



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



ÖZELLİK MODELLERİ İÇİN BULANIK
İNTEGRAL OPERATÖRÜ

Alper KILIÇ

DOKTORA TEZİ

Bilgisayar Mühendisliği Anabilim Dalı

Temmuz-2019
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Alper KILIÇ tarafından hazırlanan “ÖZELLİK MODELLERİ İÇİN BULANIK İNTEGRAL OPERATÖRÜ” adlı tez çalışması 11/07/2019 tarihinde aşağıdaki jüri tarafından oy birliği ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda DOKTORA TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

Başkan

Prof. Dr. Şirzat KAHRAMANLI

Danışman

Prof. Dr. Ahmet ARSLAN

Üye

Prof. Dr. Harun UĞUZ

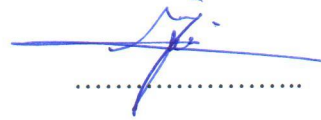
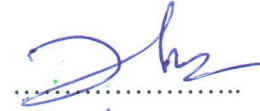
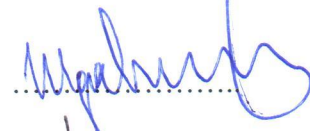
Üye

Doç. Dr. Mesut GÜNDÜZ

Üye

Doç. Dr. İsmail BABAOĞLU

İmza



Yukarıdaki sonucu onaylarım.

Prof. Dr. Hakan KARABÖRK
Enstitü Müdürü

TEZ BİLDİRİMİ

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

DECLARATION PAGE

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



Alper KILIÇ

Tarih: 20.06.2019

ÖZET

DOKTORA TEZİ

ÖZELLİK MODELLERİ İÇİN BULANIK İNTEGRAL OPERATÖRÜ

Alper KILIÇ

Konya Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Ahmet ARSLAN

2019, 61 Sayfa

Jüri

Prof. Dr. Ahmet ARSLAN
Prof. Dr. Şirzat KAHRAMANLI
Prof. Dr. Harun UĞUZ
Doç. Dr. İsmail BABAĞLU
Doç. Dr. Mesut GÜNDÜZ

Özellik modelleri son yıllarda yazılım ürün hatlarının modellenmesi ve ürün varyantlarının sistem üzerindeki etkilerinin gösterilmesi amacıyla kullanılan yöntemlerin başında gelmektedir. Bulanık integral de farklı seçeneklerin farklı öncelik ve kriterlere sahip varyantların değerlendirilmesi için kullanılacak etkin bir hesaplama yöntemi olarak değerlendirilmektedir. Bu tez çalışmasında duvar arkası canlı tespit, görüntüleme ve sınıflandırma amacı ile ultra geniş bant radar sistemin özellik modeli oluşturulmuş, farklı kriterlere ve önceliklere sahip sistem varyantları bulanık integral yöntemi ile değerlendirilerek oluşturulan radar sisteminin sınıflandırma amacı ile kullanılması ele alınmıştır. Sınıflandırma metodu olarak derin öğrenme yöntemlerinden olan evrişimsel sinir ağları kullanılmış ve başarılı sonuçlar elde edilmiştir.

Anahtar Kelimeler: Bulanık İntegral, Evrişimsel Sinir Ağları, Duvar Arkası Radar, Özellik Modelleri, Ultra Geniş Bant Radar Sinyal Sınıflandırma

ABSTRACT

PhD THESIS

FUZZY INTEGRAL OPERATOR FOR FEATURE MODELS

Alper KILIÇ

**Konya Technical University
Institute of Graduate Studies
Department of Computer Engineering**

Advisor: Prof. Dr. Ahmet ARSLAN

2019, 61 Pages

Jury

Prof. Ahmet ARSLAN

Prof. Şirzat KAHRAMANLI

Prof. Harun UĞUZ

Assoc. Prof. İsmail BABAÖĞLU

Assoc. Prof. Mesut GÜNDÜZ

Feature models have been one of the leading methods, which demonstrate the effects of product variants on the system, used for modeling software product lines, recently. Fuzzy integral has been considered as an effective calculation method that can be used to evaluate variants of different options having different priorities and criteria. In this thesis, the feature model of an ultra-wideband radar system has been proposed for detection, imaging, and classification of lives behind the wall. Convolutional neural networks, one of the deep learning methods, were used as the classification method, and successful results were obtained.

Keywords: Convolutional Neural Networks, Feature Models, Fuzzy Integral, Through-the-Wall Radar, Ultra-wideband Radar Signal Classification

ÖNSÖZ

Bu tez çalışması başta olmak üzere tüm akademik yaşantım süresince desteğini her an hissettiğim değerli hocam Prof. Dr. Ahmet ARSLAN'a, bilgi birikim ve tecrübelerini esirgemeyen ve çalışmalarına katkı sağlayan Doç. Dr. İsmail BABAOĞLU'na, Dr. Öğr. Üyesi Ahmet BABALIK'a, Doç. Dr. Mesut GÜNDÜZ'e, Tez izleme komitesi üyeleri Prof. Dr. Şirzat KAHRAMANLI ve Prof. Dr. Harun UĞUZ'a, Konya Teknik Üniversitesi Mühendislik ve Doğa Bilimleri Fakültesi Bilgisayar Mühendisliği Bölümü çalışma arkadaşlarıma, STM A.Ş RF ve Simülasyon Sistemleri Direktörlüğü'ne, Başak HASSOY'a, Özgür SÜTÇÜOĞLU'na, Haluk CANBERİ'ye,

Ayrıca gösterdikleri sabır, sevgi ve manevi desteklerinden ötürü eşim Zeynep Özkurt KILIÇ'a, kızlarım Ayşe Ceylin KILIÇ ve Meryem Tuğba KILIÇ'a sonsuz teşekkür ve şükranlarımı sunarım.

Alper KILIÇ
KONYA-2019

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
SİMGELER VE KISALTMALAR	viii
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	5
2.1. Özellik Modelleri	5
2.2. Duvar Arkası Radar Sistemi	7
3. MATERYAL VE YÖNTEM.....	14
3.1. Duvar Arkası Radar Teknolojisi	16
3.1.1. Frekans Modülasyonlu Sürekli Dalga RADAR.....	16
3.1.2. Basamak Frekanslı Sürekli Dalga RADAR.....	18
3.2. Özellik Modelleri.....	21
3.3. Bulanık İntegral	26
3.4. Derin Öğrenme	30
3.4.1 Yinelemeli Sinir Ağları.....	32
3.4.2 Uzun Kısa-Vadeli Bellek Ağları.....	33
3.4.3 Evrişimsel Sinir Ağları	34
3.5. DAR Özellik Modelinin Oluşturulması	38
3.6. DAR Verilerinin Elde Edilmesi	43
3.7. DAR Sınıflandırma Yöntemi	48
4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....	51
5. SONUÇLAR VE ÖNERİLER	55
5.1 Sonuçlar	55
5.2 Öneriler	56
KAYNAKLAR	57
ÖZGEÇMİŞ	62

SİMGELER VE KISALTMALAR

Kısaltmalar

1-B	: Bir Boyutlu
2-B	: İki Boyutlu
3-B	: Üç Boyutlu
ADC	: Analog Sayısal Dönüştürücü (Analog Digital Converter)
DAR	: Duvar Arkası Radar
DDS	: Doğrudan sayısal sentezleme (Direct Digital sythesis)
ESA	: Evrişimsel sinir ağları (Convolutional Neural networks)
FCC	: A.B.D. Federal Haberleşme Komisyonu (U.S.A. Federal Communication Commission)
FFT	: Hızlı Fourier Dönüşümü (Fast Fourier Transformation)
FMCW	: Frekans Kiplmeli Sürekli Dalga (Frequency-modulated Continuous Wave)
IF	: Ara frekans (Intermediate frequency)
IFFT	: Ters Hızlı Fourier Dönüşümü (Inverse Fast Fourier Transformation)
LSTM	: Uzun kısa-vadeli bellek (Long short-term memory)
MUSIC	: Çoklu Sinyal Sınıflandırma (Multiple Signal Classification)
PRF	: Darbe Tekrarlama Frekansı (Pulse repetition frequency)
PRI	: Darbe Tekrarlama Aralığı (Pulse repetition Interval)
RF	: Radyo Frekansı (Radio Frequency)
RNN	: Yinelemeli sinir ağları (Recurrent neural networks)
SAR	: Sentetik Açıklıklı Radar
SFCW	: Basamak Frekanslı Sürekli Dalga (Step Frequency Continuous Wave)
SNR	: Sinyal Gürültü Oranı (Signal-to-Noise Ratio)
SPL	: Yazılım ürün hatları (Software Product Lines)
UGB	: Ultra Geniş Bant
VNA	: Vektör Network Analizör (Vector Network Analyzer)

1. GİRİŞ

Yazılım ürün hatları kavramı ile yazılım içeren sistemleri oluşturan alt bileşenlerin uygun koşullarda bir araya getirilmesi ve bileşenlerin tekrar kullanımının sağlanarak üretim etkinliğinin artırılması amaçlanmıştır. Yazılım ürün hatları (*software product lines: SPL*) ortak özellikler olsa dahi değişkenliklerin bulunduğu ve değişkenlik kısıtlarının yönetilmesi gereken bir “yazılım sistemleri kümesi” olarak tanımlanmaktadır (Karataş ve ark., 2010). Özellik modelleri ise bir SPL'nin özellik ve niteliklerini modellemek için değişkenliği ve ortaklığı modelleyebilen önemli tekniklerden biri olarak tanımlanmaktadır (Lee ve ark., 2002). Özellik modelleri bir modelin belirli özellikleri seçilerek ürün hattının konfigürasyonu ve yapılandırılması için kullanılmaktadır. Yapılandırma sürecinde seçilen özellikler olası model kısıtlamalarını karşılamak ve ürün gereksinimleri ile şekillenmiş model kurallarına uymak zorundadır.

Özellik modelleri farklı bakış açıları, farklı uzmanlık alanına sahip paydaşlar tarafından geliştirilmektedir. Farklı paydaşların oluşturduğu ve farklı kısıt ve önceliklerin bulunduğu özellik modellerinden ortaya çıkarılabilecek ürün varyantlarının probleme özgü bir şekilde ilgili kurallar çerçevesinde oluşturulmasına yönelik olmak üzere bu tezde bulanık integral kullanımı önerilmiştir. Birden fazla seçenek ve her seçeneğe atanmış bulanık öncelik değerleri bulunduğu durumda tüm seçeneklerin birlikte ele alındığı ve bulanık mantık kuralları çerçevesinde birleştirme işleminin yapıldığı bulanık integral operatörü ile model konfigürasyonu oluşturulabilmektedir.

Yöntemin etkinliğini gösterebilmek için karmaşık ve farklı paydaşların farklı yaklaşımlarını ifade edebilecek bir sistem olan duvar arkası radar canlı sınıflandırma problemi ele alınmıştır. Son yıllarda sivil/askeri uygulamalarda duvar arkası görüntüleme, algılama ve sınıflandırma konusundaki çalışmalarda dikkat çekici bir şekilde artış gözlenmektedir. Bina içinde, enkaz altında ya da duvar arkasında canlı bulunup bulunmadığının tespiti, canlının hayati fonksiyonlarının izlenmesi ve konumunun en az hata ile kestirimi özellikle arama kurtarma, itfaiye ve güvenlik güçlerinin ihtiyaç duyduğu yeteneklerdendir. Benzer şekilde yeraltında bulunan mayın benzeri nesnelerin ya da jeolojik yapıların tespit edilmesi güvenlik güçlerinin operasyon kabiliyetlerini arttıracak teknolojiler olarak literatürde yer almaktadır. Güvenlik güçlerinin belirli bazı operasyonları bina içinde ya da duvar arkasında kaç kişinin bulunduğu, canlının türü, silah bulundurup bulundurmadığı gibi birçok etkene bağlı olarak değişkenlik göstermektedir. Duvar arkasında bulunan olası tehditlerin

sınıflandırılması da operasyonun şeklini değiştirebileceğinden ötürü canlı türünün, pozisyon ve duruşunun sınıflandırılması da oldukça önemli olacaktır. Örneğin duvar arkasında tespit edilen canlının insan olmadığı ve sınıflandırmanın yapılmadığı durumlar operasyonda gecikmelere sebep olabilecektir.

Duvar arkasındaki nesne ve canlıları algılama, tespit etme ve sınıflandırma problemlerinin çözümü için optik temelli geleneksel yöntemler birçok duvar arkası algılama senaryosunda yetersiz kalmaktadır. Benzer şekilde milimetre dalga boyu kullanılan radyometre tekniği, kızılötesi, X-ışını kullanımı ya da ultrason temelli çözümlerin her birinin avantaj ve dezavantajları bulunmaktadır. Görüntüleme ya da sınıflandırma için yeterli çözünürlüğünün elde edilememesi, algılama mesafesinin oldukça kısa olması, duvar özelliklerinden kaynaklanan sinyal sönümlenmesinin büyük olması gibi teknik nedenlerin yanı sıra yapılabirlik ve maliyet açısından da uygulanabilir olmaması gibi nedenler yukarıdaki tekniklerin olumsuzlukları olarak göze çarpmaktadır. Bu yöntemler yerine duvar arkası tespit için literatürde ultra geniş bant (UGB, *Ultra wide band*) radar teknolojisinin kullanılması önerilmiştir (Farwell ve ark., 2008; Amin, 2017). Her ne kadar metalik engellerin arkasında radyo frekansının uygulanabilir olmaması, çözünürlüğün kullanılan frekansa bağlı olarak em seviyesinde olması gibi dezavantajları olsa da pratik duvar arkası algılama ve görüntüleme uygulamalarında UGB radar teknolojisinin oldukça kullanışlı olduğu değerlendirilmektedir (Amin, 2017).

UGB radarları darbe radarı (*impulse radar*), sözde gürültü radarı (*pseudo-noise radar*), frekans modülasyonu sürekli dalga radarı (FMCW: *frequency-modulated continuous wave*) ya da adım/basamak frekanslı sürekli dalga (SFCW: *step frequency continuous wave*) kullanan radar metodolojileri olmak üzere farklı yaklaşımlar kullanılarak gerçekleştirilmektedir. Bu yöntemler kendi içlerinde avantaj ve dezavantajları bulunduğu gibi farklı kriter, öncelik ve kullanım amaçlarına göre tercih edilebilmektedir.

Farklı radar tasarım yaklaşımları çıkış gücünün sınırlanması gibi ülkelerin ilgili yasal düzenlemelerine tabi oldukları göz önünde bulundurulduğunda farklı konfigürasyonların birbirlerine olan üstünlükleri değişkenlik gösterebilecektir. Benzer şekilde anten mimarisi ve sayısı, RF huzmesinin yönlendirilebilme yeteneği ya da dinamik açıklık gibi parametreler de problemin farklı konfigürasyonlara göre yeniden değerlendirilmesini gerektirecektir.

Duvar arkası tespit ve sınıflandırma probleminde teknolojik yetenek ve yapılabirliğin yanı sıra çözüm adayları sistemin ergonomik yapısı, güç tüketimi, ilgili

standartlarla belirlenmiş termal, mekanik dayanıklılık veya fiziksel boyutlar da benzer şekilde sistemin ayırt edici ve tasarım aşamasında karar verilmesi gereken, aynı zamanda teknolojik kabiliyetleri sınırlandırabilecek parametreler de birlikte ele alınmalıdır. Elde taşınması beklenen bir konfigürasyon için koni(*horn*) tipi bir anten çiftinin seçilmesi ya da uzun süre çalışması beklenen bir duvar arkası radar için yüksek çıkış gücünün ele alındığı bir tasarım kararı sistemin beklenmeyen şekilde çalışmasına neden olabilecek ve güvenlik güçleri ya da arama kurtarma ekiplerine dezavantaj oluşturabilecek kısıtları barındırabilecektir. Bu nedenle tüm tasarımın en erken zamanda ve belirli özelliklerin ele alınması, çok kriterli bir tasarım kararı verme mekanizmasının oluşturulması, konfigürasyona uygun yöntem ve algoritmaların seçilmesi ve analiz edilmesi kritik öneme sahip olacaktır. Benzer şekilde merkez frekans değeri seçimi, RF bant genişliğinin menzil ve çözünürlük göz önünde bulundurularak tespit edilmesi, seçilmiş frekans aralığına bağlı olarak anten parametrelerinin belirlenmesi, antenlerin tipi, sayısı, mekanik özellikleri, antenler arası mesafenin belirlenmesi, algılayıcı alt sistemin dinamik bant aralığı, frekans yayım şemasının özelliklerinin irdelenmesi ve uygun şemanın seçimi gibi birçok parametre yine birçok kriter ve tasarım kararı önceliğine göre sistemin toplam yetenek, performans ve maliyet etkin olma kriterlerine göre etkili olacağından çok kriterli karar verme metodlarının uygulanması gerektiği ortaya çıkmaktadır. Bu noktada farklı seçimler farklı kriter ve önceliklere göre konumlanacağından ötürü tasarım varyantlarının ortak ve ayırt edici özelliklere göre de modellenmesi, modele ait seçilen özelliklerin birlikte gösterimi ve duvar arkasında bulunan canlıların tespiti ile konum ve pozisyonunun kestirimi için uygun yöntem ve algoritmanın belirlenmesi gerekmektedir. Böylece duvar arkası radar sisteminin araç üstü uzun menzil ya da elde taşınacak ve batarya ömrü uzun olan sistem gereksinimleri kullanım senaryolarına göre erken aşamalarda alınacak tasarım kararları ile uygun teknolojinin kullanılması sağlanabilecektir. Aynı şekilde teknolojik olarak uygun olmasına rağmen kullanımı kısıtlayabilecek parametrelerin erken teşhisi ile maliyet etkin çözüm oluşturulabilecektir.

Duvar arkası canlıların tespit, konum ve pozisyon kestirimi amacına yönelik olarak kullanılacak radar teknolojisinin belirlenmesi, uygun konfigürasyon parametrelerinin belirlenmesi ve sınıflandırma algoritmalarının seçimi kapsamında özellik modelinin oluşturulması, özellik modeli kapsamında ortaya çıkan farklı varyantlardaki aday sistem konfigürasyonlarının belirli öncelik ve kriterlere göre seçilerek oluşturulması, radar ile tespit edilen canlıların konum ve pozisyonunun tespiti ve sınıflandırılması için uygun algoritmaların belirlenerek gerçekleştirilmesi bu tezin temel

motivasyon ve amacı olarak öne çıkmaktadır. Bu kapsamda duvar arkasında tespit edilen canlıların konum ve pozisyon kestirimin yapılması konusunda yapılan bu tez çalışmasından elde edilen sonuç, yöntem ve algoritmalar savunma sanayi konularında faaliyet gösteren STM Savunma Teknolojileri Mühendislik ve Ticaret A.Ş. firmasının Savunma Sanayi Başkanlığı, Emniyet Genel Müdürlüğü ve TÜBİTAK tarafından desteklenen projelerine katkıda bulunmak üzere başarı ile uygulanmış, aynı zamanda akademik literatüre de katkıda bulunulmuştur (Kilic ve ark., 2019).

Tezde ele alınan konular olarak özellik modelleri, SFCW ile duvar arkası radar modeli, bulanık integral kullanılarak konfigürasyonun oluşturulması ve canlı konum ve pozisyonunun sınıflandırılmasına yönelik çalışmalar kaynak araştırması bölümünde verilmiştir. Kullanılan yöntemlerin akademik çalışmalardaki karşılıkları ve detayları materyal ve yöntem bölümünde sunulmuştur. Gözlem ve deneyler sonucu elde edilen bulgular araştırma sonuçları ve tartışma bölümünde değerlendirilmiştir. Sonuç ve öneriler bölümünde ise genel değerlendirme ve sonuçlar verilerek çalışmayı daha ileriye taşıyabilecek öneriler sunulmuştur.

Bu tez çalışmasında özellik modellerinin konfigürasyonu için paydaş tercihlerinin dahil edilebilmesine yönelik bir yöntem önerilmiştir. Yöntemin etkinliğini göstermek için karmaşık bir sistem ele alınarak uygun konfigürasyonun oluşturulması aşamaları gösterilmiştir. Bu kapsamda duvar arkasında bulunan canlının tespit ve konumunun kestirimi yapılarak canlı pozisyonu ve türünün sınıflandırılması problemine yönelik sistem konfigürasyonu ve uygun algoritma seçimi amaçlanmıştır. Öncelikle problemin gerektirdiği teknoloji, metot, yöntem ve algoritmaların belirlenmesine yönelik olarak öncelik ataması yapılabilecek bir özellik modeli sunulmuş ve probleme özgü fakat maliyet etkin bir konfigürasyon oluşturulmuştur. Oluşturulan konfigürasyon ile veri toplama, eğitim ve test aşamaları sonunda derin öğrenme metotları uygulanarak canlının pozisyonu sınıflandırılmıştır.

