

<https://dergipark.org.tr/tr/pub/khosbd>

# Derin Öğrenme Destekli Çok Kanallı Karar Destek Sistemi ile Askeri Deniz Platformlarında Haberleşme Optimizasyonu

## Communication Optimization in Military Naval Platforms Using a Deep Learning-Based Multi-Channel Decision Support System

Yalçın KAPLAN <sup>1\*</sup> Umut SARAY <sup>2</sup>

<sup>1</sup> Turkish Coast Guard Command, Department of Research and Development, 06650, Ankara, Turkey

<sup>2</sup> Sivas Cumhuriyet University, Şarkışla School of Applied Sciences, Department of Artificial Intelligence and Machine Learning, 58400, Sivas, TURKEY

### Makale Bilgisi

Araştırma makalesi  
Başvuru: 09.03.2026  
Düzeltilme: 25.03.2026  
Kabul: 18.04.2026

### Önemli Noktalar

Askeri deniz platformlarında çok kanallı (Ka Bant, UHF/VHF, KİM, GSM) haberleşme altyapısını dinamik ve proaktif olarak optimize etmek amacıyla çok boyutlu parametreleri değerlendiren CNN-LSTM tabanlı akıllı bir karar destek sistemi geliştirilmiştir.

### Grafiksel Özet

### Anahtar Kelimeler

Derin Öğrenme  
UHF/VHF  
Ka Band  
GSM

### Keywords

Deep learning  
UHF/VHF  
Ka Band  
GSM



### Özet

Bu çalışma, askeri deniz platformlarında çok kanallı (Ka Bant, UHF/VHF, GSM, KİM) haberleşmeyi optimize eden derin öğrenme tabanlı bir karar destek sistemi sunmaktadır. Çok boyutlu sinyal ve ortam parametrelerini analiz eden yapay zekâ modeli, en uygun kanalı otomatik seçerek %91,4 doğruluk ve 0,906 F1-skoru elde etmiştir. Geleneksel yöntemlere kıyasla gerçek zamanlı karar alma ve gelecekteki kanal davranışlarını öngörme yeteneği sunan sistem; operasyonel çevikliği, haberleşme güvenliğini ve kesintisiz iletişimi önemli ölçüde artırmaktadır. Elde edilen bulgular, geliştirilen adaptif mimarinin modern ağ merkezli harp ortamlarında ve otonom deniz sistemlerinde güvenle uygulanabileceğini göstermektedir.

### Abstract

This study proposes a deep learning-based decision support system to optimize multi-channel communication (Ka Band, UHF/VHF, GSM, and wireless modules) in military naval platforms. By analyzing multi-dimensional signal and environmental parameters, the AI model dynamically selects the optimal channel, achieving 91.4% accuracy and a 0.906 F1-score. Compared to traditional methods, the proposed system provides real-time decision-making and predictive channel behavior capabilities, significantly enhancing operational agility, communication security, and uninterrupted connectivity. The findings demonstrate that this developed adaptive architecture can be reliably deployed in modern network-centric warfare environments and autonomous naval systems.

\*Corresponding author, e-mail: ykaplan@sg.gov.tr

## 1. GİRİŞ (INTRODUCTION)

Günümüzde deniz harekâtları, farklı coğrafi bölgelerde, değişken meteorolojik koşullar altında ve elektromanyetik spektrumun yoğun kullanıldığı ortamlar içerisinde icra edilmektedir. Bu durum, haberleşme altyapısında yüksek düzeyde süreklilik, esneklik ve güvenlik gereksinimini ortaya çıkarmaktadır. Modern askeri gemiler, çok sayıda haberleşme kanalını aynı anda destekleyebilen kompleks iletişim altyapılarına sahiptir. Bu kapsamda; Ka Bant gibi yüksek bant genişliğine sahip uydu bağlantıları, UHF/VHF gibi kısa ve orta menzilli radyo frekansları, gemi içi kablosuz haberleşme modülleri ve uygun koşullarda kullanılabilen GSM tabanlı sivil iletişim altyapıları entegre biçimde görev yapmaktadır. Fakat bu sistemlerin her biri, ortam koşullarına ve operasyonel gereksinimlere göre farklı avantajlar ve sınırlamalar barındırmaktadır. Bu nedenle mevcut haberleşme kanalları arasında akıllı ve koşullara duyarlı seçim yapabilen bir karar destek mekanizmasının oluşturulması büyük önem arz etmektedir.

Denizcilik haberleşme sistemlerinde derin öğrenmenin kullanımı üzerine yapılan araştırmalar; kanal modelleme, sinyal sınıflandırma ve iletişim kalitesi tahmini gibi alanlarda yüksek başarı sağladığını ortaya koymaktadır. Yapılan çalışmalar incelendiğinde, İHA (UAV) ile yer birimleri arasındaki iletişimde güvenliği artırmak amacıyla RIS destekli haberleşme stratejilerinin geliştirildiği ve bu kapsamda enerji cezalı çok etmenli derin pekiştirmeli öğrenme (MATD3-EP) tekniklerinden yararlanıldığı görülmektedir [1].

Derin pekiştirmeli öğrenme tabanlı yaklaşımların, çoklu kanal ortamlarında dinamik spektrum tahsisi ve kanal seçimi süreçlerinde etkili çözümler sunduğu gösterilmiştir. Bu tür sistemlerde doğru kanal seçimi, iletişim güvenliği ile sistem verimliliği üzerinde doğrudan belirleyici bir etkiye sahiptir. Bu bağlamda, kanal seçimi sürecine yapay zekâ destekli karar destek sistemlerinin entegrasyonu, önemli ve yenilikçi bir yaklaşım olarak öne çıkmaktadır [2]. Bununla birlikte, bilişsel radyo ağlarında, pekiştirmeli öğrenme ile meta-sezgisel optimizasyon yöntemlerinin birleştiren yaklaşımların kanal tahsisi ve kaynak yönetimini optimize ettiği; bu sayede spektrum kullanım verimliliğini artırırken çakışma oranlarını önemli ölçüde azalttığı gösterilmiştir [3]. Bir diğer çalışmada, kablosuz iletişim sistemlerinde makine öğrenmesi ve derin öğrenme tabanlı yaklaşımların; kanal tahmini, bağlantı kalitesi öngörüsü ve ağ performansının iyileştirilmesi gibi alanlarda önemli katkılar sağladığı ortaya konmuştur. Gemi içi ve gemiler arası iletişimde kullanılan kablosuz iletişim modülleri de sistemin genel performansı üzerinde belirleyici bir rol oynamaktadır. Bu modüllerin derin öğrenme temelli yaklaşımlarla desteklenmesi hem esneklik hem de güvenlik açısından önemli avantajlar sunmaktadır [4]. Son olarak, anlamsal iletişim sistemlerini derin öğrenme ile entegre eden yaklaşımların, veri iletimi sırasında oluşan anlam kaybını en aza indiren etkili çözümler sunduğu gösterilmiştir [5]. Bu çalışmalar, kablosuz sistemlerin güvenilirliğini artırmada yeni bir perspektif sunmaktadır. Mevcut literatür; denizcilik haberleşme sistemlerinde derin öğrenme tabanlı

çözümlerin hem iletişim kalitesini hem de operasyonel sürekliliği artırma potansiyeline sahip olduğunu göstermektedir. Fakat bu sistemlerin saha koşullarında uygulanabilirliğini ve güvenlik açısından dayanıklılığını sağlamak için daha fazla saha testi, veri seti genişletme çalışmaları ve bütünleşik sistem tasarımı gerekmektedir.

Gelecekteki çalışmalar, bu teknolojilerin insansız deniz araçları ve otonom platformlarla entegrasyonu üzerine yoğunlaşarak askeri deniz operasyonlarında yeni nesil iletişim çözümlerine zemin hazırlayacaktır. Geliştirilen derin öğrenme

tabanlı karar destek sistemi, askeri deniz platformlarının haberleşme altyapısına entegre edilebilecek, dinamik olarak kanal seçimleri yapabilen, adaptif ve modüler bir yapı sunmaktadır. Bu sistem, gerçek zamanlı izleme ve analiz yetenekleri sayesinde hem operasyonel etkinliği artırmakta hem de iletişim güvenliğini daha üst bir seviyeye taşımaktadır. Ayrıca, sistemin yapay zekâ destekli karar verme kabiliyeti, gelecekte insansız deniz araçları ve otonom deniz sistemleriyle bütünleştirilebilecek bir temel teşkil etmektedir.

