıflandırılma hedeflenmiştir. Ancak kullanılan veri setinde yersel gerçeklik bilgisi olmadığından bir sınıflandırıcı eğitmek mümkün değildir. Bu yüzden veri setinde yersel gerçeklik bilgisi olmadığı için öncelikle radar görüntüleri incelenmiş (öznitelikler) ve bu görüntüler doğrultusunda tüm görüntüler üzerinden gözle tespit edilebilen yersel gerçeklik verileri toplanarak kaydedilmiştir. Tüm görüntülerden toplanan yersel gerçeklik bilgileri birleştirilip, sınıflandırıcı eğitimi için kullanılmak üzere tek bir matriste

toplanmıştır. Böylelikle sınıflandırıcı eğitimi için yeterli bir yersel gerçekliğe sahip veri seti oluşturulmuştur ve çalışmanın geri kalan kısmında sınıflandırıcı eğitimi için bu veri seti kullanılmıştır. Veri setindeki yersel gerçeklik bilgileriyle sınıflandırıcılar eğitilmiştir.




Şekil 4.2: Radar görüntülerinden yersel gerçeklik toplanmış bölgeler.

Tez kapsamında yapılan sınıflandırma çalışmalarında dört sınıf kullanılmıştır. Bu sınıflar; yağış, kuş-böcek, kargaşa ve açık hava olarak belirlenmiştir. Açık hava olarak tanımlanan sınıf radardan ölçüm alınamayan ve herhangi bir hidrometeorolojik hedef tespiti olmayan bölgeleri ifade etmektedir. Geri kalan sınıflar için ise sınıflandırma iki aşamada yapılmıştır. Öncelikle tüm verilerde yağış tespiti için bir sınıflandırıcı eğitilmiş, daha sonra ise yağış tespit edilemeyen bölgelerde kuş-böcek, kargaşa için yeni bir sınıflandırıcı eğitilip hidrometeor tespiti yapılmıştır. Sınıflandırma çalışmalarının en başında fiziksel öznitelikler kullanılmıştır. Tezin ilerleyen kısımlarında ise öznitelik seçimi yapıлып, seçilen fiziksel özniteliklerle sınıflandırılmalar yapılmıştır. Son olarak yeni yöntemle elde edilen doku öznitelikleri ve fiziksel öznitelikler birleştirilerek destek vektör makineleri eğitilmiştir.

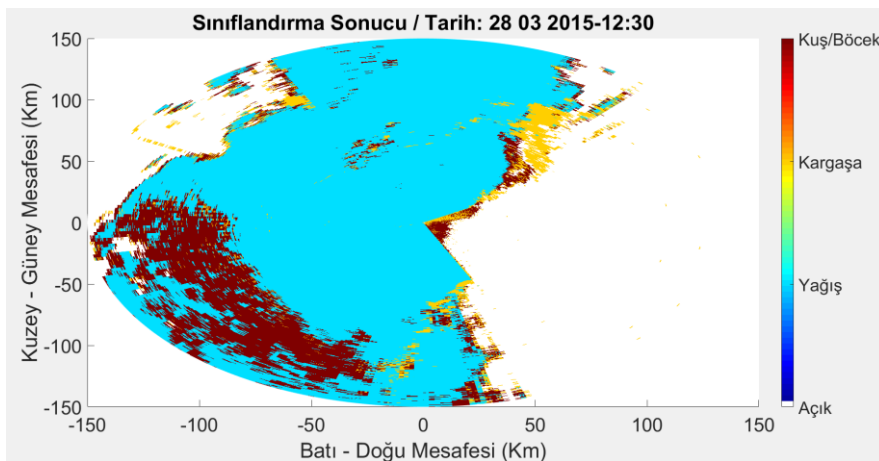
Yapılan sınıflandırmalar sonucunda yağış tespitinde ortalama %97.3'lük, kuş-böcek ve kargaşa tespitinde ise ortalama %96.6'lık bir doğruluk yüzdesi hesaplanmıştır. İki

sınıflandırıcı için ardışık bir başarımlık yüzdesi hesaplanınca ise bu başarımlık ortalaması %94 olarak hesaplanmıştır. Eğitim için kullanılan yersel gerçeklik verisi üzerinde yapılan ve sınıflandırıcı başarımlık tespiti amacıyla elde edilen bu sonuçlardan sonra eğitilen destek vektörleri ile radar görüntüleri sınıflandırılmıştır.




Şekil 4.3: Doğrusal destek vektör makineleri kullanılarak yapılan sınıflandırma sonuçları.

Radar görüntüleri sınıflandırılırken önceki sınıflandırma aşamasında olduğu gibi sınıflandırıcı eğitimi için yersel gerçekliğe sahip veri seti kullanılmış ve bu verilere göre tüm görüntü sınıflandırılmıştır. Yapılan sınıflandırma sonuçlarından elde edilen başarımlık yüzdeleri incelenince görüldüğü gibi destek vektör makineleri her iki sınıf için de oldukça yüksek bir başarımlık sahiptir. Ancak öznelilik uzayının çok boyutlu olmasından dolayı sınıflandırıcı eğitimi oldukça zaman almaktadır.



Şekil 4.4: Şekil 3.3'e ait radar verilerinin sınıflandırma sonucu.



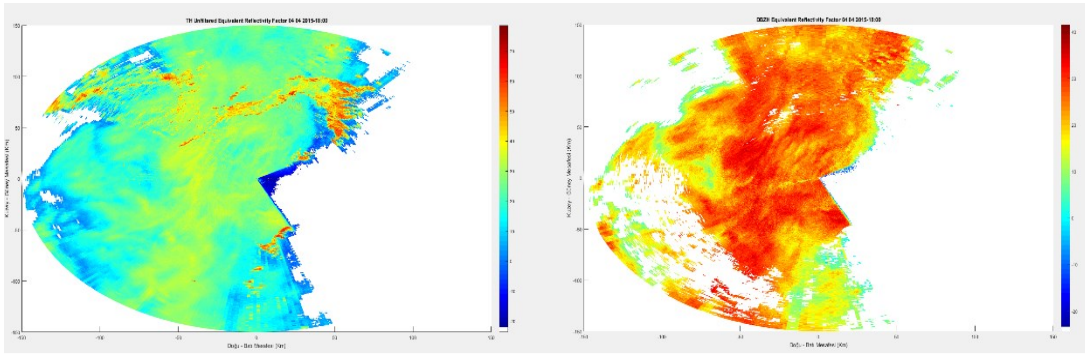
Şekil 4.5: Şekil 3.4'e ait radar verilerinin sınıflandırma sonucu.