2. KAYNAK ARAŞTIRMASI

2.1. Özellik Modelleri

Yazılım ürün hatları yazılım ürün çeşitliliğini ve verimliliği arttırmak için önerilmiş bir modelleme yaklaşım biçimi olarak tanımlanmaktadır (Toft ve ark., 2000). Diğer bir ifade ile yazılım ürün hatları değişkenliklerin ve değişkenlik kısıtlarının yönetilmesi gereken bir “yazılım sistemleri kümesi” olarak (Karataş ve ark., 2010) ele alınmaktadır. Yazılım ürün hatları değişik varyant noktalarına sahip, bu noktalar üzerinde karmaşık seçim kuralları içeren ve farklı hatlarla benzerlik taşıyan birçok özellik içermektedir. Yazılım ürün hatları günümüzde sadece kavramsal yazılım bileşenlerini değil, donanım ve mekanik gibi fiziksel bileşenleri ya da somut olmayan özellikleri de içerebilmektedir. Yazılım ürün hatları ile gereksinimler, tasarım, kod ve test süreçleri gibi farklı süreçler için çeşitli yazılım bileşenlerinin uygun bir şekilde yapılandırılmasını sağlanabilmektedir (Apel ve Kästner, 2009).

Farklı yapılandırmaların oluşturulduğu ve analiz edilebildiği “Özellik Modelleri” kavramı son yıllarda değişken ve ortak özelliklerin kavramsal olarak modellenmesi amacıyla kullanılmaktadır (Benavides Cuevas ve ark., 2010). Özellik modelleri bir yazılım ürün hattının özellik ve niteliklerini, değişkenliği ve ortaklığı modelleyebilen önemli tekniklerden biridir (Lee ve ark., 2002). Özellik modelleri bir modelin belirli özellikleri seçilerek ürün hattının konfigürasyonu ve yapılandırılması için kullanılmaktadır. Yapılandırma(konfigürasyon) sürecinde seçilen özellikler olası model kısıtlamalarını karşılamak ve ürün gereksinimleri ile şekillenmiş model kurallarına uymak zorundadır. Buna paralel olarak farklı bakış açısına sahip paydaşların sistemin özellik modelini oluşturmaları ve bu özellik modellerinin birleştirilerek tutarlılık analizi yapılması gerekmektedir.

Model tabanlı uygulama ve ürün geliştirme süreçlerinde özellik modelleri (Kang ve ark., 1990) sıklıkla kullanılmaktadır. Bu modellerde sistemin barındırması beklenen özellikler sınıflandırılarak hiyerarşik bir şekilde gösterilirler (Acher ve ark., 2010). Bu modeller ağaç yapısında gösterilerek anlaşılabilirliğin yüksek olması hedeflenmiştir. Hiyerarşik özellikler arasındaki çizgiler daha detaylı alt özellikleri ayrıştırmaktadır. Bu modelde özellikler arası hiyerarşik olmayan ilişkiler için de “dışlayan” ve “dâhil eden” olmak üzere iki farklı kısıt tanımlanmıştır. Özellik modelleri aynı zamanda kısıt semantiğini de desteklemektedir (Karataş ve ark., 2010). Ata ve ebeveyn özellik ile çocuk özellikler arasındaki ayrıştırma ilişkisi kavramsal modele de kolaylıkla

dönüştürebilmektedir. Birçok araştırmacı özellik modellerinin döngü içermeyen yönlü çizgilerle göstermekte iken, analiz ve araştırma amacıyla diğer araştırmacılar da ağaç yapısı ile modeli ifade etmektedirler (Acher ve ark., 2009). Karmaşık sistemlerde ise alanlarında uzman birden fazla paydaş çoklu bakış açılı modelleme yaklaşımını kullandıklarından ya da tüm sistem birden fazla alt sistem içerdiğinden ötürü özellik modelleri de farklı bakış açılarındaki modellenirler. Doğal olarak sistemin tutarsız özellikler içermemesi için özellik modellerinin detaylıca analiz edilmesi gerekmektedir. Her özellik modelin tutarlılığı kendi içerisinde kolaylıkla analiz edilebildiğinden (Benavides ve ark., 2005), farklı modeller arasındaki tutarlılığın da ele alınması için özellik modellerinin birleştirilmesi ve analizin ortak bir kavramsal model üzerinde yapılması gerekmektedir.

Karmaşık ve birden fazla alt sistem barındıran büyük ölçekli tasarımlarda farklı alanlarda bilgi birikimine sahip uzmanlar, paydaşlar bulunmaktadır. Her paydaş kendi saha uzmanlıkları çerçevesinde sistemin ya da sistemi oluşturan alt sistemlerin belirli bir kısmını ele almaktadırlar. Bu yaklaşım biçimi literatürde “bakış açısı (*viewpoint*)” olarak tanımlanmıştır (Dijkman, 2006). Bu yaklaşıma göre tasarlanan sistem başlangıçta farklı paydaşların tasarım ve yöntemleri ile modellenerek alana özgü analiz işlemleri gerçekleştirilmektedir. Ardından kendi sahasında tutarlı modeller entegre edilerek tümleşik sistem modeline ulaşılmaktadır. Örneğin makine, elektrik-elektronik, bilgisayar ve sistem mühendislikleri konularında uzman paydaşlar aynı fiziksel ürün üzerinde farklı bakış açısı, modelleme aracı, değişik gereksinim ve öncelik atamaları tanımlamaktadırlar. Farklı paydaşların belirli bir sistemi kendi alan uzmanlığı çerçevesinde modellemesi ise “çok bakış açılı (*multi-viewpoint*) modelleme yaklaşımı” olarak ele alınmaktadır (Finkelstein ve ark., 1992; Dijkman, 2006). Çok bakış açılı sistemlerde farklı paydaşlar sistemin bütünü oluşturacak alt sistemler ve bölümler üzerinde yoğunlaştıklarından dolayı, sistem tutarlılığının modelleme aşamasında sağlanması ve yönetilmesi beklenir. Bununla birlikte modeli oluşturan uzman ya da paydaşlar kendi bakış açıları ile probleme odaklanacaklarından ötürü farklı kısıtlar ve öncelik kriterleri olabilmektedir (Stein ve ark., 2014). Farklı paydaşlar kısıtları ve öncelikleri sadece birinci derece mantık (*first order logic*) operatörleri ile değil aynı zamanda bulanık mantık (*fuzzy logic*) ifadeleri ile de gösterilebilmektedir (Robak ve Pieczynski, 2003).


2.2. Duvar Arkası Radar Sistemi

Duvar arkasında bulunan nesne ya da canlıların tespit edilmesine yönelik sistemler enkaz altı canlı tespiti amacıyla arama kurtarma ekipleri, itfaiye ekipleri ya da rehine kurtarma operasyonları veya suç ve terörle mücadelede durumsal farkındalığa ihtiyaç duyan güvenlik güçleri gibi askeri/sivil birimler tarafından kullanılabilir (Fioranelli, 2013). Duvar arkası tespitine yönelik teknik ve teknolojiler kapsamında ilk geniş çaplı araştırma Ferris ve Currie tarafından (Ferris ve Currie, 1999) yapılmıştır. Optik tekniklerin kullanılmayacağı duvar arkası tespit uygulamalarında radyo frekansı, X-ışınları ya da akustik tekniklerin karşılaştırıldığı çalışmada radyasyon ve güvenlik risklerinin bulunmasından ötürü X-ışınlarının uygun olmayacağı belirtilmiş, ayrıca kısa mesafe sınırlandırmasının bulunduğu vurgulanmıştır. Çözünürlük ve görüntüleme performansının oldukça düşük olacağı akustik teknikler yerine söz konusu incelemede radyo frekansı kullanılmasının uygun olacağı değerlendirilmiş ve daha sonraki çalışmalarda bu değerlendirme referans olarak kullanılmıştır (Ahmad ve ark., 2008). Gelişen teknoloji nedeni ile yapılan bir diğer çalışmada (Farwell ve ark., 2008) RF mikrodalga, terahertz frekanslar, akustik ve X-ışını seçenekleri karşılaştırılarak farklı kriterlere göre RF mikrodalga kullanımının uygun olacağı değerlendirilmiştir.

Duvar arkası algılama sistemleri yetenek ve kullanıcılarına sağladıkları bilgi düzeyine göre sınıflandırılmaktadır (Baranoski, 2008). En temel duvar arkası radar sistemi duvar arkasında herhangi bir hareketin varlığını algılayan, ancak konum veya hedeflerin sayısı hakkında bilgi vermeyen sistemlerdir. Bu sistemler genel olarak sıfır boyutlu (0-B) olarak adlandırılarak nesnenin var olduğunu hakkında bilgi verebilmektedir. Bu sistemlerin tasarımı yalnızca tek bir anten (monostatik radar) ve bir sürekli dalga (*continuous wave*) formu ile oluşturulabilmektedir. Tek boyutlu (1-B) duvar arkası radar sistemleri ise hedeflerin uzaklıkları hakkında bilgi vermelerine rağmen açısız konum ile ilgili bilgi verememektedir. 1-B radarların tasarımı için monostatik radarlar ve modüle edilmiş ya da darbe dalga formu gerekir. İki boyutlu (2-B) duvar arkası sistemler ise durumsal farkındalığa yardımcı olabilecek düzlemsel bilgi sağlar. 2-B duvar arkası radar sistemleri için en az 2 (bistatik radar) veya belirli bir düzleme yerleştirilmiş daha fazla (multistatik radar) alıcı anten gereklidir. 2-B bilgi sağlanabilmesi için antenleri hareket ettirerek Sentetik Açıklık Radarı (SAR) metodolojisinin uygulanması teorik olarak mümkün olsa da pratikte bazı uygulama senaryoları için operasyonel zorluklar göz önünde bulundurulmalıdır. Literatürde üç boyutlu (3-B) bilgi elde edilebilmesine yönelik olarak 2-B yaklaşımında olduğu gibi 2-B anten diziliminin oluşturulması ya da sentetik

açıklığın yükseklik oluşturularak gerçekleştirilmesi ile yapılan çalışmalara da rastlanmaktadır (Karanam ve Mostofi, 2017). Duvar arkası radar sisteminin gerçekleştirilme zorluğu boyutla orantılı olarak artmasına karşılık sınıflandırma algoritmasının karmaşıklığı da aynı şekilde azalmaktadır. 3-B bilgi ile çözünürlüğe de bağlı olmak kaydı ile sınıflandırma algoritmasının karmaşıklığının azalacağı açıktır. Bununla birlikte sistemin fiziksel özelliklerinin de göz önünde tutularak pratik uygulamalar için uygun bir çözümün değerlendirilmesi gerekmektedir.


Duvar arkası radar sistemlerinin menzil çözünürlüğünün artırılması için ultra geniş bant kullanımı önerilmektedir (Fioranelli, 2013). Duvara nüfuz edebilen ve uygun çözünürlüğün sağlanması için gerekli bant genişliğinin sağlanması için UGB radarları kullanılmaktadır. UGB terimi merkez frekansı ile kullanılan bant genişliği arasındaki orana bağlı olarak tanımlanmaktadır. Örneğin FCC (*Federal Communication Commission*) tarafından bu oran %25 (ya da 3dB veya 500MHz) olarak belirlenmiştir. UGB işaretler çok kısa zamanlı darbelerden ya da tüm bant genişliğini zamanın bir fonksiyonu olarak kullanan işaretler şeklinde oluşturulmaktadır. UGB işaretler yer altı ya da duvar arkası tespit (Şekil 2.1), görüntüleme ve konum kestirimi amaçlarına yönelik olarak kullanılabilir (Taylor, 1994). Literatürde UGB sinyallerinin düşük enerjili olması ve canlı dokuya zararının bulunmaması gerekçeleri öne sürülerek medikal uygulamalarda da kullanıldığı görülmüştür (Atli ve Öztürk, 2011).



Şekil 2.1. Duvar Arkası Radar örnek kullanım senaryosu

UGB teknolojisi ile dar bant sürekli dalga radarlarında bulunan düşük çözünürlük problemi giderilebilmekte ve çoklu-yol (*multipath*) girişim asgari düzeyde tutulabilmektedir. Ayrıca hedef ve diğer dağıtıcı yüzey (*target-clutter*) ayırımın yüksek olması da UGB kullanılarak sağlanabilmektedir (Yarovoy ve ark., 2007).

UGB duvar arkası radar sistemlerinin (Şekil 2.2) tasarımı için literatürde farklı yaklaşımlar ve konfigürasyonlar önerilmiştir. Bunun için basamak frekanslı sürekli dalga formu (*SFCW: stepped frequency continuous wave*), frekans modüasyonlu sürekli dalga formu (*FMCW: frequency-modulated continuous wave*), darbe dalga formu (*Impulse waveform*) ya da sözde-gürültü radarları (*pseudo-noise radar*) kullanılmaktadır. Duvar arkası tespit, görüntüleme ve sınıflandırma (Liu ve ark., 2008; Lu ve ark., 2011; Mercuri ve ark., 2012; Zhang ve Zhu, 2015; Qi ve ark., 2016) dışında UGB dalga formları tıbbi görüntüleme (Marimuthu ve ark., 2014), yere nüfuz eden radar uygulamaları (Liu ve Sato, 2014), inşaat mühendisliği uygulamaları (Wei ve Zhang, 2014), yapı statik testleri (Pieraccini ve ark., 2000), yol yüzey katmanının kalite kestiriminin yapılması (Hartikainen ve ark., 2018), gömülü mayın ya da patlamamış mühimmat tespiti (Yarovoy ve ark., 2004; Mohana ve ark., 2013), boru, kablo tespiti (Seyfried ve ark., 2012; Seyfried ve ark., 2014) ve arkeolojik uygulamalarda (Urban ve ark., 2014) kullanılmaktadır.



Şekil 2.2. Duvar Arkası Radar Birimleri

Duvar arkası radar sistemleri tasarımında kullanım amacına yönelik olarak aşağıdaki özellikler birincil olarak göz önünde bulundurulmaktadır:

- *Frekans:* Duvara nüfuz edebilmesi açısından düşük frekans avantajlı olmakla birlikte çözünürlüğün önemli olduğu durumda yüksek frekans kullanımı yerinde olacaktır. Bununla birlikte ortamdaki diğer cihaz ve sistemlerle olabilecek elektromanyetik girişiminden kaçınılması da gerekeceğinden dolayı yasal düzenlemeler çerçevesinde uygun ve operasyonel frekansların seçilmesi söz konusu olacaktır.
- *Çözünürlük:* Birbirlerine yakın nesnelere ayırt edilmesine yönelik bir parametre olarak duvar arkası radar sistemlerinde derinlik çözünürlüğü kullanılan bant genişliği ile doğru orantılıdır. Bu nedenle ultra geniş bant radarları ile yüksek çözünürlük elde edilebilmektedir. Basamak frekans yöntemi ya da kullanılacak bant genişliğine bağlı olarak frekans modülasyonlu sürekli dalga oluşturarak basitçe ultra geniş bant sinyaller elde edilebilmektedir. Benzer şekilde darbe ya da gürültü radarları da matematiksel olarak ultra geniş bant kategorisinde değerlendirilmektedir. Derinlik çözünürlüğünün yanı sıra yanca eksenindeki çözünürlük ise sistemin anten açıklığı ile doğru orantılıdır. Bu açıklık daha büyük antenlerin kullanılması, algılayıcı dizilerinin kullanılması ya da yapay olarak antenin hareket ettirilmesi gibi yöntemlerle oluşturulabilmektedir. Bununla birlikte yanca çözünürlüğünü arttırırken sistemin boyut ve ağırlık gibi fiziksel kısıtları ya da operasyonel kullanım zorluğunun bulunacağı göz önünde bulundurulmalıdır.
- *Menzil ve Dinamik Bölge:* Radar sisteminin en uzak algılama mesafesine karşılık gelen menzil değeri ile duvardan yansiyacak maksimum genlikli sinyal ve en düşük genlikli sinyal arasındaki farkı ifade eden dinamik bölge değeri dikkate alınmalıdır. Uzun menzil hedefine ulaşmak için yüksek güç kullanımı durumunda duvardan yansiyarak alıcı antene ulaşacak sinyal gücü yüksek olacaktır. RF algılayıcı sistemin geri yansıyan bu sinyal ile en az iki defa duvardan geçtiğinde ve duvar arkası uzak mesafedeki bir nesneden yansiyarak oldukça zayıflayan en düşük genlikli sinyal arasındaki fark dinamik bölge olarak tanımlanmaktadır.
- *Elektriksel Güç:* Operasyonel kullanım süresi, yasal sınırlandırmalar, batarya kapasitesi, sistemin RF tasarım bileşenlerinin sınır değerleri gibi parametreler göz önünde bulundurulmalıdır.

- *Fiziksel Özellikler:* Ağırlık ve boyut dikkate alınmalıdır. Elde taşınabilecek duvar arkası radar sistemleri operasyonel açıdan oldukça kullanışlı olacaktır. Bununla birlikte antenlerin özellikleri, antenler arasındaki açıklık, batarya kapasitesi, RF ve diğer elektronik bileşenlerden oluşan tüm sistemin harcayacağı elektriksel güç, mekanik sınırlandırmalar gibi birçok kısıt duvar arkası radar sisteminin yeteneğini şekillendirecek unsurlardır.
- *Tespit Süresi:* Duvar arkası radar en az bir operatör tarafından kullanılacaktır. Özellikle hayati önemin bulunduğu uygulamalarda duvar arkası radarların tespit ve sınıflandırmada kullanacağı zaman oldukça sınırlıdır. Bu nedenle uzun süre boyunca ya da yapay açıklık oluşturularak elde edilecek verilerin kullanılacağı tespit ve sınıflandırma algoritmalarının pratik uygulamalar açısından dezavantajları bulunacaktır.

Çizelge 2.1’de (Fioranelli, 2013) çalışmasından derlenen ve literatürde bulunan duvar arkası radarlara yönelik konfigürasyon özellikleri ve kullanılan yöntemler özetlenmiştir.

Çizelge 2.1. Literatürde bulunan bazı duvar arkası radar sistemleri

Kaynak	Dalga formu ve frekans	Antenler	Açıklama
(Yang ve Fathy, 2007)	Darbe, 7-13GHz	1 boynuz TR, 16 Vivaldi RX	Durağan metal hedef tespiti, 5cm kontrplak duvar.
(Liu ve ark., 2012)	Darbe, 1.5-4.5GHz	1 boynuz TR, 8 Vivaldi RX	Çimento duvar arkası yürüyen kişi tespiti, omuz salınımı tespiti, Doppler.
(Wu ve ark., 2012)	Darbe, 0.5-3GHz	2 TR, 4 RX	24cm beton duvar arkası hareketli kişi tespiti, değişim algıma ile duvar eliminasyonu.
(Ahmad ve Amin, 2007)	Adım Frekans, 2-3GHz	4 boynuz anten, 4-port VNA	1.9cm kontrplak ve 1.6cm alçıpan duvar, arka plan eliminasyon algoritması.
(Ahmad ve Amin, 2012)	Adım Frekans, 1-3GHz	2 boynuz TR, 1 boynuz RX	14cm beton duvar arkasında sabit metal levhanın tespiti.
(Ahmad ve Amin, 2013)	Adım Frekans, 1.5-2.5GHz	2 boynuz TR, 1 boynuz RX	14cm beton duvar arkasında ayakta duran iki kişinin tespiti.
(Charvat ve ark., 2012b)	Frekans modülasyonu, 1.926-4.069GHz	13 slot TR, 8 slot RX	10cm beton duvar arkası sabit metal nesnelerin tespiti.
(Ralston ve ark., 2010)	Frekans modülasyonu, 2-4GHz	21 doğrusal ve Vivaldi anten	10cm beton duvar arkası yuvarlanan metal küre tespiti.
(Charvat ve ark., 2012a)	Frekans modülasyonu, 2-4GHz	21 doğrusal ve Vivaldi anten	10cm ve 20cm beton ve cüruf tuğla duvar arkası nefes ve kalp atışı tespiti.

DAR kapsamında doğrudan canlı sınıflandırmaya yönelik olmasa dahi literatürde bilinen tekdüze bir duvar arkası 3-B görüntüleme çalışması dikkat çekmektedir (Ahmad ve ark., 2008). Burada yapay açıklık tekniği kullanılarak hedef konumun mesafe ve açı değerlerinin yanı sıra hedefin boyu hakkında bilgi elde edilmeye çalışılmıştır. Diğer bir çalışmada (Wang ve Amin, 2006) duvar parametrelerinin oluşturduğu hesaplama hatalarını gidermek amaçlanmış, iki ya da daha fazla mesafeden alınan görüntüleme için iki farklı görüntüleme yaklaşımı oluşturmuştur. Yapay açıklık radarı tekniği kullanılarak gerçekleştirilen çalışmada birinci yaklaşım her biri farklı mesafelerde olan ve farklı duvar kalınlık katsayısı ile dielektrik katsayılarına sahip görüntülemelerden hedeflerin yer değiştirme yörüngelerinin kesişim noktalarını oluşturmaya dayanmaktadır. İkinci yaklaşım ise aynı duvar parametreleri kullanılarak farklı mesafelerden alınan görüntülerin süper pozisyonu ile bir görüntü dizisi oluşturulması ve bu dizinin görüntü odaklama yolu ile hedef pozisyonunun elde edilmesine dayanır.