**Tablo 1:** İletişim sistemleri ve kanal seçimi yaklaşımlarına ilişkin literatür özeti ve karşılaştırması.

| Kullanılan Yöntem                                                     | Hedef Sistem                                       | Kanal Türleri                                                           | Temel Katkı                                                                                                                    | Eksiklik / Sınırlama                                                                  | Çalışma |
|-----------------------------------------------------------------------|----------------------------------------------------|-------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------|---------|
| Derin öğrenme                                                         | Kablosuz haberleşme                                | RF                                                                      | Sinyal sınıflandırma ve kanal modelleme                                                                                        | Operasyonel optimizasyon eksik                                                        | [6]     |
| Deep Q-Network (DQN)                                                  | Bilişsel radyo ağı                                 | Dinamik spektrum                                                        | Dinamik kanal erişimi ve spektrum verimliliği optimizasyonu                                                                    | Gerçek zamanlı saha uygulamaları sınırlı                                              | [7]     |
| Deep Reinforcement Learning (DQN + LSTM)                              | Bilişsel araç ağı (CR-VANET)                       | Dinamik spektrum (vehicular RF)                                         | Zaman bağımlı kanal erişimi ve çoklu ajan optimizasyonu                                                                        | Askeri deniz ortamına doğrudan uygulanmamış                                           | [8]     |
| Federated Deep Reinforcement Learning (FDRL) + Semantic Communication | Dijital ikiz destekli Internet of Drones (IoD) ağı | OFDMA tabanlı kablosuz bağlantılar / UAV linkleri                       | Anlamsal veri iletimi ve hesaplama süreçlerinin birlikte optimize edilmesiyle gecikme ve enerji verimliliğinin iyileştirilmesi | Askeri deniz platformları ve çoklu kanal taktik haberleşme ortamlarında doğrulanmamış | [9]     |
| Multi-Agent Deep Reinforcement Learning (VDN tabanlı)                 | LEO uydu haberleşme sistemi                        | LEO downlink spektrumu (çok kanallı RF, jammer ortamı)                  | Anti-jamming altında dinamik spektrum erişimi ve kullanıcı memnuniyeti odaklı kanal seçimi optimizasyonu                       | Gerçek saha uygulaması ve deniz platformlarına entegrasyon gösterilmemiş              | [10]    |
| Hybrid ML (XGBoost + DL) + Windowing                                  | GNSS tabanlı uydu navigasyon sistemi               | GNSS RF sinyalleri (GPS, GLONASS, jammer ortamı)                        | Gerçek zamanlı jamming tespiti ve erken uyarı mekanizması ile yüksek doğruluklu sınıflandırma                                  | Uydu haberleşme (LEO vb.) ve ağ seviyesinde entegrasyon sınırlı                       | [11]    |
| LSTM tabanlı derin öğrenme (DNN)                                      | OFDM tabanlı 5G kablosuz haberleşme sistemi        | TDL, CDL, Rayleigh ve 3GPP TR38.901 kanal modelleri                     | LSTM tabanlı kanal tahmini ile LS ve MMSE yöntemlerine göre daha düşük hata oranı ve daha iyi performans sağlanması            | Hesaplama karmaşıklığı yüksek ve gerçek zamanlı saha uygulamaları gösterilmemiş       | [12]    |
| Derin öğrenme tabanlı optimizasyon (CNN-GRU)                          | Deniz haberleşme röle ağı (maritime relay network) | Deniz ortamı kablosuz kanalları (Rayleigh fading, hidrodinamik etkiler) | Dinamik deniz ortamında röle seçimi ve bağlantı olasılığı tahmini ile iletişim güvenilirliğinin artırılması                    | Gerçek saha verisi ve ekstrem hava koşullarında doğrulama sınırlı                     | [13]    |

| Kullanılan Yöntem                              | Hedef Sistem                                                       | Kanal Türleri                                                                  | Temel Katkı                                                                                    | Eksiklik / Sınırlama                                      | Çalışma    |
|------------------------------------------------|--------------------------------------------------------------------|--------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------|-----------------------------------------------------------|------------|
| LSTM tabanlı derin öğrenme + transfer learning | O-RAN uyumlu yeni nesil kablosuz ağlarda mobility management / RRM | Hücre RF kanalları, dinamik kullanıcı hareketliliği ve değişen kanal koşulları | Gelecek serving cell tahmini, yük dengeleme ve enerji verimliliği için hızlı model adaptasyonu | Fiziksel katman düzeyinde ayrıntılı kanal modelleme değil | [14]       |
| Multi-parametric Deep Neural Network           | Askeri deniz platformları                                          | Ka Bant, UHF/VHF, GSM, KİM                                                     | Koşullara bağlı kanal seçimi, çevresel faktör değerlendirilmesi, çoklu kanal optimizasyonu     | Gerçek zamanlı test ve saha prototipi geliştirme gerekli  | Bu Çalışma |

Literatürde yer alan çalışmaların yöntemsel yaklaşımları ve uygulama sonuçları bakımından karşılaştırılması Tablo 1’de özetlenmiştir. Tablo 1 incelendiğinde, mevcut çalışmaların büyük çoğunluğunun belirli haberleşme senaryolarına veya sınırlı kanal türlerine odaklandığı görülmektedir. Bu durum, geliştirilen yöntemlerin performansının çoğunlukla belirli çevresel koşullara ve uygulama bağlamlarına bağlı olarak değişkenlik göstermesine neden olmaktadır.

Özellikle derin öğrenme tabanlı yaklaşımların kanal tahmini, sinyal sınıflandırma ve veri bütünlüğü sağlama gibi alanlarda yüksek başarı oranları sunduğu görülmekle birlikte, bu çalışmaların önemli bir kısmında çoklu haberleşme kanallarının bütünlük olarak ele alınmadığı dikkat çekmektedir. Benzer şekilde, bazı çalışmaların yalnızca teorik modelleme veya simülasyon düzeyinde kaldığı, gerçek zamanlı uygulama ve adaptif karar mekanizmaları açısından sınırlı kaldığı gözlemlenmektedir.

Ayrıca, literatürdeki birçok yaklaşımın çevresel faktörler (parazit, sinyal zayıflaması, görüş hattı durumu vb.) ile operasyonel gereksinimleri eş zamanlı olarak değerlendirebilecek bütüncül bir

karar mekanizması sunmadığı görülmektedir. Bu eksiklikler, özellikle dinamik ve belirsiz koşulların hâkim olduğu askeri haberleşme ortamlarında mevcut yöntemlerin etkinliğini sınırlandırmaktadır.

Bu bağlamda, Tablo 1’de sunulan karşılaştırma, mevcut çalışmaların güçlü yönlerinin yanı sıra çok kanallı yapıların entegrasyonu, gerçek zamanlı karar verme ve çevresel farkındalık gibi alanlarda geliştirilmesi gereken yönlerini ortaya koymakta ve önerilen çalışmanın literatürdeki boşluğu doldurma potansiyelini açıkça göstermektedir. Bu çalışma, askeri deniz platformlarında kullanılan haberleşme sistemlerinin (Ka Bant, UHF/VHF, KİM’ler ve GSM) performanslarının derin öğrenme tabanlı yöntemlerle analiz edilerek, çoklu kanal yapılarına dayalı karar destek sistemlerinin geliştirilmesini amaçlamaktadır. Önerilen yapı, farklı haberleşme kanallarından elde edilen çok boyutlu verilerin analizine dayalı olarak çalışan bir derin öğrenme mimarisi içermektedir. Model; sinyal gücü, paket kaybı oranı, gecikme süresi, elektromanyetik parazit seviyesi, platformlar arası görüş hattı durumu ve çevresel koşullar gibi parametreleri değerlendirerek en uygun haberleşme kanalını belirlemekte ya da geçişi

otomatik olarak gerçekleştirmektedir. Bu yaklaşım, hem iletişimin sürekliliğini artırmakta hem de askeri operasyonlar sırasında insan faktöründen kaynaklı gecikmeleri minimize etmektedir. Modelin eğitimi, farklı operasyon senaryolarında toplanmış çok kanallı iletişim verileri kullanılarak gerçekleştirilmiştir. Bu veriler, haberleşme altyapısının hem normal işleyişini hem de arıza ya da tehdit durumlarındaki davranışını kapsayacak şekilde çeşitlendirilmiştir. Böylece modelin öğrenme kapasitesi artırılmış, öngörülemeyen durumlara karşı daha dayanıklı bir yapı oluşturulmuştur. Eğitim süreci boyunca veri kümesine çeşitli etiketleme yöntemleri uygulanarak sinyal

## 2. MATERYAL METOT(MATERIAL METHOD)


Askeri deniz platformlarında görev başarı oranının yüksek tutulabilmesi için haberleşme altyapısının çok yönlü, güvenilir ve çevresel değişkenlere karşı dayanıklı olması gerekmektedir [15]. Bu bağlamda, gemilerde farklı teknolojik altyapılara sahip çoklu haberleşme sistemleri bütünlüştürülmüş biçimde kullanılmakta ve her sistemin kendine özgü avantajları ve sınırlamaları bulunmaktadır. Bu bölümde, çalışmada ele alınan başlıca haberleşme sistemleri detaylı olarak incelenmiştir.

### 2.1. Ka bant Uydu Haberleşme Sistemleri

Ka bant, 26.5- 40 GHz frekans aralığında çalışan ve özellikle yüksek bant genişliği gerektiren uygulamalarda tercih edilen bir uydu haberleşme teknolojisidir. Modern askeri gemilerde kullanılan Ka bant sistemleri; video aktarımı, büyük hacimli veri transferleri ve komuta-kontrol sistemleri gibi yüksek veri hızı gerektiren uygulamalarda kritik rol oynamaktadır. Bu

kesintisi, kanal çakışması, parazit etkisi ve çevresel faktörlere dayalı kalite değişimleri doğru biçimde tanımlanmıştır. Askeri deniz platformlarında kullanılan haberleşme sistemlerinin güvenilirliği ve sürekliliği, modern deniz harekâtlarının başarısı açısından kritik bir öneme sahiptir. Bu bağlamda, derin öğrenme yöntemlerinin haberleşme sistemlerine entegrasyonu son yıllarda dikkat çeken bir araştırma alanı haline gelmiştir. Özellikle deniz ortamının değişken koşulları ve elektromanyetik yoğunluğu, geleneksel iletişim yaklaşımlarının yetersiz kalmasına neden olmakta ve akıllı sistemlerin kullanımını gerekli kılmaktadır

sistemler, coğrafi sınırlamalardan bağımsız olarak geniş kapsama alanı sağlar.




Şekil 1: Ka bant uydu iletişim sistemi.

Gemi üzerindeki anten ve VSAT modem aracılığıyla uyduya gönderilen veriler uydu üzerinden yer istasyonuna iletilmekte ve aynı şekilde geri dönüş sağlanmaktadır [16]. Şekil 1'de Ka bant uydu haberleşme sisteminin blok diyagramı gösterilmiştir. Ancak yüksek frekans nedeniyle Ka bant sinyalleri, yağmur, nem ve

atmosferik yoğunluk gibi çevresel faktörlerden etkilenmeye oldukça açıktır. Bu nedenle, Ka bant etkin kullanımı için çevresel koşulların sürekli izlenmesi ve gerektiğinde alternatif haberleşme kanallarına geçiş yapılması gerekmektedir [17].

## 2.2 UHF/VHF Telsiz Haberleşme Sistemleri

UHF ve VHF bandlarında çalışan sistemler, düşük frekans aralıklarında çalışmaları nedeniyle elektromanyetik yayılım konusunda daha stabil performans sunmaktadır. VHF sistemleri genellikle 30–300 MHz, UHF sistemleri ise 300 MHz–3 GHz aralığında faaliyet göstermektedir. Bu frekans aralıkları sayesinde, özellikle kısa ve orta menzilli haberleşmede yüksek güvenilirlik sağlamaktadırlar [18].