Sınıflandırma sonuçları incelendiğinde ve öznitelik görüntüleriyle kıyaslandığında hemen hemen yağışlı bölgelerin tespiti ve yağışsız bölgelerde kuş-böcek, kargaşa tespitlerinde tutarlı sonuçlarla karşılaşılmıştır. Şekil 4.4 'te beklenildiği üzere yoğun bir yağış tespit edilmiş ayrıca radarın yakınlarında ufak çaplı kuş-böcek örnekleri gözlemlenmiştir. Ancak radarın batısında yoğun olarak tespit edilen kuş-böcek sonuçları beklenenin dışındadır. Şekil 3.3'teki öznitelikler incelendiğinde bu bölgede kuş-böcek hidrometeoru gözlenmemiştir. Şekil 4.5 incelendiğinde ise yine bazı hatalı sınıflandırma sonuçları gözlemlenmiştir. Kuzeydoğu kısmından görülen yağış dışında radarın diğer bölgelerinde de bazı piksellerde noktasal yağışlar gözlenmiştir. Ancak tek bir pikselde yağış görülmesi pek olası bir durum değildir.

Yersel gerçeklik veri seti ve radar görüntüleri sınıflandırma sonuçları doğrultusunda hem sınıflandırıcı performansının artırılması hem de hatalı durumların elemine edilip özellikle radar görüntülerinden gelen sonuçların daha tutarlı olması hedeflenmiştir. Öncelikle sınıflandırma sonuçları tekrar incelendiğinde gürültü kaynaklı hatalar tespit edilmiştir. Özellikle yağışlı havalarda, hava şartları etkisiyle farklı ve olağan dışı ölçümler aldığı tespit edilmiştir. Bu gürültülü ve hatalı ölçümlerden dolayı hem sınıflandırma sonuçları olumsuz etkilenmiş hem de gürültülü veriler eğitim setinde de kullanıldığı için sınıflandırıcı da tam olarak doğru eğitilememiştir.

### 4.3 Sınıflandırma Sonuçları Doğrultusunda Gürültülü Verinin Tespiti ve Temizlenmesi

Radar görüntülerinde gürültülü olduğu düşünülen piksellerin tespit edilmesi için daha önceden çıkarılan öznelik görüntüleri incelendi. Öznelik gruplarından özellikle radar ve hedef arasındaki diferansiyel farklar, faz farkı, gecikme ve ilinti üzerinden hesaplanan özneliklerde, diğer özneliklerde boş olduğu görülen ve hedef tespit edilemeyen piksellerden de ölçümler alındığı görüldü. Özellikle yağışlı havalarda tüm radar çevresinde yoğun bir hidrometeor saçılımı olduğu için bu özneliklerin hatalı ve gürültülü ölçümler aldığı görüldü. Şekil 3.3'te de görüldüğü gibi  $S_{QI}$  ve  $W_{RAD}$  özneliklerinin herhangi bir ölçüm alamamasına karşın  $\Phi_{DP}$ ,  $K_{DP}$ ,  $\rho_{hv}$  ve  $Z_{dr}$  öznelikleri bu piksellerden sabit ölçümler almakta ve  $V_{RAD}$  özneliği ise bu bölgelerde oldukça tutarsız saçılımlar göstermektedir. Ayrıca veri setinde bulunan  $Z_h$  özneliği Meteoroloji Genel Müdürlüğü tarafından filtre edilerek veri setine eklenmiş bir öznelik olup bu özneliğin filtre edilmemiş görüntüsü sınıflandırılma için kullanılmamasına karşın veri setinde bulunmaktadır. Filtrelenmemiş yansıtıcılık değeri veri setinde  $T_H$  olarak tanımlanmış filtrelenmiş görüntüyle beraber Şekil 4.6'da incelenmiştir. Hatalı ve gürültülü olduğu düşünülen görüntülerin bu filtreleme sonucu temizlendiği ve filtelenmiş  $Z_h$  özneliğinin hatalı ölçüm alınan pikselleri içermediği görülmüştür.

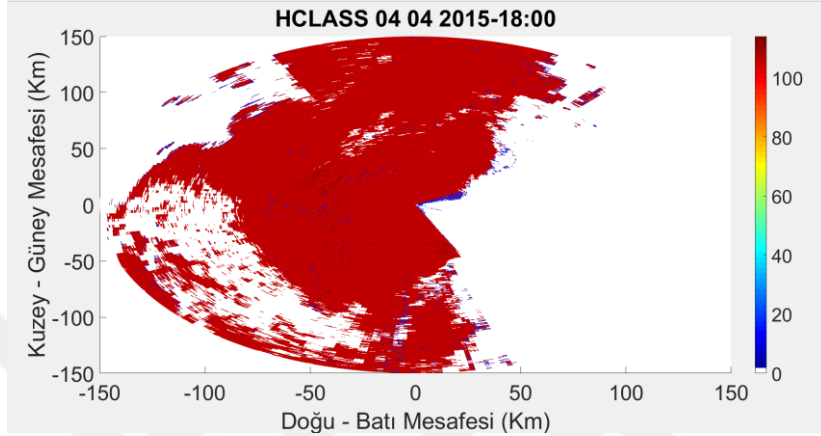


Şekil 4.6: Filtrelenmiş ve filtrelenmemiş yansıtıcılık.

Ayrıca Meteoroloji Genel Müdürlüğüne ait bir veri setiyle yapılan bir çalışmada da benzer sonuçlar görülmüştür. Bulanık mantık algoritması kullanılarak meteorolojik ve meteorolojik olmayan verileri ayırma üzerine yapılan çalışmada  $\rho_{hv}$  ve  $Z_{dr}$  öznelikleri kullanılmış ve bu özneliklerin benzer ölçüm aldığı piksellerde herhangi bir hidrometeor görülmemiş ve sınıflandırma amacıyla oluşturulmuş “hydroclass”

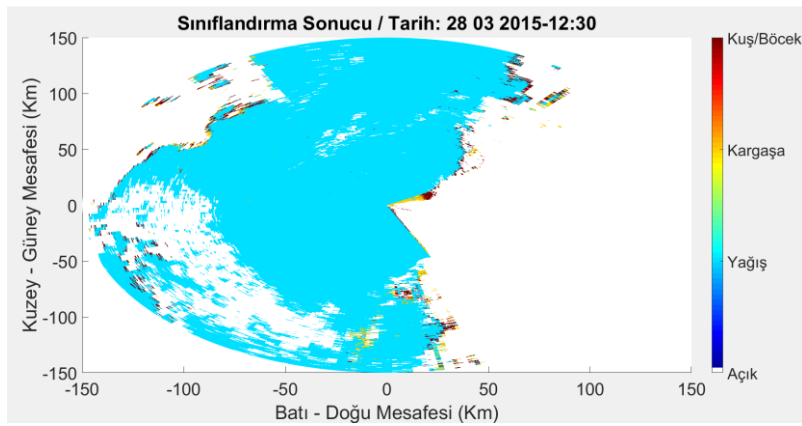


bileşenine dahil edilmemiştir [22]. Çalışmada kullanılan “hydroclass” bileşeni kullanılarak veri seti incelendiğinde Şekil 4.7’deki sonuç alınmıştır. Bu sonuçla beraber beklenen noktalarda gürültü ve hatalı ölçüm olduğu tespit edilmiş, bu bilgilere sahip radar verileri temizlenmiştir. Şekil 4.7’de görülen sonuçlarda sadece bölgedeki hedef tespit bilgisi kullanılmış, bu radar ürünüyle hedefe ait sınıflandırma sonuçlarında elde edilen sayısal bilgiler kullanılmamıştır.