UGB sinyalleri kullanılarak gerçekleştirilen bir başka çalışmada (Baboli ve ark., 2012) kalp ve solunum ritimleri dalgacık dönüşümü ve çeşitli filtreler yardımı ile tespit edilmiştir. Çalışmada biri gönderici biri alıcı olmak üzere iki anten ile darbe yapısında sabit frekanslı aşırı geniş bant sinyalleri kullanılmıştır. Benzer şekilde sağlık uygulaması olarak solunum ritminin tespiti için doppler radar sinyallerini çoklu sinyal sınıflandırma (MUSIC-Multiple Signal Classification) algoritması ile değerlendiren bir çalışma da dikkat çekicidir (Dell'Aversano ve ark., 2017). Çalışmada VNA (vektör network analizör) ve biri gönderici diğeri alıcı olmak üzere iki anten kullanılmıştır. Sürekli formdaki UGB radar ile göğüs hareketlerinden kaynaklanan doppler sinyalleri MUSIC algoritması ile değerlendirilmiş ve benzerlerinden daha iyi sonuçlar elde edilmiştir.

UGB radar sinyallerinin derin öğrenme algoritmaları kullanılarak değerlendirildiği farklı uygulamalara da literatürde rastlanabilmektedir (Diraco ve ark., 2017). Bu çalışmada yaşlı insanların düşmelerine karşın uzun süreli tedavi ve hatta ölüm riskini azaltmak amacıyla düşme tespit algoritması geliştirilmiştir.

Derin öğrenme kullanan diğer bir çalışmada (Seyfioğlu ve ark., 2017) yardımsız ve yardımcı (baston vb. araçlar kullanılarak) yürüyüşlerdeki çeşitli düşme şekillerinin sınıflandırılması amacı ile mikro-doppler radar sinyallerinin işlenmesine dayalı bir yöntem geliştirmiştir. Derin öğrenme algoritmaları kullanılarak tespit ve sınıflandırılması yapılan çalışmada yazılım tabanlı radyo (*Software defined radio*) ile oluşturulan sürekli UGB radar sinyalleri ve iki adet koni tipi anten kullanılmıştır. Uygulamada UGB

radardan edilen mikro-doppler sinyaller ön işlem uygulandıktan sonra gri seviye resme çevrilerek derin öğrenme algoritmasına girdi olarak sunulmuştur.

Duvar arkası radar sistemleri kullanarak duvar arkasında bulunan canlının pozisyonunun tespiti ve duruşunun sınıflandırılması kapsamında literatürde bir çalışmaya rastlanmamıştır. Bununla birlikte insan hareketlerini sınıflandırma amaçlı duvar olmadan açık alanda ve uzun süre veri toplama ihtiyacı bulunan çalışmalara rastlanmaktadır. Örneğin (Park ve ark., 2016) çalışmalarında yüzen insanların pozisyonlarını derin öğrenme yöntemleri ve UGB radarı kullanarak tespit etmeye odaklanmıştır. Yine duvar olmadan açık alanda omuz, gövde, diz gibi hareketli insan uzuvlarının tespiti ve sınıflandırması için UGB radar sinyalleri ve derin öğrenme metotlarını kullanarak gerçekleştiren çalışmalar da literatürde bulunmaktadır (Teixeira ve ark., 2010).



3. MATERYAL VE YÖNTEM

Bu tezde Duvar arkası radar tespit ve sınıflandırma amacı ile veri kaynağı olarak UGB radar teknolojisinin kullanılması önerilmiştir. Her ne kadar metalik engellerin arkasında radyo frekansının uygulanabilir olmaması, çözünürlüğün kullanılan frekansa bağlı olarak düşük olması gibi dezavantajları olsa da pratik duvar arkası algılama ve görüntüleme uygulamalarında UGB radar teknolojisi oldukça kullanışlıdır.

UGB radarları darbe radarı, sözde gürültü radarı, frekans modülasyonu sürekli dalga radarı ya da basamak frekanslı sürekli dalga kullanan radar metodolojileri olmak üzere farklı yaklaşımlar kullanılarak gerçekleştirilmektedir. Bu yöntemler kendi içlerinde avantaj ve dezavantajları bulunduğu gibi farklı kriter, öncelik ve kullanım amaçlarına göre tercih edilebilmektedir.

Duvar arkası tespit ve sınıflandırma probleminde aday sistemin ergonomik yapısı, güç tüketimi, standartlarla belirlenmiş termal, mekanik dayanıklılık veya fiziksel boyutlar sistemin ayırt edici ve tasarım aşamasında karar verilmesi gereken, aynı zamanda teknolojik kabiliyetleri sınırlandırabilecek parametreler olarak birlikte ele alınmalıdır. Elde taşınması beklenen bir konfigürasyon için koni tipi anten çiftinin seçilmesi ya da uzun süre çalışması beklenen duvar arkası radar için yüksek çıkış gücünün ele alındığı bir tasarım kararı sistemin beklenmeyen şekilde çalışmasına neden olabilecektir. Bu nedenle tüm tasarımın alt özelliklerin ele alınması, çok kriterli bir karar verme mekanizmasının oluşturulması, konfigürasyona uygun tespit ve sınıflandırma algoritmalarının seçilerek analiz edilmesi kritik öneme sahip olacaktır. Benzer şekilde merkez frekans değeri seçimi, RF bant genişliğinin menzil ve çözünürlük göz önünde bulundurularak tespit edilmesi, seçilmiş frekans aralığına bağlı olarak anten parametrelerinin belirlenmesi, antenlerin tipi, sayısı, mekanik özellikleri, antenler arası mesafenin belirlenmesi, algılayıcı alt sistemin dinamik bant aralığı, frekans yayım şemasının özelliklerinin irdelenmesi ve uygun şemanın seçimi gibi birçok parametre yine birçok kriter ve tasarım kararı önceliğine göre sistemin toplam yetenek, performans ve maliyet etkin olma kriterlerine göre etkili olacağından çok kriterli karar verme metodlarının uygulanması gerektiği ortaya çıkmaktadır. Bu noktada farklı seçimler farklı kriter ve önceliklere göre konumlanacağından ötürü tasarım varyantlarının ortak ve ayırt edici özelliklere göre modellenmesi, modele ait seçilen özelliklerin birlikte gösterimi ve duvar arkasında bulunan canlının tespiti ile konum ve pozisyonunun kestirimi için uygun yöntem ve algoritmanın belirlenmesi gerekmektedir. Böylece duvar arkası radar sisteminin araç üstü

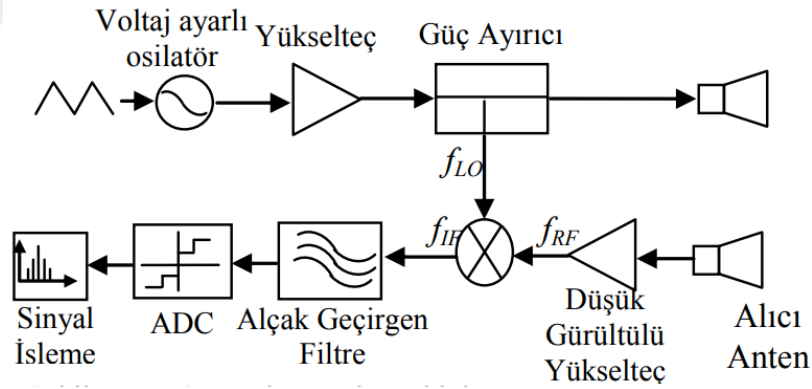
uzun menzil ya da elde taşınacak ve batarya ömrü uzun olan sistem gereksinimleri kullanım senaryolarına göre erken aşamalarda alınacak tasarım kararları ile uygun teknolojinin kullanılması sağlanabilecektir. Aynı şekilde teknolojik olarak uygun olmasına rağmen kullanımı kısıtlayabilecek parametrelerin erken teşhisi ile maliyet etkin çözüm oluşturulabilecektir.

Bu bölümde tezde kullanılan ilgili teknolojiler ve metotlar kapsamında açıklamalar verilmiş, kavramsal bir duvar arkası radar sisteminin hedef konum tespit ve pozisyon sınıflandırılması probleminin çözümüne yönelik bir özellik modeli sunulmuştur. Bu özellik modelinin opsiyonel seçim noktalarında bulanık integral kullanarak tasarım kararları belirlenerek amaçlanan konfigürasyon elde edilmiştir. Oluşturulan konfigürasyon kullanarak ilerleyen bölümlerde veri toplama işlemleri ile sınıflandırma sonuçları ve elde edilen başarı oranı değerlendirilmiştir.


3.1. Duvar Arkası Radar Teknolojisi

3.1.1. Frekans Modülasyonu Sürekli Dalga RADAR

Radar sistemlerinde darbe sinyalleri oluşturarak yüksek menzil çözünürlüğü elde edilebilmektedir. Darbe sinyali yüksek anlık bant genişliğine sahip oldukları için yüksek örnekleme yapabilen ADC birimlerine ihtiyaç duyulmaktadır. Çok yüksek örnekleme kabiliyeti yerine pratikte sıralı örnekleme ya da sinyalin modülasyonu kullanılmaktadır. Tipik olarak doğrusal frekans şeklinde zamanın bir fonksiyonu olarak üretilen işaretler ile oluşturulan radar metodolojisine FMCW adı verilmektedir. Şekil 3.1’de FMCW radarın basitleştirilmiş blok şeması verilmiştir. Zamana bağlı olarak değişken frekanslı bu sistemde gönderilen sinyal ile geri yansıyan sinyal (Şekil 3.2) karıştırıcı birimden geçirilerek fark frekansına sahip gecikmiş sinyal elde edilir. Böylece darbe genişliğini ve dolayısıyla darbe enerjisini azaltmadan yüksek çözünürlük elde edilebilmekte ve yüksek sinyal-gürültü oranı (*SNR: signal-to-noise ratio*) elde edilebilmektedir. Duvar arkası radar uygulamalarında hedeften yansıyarak duvardan geçecek sinyalin gecikme süresi çok kısa olacağından ötürü alıcı antene ulaşacak sinyal veri aktarımı yapılırken ulaşacaktır.



Şekil 3.1. FMCW Radar blok şeması



Şekil 3.2. FMCW Radar sinyalleri (Testeredişi örneği)

FMCW radar dalga formları genellikle üçgen dalga (Şekil 3.2) ya da testere dişi dalga biçimindedir. FMCW radarlarda gönderilen sinyal $S_t(t)$ matematiksel olarak aşağıdaki gibi ifade edilebilir (3.1):

$$S_t(t) = \text{rect}\left(\frac{t}{PRI}\right) \cdot \cos\left(2\pi\left(f_0 t + \frac{1}{2} a t^2\right)\right) \quad (3.1)$$

Burada $\text{rect}(\cdot)$ dikdörtgen fonksiyonunu göstermektedir. PRF (*pulse repetition frequency*) darbe tekrarlama frekansı olmak üzere denklemdeki PRI (*pulse repetition interval*) terimi $PRI=1/PRF$ olarak tanımlanmaktadır. f_0 , taşıyıcı frekansını, a ise frekans tarama hızını belirtmektedir. Frekans tarama oranı toplam bant genişliği ile doğru orantılıdır (3.2).

$$a = \frac{B}{PRI} = B \cdot PRF \quad (3.2)$$

Gönderilen sinyal duvardan geçtikten sonra hedeften geri yansıtacak ve tekrar duvardan geçerek alıcı antene ulaşacaktır. İletilen sinyalin gecikmiş bir fonksiyonu olarak alıcı antene ulaşan $S_r(t)$ yankı sinyalinin matematiksel ifadesi aşağıdaki gibidir (3.3):

$$S_r(t) = \text{rect}\left(\frac{t}{PRI}\right) \cdot \cos\left(2\pi\left(f_0(t - t_d) + \frac{1}{2} a(t - t_d)^2\right)\right) \quad (3.3)$$

Burada t_d gönderilen ile yansıyan sinyal arasındaki zaman gecikmesini ifade etmektedir. Belirli bir r mesafesindeki hedef için c ışık hızı olmak üzere $t_d = 2r/c$ olacaktır. Algılanan sinyal anlık iletilen sinyalin bir kopyası ile RF mikser biriminden geçirildikten sonra yüksek frekanslı bileşenlerin giderilmesi için alçak geçiren filtreden geçirilerek (Şekil 3.1) ara frekans sinyali (IF) elde edilir.

IF sinyalinin frekansı hedeften yansıyan zaman gecikmesi ve dolayısıyla hedef mesafesi ile doğru orantılıdır (3.4).

$$f_b = a t_d = \frac{2a}{c} r \quad (3.4)$$

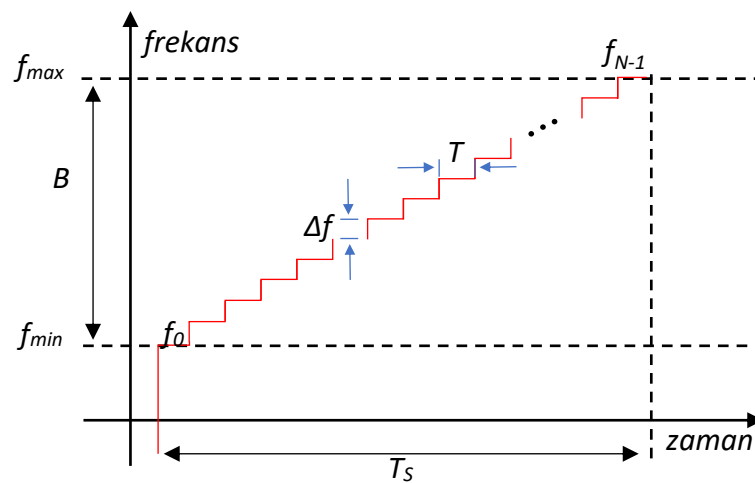
RF mikser ve alçak geçiren filtreden alınan sinyal belirli bir örnekleme frekansı ile ADC kullanılarak sayısal hale getirilir. Sayısal sinyal ise ters hızlı Fourier dönüşümü (IFFT) ile frekans düzlemi verisine eşdeğer olan menzil profili elde edilir.

FMCW radarları düşük örnekleme frekansı gerektirdiği için karmaşıklığı az ve uygun maliyetlidir. Bununla birlikte iletim ve algılama işlemi aynı anda olmasından dolayı alıcı-iletici arasındaki sızıntı sinyallerine bağlı dezavantajı bulunmaktadır.

3.1.2. Basamak Frekanslı Sürekli Dalga RADAR

Belirlenen bant genişliği boyunca frekansın zamanın bir fonksiyonu olarak kademeli bir şekilde artırılması ile oluşturulan dalga formunun iletim verimliliği ve menzil çözünürlüğünün artırılması yönünde avantajı bulunmaktadır (Kilic ve ark., 2019). Gönderilen sinyalin ortalama iletim gücünün ve alıcı hassasiyetinin yüksek olması dolayısıyla SFCW radarları oldukça avantajlıdır (Lu ve ark., 2011). Bant üzerindeki bazı belirli ve sınırlandırılmış frekansların kullanılmasının istenmediği durumlarda SFCW tercih edilmektedir. Bunun yanı sıra menzil, çözünürlük ve yayılım karakteristiğinin daha iyi olması dolayısıyla elektriksel olmayan ortam olarak duvarların arkasındaki hedef ve nesnelerin tespit/görüntüleme uygulamalarında tercih edilmektedir (Fontana, 2004; Qamar ve Faruq, 2014). İletim süresi boyunca belirli bir frekans ile üretilen sinyalin gücünün kontrol edilebilmesi ve ortalama gücün yüksek olması avantajları sistem karmaşıklığı yüksek olsa dahi menzil ve çözünürlük avantajlarından ötürü SFCW radarları tercih edilmektedir.

SFCW radarlarında belirlenen minimum f_{min} ve maksimum f_{max} frekansları arasında N adımda kademeli olarak artan frekansta sinyaller üretilerek hedefe aktarılmaktadır (Şekil 3.3). SFCW radarlarında dalga kaynağı olarak doğrudan sayısal sentezleme (DDS) tekniği kullanılabilir. Böylece RF bileşen karmaşıklığı büyük oranda azaltılabilmektedir.



Şekil 3.3. SFVW radar sinyalleri zaman-frekans grafiği

SFCW radar için üretilen sinyalin toplam periyodunun T , başlangıç (minimum) frekansının f_0 , N adım ile oluşturulan sinyaldeki fark frekansının Δf olduğu durumda toplam bant genişliği $B = N\Delta f$ olacaktır.

Gönderilen radar sinyali $S_t(t)$ matematiksel olarak aşağıdaki gibi (3.5) ifade edilebilir (Qi ve ark., 2016):

$$S_t(t) = \sum_{n=0}^{N-1} \text{rect}\left(\frac{t - \left(n + \frac{1}{2}\right) * T}{T}\right) \exp\{j(2\pi(f_0 + n\Delta f)t + \varphi_0)\} \quad (3.5)$$

burada $\text{rect}\left(\frac{t}{T}\right) = \begin{cases} 1 & -\frac{T}{2} \leq t < \frac{T}{2} \\ 0 & \text{else} \end{cases}$, $n = 0, 1, 2, \dots, N-1$ dikdörtgen fonksiyonu olarak tanımlanmıştır. φ_0 ifadesi ise gönderilen sinyalin başlangıç fazını ifade etmektedir.

Gönderilen sinyal yayılım yolundaki elektriksel olmayan hedeflerden geri yansiyarak alıcı anten birimine ulaşacaktır. Ulaşan $S_r(t)$ sinyalinin matematiksel ifadesi ise (3.6):

$$S_r(t) = \sum_{n=0}^{N-1} \text{rect}\left(\frac{t - \left(n + \frac{1}{2}\right) * T - \tau(t)}{T}\right) \rho_n \exp\{j(2\pi(f_0 + n\Delta f)(t - \tau(t)) + \varphi_0)\} \quad (3.6)$$

burada $\tau(t) = \frac{2R(t)}{c}$ olarak ifade edilmiştir. $R(t)$, hedefin antene olan uzaklığı ve c ışık hızıdır. $\tau(t)$ hedeften yansıyan sinyalin gidiş ve dönüş süreleri toplamı olmak üzere zaman gecikmesini ifade etmektedir. φ_0 terimi sinyalin başlangıç fazı ρ_n ise sinyal yolu üzerindeki hedeflerin tümleşik yansıtma katsayısıdır ve gösterim basitliği açısından sinyalin saçılım yolu boyunca sabit olduğu varsayılmıştır.


SFCW radar uygulamalarında FMCW radarında olduğu gibi sayısal algılanan sinyaller sayısal hale getirilmesinin ardından ters hızlı Fourier dönüşümü (IFFT) uygulanarak frekans düzlemi verisine eşdeğer olan menzil profili elde edilir (Yoon ve Amin, 2009).

Duvar arkası radar sinyal üretimi ve algılaması için SFCW metodu ile çalışan vektör network analizör (VNA) cihazları kullanılabilir. VNA cihazları SFCW tekniğinde olduğu gibi istenilen frekans aralığında N adet frekans basamak şeklinde üreterek geri yansıyan sinyaller ile gönderilen sinyaller arasındaki ilişkiyi birimsiz olan saçılma parametresi (s-parametresi) şeklinde ifade edebilmektedir.

VNA cihazları (Şekil 3.4) portlarına uygun frekans ve bant genişliğine sahip antenlerin bağlanması ile SFCW radar uygulaması olarak da kullanılabilir. Örneğin Port1'den iletilen sinyalin hedeften yansıdıktan sonra Port2'den algılanması sonucu olarak iletilen ve yansıyan sinyallerin oranı şeklinde S21 parametresi elde edilir (Şekil 3.5). Bir karmaşık sayı formunda olacak S21 parametresi ile genlik ve faz değişimleri hakkında bilgi elde edilebilmektedir. Bant genişliği boyunca tüm frekanslarda üretilen sinyallerin iletilmesi ile elde edilecek S21 (ya da S12) dizisi üzerinde IFFT işlemi gerçekleştirilerek menzil profili elde edilmektedir. Frekans aralığındaki bu taramaya A-tarama adı verilmektedir. Antenin farklı konumlara taşınması ya da bazı uygulamalarda farklı zamanlarda yapılan taramalar dizisi iki boyutlu B-tarama olarak adlandırılmaktadır. Benzer şekilde hacimsel bilgi elde etmek için de B-tarama işleminin üçüncü boyutta da tekrarlanması ile C-tarama matrisi elde edilebilmektedir. Çok boyutlu tarama işlemleri zaman alıcıdır ve operasyonel durumunda bazı senaryolar için uygun değildir. Bununla birlikte yere nüfuz eden radar uygulamaları, mayın ya da patlamamış mühimmat tespiti gibi gömülü nesne/yapı araması senaryolarında sıklıkla kullanılabilir.



Şekil 3.4. Copper Mountain firmasına ait S5065 model VNA



Şekil 3.5. VNA s-parametre ilişkileri

Duvar arkası radar tespit ve görüntüleme işleminde A-taramalar sonucu elde edilen S-parametreleri dizisinin işlenmesi ile mikro-doppler sinyalleri tespit edildiğinden ötürü duvar arkası göğüs kafesi hareketi gibi mikro seviyede değişimler ya da omuz hareketi, yürüme, düşme gibi makro hareketler tespit edilebilmektedir (Kim ve Ling, 2009). Bununla birlikte sinyal işleme için gerekli verilerin toplanma sürelerinin makul ve uygulanabilir olması beklenecektir. Örneğin bazı çalışmalarda (Wang ve Fathy, 2013; Ritchie ve ark., 2016) bu süre 5-30sn olduğu için gerçek zamanlı tespit uygulamalarında önerilen bu metotlar dezavantajlı olarak değerlendirilecektir.