**Şekil 2:** UHF/VHF telsiz haberleşme sistemi akış diyagramı.


Şekil 2’de UHF/VHF telsiz haberleşme sistemine ait akış diyagramı gösterilmiştir. Sistem, gemi ve kıyı birimleri arasında kısa ve orta menzilli, güvenilir veri iletimini sağlamakta olup veri kapasitesi sınırlıdır. Deniz ortamlarında gemi-gemi ve gemi-kıyı haberleşmesi için sıklıkla tercih edilirler [19]. Ayrıca, elektromanyetik girişimlere (EMI) karşı Ka bant sistemlerine kıyasla daha dirençlidirler. Ancak, bu sistemler sınırlı veri iletim kapasitesine sahip

olduklarından yüksek hacimli veri aktarımı için uygun değildirler.

## 2.3 Kablosuz İletişim Modülleri (KİM)

KİM, modern askeri platformlar arasında örgün ve güvenli bir veri ağı tesis etmek amacıyla geliştirilmiş, ölçeklenebilir yapıda bir haberleşme sistemidir. Sistem; personel, kara araçları, deniz platformları (gemi, bot), hava araçları (uçak, İHA) ve diğer sabit/mobil merkezler arasında ses, veri ve görüntü aktarımı yapılmasını mümkün kılmaktadır.

KİM sistemleri, görev ihtiyaçlarına bağlı olarak farklı mimarilerde konumlandırılabilmekte ve bu bağlamda her bir platform için asgari donanım bileşenleriyle entegre şekilde çalışabilmektedir. Kullanılan frekans bandı ve çıkış gücü, ilgili platformun teknik özelliklerine göre optimize edilebilmekte, böylece operasyonel esneklik sağlanmaktadır.




**Şekil 3:** KİM sistemi akış diyagramı.

Sistem; veri türleri, donanım entegrasyonu ve bağlantı arayüzleri ile birlikte ele alındığında, frekans ve güç optimizasyonu sayesinde kesintisiz ve güvenilir iletişimi mümkün kılmaktadır. Bu yapının genel işleyişi Şekil 3'te gösterilmektedir. Sistem; Ethernet arayüzü üzerinden doğrudan veri çıkışı sağlayabilmekte olup, gerektiğinde Wi-Fi erişim noktası desteği sunarak yerel kablosuz bağlantı gereksinimlerini de karşılamaktadır. Bu yönüyle KİM, hem mobil görev birlikleri hem de sabit komuta merkezleri arasında kesintisiz ve güvenilir iletişimi mümkün kılan kritik bir bileşen olarak öne çıkmaktadır [20].

#### 2.4 GSM Tabanlı Haberleşme Sistemleri

GSM sivil telekomünikasyon altyapısına dayanan ve geniş kapsama alanı sayesinde yaygın olarak kullanılan bir mobil haberleşme teknolojisidir [21]. Askerî gemilerde, özellikle kıyıya yakın operasyon bölgelerinde, mevcut GSM şebekeleri üzerinden sivil iletişim altyapısına erişim sağlanarak düşük maliyetli ve hızlı veri iletimi mümkün olabilmektedir. Bu kapsamda GSM sistemleri; lojistik destek, bakım-onarım süreçleri, personel iletişimi ve idari veri aktarımı gibi kritik olmayan uygulamalarda etkin bir çözüm sunmaktadır.



Şekil 4: GSM tabanlı haberleşme sistemlerinin operasyonel kullanım alanları, avantajları ve sınırlılıkları.

Bununla birlikte, GSM tabanlı haberleşme sistemlerinin kullanım alanları, avantajları ve sınırlılıkları Şekil 4'te gösterilmektedir. GSM tabanlı haberleşme sistemlerinin güvenlik açısından bazı önemli sınırlılıkları bulunmaktadır. Özellikle şifreleme mekanizmalarının askerî standartlara kıyasla daha düşük seviyede kalması, bu sistemleri dinleme, müdahale ve veri sızıntısı gibi siber tehditlere karşı daha savunmasız hale getirmektedir. Ayrıca, GSM altyapısının tamamen sivil operatörlere bağlı olması, sistem üzerinde tam kontrolün sağlanamaması ve üçüncü taraf bağımlılığı gibi operasyonel riskleri de beraberinde getirmektedir.

Diğer bir önemli kısıt ise kapsama alanı ile ilgilidir. GSM sistemleri, kara tabanlı baz istasyonlarına bağımlı olduğundan açık denizlerde ve kapsama dışı bölgelerde etkin şekilde kullanılamamaktadır. Bu durum, GSM teknolojisinin sürekli ve kesintisiz haberleşme

gerektiren askerî operasyonlar için tek başına yeterli olmadığını göstermektedir.

Bu nedenlerle, GSM tabanlı haberleşme sistemleri, askerî haberleşme mimarisi içerisinde birincil iletişim aracı olarak değil, belirli operasyonel senaryolarla sınırlı, kontrollü ve destekleyici bir haberleşme kanalı olarak

değerlendirilmelidir. Özellikle hibrit haberleşme mimarilerinde, diğer güvenli ve yüksek kapasiteli sistemlerle birlikte kullanıldığında operasyonel esneklik sağlamaktadır. Böylece, kritik taktiksel ağların kesintiye uğradığı acil durumlarda görev sürekliliği korunurken, güvenlik zafiyetlerinin de asgari düzeye indirilmesi mümkün olmaktadır.

**Tablo 2:** Askerî gemilerde kullanılan haberleşme sistemlerinin karşılaştırması

| Özellikler        | Ka Bant                            | UHF/VHF                              | Kablosuz Modüller                  | GSM Sistemleri                   |
|-------------------|------------------------------------|--------------------------------------|------------------------------------|----------------------------------|
| Frekans Aralığı   | 26.5–40 GHz                        | VHF: 30–300 MHz UHF: 300 MHz–3 GHz   | Zigbee: 2.4 GHz Wi-Fi: 2.4–5 GHz   | 900 MHz – 1.8/2.1 GHz            |
| Kapsama Alanı     | Küresel (uydu tabanlı)             | Kısa ve orta menzilli                | Gemide kullanım                    | Kıyıya yakın bölgeler            |
| Veri İletim Hızı  | Yüksek                             | Düşük – Orta                         | Orta – Yüksek (Wi-Fi hariç)        | Orta                             |
| Atmosfer Etkisi   | Yüksek (yağmur, nem vs.)           | Düşük                                | Orta (parazitlere açık)            | Orta (şebeke yoğunluğu vs.)      |
| Güvenlik Seviyesi | Yüksek (askeri şifreleme ile)      | Orta – Yüksek (askeri protokollerle) | Düşük – Orta                       | Düşük                            |
| Kullanım Amacı    | Yüksek hacimli adi, komuta kontrol | Sesli haberleşme, düşük adi iletimi  | Gemi içi iletişim verisi paylaşımı | İkincil iletişim, idari destek   |
| Bağımlılık        | Uydu bağlantısına                  | Doğrudan telsiz hattı                | Yerel ağ donanımı                  | Sivil altyapı (baz istasyonları) |

Askerî gemilerde kullanılan haberleşme sistemlerine ait frekans aralıkları, kapsama alanları, veri iletim hızları ve güvenlik seviyeleri Tablo 2’de karşılaştırmalı olarak verilmiştir. Tablo 2’ye göre, Ka bant sistemler yüksek bant genişliği ve küresel erişim imkanı sunarken, UHF/VHF sistemler kısa ve orta menzilde daha kararlı iletişim sağlamaktadır. Kablosuz modüller ve GSM sistemleri ise daha çok destekleyici ve yerel haberleşme ihtiyaçları için kullanılmaktadır.

## 2.5 Derin Öğrenme

Bu çalışmada geliştirilen karar destek sisteminin temelini oluşturan derin öğrenme yöntemleri, zaman serisi analizi, özellik mühendisliği ve model eğitimi gibi birden fazla bileşeni kapsamaktadır. Sistemin hedefi; askeri deniz platformlarında çoklu haberleşme kanalları

arasından çevresel koşullar ve operasyonel gereksinimler doğrultusunda en uygun olanını seçebilecek akıllı bir yapı ortaya koymaktır. Bu bağlamda, özellikle zaman içinde değişkenlik gösteren haberleşme parametrelerini işleyebilecek ve öğrenebilecek modeller tercih edilmiştir. LSTM ağları, klasik yapay sinir ağlarının ötesine geçerek zaman bağımlı verilerdeki uzun vadeli ilişkileri modelleyebilme kabiliyetine sahiptir. Bu nedenle, sinyal kalitesi, parazit oranı, gecikme süresi gibi zamanla değişen haberleşme parametrelerinin analizi için LSTM yapıları oldukça uygundur. LSTM ağları, özellikle bir iletişim kanalının önceki performansını dikkate alarak gelecekteki uygunluk düzeyini öngörebilme yeteneği sunmaktadır. Modelin her bir hücresinde bulunan “giriş”, “çıktı” ve “unutma” kapıları sayesinde bilgi akışı dengeli bir şekilde sağlanmakta ve gereksiz bilgilerin model içinde taşınması

engellenmektedir. Bu sayede, hem geçmiş hem de mevcut iletişim koşulları dikkate alınarak karar mekanizması güçlendirilmektedir. Modelin başarısı büyük ölçüde kullanılan verinin kalitesine ve işleme biçimine bağlıdır. Bu nedenle, sinyal gücü, paket kaybı oranı, parazit seviyesi, gecikme süresi, platformlar arası görüş hattı durumu gibi haberleşme sistemlerine ilişkin parametreler detaylı bir ön işleme sürecine tabi tutulmuştur. LSTM ağırları, geleneksel RNN (Recurrent Neural Network) mimarilerinin uzun vadeli bağımlılıkları öğrenmekte yaşadığı zorlukları ortadan kaldırmak amacıyla geliştirilmiştir. Özellikle zamanla değişen sinyal gücü, parazit düzeyi, gecikme süresi gibi haberleşme parametrelerinin ardışık biçimde analiz edilmesi gereken durumlarda LSTM mimarileri oldukça başarılı sonuçlar vermektedir. LSTM hücresi, içeriğindeki kapı mekanizmaları sayesinde, hangi bilgilerin saklanacağına, hangilerinin unutulacağına ve hangilerinin çıktıya dönüştürüleceğine dinamik olarak karar verir. Bir LSTM hücresinin temel matematiksel yapısı aşağıdaki formüllerle tanımlanır [17].