Şekil 4.7: Şekil 3.3’e ait verinin Hydroclass bileşeni görüntüsü.

Hydroclass bileşeni Şekil 4.8’de incelendiğinde Şekil 4.4’te tespit edilen gürültülü bölgelerde bir hidrometeor olmadığı görülmüştür. Radar veri setindeki bu bilgi kullanılarak gürültülü bölgeler maskelenip temizlenerek, tekrar eğitilen ve gürültülü verileri içermeyen destek vektör makineleri sınıflandırıcı uygulamaları birleştirilerek sınıflandırma sonuçları incelenmiş ve gürültülü verilerle yapılan sınıflandırma sonuçlarıyla karşılaştırılmıştır.



Şekil 4.8: Şekil 4.4’e ait veriye gürültü filtremesi yapılmış sınıflandırma sonucu.



Şekil 4.9: Şekil 4.5'e ait veriye gürültü filtremesi yapılmış sınıflandırma sonucu.

Sınıflandırma sonuçları incelendiğinde gürültü ve hatalı sinyaller temizlendikten sonra elde edilen sınıflandırma sonuçları daha tutarlıdır. Gürültü filtreme öncesi yapılan sınıflandırma sonuçları incelendiğinde, Şekil 4.8'de görüldüğü gibi bu radar görüntüsüne ait önceki sınıflandırma sonuçlarında görülen batı bölgesindeki hatalı ve büyük ölçekli bir alan kaplayan kuş/böcek sonuçları temizlenmiştir. Şekil 4.9 incelendiğinde ise yine gürültülü veriler temizlenmiştir. Ancak çok yağış olmadığı için gürültü az olduğundan radar görüntüsünde çok fazla değişiklik gözlemlenmemiştir.

## 5. METEOROLOJİK RADAR VERİLERİNİ SINIFLANDIRMA İÇİN ÖZNETELİK SEÇİMİ

Bu bölümde Radar veri setinde bulunan sekiz öznitelik arasından bir öznitelik seçimi yapılmıştır. Literatürde daha önce yapılan çalışmalarda, meteoroloji radar verileri sınıflandırılması üzerine bir öznitelik seçimi yapılmamıştır. Dolayısı ile, geliştirdiğimiz öznitelik seçim yöntemleri literatürdeki bu boşluğu doldurulmayı amaçlamıştır [23-25]. Sınıflandırma aşamalarında gerekli özniteliklerin tespiti hedeflenen çalışmada iki sınıflandırma aşaması için de öznitelikler hesaplanmıştır [11].

Öznitelik seçimi için yapılan çalışmada doğrusal ayrımcılık analizi (linear discriminant analysis) sınıflandırma metodu kullanılmıştır. Doğrusal ayrımcılık analizi, sınıflar arası ayrımı yapmak için en iyi ayıran değişkenler arasında doğrusal bir kombinasyon bulma konseptine dayanmaktadır [26].

Doğrusal ayrımcılık analizi ile yapılan çalışmada, öznitelik seçimi için öncelikle özniteliklerin veri setindeki dağılımları ve farklı sınıflar için ayırt ediciliği Fischer Skor metodu ile hesaplanmıştır [11]. Fischer Skor, her bir özneliğin iki sınıfa ait ortalama değerleri ve varyansları üzerinden, özneliğe ait bir ayırt etme potansiyeli hesaplanır [27].

$$F(x) = \frac{(\mu_i - \mu_j)^2}{\sigma_i + \sigma_j} \quad (5.1)$$

Denklem(5.1)'de  $\mu_i$  ve  $\mu_j$  iki sınıfa ait  $x$  özneliğine ortalamalarını,  $\sigma_i$  ve  $\sigma_j$  ise bu sınıflara ait öznitelik varyanslarını temsil etmektedir.  $X$  numaralı öznitelik için Fischer Skor sonucu  $F(x)$ 'tir. Sınıflandırıcının iki aşaması için Fischer Skor değerleri çıkarılmıştır ve Çizelge-5.1'deki sonuçlar elde edilmiştir.

Çizelge 5.1: Fischer Skor [11].

Yağış	$\Phi_{DP}$	$V_{RAD}$	$K_{DP}$	$\rho_{hv}$	$Z_h$	$W_{RAD}$	$Z_{dr}$	SQI
Var-Yok								
Tespiti	0,3026	0,0538	0,0195	2,419	5,239	0,6616	0,2609	0,0263
Kuş-Böcek	$\Phi_{DP}$	$VRAD$	$KDP$	$\rho_{hv}$	$Z_h$	$WRAD$	$Zdr$	$SQI$
Kargaşa								
Tespiti	0,0574	2,950	0,0005	0,0533	0,1918	0,0033	0,1878	0,4915

Fischer skorlar hesaplandıktan tüm özniteliklere ait tekli sınıflandırma sonuçları hesaplanmıştır. Öznitelik seçiminin bu aşamasında yersel gerçekliğe sahip veri seti kullanılmıştır. Böylelikle her bir öznitelikliğin veri setini sınıflandırmasına ait performansları elde edilip, öznitelik seçimi için ikinci bir metrik oluşturulmuştur.

Çizelge 5.2: Tekli öznitelik sınıflandırma başarımları [11].

Yağış	$\Phi_{DP}$	$V_{RAD}$	$K_{DP}$	$\rho_{hv}$	$Z_h$	$W_{RAD}$	$Z_{dr}$	SQI
Var-Yok								
Tespiti	%90,6	%57,7	%67,4	%93,2	%95,3	%68,3	%87,2	%61,6
Kuş-Böcek	$\Phi_{DP}$	$VRAD$	$KDP$	$\rho_{hv}$	$Z_h$	$WRAD$	$Zdr$	$SQI$
Kargaşa								
Tespiti	%57,0	%95,7	%17,4	%55,0	%80,7	%52,9	%63,0	%80,6