3.2. Özellik Modelleri

Bölüm 3.1’de duvar arkası radar tespit, görüntüleme ve konum kestirimi için literatürde bulunan UGB temelli teknolojiler ele alınmıştır. Duvar arkasında bulunan canlıların konumlarının tespitinin yanı sıra canlı tipi ve pozisyonu da çoğu uygulama için önemlidir. Örneğin rehine operasyonları, terörle mücadele ya da arama-kurtarma senaryolarında duvar arkasındaki kişilerin ayakta, sandalyede, yürümekte ya da yatıyor olduğu bilgisi operasyonu şekillendirecek ve ekiplere zaman kazandıracaktır. Bu gibi ihtiyaçlar için radar tespit ve kestirim probleminin yanı sıra görüntüleme ve elde edilen görüntünün sınıflandırılması problemi için çözüm aranmaktadır. Bu nedenle radarın kullanılacağı senaryoya uygun bir şekilde konfigürasyonun yapılması ve uygun algoritmanın belirlenmesi gerekmektedir. Teknoloji aynı olsa dahi duvarın bulunup bulunmaması, duvarın tipi ve karakteristik özellikleri, veri toplama süresi, cihazın taşınabilirlik kabiliyeti, kalibrasyon ihtiyacı, batarya ve kullanım ömrü, kullanıcı ara yüzü ve kayıt kapasitesi gibi birçok etken cihaz konfigürasyonunu değiştirebilecektir. Radar sistemini tasarlayan, kullanan ve ihtiyacı bulunan farklı disiplinlerdeki paydaşlar duvar arkası radar sisteminin farklı parametrelerini farklı önceliklere göre sınıflandırarak tanımlayacaktır. Ayrıca tanımlı özelliklerin diğer özelliklerle arasında kısıt (*constraint*) ilişkisi de bulunabileceğinden ötürü konfigürasyonun tasarım öncesi modellenmesi, doğrulanması ve gereksinimlere uygunluğunun denetlenmesi gerekmektedir. Radar sisteminin konfigürasyonunun belirlenmesi, kısıt ve özelliklerinin yönetilebilmesi için konfigürasyon olasılıklarının ve birimler arası ilişkilerin modellenmediği özellik modelleri (*feature models*) (Lee ve ark., 2002) uygun bir teknik olacaktır. Özellik ifadesi; belirli bir alan için belirlenen bir niteliğin o alan kapsamında gerçekleştirilecek sistemin belirli gereksinim, tasarım kararı ve potansiyel yapılandırma seçeneklerine karşılık olacak

bir terim şeklinde ifade edilebilir (Kaya, 2015). Özellik modelleri değişkenliğin yüksek olduğu ve birimler arası kısıt ve ilişkilerin oldukça karmaşık olduğu yazılım ürün hatlarının modellenmesinde oldukça başarılıdır (Benavides ve ark., 2005).

Yazılım ürün hatları (*software product lines: SPL*) ortak özellikler olsa dahi değişkenliklerin bulunduğu ve değişkenlik kısıtlarının yönetilmesi gereken bir “yazılım sistemleri kümesi” olarak tanımlanmaktadır (Karataş ve ark., 2010). SPL ile gereksinimler, tasarım, kod ve test süreçleri gibi farklı süreçler için çeşitli yazılım bileşenlerinin uygun bir şekilde yapılandırılması sağlanabilmektedir (Apel ve Kästner, 2009). Özellik modelleri ise bir SPL'nin özellik ve niteliklerini modellemek için değişkenliği ve ortaklığı modelleyebilen önemli tekniklerden biri olarak tanımlanmaktadır (Lee ve ark., 2002). Özellik modelleri bir modelin belirli özellikleri seçilerek ürün hattının konfigürasyonu ve yapılandırılması için kullanılmaktadır. Yapılandırma sürecinde seçilen özellikler olası model kısıtlamalarını karşılamak ve ürün gereksinimleri ile şekillenmiş model kurallarına uymak zorundadır.

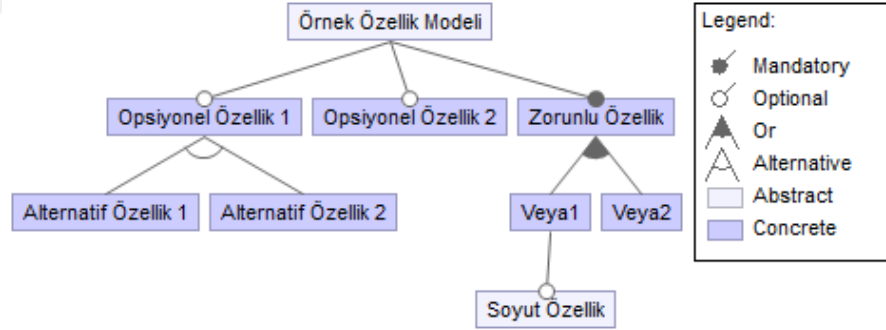
Zorunlu Özellik: Özellik modelinin türetilebilecek tüm konfigürasyonlarında bulunması zorunlu özelliklerin tanımlandığı özelliktir. İki farklı zorunlu özellik tipi bulunmaktadır. Birincisi, doğal olarak seçili bir özelliğin ata özelliğinin de seçilmiş olma zorunluluğudur. Örneğin “B” özelliği seçildiği ve “A” özelliğinin “B” özelliğinin atası olduğu durumda doğal olarak “A” özelliği seçilmek zorundadır. Bu kompozisyon kuralının haricinde modelde de gösterilen ve model konfigürasyonunda ilk seçilecek özellikler zorunlu özellikler olarak sınıflandırılır ve gösterilirler.

Opsiyonel Özellik: Ürün yapılandırma sürecinde bir özelliğin bulunması seçenek olarak gösterilmek istendiğinde bu özellik *Opsiyonel* özelliği ile tanımlanır. Opsiyonel olarak seçilen özelliğin atası zorunlu olarak seçilmelidir. Opsiyonel özelliğe bağlanmış tüm kısıtlar seçimin ardından aktif hale gelir ve ilgili kurallar çalıştırılır. Örneğin “B” özelliği opsiyonel özellik, “A” özelliği de “B” özelliğinin atası olduğu durumda “A→C”, “B→not D” kısıtları varsa ve “B” özelliği seçildiği zaman otomatik olarak “A” özelliği de seçilecek, buna bağlı olarak “gerekir” kısıtı sebebi ile “C” özelliği seçilmelidir. “B→not D” kısıtı gereği opsiyonel “D” özelliği seçim kümesinden kaldırılacaktır. Bu örnekte “D” özelliği zorunlu olarak modellenmiş olduğu durumda ise model tutarsızlığı meydana gelecek ve böyle bir konfigürasyonun oluşturulmasının modele göre mümkün olmadığı sonucuna ulaşılabilecektir.

VEYA Bağlantısı: Bir özelliğin çocuk özellikleri kümesi içerisinde 0..* seçimi bağlantısını göstermek için kullanılmaktadır. Bu durumda bir özelliğin n adet çocuk özelliği “veya” bağlantısı ile gösterilmesi durumunda 2^n farklı seçenek mevcut olacaktır.

Alternatif Bağlantısı: Bir özelliğin çocuk özellikleri kümesi içerisinde 1..1 seçimi bağlantısını göstermek için kullanılmaktadır. Bu durumda bir özelliğin n adet çocuk özelliği “alternatif” bağlantısı ile gösterilmesi durumunda çocuk özelliği seçeneklerinden yalnız bir özellik seçilebilir durumda olacaktır.

Şekil 3.6’da örnek olarak FeatureIDE yazılımı ile hazırlanmış bir özellik modeli gösterilmiştir. Burada somut (*concrete*) ve soyut (*abstract*) özellikler konfigürasyon aşamasında özelliğin niteliğini belirtmektedir. Özellik modellerinin kuralları gereği zorunlu (*mandatory*) özellikler konfigürasyon ve yapılandırma sırasında mutlaka seçilmesi gerekiyken, opsiyonel (*optional*) özellikler seçimlidir. Alternatif (*alternative*) özellikler “xor” ilişkisine sahip olmaları sebebi ile birden fazla seçenek arasında “sadece bir” özellik seçenek dahilindedir. Buna karşılık veya (*or*) özellikler 0..* ilişkisi içerisinde alt-küme yapılandırması ile konfigürasyona dahil edilebilmektedir.



Şekil 3.6. Özellik Modeli örneği

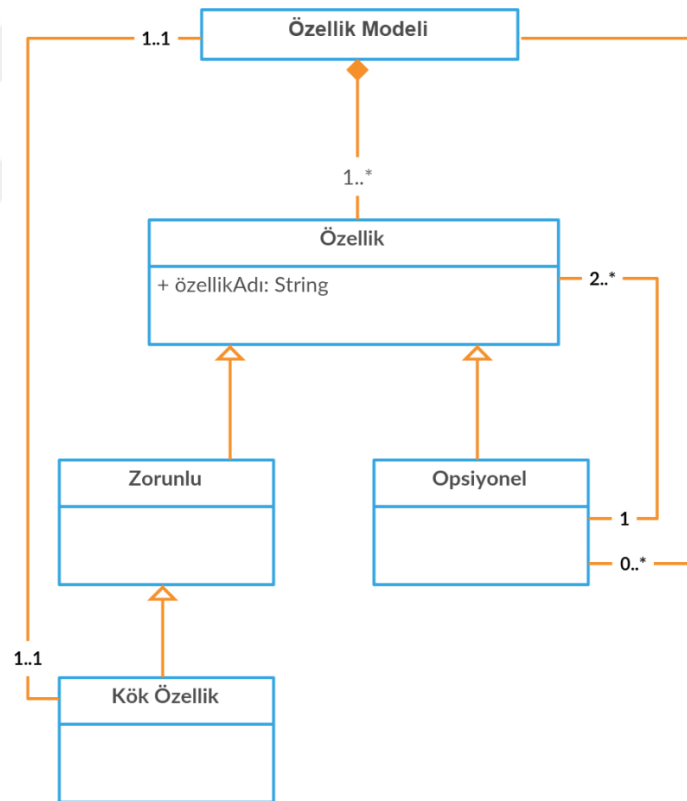
Şekil 3.6’da örnek olarak verilen modelde 30 farklı konfigürasyon ve 18 varyant bulunmaktadır. Örneğin modele göre aşağıdaki seçenekler ürün konfigürasyonu şeklinde yapılandırılabilir.

- Opsiyonel Özellik 1 – Alternatif Özellik 1 – Zorunlu Özellik → “Geçerli Konfigürasyon”
- Opsiyonel Özellik 2 – Alternatif Özellik 1 – Zorunlu Özellik – Veya1 → “Geçerli Konfigürasyon”
- Zorunlu Özellik – Veya1 – Veya2 → “Geçerli Konfigürasyon”

- Opsiyonel Özellik 2 – Alternatif Özellik 1 – Zorunlu Özellik – Veya1 → “Geçerli Konfigürasyon”
- Opsiyonel Özellik 1 – Alternatif Özellik 1 → “Geçersiz Konfigürasyon”
→ “Zorunlu Özellik” mevcut değil

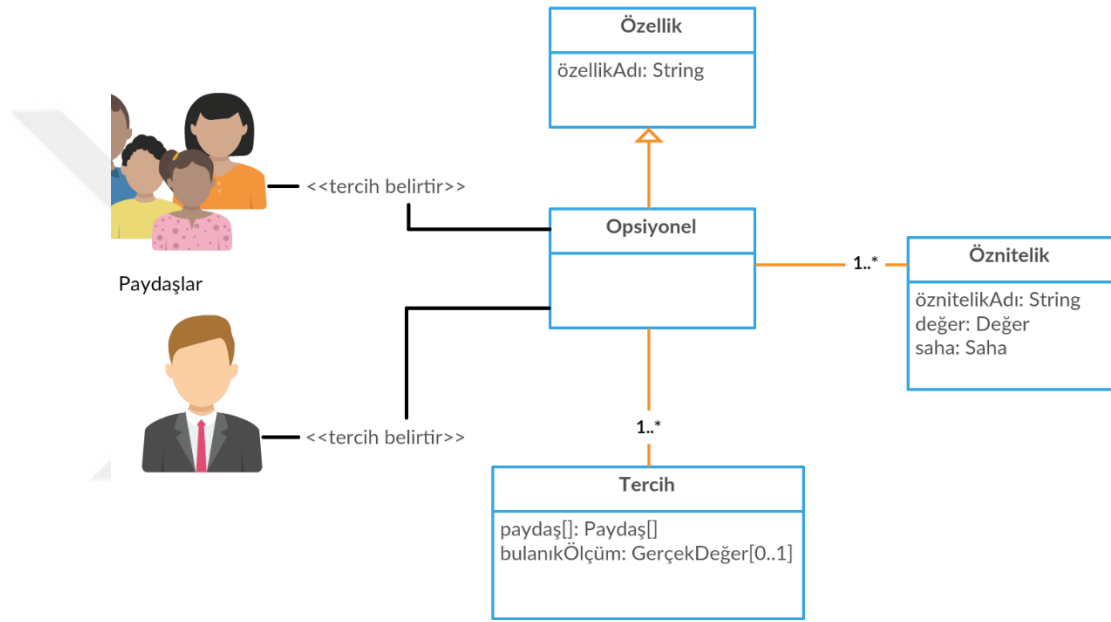
Özellik modelleri aynı zamanda kısıt semantiğini de desteklemektedir (Karataş ve ark., 2010). Kısıtların her biri “ve, veya, gerektirir, değil” vb. mantıksal ifadeler ile tanımlanabilmektedir. Bununla birlikte modeli oluşturan uzman ya da paydaşlar kendi bakış açıları ile probleme odaklanacaklarından ötürü farklı kısıtlar ve öncelik kriterleri olabilmektedir (Stein ve ark., 2014). Farklı paydaşlar kısıtları ve öncelikleri sadece birinci derece mantık (*first order logic*) operatörleri ile değil aynı zamanda bulanık mantık (*fuzzy logic*) ifadeleri ile de gösterilebilmektedir (Robak ve Pieczynski, 2003).

Şekil 3.7’de standart özellik modellerine ait kavramsal diyagram verilmiştir.



Şekil 3.7. Genişletilmiş Özellik Modeli

Şekil 3.8’de standart ve genişletilmiş özellik modeli tanımında yer almayan paydaşların etkisinin gösterildiği kavramsal diyagram verilmiştir. Buna göre paydaşlar özellik modeli varyant noktaları olan opsiyonel özellikler üzerinde kendi uzmanlık alanları, bilgi birikimi, tecrübe, ilgi ve kaygılarını göz önünde bulundurarak tercihlerini belirtecektir. Farklı bakış açılarına sahip farklı tercih değerleri opsiyonel özellik üzerindeki varyantların konfigürasyonuna doğrudan etki edecektir. Bununla birlikte her paydaşın farklı etki değeri olabileceği gibi göz önünde bulundurulmuş her bir kriterin de ayrı ayrı etki değerleri olabilecektir.



Şekil 3.8. Özellik Modelinde Paydaşlar

3.3. Bulanık İntegral

Farklı paydaşların oluşturduğu ve farklı kısıt ve önceliklerin bulunduğu özellik modellerinden ortaya çıkarılabilecek ürün varyantlarının probleme özgü bir şekilde ilgili kurallar çerçevesinde oluşturulmasına yönelik olmak üzere bu tezde bulanık integral kullanımı önerilmiştir. Birden fazla seçenek ve her seçeneğe atanmış bulanık öncelik değerleri bulunduğu durumda tüm seçeneklerin birlikte ele alındığı ve bulanık mantık kuralları çerçevesinde birleştirme işleminin yapıldığı bulanık integral operatörü ile model konfigürasyonu değerlendirilebilmektedir.

“Bulanık integral” terimi bulanık ölçümler sonucu elde edilen integraller için kullanılan genel bir ifadedir. Bulanık integral teorisi, bulanık analizin önemli bir parçası olarak ölçülebilir fonksiyon aralığının $[0,1]$ olduğu durumlar için tanımlanmıştır. Birçok varyantı olmasına rağmen *Choquet* (Klement ve ark., 2009) ve *Sugeno* integralleri (Sugeno, 1993) özellikle karar verme uygulamaları başta olmak üzere bulanık uygulamalarda önemli avantajlar sağlar.

Bulanık integral bulanık yoğunluk değerine bağlı lineer olmayan bir birleştirme operatörüdür (Auephanwiriyaikul ve ark., 2002). Bulanık integral operatörü farklı bileşenlerin önceliğinin bulunduğu ya da farklı önem derecelerinin atandığı durumlarda seçeneklerin birleştirilmiş şeklini sonuç bulanık değer şeklinde çözümler. Başka bir ifade ile bulanık integral ağırlıklı toplam işleminin aksine ikincil karar alma faktörlerinin etkisini iyileştirir. Bulanık integral bulanık ölçümlere (*fuzzy measure*) göre birleştirme işlemini gerçekleştirir. Bulanık ölçüm ise modeli oluşturan uzman ya da paydaşların bilgi birikimi, etki derecesi ve diğer faktörlere göre değerlendirilmesi sonucu elde edilen ve rasyonel olmayabilecek bir değerdir. X , karar verilecek kriterler kümesi olmak üzere $X = \{x_1, x_2, \dots, x_k\}$ kümesi olarak gösterildiği durumda ele alınacak kriterlere ait σ -cebiri kümesi $\{\emptyset, \{x_1\}, \{x_2\}, \{x_1, x_2\}, \dots, X\} = \Omega$ olarak ifade edilir.

X sonlu kümesi üzerinde bulanık ölçüm olarak $g: \Omega \rightarrow [0,1]$ fonksiyonu olarak gösterilir (3.7):

$$g(\emptyset) = 0, g(X) = 1 \quad (3.7)$$

olması koşuluyla (3.8),

$$A \subseteq B \subseteq X \text{ ise } g(A) < g(B) \quad (3.8)$$

şartını sağlar (Terano ve Sugeno, 1975). $\{A_i\}_{i=j}^{\infty}$, ölçülebilir kümelerin artan şekilde sıralı dizilimi olduğu durumda (3.9):

$$\lim_{i \rightarrow \infty} g(A_i) = g(\lim_{i \rightarrow \infty} A_i) \quad (3.9)$$

eşitliği söz konusudur. Sugeno bulanık integralinde iki ayrık alt kümenin ölçümü olarak g_λ –bulanık ölçümü ifadesi tanımlanmıştır. g_λ , aşağıdaki toplamsal eşitlikleri sağlamalıdır (3.10):

$$\begin{aligned} A, B \subset X, A \cap B = \emptyset, \\ g(A \cup B) = g(A) + g(B) + \lambda g(A)g(B) \end{aligned} \quad (3.10)$$

$X = \{x_{i1}, x_{i2}, \dots, x_{im}\}$ bir sonlu küme ve $g^i = g(\{x_i\})$ olarak gösterildiği durumda bulanık ağırlık fonksiyonu $x_i \rightarrow g^i$ olarak ifade edilir.

3.10 eşitliğindeki λ değeri ise (3.11) çok terimli denklemin çözülmesi ile elde edilir.

$$\lambda + 1 = \prod_{i=1}^n (1 + \lambda g^i), \lambda > -1 \quad (3.11)$$

Sabit bir g^i kümesi için $0 < g^i < 1$, $\lambda \in (-1, +\infty)$ ve $\lambda \neq 0$ şartlarını taşıyan bir değer bulunur. Böylece $i = 1, \dots, n$ olarak tanımlı iken g^i bulanık ağırlıklar belirlendiği durumda g_λ –bulanık ölçüm kümesi oluşturulabilmektedir. g^i , karar verme aşamasındaki son değerlendirme için x_i kaynakları kümesinde önem derecesi kümesi olarak değerlendirilir.

Tanım: $g, (X, 2^X)$ üzerinde bulanık ölçüm kümesi ve h giriş değerleri kümesi olsun. Bu durumda Sugeno bulanık integrali aşağıdaki (3.12) şekilde ifade edilir:

$$\int_S h \circ g = S_g(h) := \bigvee_{i=1}^n \left(h(x_{\pi(i)}) \wedge g(A_i) \right) \quad (3.12)$$

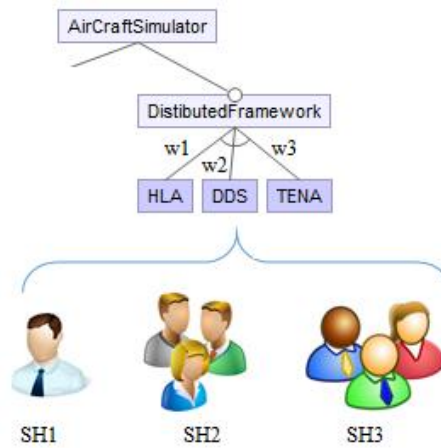
3.12 eşitliğinde \wedge minimum ve \bigvee maksimum operatörlerini, $h(x_{s(i)})$ ise aşağıdaki şekilde yeniden sıralanmış küme olarak ifade edilmektedir (3.13):

$$\begin{aligned} h \xrightarrow{\pi} h(x_{\pi(1)}) \geq \dots \geq h(x_{\pi(n)}), \\ A_i = \{x_{\pi(1)}, \dots, x_{\pi(i)}\}_{i=1}^n \end{aligned} \quad (3.13)$$

Tanım: $g, (X, 2^X)$ üzerinde bulanık ölçüm kümesi ve h giriş değerleri kümesi olsun. Bu durumda Choquet bulanık integrali aşağıdaki şekilde ifade edilir (3.14):

$$\int_C h \circ g = \sum_{i=1}^n \left(h(x_{\pi(i)}) [g(A_{(i)}) - g(A_{(i-1)})] \right) \quad (3.14)$$

Örnek olarak Şekil 3.9’da bir özellik modeli üzerinde opsiyonel olarak sunulan bir özellik ve bu özelliğin altında 3 farklı özellik gösterilmiştir. SH1..3 paydaş ya da paydaş grupları kendi tercihlerine göre farklı önceliklere göre tercih yapmıştır.