Forget gate, Eşitlik 1.'de belirtildiği şekliyle bir önceki hücre durumundan hangi bilgilerin unutulacağına karar verir.

$$f(t) = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

Input gate, yeni bilgi hücreye ne ölçüde eklenecek, bu kapı tarafından belirlenir (Eşitlik 2,3).

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

$$\hat{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3)$$

Cell state, hücrenin uzun vadeli belleği güncellenir. Önceki hücre durumu ile yeni aday değerler birleştirilerek yeni hücre durumu oluşturulur (Eşitlik 4).

$$C_t = f_t * C_{t-1} + i_t * \hat{C}_t \quad (4)$$

Output gate, hangi bilginin hücreden çıkacağına bu kapı karar verir (Eşitlik 5,6).

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t * \tanh(C_t) \quad (6)$$

LSTM tabanlı modelde kullanılan eşitliklerde yer alan parametreler, zaman serisi içerisindeki bilgi akışını ve bellek mekanizmasını tanımlamaktadır. Buna göre  $x_t$  zaman  $t$ 'deki giriş verisini temsil ederken,  $h_{t-1}$  bir önceki zaman adımına ait gizli durum çıktısını ifade etmektedir. Hücre durumunu gösteren  $C_t$ , uzun süreli bağımlılıkların korunmasını sağlayan bellek yapısını temsil etmektedir. Eşitliklerde yer alan  $W_f, W_i, W_c, W_o$  ağırlık matrisleri, sırasıyla unutma kapısı, giriş kapısı, hücre aday durumu ve çıkış kapısına ait öğrenilebilir parametrelerdir. Benzer şekilde,  $b_f, b_i, b_c, b_o$  terimleri her bir kapı mekanizmasının aktivasyonunu düzenleyen sabit parametreler olarak modele dahil edilmektedir. Kapı fonksiyonlarında kullanılan  $\sigma$  sigmoid aktivasyon fonksiyonu, bilgiyi 0 ile 1 arasında ölçekleyerek hangi bilginin tutulacağına veya unutulacağına karar verirken,  $\tanh$  fonksiyonu hücre durumunun güncellenmesinde kullanılan doğrusal olmayan dönüşümü sağlamaktadır.

Bu mekanizma sayesinde LSTM modeli, geçmiş veri örüntülerinden öğrenerek, haberleşme sisteminin ilerleyen zamanlardaki performansına

ilişkin çıkarımlarda bulunabilir. Örneğin; eğer geçmişte sinyal gücü azalmaya başlamış ve parazit artış göstermişse, model bu örüntüyü öğrenerek, benzer koşullarda ilgili haberleşme kanalının uygun olmadığını tahmin edebilir. Bu sayede iletişim kanalının zamanında değiştirilmesi sağlanarak operasyonel süreklilik korunur.

Özellik mühendisliği kapsamında, ham veriler normalize edilerek ölçek farklılıklarının model öğrenimini olumsuz etkilemesi engellenmiştir. Ayrıca, bazı parametreler arasında korelasyon ilişkileri incelenerek yeni türetilmiş özellikler oluşturulmuştur. Örneğin; sinyal gücü ve parazit seviyesi birlikte değerlendirilerek “etkili sinyal kalitesi” adında yeni bir özellik tanımlanmıştır. Bu tür türetilmiş veriler, modelin soyut ilişkileri daha iyi öğrenmesini sağlamıştır.

Model eğitimi süreci, derin öğrenme tabanlı karar destek sisteminin başarısını doğrudan etkileyen en kritik aşamalardan biridir. Bu çalışmada, haberleşme sistemlerine ait çok kanallı sinyal verileri kullanılarak oluşturulan etiketli veri kümesi, LSTM mimarisi başta olmak üzere çeşitli derin öğrenme modellerinin eğitimi için temel veri kaynağını oluşturmaktadır. Veri kümesi, sahadan toplanan ya da simülasyon ortamlarında oluşturulan sinyal örneklerinden meydana gelmektedir. Bu örnekler, sinyal gücü, paket kaybı oranı, gecikme süresi, elektromanyetik parazit seviyesi, kanal band genişliği, görüş hattı durumu, atmosferik koşullar ve platform tipi gibi çok boyutlu özellikleri içermektedir [22-23]. Her bir veri örneği, ideal koşullarda kullanılması gereken iletişim kanalına ilişkin doğru etiket bilgisiyle (örneğin: Ka bant, UHF/VHF, KİM,

GSM) eşleştirilmiştir. Modelin eğitimi öncesinde kullanılan veriler çeşitli ön işleme adımlarından geçirilmiştir. İlk olarak, veri setinde yer alan eksik veriler giderilmiş, aykırı değerler analiz edilerek uygun istatistiksel yöntemlerle ayıklanmış ve sinyaller üzerinde bulunan gürültü bileşenleri filtreleme teknikleriyle temizlenmiştir. Bu işlem, modelin öğrenme sürecinde veri kalitesinin artırılmasını ve hatalı örüntülerin azaltılmasını sağlamıştır. Daha sonra, farklı ölçeklere sahip giriş parametrelerinin ortak bir çerçevede değerlendirilebilmesi amacıyla normalizasyon işlemi uygulanmış ve tüm özellikler 0 ile 1 arasına ölçeklendirilmiştir.

Ayrıca, modelin genel performansını korumak ve gereksiz uzun eğitim sürelerinin önüne geçmek amacıyla erken durdurma yöntemi uygulanmıştır. Bu yöntem kapsamında, doğrulama başarımı belirli sayıda ardışık döngü boyunca iyileşmediğinde eğitim işlemi otomatik olarak sonlandırılmıştır. Tüm bu süreçlerin sonunda, model zaman dizisi olarak aldığı sinyal parametrelerini değerlendirerek, hangi iletişim kanalının kullanılmasının daha uygun olduğunu yüksek doğruluk oranlarıyla tahmin edebilecek bir seviyeye ulaşmıştır. Geliştirilen model, sadece geçmiş sinyal değerlerinden öğrenmekle kalmayıp aynı zamanda kanal geçişlerine sebep olan çevresel faktörleri de dikkate alarak daha esnek ve koşullara duyarlı kararlar verebilecek kapasiteye sahiptir.

Veri toplama süreci, sistemin güvenilirliği ve doğruluğu açısından en kritik bileşenlerden biridir. Bu süreçte haberleşme sistemlerine entegre edilen sensörler, belirli periyotlarla ölçüm değerlerini merkezi veri havuzuna

iletmektedir. Toplanan veriler arasında; sinyal gücü, parazit seviyesi, kanal gecikme süresi, paket başarı/kayıp oranları, frekans kullanımı ve elektromanyetik spektrum yoğunluğu yer almaktadır. Ayrıca operasyon ortamı ile ilgili meteorolojik veriler ve platform konumu gibi bağlamsal bilgiler de sistem tarafından alınmakta ve kanal seçimi sürecine katkı sağlamaktadır [18].

Zaman senkronizasyonu, farklı kaynaklardan gelen verilerin uyumlu biçimde işlenebilmesi için

temel gereksinimdir. Bu amaçla tüm veriler evrensel zamana göre senkronize edilmekte ve sabit zaman aralıklarında güncellenmektedir. Normalizasyon işlemi ise, farklı ölçeklerde ölçülen parametrelerin karşılaştırılabilir hale gelmesini sağlayarak, modelin eğitimi sırasında dengeleme sağlar. Bu sayede, örneğin 0-100 aralığında ölçülen sinyal gücü ile milisaniye cinsinden ölçülen gecikme süresi aynı önem düzeyinde değerlendirilebilir hale gelir [19].

**Tablo 3:** Kullanılan parametreler.

|                               | Değer / Aralık            | Açıklama                                                                     |
|-------------------------------|---------------------------|------------------------------------------------------------------------------|
| CNN Katman Sayısı             | 2-3                       | Mekânsal ve spektral özellik çıkarımı için kullanılan konvolüsyon katmanları |
| Filtre Sayısı                 | 32, 64, 128               | Özellik haritalarının derinliğini belirleyen filtre sayıları                 |
| Kernel (Çekirdek) Boyutu      | 3×3, 5×5                  | Özellik çıkarımı için kullanılan pencere boyutu                              |
| Aktivasyon Fonksiyonu         | ReLU                      | Doğrusal olmayan dönüşüm sağlayan aktivasyon fonksiyonu                      |
| LSTM Katman Sayısı            | 1-2                       | Zamansal bağımlılıkların modellenmesi için kullanılan katman sayısı          |
| LSTM Hücre Sayısı             | 64, 128                   | Zaman serisi öğrenme kapasitesini belirleyen gizli birim sayısı              |
| Dropout Oranı                 | 0.2 – 0.5                 | Aşırı öğrenmeyi azaltmak için kullanılan düzenleme parametresi               |
| Öğrenme Oranı (Learning Rate) | 0.001 – 0.0001            | Modelin öğrenme hızını belirleyen parametre                                  |
| Batch Size                    | 32, 64                    | Her eğitim adımında kullanılan veri örneği sayısı                            |
| Epoch Sayısı                  | 50 – 100                  | Modelin eğitim süresi                                                        |
| Kayıp Fonksiyonu              | Categorical Cross-Entropy | Çok sınıflı sınıflandırma için kullanılan kayıp fonksiyonu                   |

CNN-LSTM [24] tabanlı modelde kullanılan hiperparametreler Tablo 3'te ayrıntılı olarak sunulmuştur. Tablo incelendiğinde, modelin mekânsal özellik çıkarımını gerçekleştiren CNN katmanlarının 2-3 katmanlı bir yapıdan oluştuğu ve filtre sayılarının 32'den başlayarak 128'e kadar kademeli olarak artırıldığı görülmektedir. Bu yaklaşım, giriş verilerindeki düşük seviyeli özelliklerden daha karmaşık ve ayırt edici örüntülere doğru hiyerarşik bir temsil öğrenilmesini sağlamaktadır. Kernel boyutlarının 3×3 ve 5×5 olarak seçilmesi, hem lokal hem de daha geniş ölçekteki örüntülerin yakalanmasına olanak tanımaktadır.