Fischer Skor değerleri ve tekli öznitelik sınıflandırma başarımları incelendikten sonra iki sınıflandırma aşaması için (yağış tespiti, kuş-böcek ve kargaşa tespiti) belirleyici olan veya etkisiz olan öznitelikler büyük ölçüde tespit edilebilmiştir. Elde edilen Fischer skor ve başarımlar yüzdelere göre yağış tespiti için  $\rho_{hv}$  ve  $Z_h$  özniteliklerinin oldukça belirleyici ve ayırt edici öznitelikler olduğu Çizelge-5.1 ve Çizelge-5.2 incelendiğinde görülmüştür. Radyal hız bileşeni ( $V_{RAD}$ ) özniteliğinin tablolardaki değerleri incelendiğinde ise yağış tespiti için verileri ayırmada oldukça etkisiz olduğu görülmüştür. Öte yandan  $V_{RAD}$  özniteliği Kuş/Böcek-Kargaşa tespitine ait sınıflandırma aşamasında hem Fischer Skor değerleri hem de bireysel başarımlar yüzdesi incelendiğinde büyük derecede ayırt edici bir öznitelik olduğu tespit edilmiştir. Ayrıca bu sınıflandırma aşaması için ise  $K_{DP}$ ,  $\rho_{hv}$  ve  $W_{RAD}$  özniteliklerinin sınıflandırma sonucuna faydası olmadığı da yine Çizelge-5.1 ve Çizelge-5.2’de görülmüştür. İki

sınıflandırma aşaması için de önemli olan öznitelikler kısmen belirlenmiştir. Ayrıca sonuçlar incelendiğinde özellikle yağış tespiti için büyük ölçüde belirleyici olan  $\rho_{hv}$  özneliğinin kuş/böcek-kargaşa tespiti için bir etkisi olmadığı aynı zamanda kuş/böcek-kargaşa tespiti için belirleyici bir öznitelik olan  $V_{RAD}$  özneliğinin ise yağış tespitinde verimli olmadığı görülmüştür.

Öznitelik seçimi için bir sonraki aşamada özniteliklerin beraber kullanıldığı durumlarda başarımların performansları incelenmiştir. Tüm öznitelik kullanılarak, sekiz özneliğin tüm alt kümeleri kapsayan  $2^8$  kombinasyonu ile 256 sınıflandırma yapılmış ve bu sınıflandırma sonuçları incelenmiştir. Çizelge-5.3 her iki sınıflandırma aşaması için de Fischer Skor ve bireysel başarımları göz önünde bulundurularak belirlenen önemli özniteliklerin beraber kullanılması ile eğitilen sınıflandırıcılara ait sınıflandırma doğruluk yüzdeleri gösterilmiştir.

Çizelge 5.3: Toplu başarımların sonuçları [11].

Yağış Var-Yok Tespiti	Öznitelikler	$W_{RAD} - \rho_{hv} - Z_h$	$Z_h - \rho_{hv}$	$\rho_{hv} - Z_h - \Phi_{DP}$	$Z_h - \Phi_{DP} - Z_{dr}$
	Başarımlar	%97,2	%96,9	%95,9	%95,8
Kuş- Böcek Kargaşa Tespiti	Öznitelikler	$Z_h - V_{RAD} - S_{QI}$	$V_{RAD} - S_{QI}$	$Z_{dr} - V_{RAD} - S_{QI}$	$V_{RAD} - Z_h$
	Başarımlar	%95,90	%95,94	%96	%95,7

Fischer Skor analizi, bireysel ve toplu sınıflandırma başarımların yüzdeleri tespitleri sonucunda yağış tespiti için  $W_{RAD}$ ,  $\rho_{hv}$ ,  $Z_h$  özneliklerinin Çizelge-5.3'e göre %97,2'lik bir doğruluk oranı gösterdiği görülmüş ve sadece bu üç öznitelik kullanılarak elde edilen başarımların, tüm öznitelikler kullanılarak elde edilen başarımların yüzdesiyle kıyaslanmıştır. Tüm öznitelikler kullanılarak ve eğitilen doğrusal ayrımcılık analizi sınıflandırıcısı %97,3 doğruluk değerinde bir sınıflandırma başarımlarını göstermiştir [11]. Bu iki sonuç kıyaslandığında seçilen öznitelikler elde edilen başarımlar oldukça yakındır. Fischer Skor ve sınıflandırma sonuçları göz önüne alınarak yapılan öznitelik seçimiyle bu üç özneliğin diğer özniteliklerden daha sınıflandırma için daha belirleyici olduğu ispatlanmıştır.

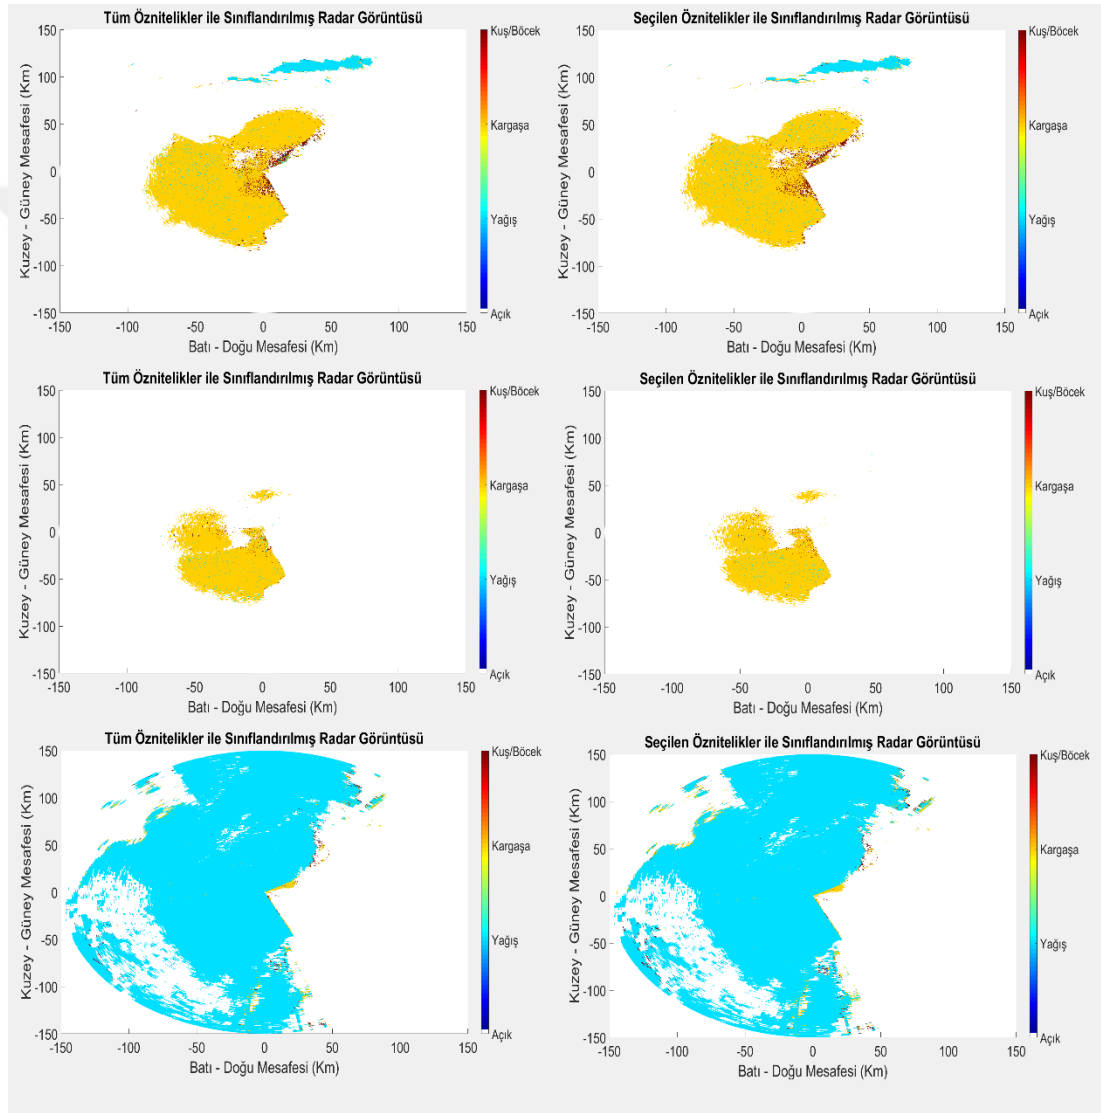
Kuş/Böcek-Kargaşa tespiti için yapılan Fischer Skor analizi, bireysel ve toplu sınıflandırma başarımları yüzdeleri incelendiğinde ise Çizelge-5.3'e göre  $V_{RAD}$  ve  $S_{QI}$  özneliklerinin %95,94'lük bir oranı gösterdiği görülmüştür. Tüm öznelikler kullanılarak ve eğitilen doğrusal ayrımcılık analizi sınıflandırıcısı %95,95 doğruluk değerinde bir sınıflandırma başarımları göstermiştir [11]. Sadece iki öznelik kullanılarak hemen hemen eşit bir başarımları yüzdesi (%95,95) sağlanmıştır.  $V_{RAD}$  ve  $S_{QI}$  özneliklerinin Fischer Skor ve tekli başarımları yüzdeleri de incelendiğinde elde edilen sonuçlar ve toplu başarımları yüzdeleri arasında tutarlılık sağlanmıştır. Kuş/Böcek-Kargaşa tespiti için öznelik seçimi yapıldığında, iki özneliği sınıflandırıcı için yeterli olduğu görülmüştür.