Şekil 3.9. Farklı paydaş gruplarının “Distributed Framework” seçeneği üzerindeki farklı tercihleri

Karar verici aynı zamanda her paydaş grubu için farklı ağırlık parametresi belirlemiştir (Çizelge 3.1).

Çizelge 3.1. Paydaşların ve karar vericinin atadığı öncelikler tablosu.

Paydaş	Paydaş etki katsayısı (g)	HLA (w1)	DDS (w2)	TENA (w3)
SH1	0.2	0.8	0.3	0.3
SH2	0.3	0.7	0.1	0.2
SH3	0.1	0.4	1.0	0.1


Bu tablodaki değerler ile (3.11) denklemi çözülerek $\lambda=3.109$ değeri elde edilir. (3.12) ve (3.14) denklemlerinden de Sugeno ve Choquet varyantı integraller hesaplanabilir. Aşağıda (Çizelge 3.2) örneğe ait sonuç çizelgesi verilmiştir.

Çizelge 3.2. Alternatif özelliğe ait hesaplama sonuçları

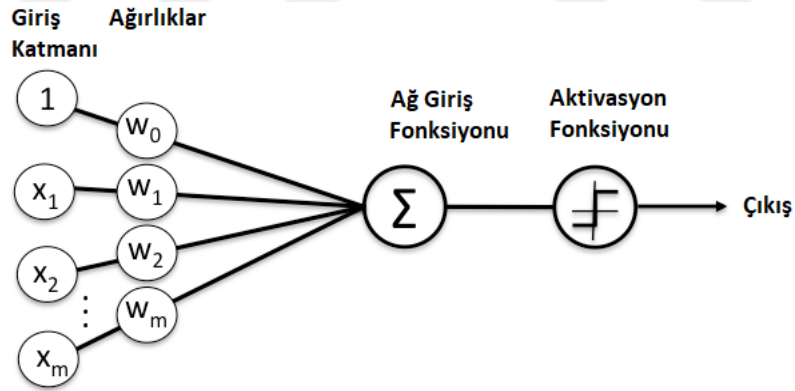
İntegral Methodu	HLA (w1)	DDS (w2)	TENA (w3)
Sugeno	0.687	0.3	0.2
Choquet	0.626	0.242	0.189
Ağırlıklı Ortalama	0.683	0.317	0.217

3.4. Derin Öğrenme

Derin öğrenme terminolojisi ve son yıllarda oldukça popüler olsa da kavramın temelindeki tekniğin tarihi 1950'li yıllara dayanmaktadır. *Perceptron* (Rosenblatt, 1958) adı verilen ilk yapay sinir ağı modeli ile ikili sınıflandırıcı (Şekil 3.11) probleminin eğitilmesi sağlanmıştır. Bu model temel olarak biyolojik nöronun (Şekil 3.10) en basit şekilde matematiksel modeli (3.15) olarak ele alınmıştır.



Şekil 3.10. Biyolojik nöron (Kriesel, 2007)



Şekil 3.11. Basit nöron modeli

$$f(x) = \begin{cases} 1, & \text{eğer } w \cdot x + b > 0 \text{ ise} \\ 0, & \text{diğer} \end{cases} \quad (3.15)$$

burada $f(x)$ nöronun çıkışını, w ağırlık vektörünü, $w \cdot x$ ağırlık vektörünün nokta çarpımını ve b ise yanlılık değeri (eğilim veya bayas (*bias*) olarak da isimlendirilir) katsayısını göstermektedir. Yapay sinir ağı modelinin ilk varyantları başlangıçta popüler olsa da birçok uygulama için yetersiz olduğu ve XOR problemi gibi lineer olarak

ayrıştırılmayacak veri setleri için modelin çözüm sunmadığı gösterilmiştir. Tekil nöron modelinin yerine karmaşık problemlerin çözümü için birden fazla nöronun bulunduğu ve nöronlar arası bağlantıların katmanlar halinde birleştirildiği modeller önerilmiştir (Yao, 1999). Bu modellerde nöronlar tekil ya da çoklu girdiye sahiptir. Bilgi, giriş katmanından saklı katmana taşınır, saklı katmanlar işlem yapar ve bilgiyi çıktı katmanına gönderir. Aktivasyon fonksiyonu yapay sinir ağındaki nöronun aktif olup olmayacağına karar veren bir fonksiyondur. *Sigmoid*, *tanh*, *relu*, *softmax* gibi çeşitli aktivasyon fonksiyonları çözümü amaçlanan probleme göre uygun olabilecek fonksiyonlar tanımlanmıştır. Ayrıca çok katmanlı modellerde hedef değişken ve çıktı arasındaki farkı hesaplayan ve kayıp değerini belirleyen hata fonksiyonu (*loss function*) tanımlanmıştır. Sınıflandırma amaçlı problemler için ayrıca ikili çapraz entropi (*binary cross entropy*), negatif log olabilirlik (*negative log likelihood*) benzeri birçok hata fonksiyonu da tanımlanmıştır.


Yapay sinir ağları temelli modellerde öğrenme işlemi bir dizi eğitim kümesinin modele uygulanması ve bilinen sonuçlar ile karşılaştırılması (danışmanlı öğrenme) esasına dayanır. Burada öğrenme işleminin hedefi temel olarak giriş ile çıkış ve beklenen değer arasındaki hatayı asgariye indirmektir. Hatanın yüksek olması durumunda hata değerini düşürmek üzere ağırlık ve yanlılık değerlerinin düzeltilmesi gerekmektedir. Bu modelde hata oranının en az olduğu durumdaki ağırlık ve yanlılık değerlerini öğrenme hedeflenir. Bu süreç için literatürde çeşitli optimizasyon algoritmaları (*optimization algorithms*) önerilmiştir. Stochastic Gradient Descent (Bottou, 2012), Adagrad (Duchi ve ark., 2011) ve Adam (Kingma ve Ba, 2014) yöntemleri örnek olarak verilebilir.

Yapay sinir ağlarının katmanlarının arttırılması ve katmanlar arasındaki bilgi akışının değişik şekillerde modellendiği metodoloji genel olarak “derin öğrenme” olarak adlandırılmış ve son yıllarda sınıflandırma problemlerinde oldukça başarılı uygulamalar geliştirilmiştir (LeCun ve ark., 1998; Krizhevsky ve ark., 2012; Montufar ve ark., 2014; Nielsen, 2015).

3.4.1 Yinelemeli Sinir Ağları

Yinelemeli sinir ağları (RNN: *Recurrent Neural Networks*) geleneksel sinir ağları modellerinden farklı olarak belirli bir düzende ve sıralı olarak bilgiyi kullanmaktadır. RNN döngüler içererek bilginin sürekliliğini sağlamaktadır. Yapay sinir ağı modelinde tüm girdiler birbirinden bağımsız olsa dahi bazı uygulamalarda bilginin önceki değerleri önem kazanmaktadır. RNN'ler teorik olarak önceden hesaplanmış verileri kaybetmemek ve uzun vadeli bilgiyi tutmak için tasarlanmış olmalarına rağmen, birçok uygulamada birkaç adım önceki bilgiler yeterli olmaktadır. Gerçek dünya problemlerinde bilginin sıralı şekilde anlam kazandığı ve durumun bir önceki duruma bağlı olarak şekillendiği zaman serilerinde RNN uygulamaları geleneksel sinir ağlarından daha başarılı sonuçlar vermektedir.

RNN ağ mimarisinde ağ içerisindeki her bir döngü ağın diğer katmanına bilgi taşır (Şekil 3.12). RNN modelinde birebir (*one-to-one*) ilişki sıklıkla kullanılmasına rağmen bire çok (*one-to-many*), çok bir (*many-to-one*) ve çok çok (*many-to-many*) ilişkiler de kullanılmaktadır.



Şekil 3.12. RNN yapısı ve RNN döngüsünün açılımı (Anonim, 2018)

RNN bilgi transferi aşağıdaki şekilde gerçekleştirilir:


$$\begin{aligned} s_t &= \tanh(U \cdot x_t + w \cdot s_{t-1} + b) \\ h_t &= \text{softmax}(V \cdot s_t + c) \end{aligned} \quad (3.16)$$

burada x_t giriş vektörü, s_t , t zaman adımında saklı olan durum vektörü, h_t çıktı vektörü, b ve c ise yanlılık vektörleridir. U, V, W vektörleri sırasıyla $x_t - s_t$, $s_t - h_t$ ve $s_t - s_t$ arasındaki bağlantılara ilişkin parametrelerdir. U, V, W ağırlık vektörleri zaman adımlarında değişiklik göstermemektedir.

3.4.2 Uzun Kısa-Vadeli Bellek Ağları

Uzun kısa-vadeli bellek ağları (LSTM: *Long Short Term Memory*) RNN mimarisinin uzak geçmişte tutamadığı bilgileri de saklayabilme özelliğinden ötürü RNN mimarisinden ayrılmaktadır. LSTM saklı durumlar üzerindeki hesaplamaları RNN mimarisinden daha derinleştirilmiş ve katman sayısı artırılmıştır (Hochreiter ve Schmidhuber, 1997).

Şekil 3.13'te LSTM mimarisi örneği verilmiştir. Burada RNN'den farklı olarak saklı durumda yerine 4 katman bulunmaktadır. LSTM kapı (*gate*) olarak adlandırılan yapılar tarafından hücre durumundaki (*cell state*) bilgileri silme veya tutma yeteneğine sahiptir. Dört adet sinir ağı katmanı girdi, unutma ve çıktı kapıları hücre durumunda ağın hafızasını meydana getirmektedir. LSTM'de ilk karar verilmesi gereken hangi bilgilerin kullanılacağıdır.



Şekil 3.13. LSTM Mimarisi (Anonim, 2018)

Şekil 3.13'te gösterilen ilk aktivasyon katmanı olan *sigmoid* katmanı bu durumun tespit edilmesi için kullanılmaktadır ve 0-1 aralığında bir değer üretir. 1 değeri bilginin gerektiğini, 0 ise bilginin silinmesi ve kullanılmaması gerektiğini belirtmektedir. İkinci adım yeni eklenen aday bilgilerin tutulduğu vektörlerin hesaplanması ve hücre

durumunda hangi verilerin saklanacağı bilgisidir. Şekil 3.13'teki ikinci aktivasyon (*sigmoid*) katmanı (unutma kapısı katmanı, *forget gate layer*) ve *tanh* katmanı iki kısımlı bilgi saklama sürecini göstermektedir. *Sigmoid* katmanı hangi bilgilerin güncelleneceğinin kararı için hesaplama yaparken, *tanh* katmanı yeni aday bilgileri oluşturmaktan sorumludur. Bu bilgiler sayesinde yeni hücre durumu unutilan ve güncellenen bilgiler kapsamında güncellenmektedir. Son aşamada çıktı olarak hangi bilginin iletileceğine karar verecek katman olan son *sigmoid* katmanında (çıkııı kapısı katmanı, *output gate layer*) filtreleme sonucu çıktı bilgisi elde edilmektedir. Sonuç olarak RNN'nin bir uyarlaması olarak kullanılan LSTM'in uzun geçmiş veri bağımlılıklarını öğrenebilen mimarisi ile bazı problemler için avantajları bulunmaktadır. Duvar arkası radar sinyalleri menzıl profillerine benzeyen uygulamalar olabilecek radar sinyallerinden hedef sınıflandırma (Schwegmann ve ark., 2016; Jithesh ve ark., 2017; Zhang ve ark., 2017), konuşma ve ses tanıma (Graves ve ark., 2013), ECG sinyallerinin sınıflandırılması (Yıldırım, 2018), mikro-doppler sinyallerinin sınıflandırılması (Klarenbeek ve ark., 2017; Angelov ve ark., 2018; Zhang ve ark., 2018) çalışmalarında LSTM başarı ve üstünlüğü gösterilmiştir.


3.4.3 Evrişimsel Sinir Ağları

Evrişimsel sinir ağları (ESA: *Convolutional Neural Networks-CNN*) temel olarak matematiksel evrişim (*convolution*) işleminin yapay sinir ağı giriş katmanına uygulanması esasına dayanmaktadır. Çok katmanlı bir yapay sinir ağı modeli olan ESA'da veri işleme için matris çarpımı yerine evrişim işlemi uygulanır (Goodfellow ve ark., 2016).

Genellikle resimler gibi matris ya da vektör formundaki verilerin eğitilmesi amacı ile basit bir ESA mimarisinde evrişim katmanları ve alt-örnekleme katmanları bulunmaktadır. Resimlerdeki kabul edilebilir gürültü oluşması, resimdeki öğelerde kayma ya da resmin yeniden boyutlandırma gibi bozucu etkilerden etkilenmemek üzere ESA mimarisi yerel algı alanları, paylaşılan ağırlık mekanizması ve alt-örnekleme gibi yapısal birimler barındırmaktadır. ESA mimarisinin güçlü etkisini göstermek üzere yapılan ilk çalışmalarda karakter tanıma problemi üzerinde durulmuştur (LeCun ve ark., 1998). Bu çalışmada ESA giriş bilgisi olarak ortalanmış el yazısı resmini almaktadır. Her katman ve katmandaki her birim önceki katmandaki komşuluk ilişkisi etrafında girdi kabul etmekte ve düzlemsel olarak aynı ağırlıkları paylaşacak şekilde organize edilmiştir.


Katmandaki her birim ayrı ayrı özellik haritası çıktı kümesi barındırmaktadır ve bu özellik haritasındaki bilgiler resmin farklı bölgelerinden elde edilmiştir.

Şekil 3.14'te gösterilen LeNet-5 ESA mimarisindeki ilk katman her biri ayrı bir özelliği haritalayan altı düzlemden oluşmaktadır. Özellik haritası 5x5 boyutlu 6 farklı özellik çıkarım matrisinin ilk giriş matrisi üzerinde dolaştırılarak evrişim işleminin gerçekleştirilmesi ile oluşturulmaktadır. Katmanda bulunan ve özellik haritaları bilgilerini barındıran düzlemler ortak ağırlık ve yönelim katsayılarını barındırdıklarından ötürü bu katsayılar paylaşılan ağırlıklar olarak tanımlanmaktadır.



Şekil 3.14. LeNet-5 ESA Mimarisi (LeCun ve ark., 1998)

ESA mimarisinde evrişim katmanlarındaki çıkış verisinin boyutunu azaltmak amacı ile ortaklama (*pooling*) katmanları bulunmaktadır. En çok kullanılan yöntemler maksimum ve ortalama değer ortaklama yöntemleridir (Şekil 3.15).




Şekil 3.15. LeNet-5 ESA Mimarisi (LeCun ve ark., 1998)

Ortaklama yöntemleri genellikle evrişim katmanlarının ardından kullanılır ve her bir özellik haritası düzlemine ayrı ayrı uygulanır. Genellikle iki boyutlu olarak alınan bilgi eşit boyutlu matrislere bölünerek yonteme göre eşleştiği değerler ile maksimum ya da ortalama değerler üretilir.

ESA mimarisinin son katmanlarında ise genellikle tam bağlantılı (*fully-connected*) ve softmax katmanları bulunmaktadır. Tam bağlantılı katman ortaklama katmanından aldığı bilgileri bir sonraki katmandaki nöronların tümüne dağıtarak yapay sinir ağı modelini oluşturur. Ağın en sonunda ise sınıflandırma probleminin çözülmesine yönelik olarak softmax katmanı bulunur. Bu katman beklenen çıkış değerlerine ya da sınıflandırma sonuçlarını barındırmaktadır. Softmax katmanı girdi olarak verilen bilginin hangi oranda çıkış değerine benzediği hakkında bilgi üretmektedir. Softmax fonksiyonu genel olarak olasılık dağılım fonksiyonu olarak tanımlanır (3.17).

$$f_{softmax}(z) = \frac{e^{z_j}}{\sum_k e^{z_k}} \quad (3.17)$$


İlk ESA modellerinin ardından özellikle çok çekirdekli görüntü kartlarının yaygınlaşması, hesaplama ve bellek miktarının artmasının da etkisi ile 2010 yılından itibaren oldukça yüksek bir ilgi ile daha yetenekli, başarı oranı daha yüksek ve temelde derinliği arttırılmış yeni modeller ortaya çıkmıştır. Örneğin AlexNet (Krizhevsky ve ark., 2012) modelinin 2012 yılındaki *ImageNet Large-Scale Visual Recognition Challenge* adlı yarışmada elde ettiği yüksek başarı dikkatleri tekrar ESA mimarisine çekmiştir. Yarışmada 22.000 kategoride 15M'den fazla resim barındıran ImageNet veri kümesi kullanılmıştır. AlexNet ise 8 katmanlı bir ESA modeli kullanarak (Şekil 3.16) yüksek başarı elde etmiştir.



Şekil 3.16. AlexNet ESA Mimarisi (Krizhevsky ve ark., 2012)

AlexNet mimarisinde giriş katmanı $224 \times 224 \times 3$ olmak üzere RGB resimleri kabul etmektedir. Ardından gelen beş katman maksimum değer ortaklama yöntemini kullanan evrişim katmanları, sonraki üç katman ise tam bağlantılı katmanlardır. Ağın çıkışı softmax katmanı ile 1000 kategori sınıflandırma katmanıdır.

ESA mimarisini kullanan ve katman derinliğini oldukça arttırarak başarıya ulaşan bir çalışma olarak GoogleNet gösterilebilir (Szegedy ve ark., 2015). GoogleNet parametrelili 27 katman (100 bağımsız katman) ile AlexNet'ten daha iyi bir başarı göstermiştir (Şekil 3.17).

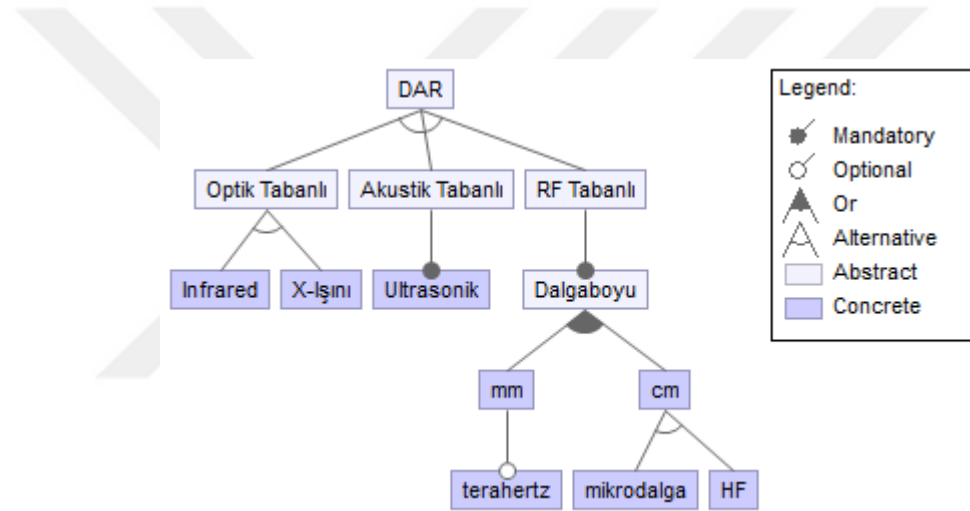


Şekil 3.17. GoogleNet ESA Mimarisi (Szegedy ve ark., 2015)

3.5. DAR Özellik Modelinin Oluşturulması

DAR özellik modeli farklı bakış açıları ile farklı kategorilerde modellenebilecektir. Her ne kadar özellik modellerine has hesaplama araçları tümleşik bir modelin varlığına ihtiyaç duysa da özellik modelleri üzerinde birleştirme operatörlerinin bulunması, modelin anlaşılabilir olmasının amaçlanması ve farklı noktaların vurgulanması gerekliliği nedenlerinden ötürü bu bölümde tümleşik modelin ilgili kısımları verilmiştir.

Şekil 3.18’de DAR sisteminin kullanılacak teknoloji açısından olası seçenekleri verilmiştir. Buna göre optik, akustik ya da RF teknolojilerinden biri kullanılarak gerçekleştirilmesi gerektiği vurgulanmıştır. Bu noktada sistemin oluşturulması için gerekli seçimin farklı kriterler ve öncelikler eşliğinde tamamlanması gerekmektedir.