Aktivasyon fonksiyonu olarak ReLU'nun tercih edilmesi[25], doğrusal olmayan ilişkilerin etkin şekilde modellenmesini sağlarken aynı zamanda gradyan kaybı problemini azaltarak eğitim sürecinin kararlılığını artırmaktadır. Zamansal bağımlılıkların modellenmesinde kullanılan LSTM katmanlarının ise 1-2 katmanlı bir yapıdan oluştuğu ve 64 ile 128 arasında değişen hücre sayıları ile optimize edildiği görülmektedir. Bu yapı, zaman serisi içerisindeki kısa ve uzun vadeli bağımlılıkların dengeli bir şekilde öğrenilmesine olanak tanımaktadır

Modelin aşırı öğrenmesini önlemek amacıyla 0.2-0.5 aralığında dropout uygulanmış olup, bu sayede modelin genelleme kabiliyeti artırılmıştır.

Öğrenme oranı ise 0.001-0.0001 aralığında test edilerek eğitim sürecinin hem kararlı hem de hızlı yakınsama sağlayacak şekilde optimize edilmiştir. Bu süreçte Adam optimizasyon algoritmasının tercih edilmesi, adaptif öğrenme oranı güncellemeleri sayesinde model performansını artırmıştır. Eğitim sürecinde kullanılan batch size değerleri 32 ve 64 olarak belirlenmiş, epoch sayısı ise 50–100 aralığında seçilerek modelin yeterli sayıda iterasyon ile öğrenmesi sağlanmıştır. Genel olarak değerlendirildiğinde, Tablo 3'te verilen hiperparametrelerin modelin hem doğruluk hem de genelleme performansını maksimize edecek şekilde seçildiği görülmektedir.

CNN katmanlarından elde edilen öz nitelik haritaları, önerilen hibrit model mimarisinde LSTM katmanına aktarılmadan önce uygun bir boyutsal dönüşüm işlemine tabi tutulmaktadır. Bu çalışmada kullanılan veri seti toplamda 1000 örnekten oluşmakta olup, CNN katmanlarının çıktısı (1000,8,8,64)(1000, 8, 8, 64)(1000,8,8,64) boyutundadır. Burada 1000 örnek sayısını,  $8 \times 8$  boyutu sinyal verilerinden çıkarılan mekânsal/spektral temsil alanını, 64 ise elde edilen öz nitelik haritalarının sayısını ifade etmektedir.

LSTM katmanlarının zaman serisi formatında giriş beklemesi nedeniyle, bu çıktı yeniden şekillendirilerek (1000,64,64) boyutuna dönüştürülmüştür. Bu dönüşümde, mekânsal boyutlar  $8 \times 8 = 64$  olacak şekilde birleştirilerek zaman adımları ( $T=64$ ) olarak ele alınmış, her bir zaman adımı için kanal sayısı ( $C=64$ ) özellik boyutu ( $F=64$ ) olarak kullanılmıştır. Böylece her bir örnek için 64 zaman adımı ve her adımda 64

boyutlu özellik vektöründen oluşan bir zaman serisi elde edilmiştir.

Bu yapı sayesinde, CNN katmanları tarafından çıkarılan mekânsal ve spektral özellikler, LSTM katmanı tarafından zaman ekseninde işlenerek ardışık bağımlılıklar öğrenilebilmektedir. Özellikle sinyal gücü, gecikme, paket kaybı ve elektromanyetik parazit gibi zamanla değişen haberleşme parametrelerinin modellenmesinde bu dönüşüm kritik bir rol oynamaktadır.

Ayrıca, model karmaşıklığını azaltmak amacıyla alternatif olarak CNN çıktısı (1000,1,1,64) boyutuna indirgenerek (1000,1,64) formatında LSTM girişine verilmiştir. Bu yaklaşım, hesaplama maliyetini düşürürken temel öz niteliklerin korunmasını sağlamıştır. Veri seti, model eğitimi sürecinde %80 eğitim ve %20 doğrulama olacak şekilde ayrılarak sırasıyla (800,64,64) ve (200,64,64) boyutlarında modele sunulmuştur.

## 2.6 Veri

Bu çalışmada geliştirilen karar destek sisteminin eğitimi ve değerlendirilmesi amacıyla, askeri deniz platformlarında kullanılan haberleşme sistemlerine ilişkin senaryolardan türetilmiş sentetik bir veri kümesi oluşturulmuştur. Bu çalışmada kullanılan 1000 örnekli veri seti sentetik olarak üretilmiş olup, veri üretim süreci kablosuz haberleşme sistemlerinin fiziksel ve istatistiksel özelliklerini yansıtacak şekilde modellenmiştir. Gürültü etkisini temsil etmek amacıyla Toplamsal Beyaz Gauss Gürültüsü (AWGN) modeli, çok yollu yayılım etkilerini yansıtmak için ise Rayleigh ve Rician sönümleme modelleri kullanılmıştır.

Sinyal gücü, gecikme, paket kaybı, parazit seviyesi ve görüş hattı durumu gibi parametreler, farklı kanal koşullarını temsil edecek şekilde istatistiksel dağılımlar üzerinden üretilmiş ve zaman serisi formatına dönüştürülmüştür. Bu kapsamda, her bir veri örneği geçmiş 5 zaman adımını içerecek şekilde yapılandırılarak modele (N,T,F) formatında sunulmuştur.

Bu yapı sayesinde veri seti, CNN katmanları tarafından mekânsal/spektral özelliklerin çıkarılmasına ve LSTM katmanları tarafından zamansal bağımlılıkların öğrenilmesine uygun hale getirilmiştir. Oluşturulan veri setinin, çok kanallı haberleşme ortamlarını temsil edebilecek çeşitlilikte olduğu ve modelin hem uzaysal hem de zamansal örüntüleri öğrenmesine imkân sağladığı değerlendirilmektedir. Veri seti, farklı çevresel ve operasyonel koşullar altında sinyal kalitesi, parazit seviyesi, gecikme süresi gibi haberleşme performansını etkileyen çok sayıda değişkeni içermektedir. Veri, dört farklı iletişim kanalını temsil edecek şekilde sınıflandırılmıştır: UHF/VHF (0), Ka Bant (1), KİM (2) ve GSM (3).

### 2.6.1 Veri Setinin İçeriği

Oluşturulan veri kümesi toplamda 1000 adet senaryo örneğinden oluşmaktadır. Her bir örnek, belirli bir zaman aralığında elde edilen ölçümleri temsil etmekte olup, haberleşme performansını etkileyen çeşitli sinyal özelliklerini içermektedir. Bu kapsamda veri seti; sinyal gücü, gürültü seviyesi, gecikme, paket kaybı ve elektromanyetik parazit gibi kritik parametreleri kapsayacak şekilde yapılandırılmıştır.

Veri setinde yer alan tüm sayısal özellikler, model performansını artırmak ve farklı

ölçeklerdeki değişkenlerin dengeli şekilde işlenmesini sağlamak amacıyla [0,1] aralığında min-max normalizasyonu kullanılarak ölçeklendirilmiştir. Bu normalizasyon yaklaşımı, özellikle makine öğrenmesi ve derin öğrenme algoritmalarında eğitim sürecinin kararlılığını artırmakta, yakınsama hızını iyileştirmekte ve modelin genelleme kabiliyetine olumlu katkı sağlamaktadır. Ayrıca, veri setinin homojen bir yapıya kavuşturulması sayesinde farklı parametrelerin modele olan etkisi daha tutarlı ve karşılaştırılabilir hale getirilmiştir.

**Tablo 4:** Haberleşme performans parametreleri.

| Parametre       | Açıklama                                                                                         |
|-----------------|--------------------------------------------------------------------------------------------------|
| signal_strength | İletilen sinyalin şiddetini temsil eden değerdir (dBm cinsinden normalize edilmiştir).           |
| noise_level     | Çevresel gürültü seviyesi (dBm cinsinden normalize edilmiştir).                                  |
| latency         | Haberleşme sürecindeki gecikme süresi (milisaniye cinsinden normalize edilmiştir).               |
| packet_loss     | İletim sırasında kaybedilen veri paketlerinin yüzdesel oranını ifade eder.                       |
| interference    | Elektromanyetik parazit seviyesi olup spektrum yoğunluğu üzerinden normalize edilmiştir.         |
| line_of_sight   | Platformlar arası doğrudan görüş hattının varlığını belirten ikili değişkendir (0: yok, 1: var). |
| channel_label   | Örneklemin ait olduğu hedef kanal sınıfını ifade eder (0, 1, 2 veya 3).                          |

Çalışmada kullanılan giriş değişkenleri ve hedef etiketler Tablo 4'te özetlenmiştir.

### 2.6.2 Veri etiketleme

Veri etiketleme aşamasında, her bir senaryo örneği ilgili haberleşme kanalını temsil eden sınıf etiketiyle işaretlenmiştir. Bu bağlamda, veri kümesindeki örnekler; UHF/VHF, Ka bant, KİM ve GSM kanallarını sırasıyla temsil edecek şekilde sayısal etiketlerle (örneğin, 0: UHF, 1: Ka bant, 2: KİM, 3: GSM) sınıflandırılmıştır. LSTM mimarisiyle uyumlu hale getirmek amacıyla

veriler zaman dizisi formatına dönüştürülmüş, geçmişe dönük belirli uzunluktaki ardışık zaman pencereleri oluşturularak modele sıralı veri akışı sağlanmıştır. Bu sayede modelin geçmiş veriler üzerinden öğrenim yapması ve zaman bağımlı örüntüleri analiz edebilmesi mümkün kılınmıştır. Model eğitimi sırasında çeşitli optimizasyon stratejileri kullanılmıştır. Tahmin edilen kanal ile gerçek kanal etiketi arasındaki farkı minimize etmek amacıyla çok sınıflı sınıflandırma problemlerinde yaygın olarak kullanılan Categorical Cross-Entropy kayıp fonksiyonu tercih edilmiştir. Ağırlıkların güncellenmesi ve öğrenme hızının dengelenmesi için Adam

optimizasyon algoritması uygulanmıştır. Eğitim sürecinde modelin aşırı öğrenme (overfitting) eğilimi göstermemesi için veri seti eğitim ve doğrulama olmak üzere iki ayrı alt kümeye ayrılmış, her bir öğrenme döngüsü (epoch) sonunda modelin doğrulama verisi üzerindeki performansı izlenmiştir. Her bir veri örneği, o anki sistem koşullarına göre tercih edilmesi gereken haberleşme kanalını temsil eden bir etiketle sınıflandırılmıştır. Bu sınıflandırma, uzman görüşlerine dayalı kurallar ve sistem performans kriterlerine göre yapılmıştır. Etiketler aşağıdaki gibi belirlenmiştir:

**Tablo 5:** Haberleşme kanal sınıfları ve kullanım senaryoları.

| Kanal Etiketi | Haberleşme Türü | Açıklama                                                                                               |
|---------------|-----------------|--------------------------------------------------------------------------------------------------------|
| 0             | UHF/VHF         | Kısa mesafeli ve düşük parazit ortamlarında tercih edilen haberleşme türüdür.                          |
| 1             | Ka bant         | Yüksek bant genişliği gerektiren ve görüş hattının bulunduğu açık deniz operasyonlarında kullanılır.   |
| 2             | KİM             | Gemi içi veya çok kısa mesafeli yakın ağ iletişimi için kullanılan sistemleri ifade eder.              |
| 3             | GSM             | Sivil altyapının kapsama alanında, düşük güvenlik gerektiren durumlarda kullanılan haberleşme türüdür. |

Çalışmada kullanılan haberleşme kanal sınıfları, farklı operasyonel ihtiyaçlar ve çevresel koşullar dikkate alınarak belirlenmiştir. Bu kapsamda, kısa mesafeli ve güvenilir iletişim için UHF/VHF, yüksek veri iletim gereksinimleri için


Ka bant, gemi içi haberleşme için KİM ve sivil altyapı destekli iletişim ihtiyaçları için GSM sistemleri tercih edilmiştir. İlgili kanal sınıfları ve kullanım senaryoları Tablo 5'te sunulmaktadır.

**Tablo 6:** Örnek haberleşme verileri ve kanal etiketleri.

| Örnek No | Signal Strength | Noise Level | Latency | Packet Loss | Interference | Line of Sight | Kanal Etiketi (Label) |
|----------|-----------------|-------------|---------|-------------|--------------|---------------|-----------------------|
| 1        | 0.82            | 0.10        | 0.12    | 0.02        | 0.15         | 1             | 1 (Ka Bant)           |
| 2        | 0.60            | 0.35        | 0.30    | 0.08        | 0.45         | 0             | 3 (GSM)               |
| 3        | 0.75            | 0.20        | 0.25    | 0.05        | 0.20         | 1             | 0(UHF/VHF)            |
| 4        | 0.90            | 0.05        | 0.08    | 0.01        | 0.10         | 1             | 1 (Ka Bant)           |
| 5        | 0.55            | 0.40        | 0.35    | 0.10        | 0.50         | 0             | 2 (KİM)               |
| 6        | 0.68            | 0.25        | 0.20    | 0.03        | 0.30         | 1             | 0 UHF/VHF             |

Çalışmada kullanılan örnek haberleşme verileri ve bunlara karşılık gelen kanal etiketleri Tablo 6'da sunulmuştur. Tablo 6 incelendiğinde, sinyal gücü, gürültü seviyesi, gecikme, paket kaybı ve parazit gibi parametrelerin farklı kombinasyonlarına bağlı olarak uygun haberleşme kanalının belirlendiği görülmektedir. Özellikle yüksek sinyal gücü ve düşük gecikme değerlerine sahip örneklerde Ka bant tercih edilirken, daha yüksek gürültü ve parazit seviyelerinde GSM veya KİM gibi alternatif kanalların seçildiği dikkat çekmektedir. Bununla birlikte, görüş hattının mevcut olduğu durumlarda UHF/VHF ve Ka bant sistemlerinin daha etkin kullanıldığı gözlemlenmektedir. Veriler, LSTM tabanlı derin öğrenme modeline

uygun hale getirmek için ardışık zaman pencereleri halinde organize edilmiştir. Her bir veri örneği, geçmiş 5 zaman adımını içerecek şekilde bir zaman dizisine dönüştürülmüş, böylece modelin geçmişe dayalı öğrenme yeteneği artırılmıştır. Üretilen veri seti, %80 eğitim ve %20 doğrulama oranıyla ikiye ayrılmıştır. Eğitim kümesi, modelin öğrenme sürecini yönlendirirken doğrulama kümesi, modelin genelleme performansını değerlendirmek amacıyla kullanılmıştır. Eğitim süreci boyunca doğrulama verisi kullanılarak aşırı öğrenme riski izlenmiş, erken durdurma yöntemiyle modelin optimum noktada eğitimi tamamlanmıştır.



Şekil 5: Sinyal gücü ile gürültü seviyesi.

Şekil 5'deki grafik, farklı haberleşme kanallarının sinyal gücü ve gürültü seviyesi bakımından nasıl konumlandığını göstermektedir. Renklerle ayrılmış veri noktaları her bir kanal etiketini temsil ederken, yatay eksen

sinyal gücünü, dikey eksen ise gürültü seviyesini göstermektedir. Bu sayede hangi kanalın daha kaliteli bir iletişim sunduğu görsel olarak da analiz edilebilmektedir. Örneğin, Ka bant genellikle yüksek sinyal gücü ve düşük gürültü ile

öne çıkarken, GSM veya KİM gibi alternatiflerde bu değerler daha değişken olabilmektedir.

## 2.7 Çalışmanın Modeli


Bu çalışmada önerilen model, askeri deniz platformlarında kullanılan çok kanallı haberleşme altyapılarının gerçek zamanlı ve otonom şekilde yönetilebilmesini amaçlayan, derin öğrenme tabanlı bir karar destek sistemi üzerine kuruludur. Modelin temel bileşeni, CNN ve LSTM mimarilerinin hibrid bir yapıda birleştirilmesiyle oluşturulmuştur. Bu yapı, hem zamansal hem de frekanssal örüntülerin etkin biçimde analiz edilmesine olanak tanımaktadır. Özellikle sinyal gücü, paket kaybı oranı, gecikme süresi, elektromanyetik parazit seviyesi, görüş hattı durumu ve çevresel faktörler gibi çok boyutlu giriş verileri, modelin hem kısa dönemli dalgalanmaları hem de uzun vadeli eğilimleri yakalayabilmesini sağlamaktadır. Modelin giriş katmanı, dört farklı haberleşme kanalından (Ka bant, UHF/VHF, GSM, Kablosuz İletişim Modülü) toplanan sinyal parametrelerini paralel olarak alacak şekilde tasarlanmıştır. CNN katmanları bu verilerden mekânsal ve spektral özellikleri çıkarırken, LSTM katmanları zaman serisi içindeki ardışık ilişkileri modellemekte ve veri akışındaki geçici bozulmaları anlamlandırabilmektedir. Bu çok kanallı ve çok boyutlu yaklaşım, modelin farklı operasyonel koşullar altında da tutarlı kararlar verebilmesine olanak tanımaktadır. Modelin eğitimi, farklı operasyonel senaryolardan toplanan, etiketlenmiş veri kümeleri üzerinden gerçekleştirilmiştir. Bu veri setleri içerisinde normal iletişim koşullarının yanı sıra, parazit, kanal çakışması ve sinyal kesintisi gibi olağanüstü durumlar da yer

almaktadır. Böylece sistem yalnızca mevcut durumu sınıflandırmakla kalmamakta, aynı zamanda olası bozulmaları önceden kestirerek proaktif kanal değişikliklerini önerme kapasitesine ulaşmaktadır. Eğitim sürecinde kullanılan kayıp fonksiyonu, doğruluk ve F1-skoru gibi metriklerle sürekli izlenmiş ve hiperparametre optimizasyonlarıyla genel performans maksimize edilmiştir.

Bu çalışmada önerilen sistem mimarisi, çok kanallı haberleşme altyapısının akıllı bir şekilde yönetilmesine olanak tanıyan, katmanlı ve modüler bir yapıya sahiptir. Model, askeri deniz platformları gibi zorlu ve değişken ortamlarda, iletişim sürekliliğini ve güvenliğini maksimize edecek şekilde tasarlanmıştır. Akış diyagramı sekiz temel işlem adımından oluşmakta ve her bir adım, sistemin bütünsel işleyişine katkıda bulunan özgün bir fonksiyon üstlenmektedir. İlk adım olan veri girişi aşamasında, Ka bant, UHF/VHF, GSM ve KİM gibi farklı frekans bantlarında çalışan haberleşme kanallarından gelen ham veriler sisteme alınır. Bu çok kaynaklı yapı, haberleşme esnekliğini ve dayanıklılığını artırmakta, aynı zamanda farklı kanal koşullarının paralel olarak değerlendirilmesine olanak tanımaktadır. İkinci aşama olan özellik çıkartımı sürecinde, her bir kanala ait sinyal gücü, paket kaybı oranı, gecikme süresi, elektromanyetik parazit seviyesi, görüş hattı durumu ve meteorolojik veya çevresel faktörler gibi parametreler çıkarılır. Bu çok boyutlu parametre seti, kanal durumlarının ayrıntılı olarak karakterize edilmesini sağlar. Üçüncü adım olan ön işleme katmanında, elde edilen veriler etiketlenir (örneğin: normal, arızalı, parazitli), gürültü filtreleme algoritmalarıyla arındırılır ve

analiz için uygun bir formatta normalize edilir. Bu adım, modelin öğrenme sürecinde istatistiksel tutarlılık ve genelleme kabiliyeti kazanmasına katkıda bulunur. Dördüncü aşamada, CNN + LSTM tabanlı hibrid bir derin öğrenme modeli kullanılarak sinyal verileri hem zamansal hem de frekans bağlamda analiz edilir. CNN katmanları, mekânsal örüntülerin ve kanal karakteristiklerinin çıkarımını sağlarken, LSTM katmanları bu veriler üzerindeki ardışık ilişkileri ve zaman serisi dinamiklerini öğrenir. Bu yapı, haberleşme kanallarındaki değişkenlikleri anlamada yüksek doğruluk sağlar. Beşinci adım olan eğitim süreci, farklı operasyonel senaryolardan elde edilen çok kanallı verilerle gerçekleştirilir. Özellikle parazit, kanal çakışması ve arıza gibi anormal durum senaryoları da modele dahil edilerek, sistemin genelleme ve anormali tespit kapasitesi güçlendirilmiştir. Altıncı adımda, modelin eğitilmiş yapısı gerçek zamanlı çıkarım yeteneğiyle devreye girer. Bu aşamada, o anki iletişim verileri analiz edilerek her bir kanal için performans puanları veya skorları oluşturulur. Bu skorlar, sistemin karar verme yetisini tetikler. Yedinci adım olan karar destek modülü, elde edilen skorları değerlendirerek en uygun haberleşme kanalını seçer. Gerekliğinde otomatik olarak kanal geçişi gerçekleştirilerek kesintisiz ve güvenli iletişim sağlanır. Son adımda ise sistemin çıktısı olarak optimize edilmiş, güvenli ve sürekli haberleşme hedeflenir. Bu çıktı, özellikle görev-kritik uygulamalarda sistemin bütünlüğünü ve operasyonel sürekliliğini garanti altına alır. Genel olarak bu akış yapısı, çok kaynaklı verileri yapay zeka destekli bir yaklaşımla entegre ederek adaptif ve otonom haberleşme stratejilerinin

önünü açmakta, özellikle savunma ve kritik altyapı alanlarında stratejik bir avantaj sunmaktadır.