Yersel gerçeklik verisi kullanılarak yapılan öznelik seçiminden sonra öznelik seçiminin radar görüntülerini sınıflandırma üzerine etkileri incelenmiştir. Tüm öznelikler kullanılarak eğitilen doğrusal ayrımcılık analizi sınıflandırıcısı sonuçları ve seçilen öznelikler doğrultusunda eğitilen doğrusal ayrımcılık analizi sınıflandırıcısı ile elde edilen radar görüntüleri kıyaslanmıştır. Veri setindeki tüm radar görüntüleri incelendiğinde, matematiksel başarımları yüzdelerinin yakınlığından dolayı gözle çok fazla farklılıklar tespit edilememiştir. Öznelik seçimi öncesi ve sonrası radar görüntülerinin kıyaslamalarında bire bire yakın sonuçlar gözlenmiş ve olağandışı sınıflandırma sonuçları tespit edilememiştir. Şekil 5.1'de radar görüntüleri incelendiğinde öznelik seçimi yapıldıktan elde edilen sonuçlar ilk sınıflandırma sonuçlarıyla büyük ölçüde tutarlılık göstermektedir. Sonuç olarak, öznelik seçimi ile öznelik uzayı boyutları azalmış, gereksiz öznelikler veri setinden çıkarılmış ve böylece daha verimli bir sınıflandırıcı elde edilmiştir.

Seçilen öznelikler tez kapsamında sınıflandırıcı olarak seçilen destek vektör makineleri için sınıflandırmada kullanılıncaya ise sınıflandırma sonuçlarının hemen hemen aynı olduğu görülmüştür. Öznelik seçimi için yapılan bu çalışmada [11], öznelik seçimi için doğrusal ayrımcılık analizi kullanılmasının sebebi bu sınıflandırıcının destek vektör makinelerine göre daha hızlı sınıflandırıcı eğitimi yapmasıdır. Fakat tez kapsamındaki çalışmalara, yavaş çalışmasına rağmen daha yüksek başarımları gösteren destek vektör makineleriyle devam edilmiştir. Öznelik uzayının boyutunun fazlalığından dolayı oluşan olumsuzluklar giderilmiştir. Destek vektör makineleri kullanılarak ve seçilen özneliklerle beraber eğitilen sınıflandırıcı,

tüm öznitelikler kullanılarak eğitilen sınıflandırıcıdan çok daha kısa sürede sonuç vermeye başlamıştır.

Tüm veri setindeki radar görüntüleri incelendiğinde, öznitelik seçimi sonrası elde edilen görüntüler ve tüm öznitelikler kullanılarak elde edilen görüntüler büyük ölçüde aynıdır ve öznitelik seçimi sonrası sınıflandırma sonuçlarında kayda değer bir başarı kaybı olmamasıyla beraber hem sınıflandırıcı verimi artmış hem de iki sınıflandırma aşaması içinde ideal öznitelikler belirlenmiştir.



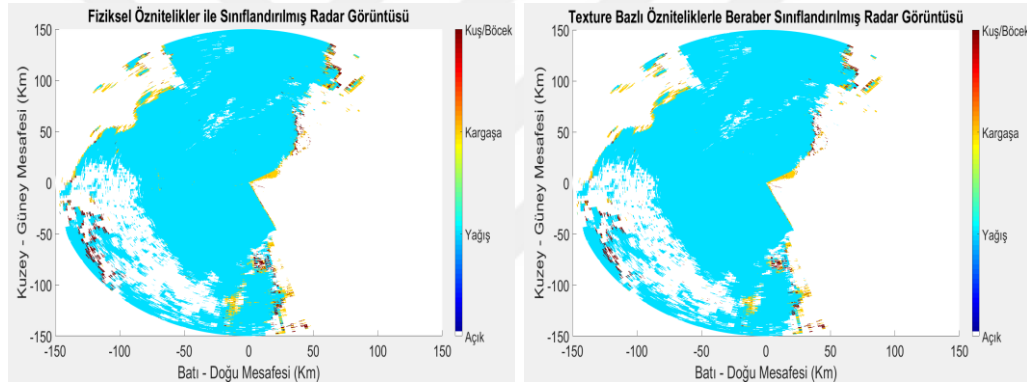
Şekil 5.1: Farklı tarihlerdeki radar görüntülerinin öznitelik seçimi ile sınıflandırma sonuçları.






## 6. DOKU ÖZNETELİKLERİ EKLENMİŞ ÖZNETELİK UZAYI İLE SINIFLANDIRMA

Sınıflandırma sonuçlarının oluşturduğu komşuluk ilişkileri doğrultusunda hesaplanan doku öznitelikleri, öznitelik seçimi sonrası yağış tespiti için belirlenen üç öznitelik ile birleştirilerek oluşturulan öznitelik uzayı kullanılarak eğitilen doğrusal destek makineleri sınıflandırıcı sonuçları incelendiğinde elde edilen görüntüler daha tutarlı olmuştur. Bölgesel olan hatalı yağış sonuçları büyük ölçüde temizlenmiş ve ayrıca yoğun yağış altında görülen ve hatalı olabilecek kargaşa ve kuş tespiti sonuçlarının önüne geçilmiştir.