Şekil 3.18. DAR Özellik Modeli – Teknoloji Kullanımı Varyantı

Kullanılacak teknoloji maliyet etkinlik, çözünürlüğün önemi ve uzun menzil ihtiyacı gibi probleme özgü kriterlere göre değişkenlik gösterebilmektedir. Çizelge 3.3’te belirlenen alternatifler ve alternatiflerin öncelik değerleri verilmiştir. Buna göre operasyonel şartlar göz önünde bulundurulduğunda maliyet etkinliğin öneminin yüksek olması ve uzun menzilde çalışabilmesi istenmektedir.

Çizelge 3.3. DAR Teknoloji alternatifleri ve öncelikler tablosu.

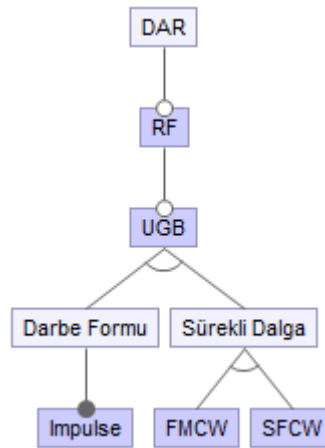
Kriter	Kriter etki katsayısı (g)	Optik (w1)	Akustik (w2)	RF (w3)
Maliyet Etkin	0.8	0.1	0.5	0.8
Çözünürlük	0.4	0.8	0.1	0.4
Menzil	0.6	0.1	0.2	0.8

Çizelge 3.4'te DAR teknoloji alternatiflerinin Sugeno ve Choquet integral yöntemleri kullanılarak 3 farklı kriterin birlikte ele alındığı sonuçlar verilmiştir. Kriterlerin birlikte ele alınması için iki integral yöntemi kullanılmıştır. Sugeno ve Choquet integralleri yöntemlerinin kullanılabilmesi için Çizelge 3.3'te verilen kriter etki katsayılarına göre (3.11) denklemi ile $\lambda=-0.9283$ değeri elde edilir. (3.12) ve (3.14) eşitliklerinin çözümü ile kriterlerin birlikte ele alındığı integral değerleri elde edilmiştir. Buna göre RF kullanımının DAR gereksinimleri doğrultusunda uygun olacağı sonucuna ulaşılmaktadır.

Çizelge 3.4. Alternatif özelliğe ait hesaplama sonuçları

İntegral Methodu	Optik (w1)	Akustik (w2)	RF (w3)
$\lambda=-0.9283$			
Sugeno	0.4	0.5	0.8
Choquet	0.378	0.4354	0.7818

Şekil 3.19'da DAR sistemi için RF kullanılması durumunda UGB dalga formları varyantları gösterilmiştir. Buna göre UGB radar için darbe ya da sürekli dalga formları ve sürekli dalga formu için de FMCW ve SFCW alternatifleri bulunmaktadır. Bölüm 3.1'de verilen bilgiler çerçevesinde bu varyantların farklı senaryolara göre avantajları bulunduğu için DAR konfigürasyonu için bu kriterlerin birlikte ele alınması gereklidir. Bu kriterler teknolojik, ekonomik, operasyonel ya da fiziksel açıdan ele alınabilmektedir.



Şekil 3.19. DAR UGB Formları Varyantları

Çizelge 3.5'te dalga formu alternatifleri için kriterler, kriterlerin ağırlıkları ve bunlara ait alternatiflerin etki değerleri verilmiştir. Buna göre operasyonel şartlar göz önünde bulundurulduğunda -örneğin el tipi konfigürasyon için- küçük boyutta olmasının ve günümüz RF bileşenleri göz önüne alındığında kolay üretilebilir olması istenmektedir.

Çizelge 3.5. DAR Dalga formu alternatifleri ve öncelikler tablosu.

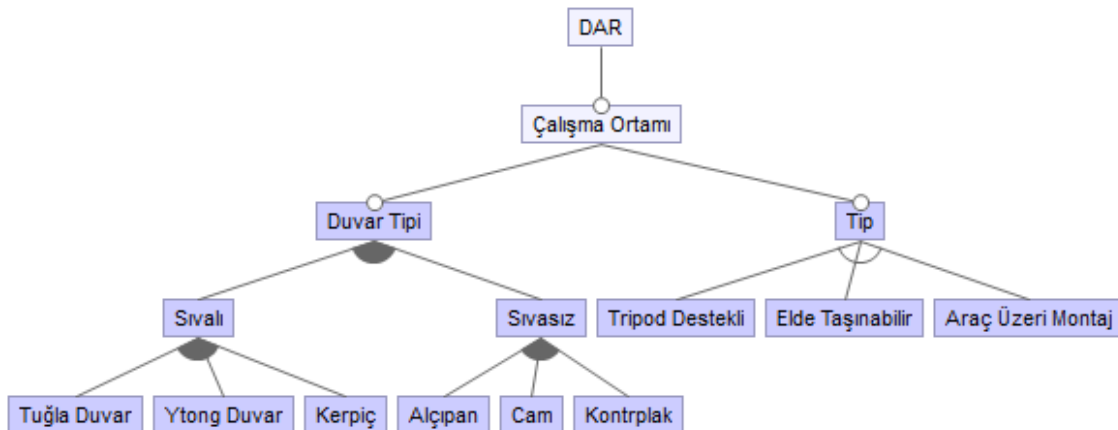
Kriter	Kriter etki katsayısı (g)	Darbe (w1)	FMCW (w2)	SFCW (w3)
Kolay Üretilebilirlik	0.7	0.2	0.8	0.9
Düşük Güç Tüketimi	0.4	0.6	0.5	0.4
Küçük Boyut	0.8	0.5	0.3	0.2

Çizelge 3.6'da verilen kriter etki katsayılarına göre (3.11) denklemi ile $\lambda=-0.9502$ değeri elde edilir. (3.12) ve (3.14) eşitliklerinin çözümü ile kriterlerin birlikte ele alındığı integral değerleri elde edilmiştir. Buna göre Sugeno integraline göre SFCW ya da FMCW kullanımının, Choquet integraline göre ise DAR gereksinimleri doğrultusunda SFCW kullanımının uygun olabileceği sonucuna ulaşılmaktadır.

Çizelge 3.6. Dalga formları alternatiflerine ait hesaplama sonuçları

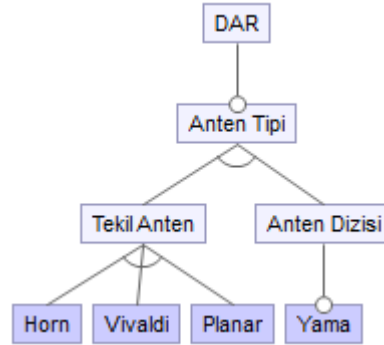
İntegral Methodu	Darbe (w1)	FMCW (w2)	SFCW (w3)
$\lambda=-0.9502$			
Sugeno	0.5	0.7	0.7
Choquet	0.5004	0.6628	0.6963

Şekil 3.20'de DAR çalışma ortamı özellik modeli verilmiştir. Bu modelde varyant olarak gösterilen tip özelliği temelde senaryoya bağlı olacağı için herhangi bir kriter verilmemiştir.



Şekil 3.20. DAR Çalışma Ortamı Özellik Modeli

Şekil 3.21’de DAR sistemine ait anten tipleri varyantlarını gösteren özellik modeli verilmiştir. Buna göre farklı özellik ve çalışma şekillerine sahip UGB anten tipleri seçilebilmektedir.



Şekil 3.21. DAR Anten tipleri varyantlarını gösteren özellik modeli

Çizelge 3.7’de dalga formu alternatifleri için kriterler, kriterlerin ağırlıkları ve bunlara ait alternatiflerin etki değerleri verilmiştir. Buna göre uzun menzil ve yüksek çözünürlük gereksinimlerinin karşılanması için küçük boyutta fakat yüksek kazançta sahip olması istenmektedir.

Çizelge 3.7. DAR Dalga formu alternatifleri ve öncelikler tablosu.

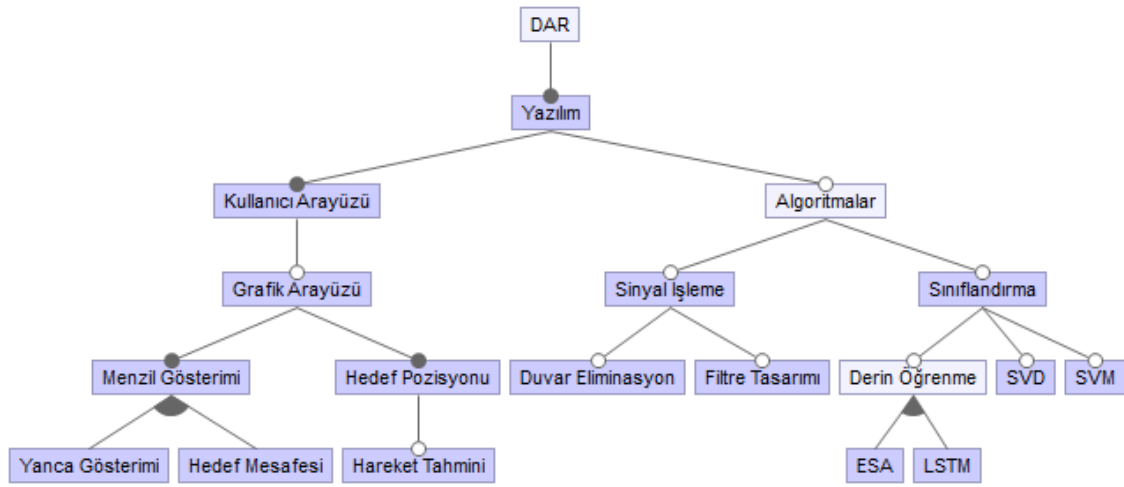
Kriter	Kriter etki katsayısı (g)	Horn (w1)	PCB Vivaldi (w2)	Planar (w3)	Yama (w4)
Bantgenişliği	0.6	0.6	0.65	0.7	0.5
Yüksek Güç	0.5	0.8	0.3	0.3	0.1
Küçük Boyut	0.8	0.1	0.3	0.3	0.6
Yüksek Kazanç	0.8	0.5	0.4	0.4	0.5

Çizelge 3.7’de verilen kriter etki katsayılarına göre (3.11) denklemi ile $\lambda = -0.9912$ değeri elde edilir. (3.12) ve (3.14) eşitliklerinin çözümü ile 4 farklı kriterin birlikte ele alındığı integral değerleri elde edilmiştir. Buna göre Horn ya da planar tipi anten kullanımının uygun olabileceği sonucuna ulaşılmaktadır. Bu gibi farklı yöntemlerin farklı değerler üretildiği durumlarda sayısal değeri yüksek olan tercih edilebilir.

Çizelge 3.8. Dalga formları alternatiflerine ait hesaplama sonuçları

İntegral Methodu $\lambda = -0.9502$	Horn (w1)	PCB Vivaldi (w2)	Planar (w3)	Yama (w4)
Sugeno	0.6	0.65	0.6565	0.6
Choquet	0.6931	0.5563	0.5892	0.5711

Şekil 3.22’de DAR sistemi yazılım konfigürasyonuna ait özellik modeli verilmiştir.



Şekil 3.22. DAR Yazılımına ait varyantları gösteren özellik modeli

Çizelge 3.9’da DAR canlı sınıflandırma algoritmaları alternatifleri için kriterler, kriterlerin ağırlıkları ve bunlara ait alternatiflerin etki değerleri verilmiştir. Buna göre yüksek sınıflandırma başarısına hızlı bir şekilde ulaşılması ve seçilecek algoritmanın mümkün olduğunca ön işlem gerektirmemesi beklentisi ifade edilmiştir.

Çizelge 3.9. DAR Sınıflandırma algoritması alternatifleri ve öncelikler tablosu.

Kriter	Kriter etki katsayısı (g)	ESA	SVD	LSTM	SVM
		(w1)	(w2)	(w3)	(w4)
Yüksek başarı oranı	0.9	0.9	0.8	0.9	0.5
Sınıflandırma Hızı	0.5	0.8	0.3	0.7	1.0
Ön işlem gerektirmemesi	0.3	1.0	0.3	1.0	0.3

Çizelge 3.10’de verilen farklı kriterlere ait etki katsayılarına göre (3.11) denklemi ile $\lambda=-0.9424$ değeri elde edilir. (3.12) ve (3.14) eşitliklerinin çözümü ile 3 farklı kriterin birlikte ele alındığı integral değerleri elde edilmiştir.

Çizelge 3.10. DAR Sınıflandırma algoritması alternatifleri hesaplama sonuçları


İntegral Methodu	ESA	SVD	LSTM	SVM
$\lambda=-0.9424$	(w1)	(w2)	(w3)	(w4)
Sugeno	0.9	0.8	0.9	0.5
Choquet	0.9228	0.758	0.9182	0.7247

3.6. DAR Verilerinin Elde Edilmesi

Duvar arkasında bulunan canlının tespit edilmesi ve konum ve duruşunun sınıflandırılmasına yönelik olarak Bölüm 3.5'te uygun konfigürasyon ve sınıflandırma algoritması seçimi yapılmıştır. Buna göre UGB olmak üzere SFCW dalga formunun kullanılması, koni tipi anten ile duvar etkisinin asgariye indirilerek uzun menzil gereksiniminin karşılanması sonucu ortaya çıkmıştır. Bu kapsamda konfigürasyonu yapılan DAR sisteminde canlı sınıflandırması için ESA yöntemi kullanılmıştır.

ESA yöntemi temelde “danışmanlı/gözetimli öğrenme” olması nedeni ile eğitim ve test verilerine ihtiyaç vardır. Bu kapsamda aşağıdaki duvarlar tipleri için Şekil 3.23'te gösterilen veri toplama ve test düzeneği oluşturulmuştur:

- Sıvalı Tuğla Duvar: 135mm genişlikte standart tuğla, ~10mm homojen olmayan sıva
- Sıvasız Tuğla Duvar: 135mm genişlikte standart tuğla
- Sıvalı Zenginleştirilmiş Beton Duvar
- Alçıpan Duvar: 12.5mm kalınlıkta 5 alçıpan levha biraraya getirilmiştir. Alçıpan levhalar arasında 10mm'den az homojen olmayan hava boşluğu bulunmaktadır.
- Cam tuğla




Şekil 3.23. DAR Ölçüm ve Test Düzeneği

Sıvalı ve sıvasız olmak üzere zenginleştirilmiş beton, tuğla ve ytong duvar ölçümleri için (Şekil 3.24) STM Savunma Teknolojileri ve Mühendislik A.Ş.'ye ait tesislerde düzenek oluşturularak ölçümler yapılmıştır.



Şekil 3.24. Farklı duvar tipleri için ölçüm ve test düzeniği

Ölçümün alınması için Copper Mountain firmasına ait S5065 2-Port 6.5GHz VNA (Şekil 3.25) kullanılmıştır. Bu VNA'ya ait teknik özellikler tablosu Çizelge 3.11'de verilmiştir. Ölçümlerden önce VNA portlarının açık, kapalı ve 50Ω değerleri için kalibrasyonu yapılmıştır.



Şekil 3.25. S5065 VNA ve kalibrasyon düzeniği

Çizelge 3.11. Kullanılan VNA'ya ait teknik özellikler

Copper Mountain S5065 VNA	Değer
Frekans aralığı	9kHz~6.5GHz
Port Sayısı	2
Ölçüm Parametreleri	S11, S12, S21, S22
Frekans Tarama Tipi	Doğrusal adım frekans, Log frekans, segment ve güç tarama
Dinamik alan	130 dB
Ölçüm hızı	70µs
Empedans	50Ω

Kalibrasyonu yapılan VNA ile Çizelge 3.12’de verilen deney düzeneği oluşturularak farklı özellikleri tanımlanmış senaryolara özgü ölçümler yapılmıştır.

Çizelge 3.12. Deney düzeneği parametreleri

Parametre	Değer
Frekans Aralığı	2 GHz ~ 4 GHz
Bant Genişliği (BW)	2 GHz
Frekans Adım Sayısı	$N_f = 201$
Frekans Adım Aralığı	10 MHz
Anten Sayısı	2
Anten Tipi	Koni (Horn)
Antenler Arası Mesafe	28cm
Anten Yüksekliği	114cm
Ölçüm Parametreleri	S11, S12, S21, S22
Frekans Tarama Tipi	Doğrusal adım frekans
IF Bant Genişliği	10 kHz
VNA Çıkış Gücü	5 dBm
SFCW Adım sayısı	201
Tarama sayısı	1000

Çizelge 3.12’deki değerlere göre maksimum radar menzili (3.18) ve radar çözünürlük değeri (3.19) eşitliklerine göre bulunur:

$$R_{max} = \frac{c(N_f - 1)}{2BW} = 15.00 \text{ m} \quad (3.18)$$

$$\Delta r = \frac{R_{max}}{(N - 1)} = \frac{c}{2BW} = 7.5 \text{ cm} \quad (3.19)$$

Senaryo duruş tipleri:

- Mikro Hareket Tipi : Sabit olarak nefes alıp verme ile göğüs kafesi hareketi
- Makro Hareket Tipi : Sabit durumda fakat omuzların salınım hareketi
- Yürüyüş : Normal yürüyüş ile iki nokta arasında yürüyüş hareketi
- Oturma : Sandalye üzerinde normal oturuş pozisyonu
- Ayakta : Ayaklar bitişik durumda ayaktaki normal duruş pozisyonu
- Çömelmiş : Sandalye olmadan sırt dik durumda oturuş pozisyonu

Senaryolar:

1. Boş ortam ölçümü
- Sıvalı tuğla duvar için:
 2. 2m ayakta insan mikro hareket,
 3. 2.5m ayakta insan mikro hareket,
 4. 3m ayakta insan mikro hareket,
 5. 3.5m ayakta insan mikro hareket,
 6. 4m ayakta insan mikro hareket,
 7. 4.5m ayakta insan mikro hareket,
 8. 5m ayakta insan mikro hareket,
 9. 2m sandalyede oturan insan mikro hareket,
 10. 2.5m sandalyede oturan insan mikro hareket,
 11. 3m sandalyede oturan insan mikro hareket,
 12. 3.5m sandalyede oturan insan mikro hareket,
 13. 4m sandalyede oturan insan mikro hareket,
 14. 4.5m sandalyede oturan insan mikro hareket,
 15. 5m sandalyede oturan insan mikro hareket,
 16. 2m ayakta insan 45deg dönmüş durumda mikro hareket,
 17. 3m ayakta insan 45deg dönmüş durumda mikro hareket,
 18. 4m ayakta insan 45deg dönmüş durumda mikro hareket,
 19. 5m ayakta insan 45deg dönmüş durumda mikro hareket,
 20. 2m ayakta insan 90deg dönmüş durumda mikro hareket,
 21. 3m ayakta insan 90deg dönmüş durumda mikro hareket,
 22. 4m ayakta insan 90deg dönmüş durumda mikro hareket,
 23. 5m ayakta insan 90deg dönmüş durumda mikro hareket,
 24. 2m çömelmiş insan mikro hareket,
 25. 3m çömelmiş insan mikro hareket,
 26. 4m çömelmiş insan mikro hareket,
 27. 5m çömelmiş insan mikro hareket,
 28. 2-5m arası ayakta insan yavaş adım yürüyüş,
 29. 2-5m arası ayakta insan hızlı adım yürüyüş,
 30. 3m mesafede ayakta insan, yancada -2m,+2m arası normal adım yürüyüş,
 31. 3m mesafede ayakta insan, yancada -2m,+2m arası yavaş adım yürüyüş,
 32. 2-5m arası ayakta insan, yanca +2m, hızlı adım yürüyüş,

33. 2m mesafe ayakta insan, kendi ekseninde döner hareket,
 34. 3m mesafe ayakta insan, kendi ekseninde döner hareket,
 35. 4m mesafe ayakta insan, kendi ekseninde döner hareket,
 36. 5m mesafe ayakta insan, kendi ekseninde döner hareket,
 37. 3m mesafe sandalyede oturan ayakta insan, kendi ekseninde döner hareket,
 38. 5m mesafe sandalyede oturan insan, kendi ekseninde döner hareket,
- Alçıpan duvar için:
 39. 3m mesafe ayakta mikro hareket,
 40. 5m mesafe ayakta mikro hareket,
 41. 3m mesafe sandalyede oturan mikro hareket,
 42. 5m mesafe sandalyede oturan mikro hareket,
 - Fiziksel özellikleri farklı bir kişi ile sıvalı tuğla duvar için:
 43. 2m sabit ayakta mikro hareket,
 44. 3m sabit ayakta mikro hareket,
 45. 4m sabit ayakta mikro hareket,
 46. 5m sabit ayakta mikro hareket,
 47. 3m sabit sandalyede oturan mikro hareket,
 48. 5m sabit sandalyede oturan mikro hareket,
 49. 3m sabit çömelerek mikro hareket,
 50. 5m sabit çömelerek mikro hareket,
 51. 2-5m yavaş adımlarla yürüyerek mikro hareket,
 - Fiziksel özellikleri farklı bir kişi ile sıvalı tuğla duvar;
 52. 2m sabit ayakta mikro hareket,
 53. 5m sabit ayakta mikro hareket,
 54. 2-5m yavaş adımlarla yürüyerek mikro hareket,
 55. 3m sandalyede oturan mikro hareket
 56. 5m sandalyede oturan mikro hareket
 57. 3m sabit çömelerek mikro hareket,
 58. 5m sabit çömelerek mikro hareket.