Şekil 6: Önerilen modelin blok diyagramı.

Şekil 6'da önerilen çok kanallı haberleşme sistemine ait blok diyagram verilmiştir. Sistem, farklı kanallardan elde edilen verileri CNN + LSTM tabanlı model ile analiz ederek gerçek zamanlı kanal seçimi ve optimizasyonu sağlamaktadır.

### 3. DENEYSEL SONUÇLAR VE TARTIŞMA (EXPERIMENTAL RESULTS AND DISCUSSION)

Bu bölümde, geliştirilen derin öğrenme tabanlı karar destek sisteminin performansı, oluşturulan veri seti üzerinden yapılan deneysel çalışmalarla değerlendirilmiştir. Modelin haberleşme kanalını doğru sınıflandırma yeteneği, çeşitli doğruluk, kayıp ve karışıklık matrisi analizleriyle ortaya konmuştur. Ayrıca modelin gerçek zamanlı

koşullara uyumu ve adaptif karar mekanizmasının güvenilirliği de test edilmiştir.

### 3.1 Performans Değerlendirmesi

Eğitim aşamasında oluşturulan model, %80 eğitim - %20 test ayrımı ile değerlendirilmiş, sınıflandırma başarımı doğruluk, kayıp ve F1-skoru gibi metriklerle analiz edilmiştir. Doğruluk, modelin doğru sınıflandırdığı örneklerin toplam örneklere oranıdır. Kayıp, modelin yaptığı tahminlerle gerçek değerler arasındaki farkı ölçer. Daha düşük olması tercih edilir. F1-Skoru, hassasiyet ve duyarlılığı

dengeleyerek sınıflandırmanın genel başarısını gösterir. Özellikle dengesiz veri setlerinde daha sağlıklı sonuç verir.

LSTM tabanlı yapı, zaman serisi verilerindeki örüntüleri öğrenerek, özellikle sinyal gücü ve parazit seviyesi değişimlerinden etkilenmeden tutarlı tahminler sunmuştur. Eğitim sonunda modelin test verisi üzerindeki genel doğruluğu %91,4 olarak ölçülmüştür. Aşağıdaki Tablo 7’de her bir kanal sınıfı için başarı oranları verilmiştir:

**Tablo 7:** Performans sonuçları.

| Kanal Türü | Doğruluk (%) | F1-Skoru | Hassasiyet | Duyarlılık | Kayıp |
|------------|--------------|----------|------------|------------|-------|
| Ka bant    | 93.2         | 0.921    | 0.925      | 0.918      | 0.18  |
| UHF/VHF    | 92.7         | 0.916    | 0.910      | 0.922      | 0.19  |
| KİM        | 88.1         | 0.872    | 0.870      | 0.874      | 0.26  |
| GSM        | 85.4         | 0.848    | 0.840      | 0.857      | 0.29  |

Önerilen modelin farklı haberleşme kanalları üzerindeki performans sonuçları Tablo 7’de sunulmuştur. Tablo incelendiğinde, Ka bant ve UHF/VHF kanallarında modelin yüksek doğruluk ve F1-skoru değerlerine ulaştığı görülmektedir. Bu durum, söz konusu kanalların daha belirgin sinyal özelliklerine sahip olması ve model tarafından daha kolay öğrenilebilir örüntüler sunması ile açıklanabilir. Buna karşılık, KİM ve GSM kanallarında performansın nispeten daha düşük olduğu, özellikle kayıp değerlerinin daha yüksek seyrettiği dikkat çekmektedir. Bu durum, bu kanallarda gürültü, parazit ve değişken ağ koşullarının daha belirgin olmasından kaynaklanmaktadır. Genel olarak

değerlendirildiğinde, modelin tüm kanal türlerinde dengeli ve kabul edilebilir bir performans sergilediği, ancak yüksek bant genişliği ve daha stabil koşullar sunan kanallarda daha başarılı sonuçlar elde ettiği görülmektedir. Modelin hangi sınıflarda daha fazla hata yaptığı, karışıklık matrisi ile incelenmiştir. Özellikle Ka bant ile GSM arasında zaman zaman yanlış sınıflandırma gözlemlenmiştir. Bu durum, her iki kanalın da benzer çevresel koşullarda kullanılabilmesi ve sinyal parametrelerinin örtüşmesiyle açıklanabilir. Ka bant ve UHF/VHF gibi daha stabil sinyal yapısına sahip kanallar, yüksek başarı göstermektedir. GSM ve KİM’de

elektromanyetik parazit ve veri trafiği nedeniyle başarıda düşüş gözlemlenmiştir.

**Tablo 8:** Gerçek zamanlı kanal geçiş performansı.

| Kanal Durumu            | Ortalama Geçiş Süresi (ms) | En Kötü Durum (ms) | En İyi Durum (ms) |
|-------------------------|----------------------------|--------------------|-------------------|
| Parazit Tespiti Durumu  | 105                        | 187                | 78                |
| Sinyal Gücü Düşüşü      | 89                         | 144                | 62                |
| LOS (Görüş Hattı) Kaybı | 96                         | 160                | 68                |

Tablo 8’de sunulan sonuçlar, önerilen sistemin gerçek zamanlı kanal geçiş performansını farklı bozucu senaryolar altında değerlendirmektedir. Ortalama, en iyi ve en kötü durum geçiş süreleri incelendiğinde, sistemin adaptif yapısının özellikle sinyal gücü değişimlerine hızlı tepki verebildiği, ancak parazit tespiti gibi daha karmaşık durumlarda gecikmenin arttığı görülmektedir. Bu durum, karar mekanizmasının çoklu parametre değerlendirmesine dayalı

yapısından kaynaklanmaktadır. Ortalama kanal geçiş süresi 100 ms’nin altında kalmakta ve gerçek zamanlı uygulamalara uygunluk göstermektedir. Model, olağandışı koşullarda da kabul edilebilir kararlılıkla çalışmaktadır. Modelin başarısı SNR yükseldikçe artmakta, ancak 15 dB üzeri değerlerde doygunluk eğilimine girmektedir. Sistemin tüm iş akışı 50 ms altında tamamlanmakta, bu da düşük gecikme gereksinimi olan taktik sistemler için uygundur.

**Tablo 9:** Model kestirim kararlılığı.

| Senaryo Türü             | Ortalama Varyans (F1) | Açıklama                          |
|--------------------------|-----------------------|-----------------------------------|
| Normal Operasyon         | 0.006                 | Kararlı tahminler                 |
| Elektromanyetik Parazit  | 0.019                 | Kısmi dalgalanma                  |
| Paket Kaybı > %30        | 0.023                 | Belirgin varyans                  |
| LOS Sürekli Kayıp Durumu | 0.028                 | Tahminlerde daha fazla dalgalanma |

Tablo 9’da verilen F1 varyans değerleri, modelin farklı bozucu senaryolar altındaki kestirim stabilitesini nicel olarak ortaya koymaktadır. Düşük varyans değerleri modelin tutarlı

tahminler ürettiğini gösterirken, LOS kaybı ve yüksek paket kaybı gibi durumlarda gözlenen artış, giriş verisindeki belirsizliğin model çıktısına yansıdığını göstermektedir.

**Tablo 10:** Kanal tahmin doğruluğu ve sinyal gürültü oranı (SNR).

| SNR (dB) | Doğruluk (%) |
|----------|--------------|
| 5        | 78.4         |
| 10       | 83.1         |
| 15       | 87.2         |
| 20       | 90.5         |

| SNR (dB) | Doğruluk (%) |
|----------|--------------|
| 25+      | 92.8         |

Kanal tahmin doğruluğunun sinyal-gürültü oranı ile değişimi Tablo 10'da sunulmuştur. Tablo incelendiğinde, SNR değerinin artmasıyla birlikte modelin doğruluk performansının belirgin şekilde yükseldiği görülmektedir. Düşük SNR seviyelerinde (örneğin 5 dB), gürültü etkisinin baskın olması nedeniyle doğruluk oranı daha düşük gerçekleşirken, SNR arttıkça sinyal kalitesinin iyileşmesine bağlı olarak modelin ayırt edici özellikleri daha etkin şekilde öğrenebildiği anlaşılmaktadır. Özellikle 20 dB ve üzeri SNR değerlerinde doğruluk oranının %90'ın üzerine çıktığı ve modelin yüksek performans sergilediği dikkat çekmektedir. Bu durum, önerilen modelin yüksek kaliteli sinyal koşullarında daha güvenilir ve kararlı tahminler ürettiğini göstermektedir. Önerilen sistemin gerçek zamanlı işlem performansına ait süreler Tablo 11'de sunulmuştur.