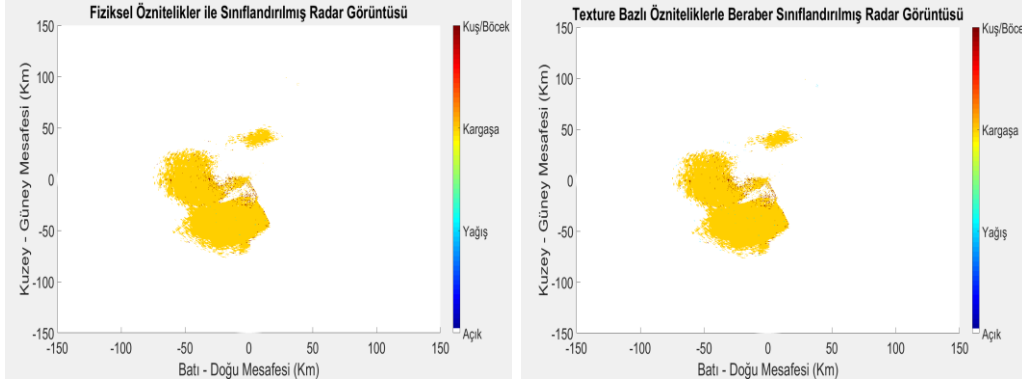
Şekil 6.1: 28 Mart 2015 12:30 tarihine ait veri için öznitelik seçimi sonrası sınıflandırma sonuçları ve doku öznitelikleri eklendikten sonra sınıflandırma sonuçları.

Radar görüntüleri detaylı bir şekilde incelendiğinde Şekil 6.1’de görülen yoğun yağış altında alınan radar verisinde yağışlı bölgelerde daha pürüzsüz ve temiz geçişler olduğu gözlemlenmiştir. Ancak beklenildiği üzere yoğun yağışlı zamanlarda alınan bu tarz verilerde çok fazla değişimler görülmemiştir. Bunun sebebi önceden de bahsedildiği üzere yağış altında küçük alanlarda ve tek bir pikselde bile kuş/böcek veya kargaşa tespiti mümkündür. Ancak seçilen öznitelikler doğrultusunda elde edilen skorlar ile oluşturulan doku özniteliklerinden dolayı yine bazı piksellerde düzelmeler olmuştur.



Şekil 6.2: 4 Nisan 2015 18:00 tarihine ait veri için öznitelik seçimi sonrası sınıflandırma sonuçları ve doku öznitelikleri eklendikten sonra sınıflandırma sonuçları.


Başka bir tarihe ait radar görüntüleri detaylı bir şekilde incelendiğinde ise Şekil 6.2’de görülen yağışsız ve genellikle kuş/böcek, kargaşa verilerine sahip görüntüde ise kuzeydoğu bölgesinden gelen yağışa rağmen radar görüntüsünün diğer kısımlarında yağış görülmemektedir. Ancak doku öznitelikleri sınıflandırıcıya eklenmeden önce özellikle batı ve güney batı kesimlerde yer yer yağışlar tespit edilmiştir. Doku bazlı öznitelikler eklendikten sonra bu hatalı tespitler büyük ölçüde temizlenmiş ve daha isabetli bir sınıflandırma yapılmıştır.



Şekil 6.3: 22 Mart 2015 22:53 tarihine ait veri için öznitelik seçimi sonrası sınıflandırma sonuçları ve doku öznitelikleri eklendikten sonra sınıflandırma sonuçları.

Özellikle hiç yağış olmayan bir zaman aralığında alınan radar görüntüsü incelendiğinde doku özniteliklerinin bu durumda oldukça verimli çalıştığı görülmektedir. Bilindiği üzere Hatay Meteoroloji Radarı’nın konumunda kaynaklı bir şekilde bu radarın çevresinde yoğun bir deniz kargaşası bulunmaktadır. Radardan alınan ölçümler sonrasında elde edilen öznitelikler ile yapılan sınıflandırmalarda ise

özellikle yağışsız havalarda yağış tespitinin sebebi bu deniz kargaşaları olmaktadır. Destek vektör makineleri kullanılarak hazırlanan sınıflandırıcı her ne kadar deniz kargaşaları ve yağışı ayırt etmede başarılı olsa da yine de bazı hatalar oluşmaktadır. Özellikle Şekil 6.4'teki radar görüntüsünü daha yakından incelersek doku öznitelikleri eklendikten sonra bu hatalı sınıflandırmaların büyük ölçüde ortadan kalktığını görebiliriz.



Şekil 6.4: Yakınlaştırılmış görüntü (A) Doku öznitelikleri ile beraber sınıflandırma sonuçları (B) Sadece fiziksel öznitelikler ile sınıflandırma sonucu.

Radar görüntüleri incelendiğinde kısmen de olsa doku özniteliklerinin sınıflandırma sonuçlarına etkisi görülebilmektedir. Detaylı ve daha isabetli bir sonuç elde etmek için görüntülerde doku öznitelikleri eklenip tekrarlanan sınıflandırma sonucunda değişen piksellere ait bilgiler incelendiğin yeni metodun daha başarılı sonuçlar verdiği görülebilmektedir.

Veri setindeki tüm radar görüntüleri doku öznitelikleri eklenerek tekrar sınıflandırıldığında elde edilen sonuçlar, ilk sınıflandırma sonuçlarıyla büyük ölçüde paraleldir. Yağışlı veriler incelendiğinde, doku öznitelikleri eklenerek yeniden eğitilen destek vektör makinesi sınıflandırıcı radar görüntülerinin sınıflandırma sonuçlarını yağışsız verilere oranla daha az etkilediği görülmüştür. Yağışsız verilerde daha yüksek bir sınıflandırma değişim oranının olmasının sebebi önceden de belirtildiği gibi, yağış tespitindeki hataların en büyük kaynağının yağışsız havalarda kuş/böcek ve kargaşanın (özellikle kuş sürülerinin) bölgesel bir yağış gibi tespit edilip hatalı sınıflandırılmasıdır. Ayrıca yeni sınıflandırma sonuçlarıyla beraber değişen piksellerin hem enerjileri hem de skorları düşük pikseller olduğu, tüm görüntüde değişmeyen piksellerin enerjisi ve skorlarından oldukça düşük bir ortalmaya sahip olduğu tespit

edilmiştir. Bu bağlamda değişen piksellerin yoğun bir şekilde ilk aşamada yapılan (sadece radar verileri kullanılarak yapılan sınıflandırma aşaması) sınıflandırma sonucu hatalı olan pikseller olduğu görülmüştür. Öznitelik seçimi yapıldıktan sonra ve doku öznitelikleri elde edilip öznitelik uzayına eklenmeden önce yağış tespiti için destek vektör makineleri sınıflandırıcı doğruluk yüzdesi %97.3 olarak hesaplanmıştır. Bu çalışmalar sonucunda yağış tespitindeki sınıflandırıcı başarısı (özellikle yağışsız havalardaki hatalı yağış sonuçlarının temizlenmesi sonucu) büyük ölçüde artırılmıştır. Yersel gerçeklik bilgisine sahip verine seti baz alınarak yapılan sınıflandırmada ise sadece doku öznitelikleri kullanılarak %96.9'luk bir başarımla sağlanmıştır. Yersel gerçeklik bilgisine sahip radar verilerinden oluşan, yersel gerçeklik matrisinde öznitelik seçimi yapıldıktan sonra elde edilen fiziksel öznitelik uzayına doku öznitelikleri eklenerek yapılan sınıflandırmalarda ise sadece seçilen fiziksel öznitelikler kullanılarak yağış tespitinde %97.3 olan başarımla %97.53'e yükseldiği görülmüştür.