3.7. DAR Sınıflandırma Yöntemi

Duvar arkası canlı tespit ve sınıflandırma amacı ile 9 farklı senaryo için VNA ölçümleri kullanılmıştır. Bu senaryolar;

- 1) Boş ortam,
- 2) Duvar arkasında ve 2.5m mesafede mikro hareket ile ayakta duran kişi,
- 3) Duvar arkasında ve 5m mesafede mikro hareket ile ayakta duran kişi,
- 4) Duvar arkasında ve 2.5m mesafede mikro hareket ile sandalyede oturan kişi,
- 5) Duvar arkasında ve 5m mesafede mikro hareket ile sandalyede oturan kişi,
- 6) Duvar arkasında ve 2.5m mesafede makro hareket ile ayakta duran kişi,
- 7) Duvar arkasında ve 5m mesafede makro hareket ile ayakta duran kişi,
- 8) Duvar arkasında ve 2.5m mesafede makro hareket ile sandalyede oturan kişi,
- 9) Duvar arkasında ve 5m mesafede makro hareket ile sandalyede oturan kişi.

Sınıflandırma yönteminde yukarıdaki senaryolara göre Bölüm 3.6'da detayları verilen test düzeneği ve VNA parametreleri ile 1000'er ölçüm (S_{11} , S_{12} , S_{21} , S_{22} parametreleri) alınmıştır. Böylece "Boş", "Ayakta" ve "Oturuyor" olmak üzere 3 sınıflı bir problem ortaya konarak duvar olmadan, sıvalı tuğla duvar ve alçıpan duvar tipleri için değerlendirme yapılmıştır.

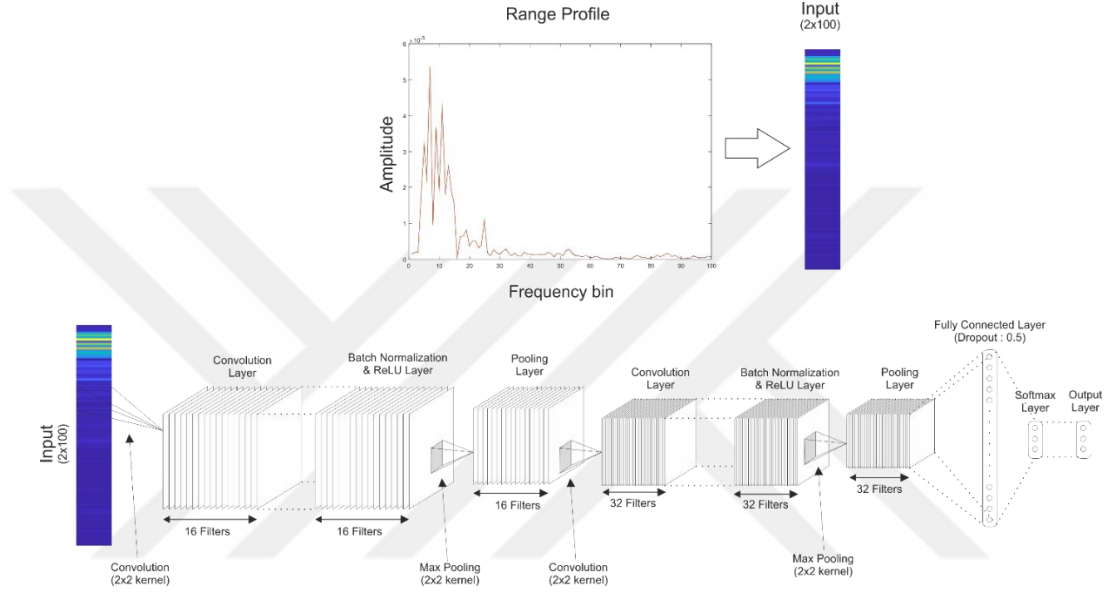
Sınıflandırma yöntemi olarak ESA kullanılmıştır. Öncelikle ölçüm sırasında alınan S_{12} ve S_{21} parametreleri ile 2×201 matris elde edilmiştir. Her ne kadar 201 frekans noktası için (3.18) eşitliği kullanılarak radar maksimum menzil mesafesi 15m olarak bulunsa dahi deney ölçüm mesafeleri 7m'den daha uzak olmadığı için ilk 100 frekans noktası dikkate alınarak 2×100 matris oluşturulmuştur (Şekil 3.26).



Şekil 3.26. ESA Akış Şeması

$$SI^j = ((S_{12,0}^j, S_{21,0}^j), (S_{12,1}^j, S_{21,1}^j), \dots, (S_{12,N-1}^j, S_{21,N-1}^j)) \quad (3.19)$$

Burada (3.19) SI^j matrisinin maksimum menzilin yarısına karşılık gelen ilk 100 parametresi 2×100 boyutlu olarak ESA giriş katmanına verilmiştir. Giriş katmanından evrişim katmanına ve derinlik sağlandıktan sonra sınıflandırma sonucu için çıkış katmanına veri aktarımı sağlanmıştır (Şekil 3.27).



Şekil 3.27. ESA Katmanları

Sınıflandırma sürecinde oluşturulan ESA yapısı için her bir senaryoda 1000 ölçüm olmak üzere toplam 9000 örnek kullanılmıştır. Bu örneklerin %80'i eğitim verisi olmak üzere rastgele seçilerek eğitim işlemi gerçekleştirilmiştir. Ayrıca farklı rastsallık değerleri kullanılarak süreç 30 defa tekrar edilmiş, sonuçlar değerlendirilmiştir. Bununla birlikte gerçek zamanlı testler için veri kümesinin tamamı eğitim verisi şeklinde ele alınarak ESA modeli oluşturulmuş ve bu model gerçek zamanlı testlerin başarısını kontrollü ortamlarda değerlendirmek amacı ile kullanılmıştır. Kontrollü ortam temel olarak anten pozisyonunun sabit olduğu, etrafta etki edebilecek kaynakların asgari olduğu ve eğitim/test verilerinin aynı konfigürasyon ile toplandığı ortam olarak değerlendirilmiştir.

Çizelge 3.13'te sınıflandırma amaçlı kullanılan ESA katmanlarının parametre değerleri verilmiştir.

Çizelge 3.13. ESA Katmanları Parametre Değerleri

Katman	Parametre	Değer
Giriş Katmanı (<i>Input Layer</i>)	Giriş Boyutu (<i>Input size</i>)	2x100
Evrişim Katmanı (<i>Convolutional Layer</i>)	Kernel Boyutu (<i>Kernel size</i>)	2x2
	Filtre Sayısı (<i># of filters</i>)	16
	Transfer Fonksiyonu (<i>Transfer function</i>)	ReLU
Toplu Normalleştirme Katmanı (<i>Batch Normalization Layer</i>)	Transfer Fonksiyonu	ReLU
Ortaklama Katmanı (<i>Pooling Layer</i>)	Kernel Boyutu	2x2
	Filtre Sayısı	16
	Transfer Fonksiyonu	ReLU
Evrişim Katmanı	Kernel Boyutu	2x2
	Filtre Sayısı	32
	Transfer Fonksiyonu	ReLU
Toplu Normalleştirme Katmanı	Transfer Fonksiyonu	ReLU
Ortaklama Katmanı	Kernel Boyutu	2x2
	Filtre Sayısı	32
	Transfer Fonksiyonu	ReLU
Tam Bağlantılı Katman (<i>Fully Connected Layer</i>)	Nöron sayısı (<i># of neurons</i>)	100
	Transfer Fonksiyonu	ReLU
	Dropout Katsayısı	0.5
Tam Bağlantılı Katman	Nöron Sayısı	3
	Sınıflandırıcı	Softmax
Çıkış Katmanı (<i>Output Layer</i>)	Çıkış Sayısı (<i># of outputs</i>)	3
	Sınıflar	Boş, Ayakta, Oturuyor

4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Duvar arkası canlıların tespit, konum ve pozisyon kestirimi amacına yönelik olarak kullanılacak radar teknolojisinin belirlenmesi, uygun konfigürasyon parametrelerinin belirlenmesi ve sınıflandırma algoritmalarının seçimi kapsamında özellik modelinin oluşturulması, özellik modeli kapsamında ortaya çıkan farklı varyantlardaki aday sistem konfigürasyonlarının belirli öncelik ve kriterlere göre seçilerek oluşturulması, radar ile tespit edilen canlının konum ve pozisyonunun tespiti ve sınıflandırılması için uygun algoritmaların belirlenerek gerçekleştirilmesi bu tezin temel motivasyon ve amacı olarak öne çıkmaktadır. Bu kapsamda Bölüm 3.5'te duvar arkasında bulunan hedefin tespitini, konumunun ve duruşunun kestirimini yapabilecek duvar arkası radar sisteminin özellik modeli oluşturulmuştur. Problemin gerektirdiği teknoloji, metot, yöntem ve algoritmaların belirlenmesine yönelik olarak öncelik ataması yapılabilecek özellik modelinden faydalanılarak probleme özgü fakat maliyet etkin bir konfigürasyon oluşturulmuştur. Oluşturulan konfigürasyon ile Bölüm 3.6'da detayları verilen veri toplama, Bölüm 3.7'de sunulan eğitim ve test aşamaları sonunda derin öğrenme metotları uygulanarak canlının pozisyonu sınıflandırılmıştır.

Duvar arkası canlı tespit ve sınıflandırma amacı ile 9 farklı senaryo için toplanan 9000 adet verinin %80'i (7200 adet) eğitim verisi, %20'si (1800 adet) ise test verisi olarak kullanılmıştır. Farklı rastsallık katsayılarına göre 30 defa çalıştırılan süreç sonucunda duvar olmadan doğrudan antenlerin karşısındaki hedef ile Bölüm 3.6'da özellikleri verilen sıvalı tuğla ve alçıpan duvarlara ait deneysel sonuçlar ve hata matrisleri (*confusion matrices*) aşağıda sunulmuştur (Çizelge 4.1, 4.2 ve 4.3). Çizelge 4.4 ise doğruluk sonuçları farklı duvar tiplerinin birlikte ele alınabilmesi için verilmiştir.

Duvarın bulunmadığı ortam testleri duvardan kaynaklanan sinyal bozucu etkilerin gözlenmesi ve sınıflandırma metoduna olabilecek olumsuz etkilerinin değerlendirilmesi için gerçekleştirilmiştir. Temel olarak duvarın yapısındaki hava boşlukları ve farklı dielektrik katsayısına sahip katmanlar bulunduğundan dolayı sinyalin genliği ve şeklinde önemli değişiklikler beklenmektedir. Bununla birlikte duvarın testler boyunca değişmemesi, anten pozisyonunun sabit olması ve ortamda bozucu diğer nesnelerin bulunmaması nedenlerinden ötürü sınıflandırma başarısında dikkat çekici azalma gözlenmemiştir.

Çizelge 4.1. Duvar olmaksızın yapılan testlere ait sonuç matrisleri

		GERÇEK DURUM			TOPLAM
		BOŞ	AYAKTA	OTURUYOR	
TAHMİN	BOŞ	200	6	7	
	AYAKTA	0	786	5	
	OTURUYOR	0	8	788	
TOPLAM		200	800	800	1800
DOĞRULUK ORANI		%100,00	%98,25	%98,50	%98,56

			GERÇEK DURUM								TOP.			
			BOŞ	AYAKTA				OTURUYOR						
				MİKRO		MAKRO		MİKRO		MAKRO				
				@ 2.5m	@ 5m	@ 2.5m	@ 5m	@ 2.5m	@ 5m	@ 2.5m		@ 5m		
TAHMİN	AYAKT.	MİKRO	@2.5m	200	1	3	1	1	1	3		3		
			@5m		198				1					
		MAKRO	@2.5m				196				1			
			@5m					196				2	1	
		OTUR.	MİKRO	@2.5m		1				198				
				@5m			1				196			
	MAKRO		@2.5m				3					198		
			@5m					3					196	
	TOP.			200	200	200	200	200	200	200	200	200	1800	
	DOĞR. ORANI (%)			100	99	98	98	98	99	98	99	98	98,56	

Duvarın bulunmadığı ortamda sinyal bozucu etkilerin en az olmasından dolayı yüksek sınıflandırma başarısı elde edilmiştir. Ortamda canlı olmadığı durumda %100 sınıflandırma başarısı gözlenmiştir. Bununla birlikte canlı bulunan toplam 1600 örnekte 13 tespit ve 13 sınıflandırma hatası gözlenmiştir. Bu değerlere göre sınıflandırma işleminin yanı sıra tespit başarısının da yüksek olduğu değerlendirilebilmektedir.

Çizelge 4.2. Sıvalı tuğla duvar senaryolarına ait test sonuç matrisleri

		GERÇEK DURUM			
		BOŞ	AYAKTA	OTURUYOR	
TAHMİN	BOŞ	200	13	21	
	AYAKTA	0	774	7	
	OTURUYOR	0	13	772	TOPLAM
	TOPLAM	200	800	800	1800
DOĞRULUK ORANI		%100,00	%96,75	%96,50	%97

				GERÇEK DURUM										
				AYAKTA				OTURUYOR						
				MİKRO		MAKRO		MİKRO		MAKRO				
				@ 2.5m	@ 5m	@ 2.5m	@ 5m	@ 2.5m	@ 5m	@ 2.5m	@ 5m			
TAHMİN	AYAKT.	MİKRO	BOŞ	200	1	4	1	7	4	7	2	8		
			BOŞ	200	1	4	1	7	4	7	2	8		
	OTUR.	MİKRO	@2.5m		196				2					
			@5m			194				1				
		MAKRO	@2.5m				194					4		
			@5m					190						
	OTUR.	MİKRO	@2.5m		3				194					
			@5m			2				192				
		MAKRO	@2.5m				5					194		
			@5m					3					192	TOP.
	TOP.			200	200	200	200	200	200	200	200	200	200	1800
	DOĞR. ORANI (%)			100	98	97	97	95	97	96	97	96	96	97

Sıvalı tuğla duvarın bulunduğu ortamda duvarın yapısından kaynaklanan sinyal bozucu etkiler bulunmaktadır. Aynı şekilde duvarın ilk yansıtma noktalarında antenler arası sinyal etkileşimi de en fazla olmaktadır. Buna rağmen sıvalı tuğla arkası senaryolarda yüksek sınıflandırma başarısı elde edilmiştir. Ortamda canlı olmadığı durumda %100 tespit başarısı gözlenmiştir. Bununla birlikte canlı bulunan toplam 1600 ölçümdeki 34 örnekte tespit hatası ve 20 örnekte sınıflandırma hatası gözlenmiştir. Bu değerlere göre tespit ve sınıflandırma başarısının yüksek olduğu değerlendirilebilmektedir. Mikro hareketlere ait senaryolardaki sınıflandırma başarısı makro hareketlerin olduğu durumlara göre daha yüksek olmasına rağmen her iki durumun başarısının da gerçek zamanlı uygulamalar açısından kabul edilebilir yükseklikte olduğu değerlendirilebilmektedir.

Çizelge 4.3. Alçıpan duvar senaryolarına ait test sonuç matrisleri

		GERÇEK DURUM			
		BOŞ	AYAKTA	OTURUYOR	
TAHMİN	BOŞ	200	13	16	
	AYAKTA	0	780	8	
	OTURUYOR	0	7	776	TOPLAM
	TOPLAM	200	800	800	1800
DOĞRULUK ORANI		%100,00	%97,50	%97,00	%97,56

TAHMİN				GERÇEK DURUM								TOP.		
				AYAKTA				OTURUYOR						
				MİKRO		MAKRO		MİKRO		MAKRO				
				@ 2.5m	@ 5m	@ 2.5m	@ 5m	@ 2.5m	@ 5m	@ 2.5m	@ 5m			
TAHMİN	AYAKT.	MİKRO	BOŞ	200	1	3	2	7	2	5	3	6		
			BOŞ	198					2					
	AYAKT.	MAKRO	@2.5m				194				1	3		
			@5m					192					2	
	OTUR.	MİKRO	@2.5m		1				196					
			@5m			1				194				
		MAKRO	@2.5m				4					194		
			@5m					1					192	TOP.
	TOP.			200	200	200	200	200	200	200	200	200	200	1800
	DOĞR. ORANI (%)			100	99	98	97	96	98	97	97	97	96	97,56

Çizelge 4.4. Sonuç Doğruluk (%) Matrisi

Scene	BOŞ	Ayakta (m)				Oturuyor (m)			
		Mikro		Makro		Mikro		Makro	
		2.5	5.0	2.5	5.0	2.5	5.0	2.5	5.0
Duvar Olmadan	100	99	98	98	98	99	98	99	98
Sıvalı Tuğla	100	98	97	97	95	97	96	97	96
Alçıpan	100	99	98	97	96	98	97	97	96

Doğruluk matrisinde her üç fiziksel şartlara bağlı tespit ve sınıflandırma başarısının oldukça yüksek olduğu gözlenmiştir. Mesafe ve hareket tipinin değişmesinin de sınıflandırma başarısına etkilerinin oldukça az olduğu değerlendirilebilmektedir.

5. SONUÇLAR VE ÖNERİLER

5.1 Sonuçlar

Özellik modelleri son yıllarda yazılım ürün hatlarının modellenmesi ve ürün varyantlarının sistem üzerindeki etkilerinin gösterilmesi amacıyla kullanılan yöntemlerin başında gelmektedir. Tasarım aşamasındaki bir sistemin olası varyantlarının modellendiği ve varyantlar arasındaki ilişki ve kısıtların gösterildiği özellik modelleri ile farklı konfigürasyonlar oluşturulabilmektedir.

Farklı seçeneklerin farklı öncelik ve kriterlere sahip varyantların değerlendirilmesi için ise iki farklı integral yöntemi olarak Sugeno ve Choquet integraller etkin bir hesaplama yöntemi olarak kullanılmaktadır. Farklı seçimler farklı kriter ve önceliklere göre konumlanacağından ötürü tasarım varyantlarının ortak ve ayırt edici özelliklere göre de modellenmesi, modele ait seçilen özelliklerin birlikte gösterimi ve duvar arkasında bulunan canlının tespiti ile konum ve pozisyonunun kestirimi için uygun yöntem ve algoritmanın belirlenmesi gerekmektedir. Böylece duvar arkası radar sisteminin araç üstü uzun menzil ya da elde taşınacak ve batarya ömrü uzun olan sistem gereksinimleri kullanım senaryolarına göre erken aşamalarda alınacak tasarım kararları ile uygun teknolojinin kullanılması sağlanabilecektir. Aynı şekilde teknolojik olarak uygun olmasına rağmen kullanımı kısıtlayabilecek parametrelerin erken tespiti ile maliyet etkin çözüm oluşturulabilecektir.

Bu tez çalışmasında duvar arkasında bulunan bir kişinin tespit ve konumunun kestirimi yapılarak duvar arkasındaki kişinin duruş sınıflandırılması amaçlanmıştır. Bu kapsamda ultra geniş bant radar sisteminin özellik modeli oluşturulmuş, farklı kriterlere ve önceliklere sahip sistem varyantları integral yöntemleri ile değerlendirilerek oluşturulan radar sisteminin sınıflandırma amacı ile kullanılması ele alınmıştır. Problemin gerektirdiği teknoloji, metot, yöntem ve algoritmaların belirlenmesine yönelik olarak öncelik ataması yapılabilecek özellik modeli ile probleme özgü ve istenilen gereksinim ve kriterleri sağlayan bir konfigürasyon oluşturulmuştur. Oluşturulan konfigürasyon ile veri toplama, eğitim ve test aşamaları sonunda derin öğrenme yöntemlerinden olan evrimsel sinir ağları kullanılarak duvar arkasındaki bir kişinin duruşu yüksek sınıflandırma başarısı ile tespit edilmiştir.

Elde edilen yüksek sınıflandırma başarısı ile önerilen yöntemin ve modelin gerçek dünya senaryolarında da kullanılabilir düzeyde olduğu değerlendirilmektedir.

5.2 Öneriler

Test ve deneyler sinyal işleme yöntemleri ile tespit edilmesi daha zor olan mikro hareketler ile tüm frekans bandı üzerinde etkileri gözlemlenen makro hareketler ele alınmıştır. Makro hareketlerin tüm frekans çerçevesinde ölçülen S-parametrelerine olan olumsuz etkisi ve antenler arası girişimin bazı testlere olan etkilerden kaynaklı olarak ölçüm başarısının az da olsa azaldığı gözlenmiştir. Bununla birlikte eğitim sürecindeki veri miktarının artırılması ve daha fazla verinin kullanılması ile bu azalma giderilebilecektir.

Kullanılan frekans adım sayısı artırılarak daha uzun menzil ile kullanılan bant genişliği artırılarak daha yüksek çözünürlük elde edilebilmektedir. Daha yüksek çözünürlük ile duvar arkasındaki nesnenin fiziksel yapısı daha detaylı bir şekilde elde edilebileceğinden ötürü uzak noktadaki nesne sınıflandırma başarısı artacaktır. Bu durumda ölçüm ve sınıflandırma süresinde artış olsa dahi kullanım senaryosuna kritik uygulamalarda daha yüksek çözünürlük önemli olacaktır. Benzer şekilde radar çıkış gücünün artırılması ile uzun menzildeki nesnelerin farklı duvar kalınlıklarında da sınıflandırma başarısını arttıracığı değerlendirilmektedir. Daha yüksek dinamik aralığa sahip VNA ile yüksek çıkış gücünün etkisi gözlenebilecektir.