## 7.SONUÇLAR

Tez kapsamında, Hatay bölgesine ait meteoroloji radarından alınan veriler incelenmiştir. Radar verilerinden elde edilen öznitelikler hakkında bilgi edinilmiştir. Veri seti çalışmaya uygun hale getirildikten sonra ise destek vektör makineleri kullanılarak bir sınıflandırıcı eğitilmiştir. Sınıflandırma sonuçları doğrultusunda ise öznitelik seçimi yapılmış ve doku bazlı öznitelikler öznitelik uzayına eklenmiştir. Yapılan çalışmalara ve elde edilen sonuçlar incelendiğinde, radar veri setinde bulunan sekiz fiziksel öznitelik ve hesaplanan iki doku özniteliği içinden en etkili öznitelikler belirlenerek bir öznitelik uzayı belirlenmiştir. Yeni bir yöntem kullanılarak hesaplanan doku özniteliklerinin birçok fiziksel özniteliğe oranla daha isabetli bir sınıflandırma yaptığı görülmüştür. Öznitelik uzayının boyutları azaltılarak sınıflandırıcı performansı optimize edilmiştir. Gürültülü verileri temizlenen radar görüntülerine uygulanan sınıflandırmalar sonucunda da bu öznitelikler ile sınıflandırıcı performansında faydalı bir artış görülmüştür.

Bu tez çalışmasının literatürü katkısı şöyle ifade edilebilir; öncelikle meteoroloji radarlarına ait verilerin işlenip sınıflandırılması üzerine tez çalışmaları yerli literatürde oldukça azdır ve bu tezde adım adım salt bir meteorolojik veri seti kullanılarak detaylı bir şekilde sınıflandırma sonuçlarına ve bu sonuçların iyileştirilmesine kadar gidilmiştir. Ayrıca ülkemizdeki meteoroloji radarları verilerinin temini, işlenmesi ve kullanımını konularında da yerli literatürdeki boşluğu kapatmıştır.

Özet olarak tez çalışmasının katkısını iki farklı noktada değerlendirebiliriz. İlk olarak, meteorolojik radar verilerinin sınıflandırılması ve hava durumu tespiti çalışmaları için bir öznitelik seçimi yapılmıştır. İkinci olarak da, meteorolojik radar verilerini sınıflandırmak için radardan gelen spektral verilerin yanı sıra hesaplanan doku bazlı spatial öznitelikler kullanılmış ve sınıflandırıcı performansına ve radar sınıflandırma sonuçlarına ait radar görüntülerindeki doğruluk oranlarını artırmıştır.

Öznitelik seçimi sonrası ve öncesi yapılan sınıflandırma sonuçları kıyaslandığında doğrusal ayırmacılık analizi sınıflandırıcıları hemen hemen aynı başarıyı gösterirken,

destek vektör makineleri seçilen özniteliklerle eğitilince başarımları artmıştır. Ayrıca öznitelik seçiminin yanı sıra gürültü ve hatalı ölçüm alınan bölgeler temizlendikten sonra radar görüntülerinde de oldukça tutarlı sonuçlar elde edilmiştir.

Doku öznitelikleri elde edilip bu öznitelikler spektral özniteliklerle birleştirilerek yapılan sınıflandırmalarda ise özellikle yağışsız havalarda tespit edilen bölgesel yağış hataları temizlenmiştir. Doku öznitelikleri doğrultusunda yapılan sınıflandırmalarda eski sınıflandırma yöntemine göre iyileştirilmiştir. Fiziksel öznitelikler ve doku öznitelikleri beraber kullanılarak %97.3 olan yağış tespiti başarımları yüzdesi bu özniteliklerin eklenmesiyle beraber %97.53'e yükselmiş hatalı sınıflandırma sonuçları kayda değer bir ölçüde giderilmiştir.

Tez kapsamında yapılan çalışmalar doğrultusunda [11] bir konferans makalesi yayınlanmıştır. Ayrıca tez çalışmaları sırasında yapılan akademik seyahatler doğrultusunda [19] iki adet konferans makalesinin yayınına katkıda bulunulmuştur [18,20].

Gelecek çalışmalarda ise, tez çalışmaları doğrultusundaki yöntemler kullanılarak Meteoroloji Genel Müdürlüğü'nden yılın her mevsimini kapsayan ve daha sık aralıklarla toplanan radar görüntülerinden bir veri seti oluşturulması hedeflenmiştir. Bu veri seti ile sınıflandırma yapılırken hem mevsimlere ve coğrafik şartlara ait doğal kurallar ön koşul olarak kullanılıp hem de radar görüntüleri arasındaki zamansal ilişkiler (ortalama üç veya dört dakikada bir alınan radar görüntüleri) kullanılarak istatistiksel bağlantılar kurulması amaçlanmıştır.

## KAYNAKLAR

- [1] **Zrnic, D. S., & Ryzhkov, A. V.** (1998). Observations of insects and birds with a polarimetric radar. *IEEE Transactions on Geoscience and Remote Sensing*, 36(2), 661-668.
- [2] **Xiao, R., Chandrasekar, V., Liu, H., & Gorgucci, E.** (1998, July). Detection of rain/no rain condition on ground from radar data using a Kohonen neural network. In *Geoscience and Remote Sensing Symposium Proceedings, 1998. IGARSS'98. 1998 IEEE International* (Vol. 1, pp. 159-161). IEEE.
- [3] **Ryzhkov, A., Zrnic, D., Doviak, R., & Zhang, P.** (2003, July). Development of a classification algorithm for operational polarimetric NEXRAD radar. In *Geoscience and Remote Sensing Symposium, 2003. IGARSS'03. Proceedings. 2003 IEEE International* (Vol. 2, pp. 869-871). IEEE.
- [4] **da Silveira, R. B., & Holt, A. R.** (2001). An automatic identification of clutter and anomalous propagation in polarization-diversity weather radar data using neural networks. *IEEE transactions on geoscience and remote sensing*, 39(8), 1777-1788.
- [5] **Gill, R. S., Soerensen, M. B., Boevith, T., Koistinen, J., Peura, M., Michelson, D., & Cremonini, R.** (2012, June). BALTRAD dual polarization hydrometeor classifier. In *Proc. Seventh European Conf. on Radar in Meteorology and Hydrology*.
- [6] **Siggia, A. D., & Passarelli, R. E.** (2004, September). Gaussian model adaptive processing (gmap) for improved ground clutter cancellation and moment calculation. in *Proc. ERAD, vol. 67, 2004*.
- [7] **Wang, P., Zhang, Y., & Jia, H. Z.** (2012, July). Doppler weather radar clutter suppression based on texture feature. In *Machine Learning and Cybernetics (ICMLC), 2012 International Conference on* (Vol. 4, pp. 1339-1344). IEEE.
- [8] **Hu, W., Huang, X., & Li, Y.** (2008, May). Texture analysis on weather radar images of severe convective precipitation in the Arid Area of Ningxia. In *Image and Signal Processing, 2008. CISP'08. Congress on* (Vol. 2, pp. 150-154). IEEE.
- [9] **Alparone, L., Benelli, G., & Vagniluca, A.** (1990, August). Texture-based analysis techniques for the classification of radar images. In *IEE Proceedings F (Radar and Signal Processing)* (Vol. 137, No. 4, pp. 276-282). IET Digital Library.