Bu çalışmada SFCW radardan elde edilen veriler kullanılmıştır. Bununla birlikte önerilen ESA modeli radar dalga formundan bağımsızdır. Giriş katmanı başta olmak üzere ESA katmanları uygun şekilde düzenlenerek konfigürasyondan bağımsız sınıflandırma yöntemi oluşturulabilecektir. Örneğin FMCW radar verilerinden de benzer sonuçlar elde edilmesi beklenebilir.

Yapılan ölçümler sonucu elde edilen verilerle eğitim ve test süreçleri gerçekleştirilmiştir. Bununla birlikte eğitim sonucu elde edilen ESA modelinin aynı özelliklere sahip fakat farklı duvarlar için ya da anten pozisyonunun değiştirildiği durumlarda eğitim yapılmadan sadece test işlemlerinin yapılması ile önerilen metodolojinin geçerliliği gösterilebilecektir.

KAYNAKLAR

- Acher, M., Collet, P., Lahire, P. ve France, R., 2009, Composing feature models, *International Conference on Software Language Engineering*, 62-81.
- Acher, M., Collet, P., Lahire, P. ve France, R., 2010, Comparing approaches to implement feature model composition, *European Conference on Modelling Foundations and Applications*, 3-19.
- Ahmad, F. ve Amin, M. G., 2007, Through-the-wall radar imaging experiments, *2007 Ieee Workshop on Signal Processing Applications for Public Security and Forensics*, 1-5.
- Ahmad, F., Zhang, Y. ve Amin, M. G., 2008, Three-dimensional wideband beamforming for imaging through a single wall, *Ieee Geoscience and Remote Sensing Letters*, 5 (2), 176-179.
- Ahmad, F. ve Amin, M. G., 2012, Wall clutter mitigation for MIMO radar configurations in urban sensing, *2012 11th International Conference on Information Science, Signal Processing and their Applications (ISSPA)*, 1165-1170.
- Ahmad, F. ve Amin, M. G., 2013, Through-the-Wall Human Motion Indication Using Sparsity-Driven Change Detection, *Ieee Transactions on Geoscience and Remote Sensing*, 51 (2), 881-890.
- Amin, M. G., 2017, Through-the-wall radar imaging, CRC press, p.
- Angelov, A., Robertson, A., Murray-Smith, R. ve Fioranelli, F., 2018, Practical classification of different moving targets using automotive radar and deep neural networks, *IET Radar, Sonar & Navigation*, 12 (10), 1082-1089.
- Anonim, 2018, <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>: [08.06.2019].
- Apel, S. ve Kästner, C., 2009, An overview of feature-oriented software development, *Journal of Object Technology*, 8 (5), 49-84.
- Atli, A. V. ve Öztürk, E., 2011, Non-invasive respiratory motion tracking using M-Sequence UWB Radar, *2011 3rd International Congress on Ultra Modern Telecommunications and Control Systems and Workshops (ICUMT)*, 1-4.
- Auephanwiriyakul, S., Keller, J. M. ve Gader, P. D., 2002, Generalized Choquet fuzzy integral fusion, *Information fusion*, 3 (1), 69-85.
- Baboli, M., Boric-Lubecke, O. ve Lubecke, V., 2012, A new algorithm for detection of heart and respiration rate with UWB signals, *2012 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 3947-3950.
- Baranoski, E. J., 2008, Through-wall imaging: Historical perspective and future directions, *Journal of the Franklin Institute*, 345 (6), 556-569.
- Benavides Cuevas, D. F., Segura Rueda, S. ve Ruiz Cortés, A., 2010, Automated analysis of feature models 20 years later: a literature review.
- Benavides, D., Trinidad, P. ve Cortés, A. R., 2005, Using Constraint Programming to Reason on Feature Models, *SEKE*, 677-682.
- Bottou, L., 2012, Stochastic gradient descent tricks, In: *Neural networks: Tricks of the trade*, Eds: Springer, p. 421-436.
- Charvat, G. L., Goodwin, J., Tobias, M., Pozderac, J. ve Peabody, J., 2012a, Detection algorithm implementation and measured results for a real-time, through-wall radar system using a TDM MIMO antenna array, *2012 IEEE Radar Conference*, 0240-0246.

- Charvat, G. L., Kempel, L. C., Rothwell, E. J., Coleman, C. M. ve Mokole, E. L., 2012b, A through-dielectric ultrawideband (UWB) switched-antenna-array radar imaging system, *Ieee Transactions on Antennas and Propagation*, 60 (11), 5495-5500.
- Dell'Aversano, A., Natale, A., Buonanno, A. ve Solimene, R., 2017, Through the wall breathing detection by means of a doppler radar and MUSIC algorithm, *IEEE sensors letters*, 1 (3), 1-4.
- Dijkman, R. M., 2006, Consistency in multi-viewpoint architectural design, Citeseer, p.
- Diraco, G., Leone, A. ve Siciliano, P., 2017, Radar-Based Fall Detection Using Deep Machine Learning: System Configuration and Performance, *AISEM Annual Conference on Sensors and Microsystems*, 257-268.
- Duchi, J., Hazan, E. ve Singer, Y., 2011, Adaptive subgradient methods for online learning and stochastic optimization, *Journal of Machine Learning Research*, 12 (Jul), 2121-2159.
- Farwell, M., Ross, J., Luttrell, R., Cohen, D., Chin, W. ve Dogaru, T., 2008, Sense through the wall system development and design considerations, *Journal of the Franklin Institute*, 345 (6), 570-591.
- Ferris, D. D. ve Currie, N. C., 1999, Survey of current technologies for through-the-wall surveillance (TWS), *Sensors, C3I, Information, and Training Technologies for Law Enforcement*, 62-73.
- Finkelstein, A., Kramer, J., Nuseibeh, B., Finkelstein, L. ve Goedicke, M., 1992, Viewpoints: A framework for integrating multiple perspectives in system development, *International Journal of Software Engineering and Knowledge Engineering*, 2 (01), 31-57.
- Fioranelli, F., 2013, Through-the-wall detection using ultra wide band frequency modulated interrupted continuous wave signals, *Durham University*.
- Fontana, R. J., 2004, Recent system applications of short-pulse ultra-wideband (UWB) technology, *IEEE Transactions on microwave theory and techniques*, 52 (9), 2087-2104.
- Goodfellow, I., Bengio, Y. ve Courville, A., 2016, Deep learning, MIT press, p.
- Graves, A., Jaitly, N. ve Mohamed, A.-r., 2013, Hybrid speech recognition with deep bidirectional LSTM, *2013 IEEE workshop on automatic speech recognition and understanding*, 273-278.
- Hartikainen, A., Pellinen, T., Huuskonen-Snicker, E. ve Eskelinen, P., 2018, Algorithm to process the stepped frequency radar signal for a thin road surface application, *Construction and Building Materials*, 158, 1090-1098.
- Hochreiter, S. ve Schmidhuber, J., 1997, Long short-term memory, *Neural computation*, 9 (8), 1735-1780.
- Jithesh, V., Sagayaraj, M. J. ve Srinivasa, K., 2017, LSTM recurrent neural networks for high resolution range profile based radar target classification, *2017 3rd International Conference on Computational Intelligence & Communication Technology (CICT)*, 1-6.
- Kang, K. C., Cohen, S. G., Hess, J. A., Novak, W. E. ve Peterson, A. S., 1990, Feature-oriented domain analysis (FODA) feasibility study, *Carnegie-Mellon Univ Pittsburgh Pa Software Engineering Inst.*
- Karanam, C. R. ve Mostofi, Y., 2017, 3D through-wall imaging with unmanned aerial vehicles using WiFi, *2017 16th ACM/IEEE International Conference on Information Processing in Sensor Networks (IPSN)*, 131-142.

- Karataş, A. S., Oğuztüzün, H. ve Doğru, A., 2010, Mapping extended feature models to constraint logic programming over finite domains, *International Conference on Software Product Lines*, 286-299.
- Kaya, M., 2015, Modeling Variability in Component Oriented Software Engineering, *Master's thesis, MIDDLE EAST TECHNICAL UNIVERSITY*.
- Kilic, A., Babaoglu, I., Babalik, A. ve Arslan, A., 2019, Through-Wall Radar Classification of Human Posture Using Convolutional Neural Networks, *International Journal of Antennas and Propagation*.
- Kim, Y. ve Ling, H., 2009, Human activity classification based on micro-Doppler signatures using a support vector machine, *Ieee Transactions on Geoscience and Remote Sensing*, 47 (5), 1328-1337.
- Kingma, D. P. ve Ba, J., 2014, Adam: A method for stochastic optimization, *arXiv preprint arXiv:1412.6980*.
- Klarenbeek, G., Harmanny, R. ve Cifola, L., 2017, Multi-target human gait classification using LSTM recurrent neural networks applied to micro-Doppler, *2017 European Radar Conference (EURAD)*, 167-170.
- Klement, E. P., Mesiar, R. ve Pap, E., 2009, A universal integral as common frame for Choquet and Sugeno integral, *IEEE transactions on fuzzy systems*, 18 (1), 178-187.
- Kriesel, D., 2007, A Brief Introduction to Neural Networks, p.
- Krizhevsky, A., Sutskever, I. ve Hinton, G. E., 2012, Imagenet classification with deep convolutional neural networks, *Advances in neural information processing systems*, 1097-1105.
- LeCun, Y., Bottou, L., Bengio, Y. ve Haffner, P., 1998, Gradient-based learning applied to document recognition, *Proceedings of the IEEE*, 86 (11), 2278-2324.
- Lee, K., Kang, K. C. ve Lee, J., 2002, Concepts and guidelines of feature modeling for product line software engineering, *International Conference on Software Reuse*, 62-77.
- Liu, H. ve Sato, M., 2014, In situ measurement of pavement thickness and dielectric permittivity by GPR using an antenna array, *Ndt & E International*, 64, 65-71.
- Liu, Q., Wang, Y. ve Fathy, A. E., 2012, A compact integrated 100 GS/s sampling module for UWB see through wall radar with fast refresh rate for dynamic real time imaging, *2012 IEEE Radio and Wireless Symposium*, 59-62.
- Liu, Y., Meng, H., Zhang, H. ve Wang, X., 2008, Motion compensation of moving targets for high range resolution stepped-frequency radar, *Sensors*, 8 (5), 3429-3437.
- Lu, B., Song, Q., Zhou, Z. ve Wang, H., 2011, A SFCW radar for through wall imaging and motion detection, *2011 8th European Radar Conference*, 325-328.
- Marimuthu, J., Bialkowski, K. ve Abbosh, A., 2014, Stepped frequency continuous wave software defined radar for medical imaging, *2014 IEEE Antennas and Propagation Society International Symposium (APSURSI)*, 1909-1910.
- Mercuri, M., Schreurs, D. ve Leroux, P., 2012, SFCW microwave radar for in-door fall detection, *2012 IEEE Topical Conference on Biomedical Wireless Technologies, Networks, and Sensing Systems (BioWireless)*, 53-56.
- Mohana, M. A., Abbas, A. M., Gomaa, M. L. ve Ebrahim, S. M., 2013, Discrimination between landmine and mine-like targets using wavelets and spectral analysis, *NRIAG Journal of Astronomy and Geophysics*, 2 (1), 54-66.
- Montufar, G. F., Pascanu, R., Cho, K. ve Bengio, Y., 2014, On the number of linear regions of deep neural networks, *Advances in neural information processing systems*, 2924-2932.

- Nielsen, M. A., 2015, *Neural networks and deep learning*, Determination press San Francisco, CA, USA:, p.
- Park, J., Javier, R., Moon, T. ve Kim, Y., 2016, Micro-Doppler based classification of human aquatic activities via transfer learning of convolutional neural networks, *Sensors*, 16 (12), 1990.
- Pieraccini, M., Tarchi, D., Rudolf, H., Leva, D., Luzi, G., Bartoli, G. ve Atzeni, C., 2000, Structural static testing by interferometric synthetic radar, *Ndt & E International*, 33 (8), 565-570.
- Qamar, A. ve Faruq, U., 2014, Modelling and simulation of UWB radar system for through the wall imaging and doppler detection, *Int. J. Eng. Trends Technol.(IJETT)*, 17 (7), 325-330.
- Qi, F., Liang, F., Lv, H., Li, C., Chen, F. ve Wang, J., 2016, Detection and classification of finer-grained human activities based on stepped-frequency continuous-wave through-wall radar, *Sensors*, 16 (6), 885.
- Ralston, T. S., Charvat, G. L. ve Peabody, J. E., 2010, Real-time through-wall imaging using an ultrawideband multiple-input multiple-output (MIMO) phased array radar system, *2010 IEEE international symposium on phased array systems and technology*, 551-558.
- Ritchie, M., Ash, M., Chen, Q. ve Chetty, K., 2016, Through wall radar classification of human micro-Doppler using singular value decomposition analysis, *Sensors*, 16 (9), 1401.
- Robak, S. ve Pieczynski, A., 2003, Employing fuzzy logic in feature diagrams to model variability in software product-lines, *10th IEEE International Conference and Workshop on the Engineering of Computer-Based Systems, 2003. Proceedings.*, 305-311.
- Rosenblatt, F., 1958, The perceptron: a probabilistic model for information storage and organization in the brain, *Psychological review*, 65 (6), 386.
- Schwegmann, C. P., Kleynhans, W., Salmon, B. P., Mdakane, L. W. ve Meyer, R. G., 2016, Very deep learning for ship discrimination in synthetic aperture radar imagery, *2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 104-107.
- Seyfioğlu, M. S., Gürbüz, S. Z., Özbayoğlu, A. M. ve Yüksel, M., 2017, Deep learning of micro-Doppler features for aided and unaided gait recognition, *2017 IEEE Radar Conference (RadarConf)*, 1125-1130.
- Seyfried, D., Busche, A., Janning, R., Schmidt-Thieme, L. ve Schoebel, J., 2012, Information extraction from ultrawideband ground penetrating radar data: A machine learning approach, *2012 The 7th German Microwave Conference*, 1-4.
- Seyfried, D., Jansen, R. ve Schoebel, J., 2014, Shielded loaded bowtie antenna incorporating the presence of paving structure for improved GPR pipe detection, *Journal of Applied Geophysics*, 111, 289-298.
- Stein, J., Nunes, I. ve Cirilo, E., 2014, Preference-based feature model configuration with multiple stakeholders, *Proceedings of the 18th International Software Product Line Conference-Volume 1*, 132-141.
- Sugeno, M., 1993, Fuzzy measures and fuzzy integrals—a survey, In: *Readings in Fuzzy Sets for Intelligent Systems*, Eds: Elsevier, p. 251-257.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V. ve Rabinovich, A., 2015, Going deeper with convolutions, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 1-9.
- Taylor, J. D., 1994, *Introduction to ultra-wideband radar systems*, CRC press, p.

- Teixeira, T., Dublon, G. ve Savvides, A., 2010, A survey of human-sensing: Methods for detecting presence, count, location, track, and identity, *ACM Computing Surveys*, 5 (1), 59-69.
- Terano, T. ve Sugeno, M., 1975, Conditional fuzzy measures and their applications, In: *Fuzzy Sets and Their Applications to Cognitive and Decision Processes*, Eds: Elsevier, p. 151-170.
- Toft, P., Coleman, D. ve Ohta, J., 2000, A cooperative model for cross-divisional product development for a software product line, In: *Software Product Lines*, Eds: Springer, p. 111-132.
- Urban, T. M., Vella, C., Bocancea, E., Tuttle, C. A. ve Alcock, S. E., 2014, A geophysical investigation of a newly discovered Early Bronze Age site near Petra, Jordan, *Journal of Archaeological Science*, 42, 260-272.
- Wang, G. ve Amin, M. G., 2006, Imaging through unknown walls using different standoff distances, *Ieee Transactions on Signal Processing*, 54 (10), 4015-4025.
- Wang, Y. ve Fathy, A. E., 2013, UWB micro-doppler radar for human gait analysis using joint range-time-frequency representation, *Active and Passive Signatures IV*, 873404.
- Wei, X. ve Zhang, Y., 2014, Autofocusing techniques for GPR data from RC bridge decks, *Ieee Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7 (12), 4860-4868.
- Wu, S., Tan, K., Xu, Y., Chen, J., Meng, S. ve Fang, G., 2012, A simple strategy for moving target imaging via an experimental UWB through-wall radar, *2012 14th International Conference on Ground Penetrating Radar (GPR)*, 961-965.
- Yang, Y. ve Fathy, A., 2007, Design and implementation of a low-cost real-time ultra-wide band see-through-wall imaging radar system, *2007 IEEE/MTT-S International Microwave Symposium*, 1467-1470.
- Yao, X., 1999, Evolving artificial neural networks, *Proceedings of the IEEE*, 87 (9), 1423-1447.
- Yarovoy, A., Kovalenko, V., Roth, F., Lighthart, E., Fogar, A. ve Lighthart, L., 2004, Landmine detection and discrimination based on gpr data, *Proceedings of the Tenth International Conference on Grounds Penetrating Radar, 2004. GPR 2004.*, 673-676.
- Yarovoy, A., Zhuge, X., Savelyev, T. ve Lighthart, L., 2007, Comparison of UWB technologies for human being detection with radar, *2007 European Microwave Conference*, 1574-1577.
- Yildirim, Ö., 2018, A novel wavelet sequence based on deep bidirectional LSTM network model for ECG signal classification, *Computers in biology and medicine*, 96, 189-202.
- Yoon, Y.-S. ve Amin, M. G., 2009, Spatial filtering for wall-clutter mitigation in through-the-wall radar imaging, *Ieee Transactions on Geoscience and Remote Sensing*, 47 (9), 3192-3208.
- Zhang, B. ve Zhu, G., 2015, High frame rate stepped frequency through-wall imaging radar, *2015 IEEE International Wireless Symposium (IWS 2015)*, 1-4.
- Zhang, F., Hu, C., Yin, Q., Li, W., Li, H.-C. ve Hong, W., 2017, Multi-aspect-aware bidirectional LSTM networks for synthetic aperture radar target recognition, *Ieee Access*, 5, 26880-26891.
- Zhang, Z., Tian, Z. ve Zhou, M., 2018, Latern: Dynamic continuous hand gesture recognition using FMCW radar sensor, *Ieee Sensors Journal*, 18 (8), 3278-3289.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Alper KILIÇ
Uyruğu : T.C.
Doğum Yeri ve Tarihi : Baskil, 1978
Telefon : 0332 223 8660
E-Posta : akilic@ktun.edu.tr

EĞİTİM

Derece	Adı	İl	Bitirme Yılı
Lise	: M.Akif Ersoy Lis. Merkez	Elazığ	1994
Üniversite	: Fırat Üniversitesi, Elek.-Elekt. Müh.	Elazığ	2000
Yüksek Lisans	: Fırat Üniversitesi, Bilgisayar Müh.	Elazığ	2002
Doktora	: Konya Teknik Üniversitesi, Bilg. Müh.	Konya	2019

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
2000-2003	Fırat Üniv. Bilgisayar Müh.	Araştırma Görevlisi
2003-2011	ODTÜ Bilgisayar Müh.	Araştırma Görevlisi
2011-2012	Gate Elektronik A.Ş.	Kıdemli Mühendis
2012-2018	Selçuk Üniv. Bilgisayar Müh.	Uzman
2018-...	Konya Teknik Üniv. Bilgisayar Müh.	Öğretim Görevlisi

UZMANLIK ALANI

Gerçek Zamanlı Gömülü Sistemler, Kritik Sistem Yazılımları, FPGA, RTOS, Duvar Arkası Radar, Modelleme ve Benzetim, Derin öğrenme

YABANCI DİLLER

İngilizce

PROJE

Araştırmacı, 2018, TÜBİTAK TEYDEB-1501, 3150900 proje numaralı “Duvar Arkası Hedef Tespit Radarı Geliştirilmesi”, STM Savunma Teknolojileri Mühendislik A.Ş.

YAYINLAR

Kılıç, A., Babaoğlu, İ., Babalık, A., Arslan, A. (2019). Through-Wall Radar Classification of Human Posture Using Convolutional Neural Networks. International Journal of Antennas and Propagation, 2019. (Doktora tezinden yapılmıştır)

Kılıç, A., Oğuztüzün, M. H. S., Karataş, A. (2011). Farklı Bakış Açılarındaki Özellik Modellerinin Analiz Amaçlı Birleştirilmesi. 4. Mühendislik ve Teknoloji Sempozyumu, (Doktora tezinden yapılmıştır)

Kılıç, A., Arslan, A. (2002, October). Minimax fuzzy Q-learning in cooperative multi-agent systems. In International Conference on Advances in Information Systems (pp. 264-272). Springer, Berlin, Heidelberg. (Yüksek Lisans tezinden yapılmıştır)

Kılıç, A., Kaya, M., Arslan, A. (2002). Finding Sub-optimal Policies Faster in Multi-Agent Systems: FQ-Learning. Intelligent Autonomous Systems 7, 177. (Yüksek Lisans tezinden yapılmıştır)