- [10] **Yozgatligil, C., Aslan, S., Iyigun, C., & Batmaz, I.** (2013). Comparison of missing value imputation methods in time series: the case of Turkish meteorological data. *Theoretical and applied climatology*, 112(1-2), 143-167.
- [11] **Hamurcu, E., Yetik, I. S.** (2018 May). Feature Selection for Optimal Weather Detection with Meteorological Radar Data, *SIU*
- [12] **Ryzhkov, A., Zrnic, D., Doviak, R., & Zhang, P.** (2003, July). Development of a classification algorithm for operational polarimetric NEXRAD radar. *In Geoscience and Remote Sensing Symposium, 2003. IGARSS'03. Proceedings. 2003 IEEE International (Vol. 2, pp. 869-871)*. IEEE.
- [13] **Bringi, V.N., Chandrasekar, V.** *Polarimetric Doppler Weather Radar Principles and Applications*, (Sf. 368-371)
- [14] **Roberto, N., Baldini, L., Adirosi, E., Facheris, L., Cuccoli, F., Lupidi, A., & Garzelli, A.** (2017). A Support Vector Machine Hydrometeor Classification Algorithm for Dual-Polarization Radar. *Atmosphere*, 8(8), 134.
- [15] **Haralick, R. M., & Shanmugam, K.** (1973). Textural features for image classification. *IEEE Transactions on systems, man, and cybernetics*, (6), 610-621.
- [16] **Tarabalka, Y., Fauvel, M., Chanussot, J., & Benediktsson, J. A.** (2010). SVM- and MRF-based method for accurate classification of hyperspectral images. *IEEE Geoscience and Remote Sensing Letters*, 7(4), 736-740.
- [17] **Artan, Y., Langer, D. L., Haider, M. A., van der Kwast, T. H., Evans, A. J., Wernick, M. N., & Yetik, I. S.** (2009, June). Prostate cancer segmentation with multispectral MRI using cost-sensitive conditional random fields. *In Biomedical Imaging: From Nano to Macro, 2009. ISBI'09. IEEE International Symposium on (pp. 278-281)*. IEEE.
- [18] **Tuncalı, T., Gürbüz, S. Z., Koistinen, J., Leskinen, M., Dokter, A., Hamurcu, E., Öztopal, A.** (2016 October). Cross Validation of Bird Detections Using Meteorological Radar, Bird Radar and Field Observations , *ERAD*
- [19] **Hamurcu, E.** (April 2016). Biological Classification Algorithms for Turkish Single and Dual Pol Weather Radar STSM Report, *FMI*
- [20] **Koistinen, J., FMI, Leskinen, M., Pulkkinen, S., Tyynelä, J., Mäkinen, T., Gürbüz, S. Z., Hamurcu, E.** (2016 October). Classification of Non-Meteorological Echoes from Finnish and Turkish Dual-Polarization Weather Radar Data , *ERAD*
- [21] **C. J. C. Burges**, *A Tutorial on Support Vector Machines for Pattern Recognition. Data Mining and Knowledge Discover*, 2(2): (Sf. 121-168), 1998y
- [22] **Macit, A., Gedeli, S., Taştan, M. A., Kuş ve Böcek Kaynaklı Biyolojik Hedeflerin Dual Polarize Meteoroloji Radarlarından Tespiti, MGM Uzaktan Algılama Birimi**



- [23] **Marzano, F. S., Scaranari, D., & Vulpiani, G.** (2007). Supervised fuzzy-logic classification of hydrometeors using C-band weather radars. *IEEE Transactions on Geoscience and Remote Sensing*, 45(11), 3784-3799.
- [24] **Grazioli, J., Tuia, D., & Berne, A.** (2015). Hydrometeor classification from polarimetric radar measurements: a clustering approach. *Atmospheric Measurement Techniques*, 8(1), 149.
- [25] **Gill, R. S., Soerensen, M. B., Boevith, T., Koistinen, J., Peura, M., Michelson, D., & Cremonini, R.** (2012, June). BALTRAD dual polarization hydrometeor classifier. In *Proc. Seventh European Conf. on Radar in Meteorology and Hydrology*.
- [26] **Theodoridis, S., Koutroumbas, K.,** *Pattern Recognition* Fourth Edition, (Sf. 91-93)
- [27] **Tang, J., Alelyani S., and Liu, H.,** *Data Classification: Algorithms and Applications*, Feature Selection for Classification, (Sf. 38-58)



## ÖZGEÇMİŞ

**Ad-Soyad** : EREN HAMURCU  
**Uyruđu** : T.C.  
**Dođum Tarihi ve Yeri** : 06.03.1992-AVUSTURYA  
**E-posta** : erenhamurcu@gmail.com

### ÖĐRENİM DURUMU:

- **Lisans** : 2015, TOBB Ekonomi ve Teknoloji Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliđi

### MESLEKİ DENEYİM VE ÖDÜLLER:

Yıl	Yer	Görev
2016-2018	TOBB Ekonomi ve Teknoloji Üniversitesi	Burslu Y.Lisans Öğrencisi

**YABANCI DİL:** İngilizce, Almanca

### TEZDEN TÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER:

**Hamurcu, E.** (April, 2016). Biological Classification Algorithms for Turkish Single and Dual Pol Weather Radar STSM Report,

**Koistinen, J., FMI, Leskinen, M., Pulkkinen, S., Tyynelä, J., Mäkinen, T., Gürbüz, S. Z., Hamurcu, E.** (2016, October). Classification of Non-Meteorological Echoes from Finnish and Turkish Dual-Polarization Weather Radar Data , *ERAD*

**Tuncalı, T., Gürbüz, S. Z., Koistinen, J., Leskinen, M., Dokter, A., Hamurcu, E., Öztopal, A.** (2016, October). Cross Validation of Bird Detections Using Meteorological Radar, Bird Radar and Field Observations , *ERAD*

**Hamurcu, E., Yetik, I. S.** (2018, May). Feature Selection for Optimal Weather Detection with Meteorological Radar Data, *SİU*