**Tablo 11:** Gerçek zamanlı performans (Inference zamanı).

| İşlem Adımı               | Ortalama Süre (ms) |
|---------------------------|--------------------|
| Özellik Çıkartımı         | 11                 |
| Veri Ön İşleme            | 7                  |
| Model İneransı (CNN+LSTM) | 24                 |
| Karar Verme               | 6                  |
| Toplam                    | 48 ms              |

Tablo incelendiğinde, toplam işlem süresinin 48 ms olduğu ve bu değer gerçek zamanlı haberleşme gereksinimlerini karşılayabilecek düzeyde olduğu görülmektedir. İşlem adımları arasında en yüksek sürenin CNN+LSTM tabanlı model çıkarım aşamasında gerçekleştiği, buna karşın veri ön işleme ve karar verme adımlarının

oldukça düşük gecikme ile tamamlandığı dikkat çekmektedir[24]. Özellik çıkartımı aşaması ise orta düzeyde işlem süresi gerektirmektedir. Elde edilen çıkarım süreleri, Intel Core i7 işlemciye sahip ve 16 GB RAM bulunan bir sistem üzerinde yalnızca CPU kullanılarak ölçülmüştür. Model çalıştırma sürecinde herhangi bir GPU hızlandırması kullanılmamıştır. Bu sonuçlar, önerilen modelin CPU tabanlı sistemlerde dahi düşük gecikme ile çalışabildiğini ve gerçek zamanlı uygulamalar için uygun olduğunu göstermektedir. Bununla birlikte, GPU destekli sistemlerde daha düşük çıkarım sürelerinin elde edilmesi mümkündür. İşlem adımları arasında en yüksek sürenin CNN+LSTM tabanlı model çıkarım aşamasında gerçekleştiği, buna karşın veri ön işleme ve karar verme adımlarının oldukça düşük gecikme ile tamamlandığı dikkat çekmektedir. Özellik çıkartımı aşaması ise orta düzeyde işlem süresi gerektirmektedir. Bu sonuçlar, önerilen modelin düşük gecikmeli ve hızlı karar verme yeteneğine sahip olduğunu, dolayısıyla dinamik ve zaman kritik haberleşme senaryolarında etkin bir şekilde kullanılabileceğini göstermektedir. Önerilen sistemin farklı senaryolar altındaki adaptasyon performansı Tablo 12'de sunulmuştur.



**Tablo 12:** Adaptasyon performansı.

| Güncelleme Türü         | Adaptasyon Süresi (saniye) | Başarı Artışı (%) |
|-------------------------|----------------------------|-------------------|
| Yeni Parazit Türü       | 3.4                        | +5.2              |
| Yeni Kanal Eklenmesi    | 4.9                        | +4.6              |
| Çevresel Koşul Değişimi | 2.8                        | +3.9              |

Tablo incelendiğinde, modelin yeni parazit türleri, yeni kanal eklenmesi ve çevresel koşul

değişimleri gibi dinamik durumlara kısa süreler içerisinde uyum sağlayabildiği görülmektedir. Özellikle çevresel koşul değişimlerinde en düşük adaptasyon süresinin elde edildiği, buna karşılık yeni kanal eklenmesi durumunda adaptasyon süresinin nispeten daha yüksek olduğu dikkat çekmektedir. Bununla birlikte, tüm senaryolarda model performansında anlamlı bir artış

sağlandığı ve sistemin öğrenme kapasitesinin etkin şekilde çalıştığı anlaşılmaktadır. Elde edilen bu sonuçlar, önerilen yaklaşımın değişken ve belirsiz haberleşme ortamlarında dahi hızlı uyum sağlayarak performansını sürdürdürebildiğini göstermektedir. Sistem kısa sürede yeni koşullara adapte olabilmekte ve performansını koruyabilmektedir.



(a) (b)  
Şekil 7: Eğitim ve test sonucu (a), Performans Grafiği (b)

Şekil 7'de önerilen modelin eğitim süreci ve performans değerlendirme sonuçları sunulmaktadır. Şekil 7(a)'da, eğitim süreci boyunca doğruluk ve F1-skoru değerlerinin artış gösterdiği, buna karşılık kayıp değerinin düzenli olarak azaldığı görülmektedir. Bu durum, modelin öğrenme sürecinin kararlı bir şekilde ilerlediğini ve genelleme kabiliyetinin arttığını göstermektedir.

Şekil 7(b)'de ise farklı haberleşme kanalları için elde edilen ROC eğrileri verilmiştir. ROC eğrileri incelendiğinde, Ka bant kanalının diğer kanallara kıyasla daha yüksek ayırt edicilik performansı sergilediği, UHF/VHF ve GSM kanallarının orta seviyede performans gösterdiği, KİM kanalının ise nispeten daha düşük ayırt edicilik değerlerine

sahip olduğu görülmektedir. Eğrilerin genel yapısı, modelin farklı kanal türlerini belirli bir doğruluk seviyesinde ayırt edebildiğini ve sınıflandırma performansının kanal koşullarına bağlı olarak değiştiğini ortaya koymaktadır. Gerçek ve tahmin edilen değerler karşılaştırıldığında, modelin genel olarak yüksek doğrulukla çalıştığı görülmektedir. UHF/VHF sinyalleri %93.2 oranında doğru sınıflandırılmış (235/250), Ka bant sinyalleri %92.5 oranında (220/250), KİM sinyalleri %89.6 oranında (230/250) ve GSM sinyalleri ise %90.3 oranında (226/250) doğru tahmin edilmiştir. En çok karışıklık Ka bant sinyallerinin GSM (%4) ve KİM (%3.2) sinyalleriyle karıştırılmasında görülmektedir. Ayrıca, modelin tahmin dağılımı

da dengelidir; her bir sınıfa yaklaşık 250 tahmin yapılmıştır. Bu tablo, modelin sinyalleri genellikle doğru sınıflandırabildiğini, ancak bazı sinyaller arasında sınırlı bir karışıklık yaşandığını göstermektedir.

UHF/VHF, Ka bant, KİM ve GSM olmak üzere birden fazla radyo sinyal türü üzerinde gerçekleştirilen sınıflandırma modeli değerlendirmesi hem karmaşıklık matrisi analizi hem de performans metrikleriyle desteklenen yüksek ayırt edicilik kapasitesini ortaya koymaktadır. Model, %91,4 makro-ortalama doğruluk oranına ulaşmış; 0,22 çapraz kaybı ve 0,906 makro F1-skoru elde ederek giriş alanı genelinde güçlü bir genelleme yeteneği sergilemiştir. Karmaşıklık matrisi, modelin özellikle UHF/VHF ve Ka bant sinyalleri için sınıflar arası ayrımı etkin biçimde yakaladığını göstermektedir. Bu bantlarda doğru sınıflandırma oranları sırasıyla %94 (235/250) ve %88 (220/250) olarak elde edilmiştir. Bu bulgular, modelin söz konusu bantlara özgü frekans ve modülasyon karakteristiklerini başarıyla öğrendiğini ve bunun muhtemelen bu sinyallerin ayırt edici zaman-frekans imzaları ve spektral özelliklerinden kaynaklandığını göstermektedir. Düşük sınıflar arası karışma oranları, gizil uzayda

iyi ayrılmış özellik gömülerinin öğrenildiğine işaret etmektedir.

Kablosuz Modül ve GSM sınıflarında gözlemlenen yanlış sınıflandırmalar, bu sinyal türlerinin kısmi spektral veya zamansal örtüşmelere sahip olduğunu ve bunun sınıflar arası belirsizliğe yol açabildiğini göstermektedir. Özellikle Ka bant ve GSM sınıfları arasında karşılıklı olarak gözlenen dikkate değer yanlış sınıflandırma oranı (her biri için 10 örnek), benzer gürültü profilleri veya ortak kanal erişim mekanizmalarından kaynaklanabilir ve bu durum modelin karar sınırlarını zorlaştırmaktadır.

Kanal bazlı kayıp değerleri, optimizasyon dinamiklerine ilişkin ek bilgiler sunmaktadır. En yüksek kayıp değeri KİM sınıfında (0,27) gözlemlenmiş olup, bu durum ilgili kanal için modelin yetersiz öğrenme gerçekleştirdiğini veya temsil öğreniminin sınırlı kaldığını göstermektedir. Bu bulgu, IDF sınıfının görece düşük F1-skoru (0,888) ile de desteklenmekte ve sınıf dengesizliği ya da sınıf içi varyasyonun eğitim sürecinde yeterince yakalanamamış olabileceğine işaret etmektedir. Bu tür belirsiz durumlar için veri artırma teknikleri veya alana özgü ön işleme yaklaşımları ayırt edicilik kapasitesini artırabilir.

**Tablo 13:** Performans karşılaştırılması.

| Model             | Doğruluk (%) | F1-Skoru | Precision | Recall | Loss |
|-------------------|--------------|----------|-----------|--------|------|
| CNN               | 88.6         | 0.874    | 0.870     | 0.878  | 0.27 |
| LSTM              | 89.8         | 0.886    | 0.882     | 0.890  | 0.24 |
| Random Forest     | 85.2         | 0.842    | 0.835     | 0.850  | 0.31 |
| SVM               | 83.9         | 0.829    | 0.820     | 0.838  | 0.34 |
| Önerilen CNN+LSTM | 91.4         | 0.906    | 0.902     | 0.910  | 0.22 |

Önerilen hibrit CNN+LSTM modelinin performansını değerlendirmek amacıyla, aynı veri seti üzerinde yalnızca CNN, yalnızca LSTM ve geleneksel makine öğrenmesi yöntemleri (Random Forest ve Destek Vektör Makineleri - SVM) ile karşılaştırmalı analiz gerçekleştirilmiştir. Elde edilen sonuçlar Tablo 13'te sunulmuştur. Tablo incelendiğinde, önerilen hibrit modelin tüm performans metrikleri açısından diğer yöntemlere kıyasla daha yüksek başarı sağladığı görülmektedir. Özellikle doğruluk ve F1-skoru bakımından CNN ve LSTM modellerine göre belirgin bir iyileşme elde edilmiştir. Bu durum, CNN katmanlarının mekânsal/spektral özellik çıkarımındaki başarısı ile LSTM katmanlarının zamansal bağımlılıkları modelleme yeteneğinin birlikte kullanılmasının avantaj sağladığını göstermektedir. Geleneksel makine öğrenmesi yöntemleri olan Random Forest ve SVM modellerinin ise daha düşük performans sergilediği gözlemlenmiştir. Bunun temel nedeni, bu yöntemlerin zaman serisi verilerindeki ardışık bağımlılıkları doğrudan modelleyememesi ve yüksek boyutlu sinyal verilerinde sınırlı temsil gücüne sahip olmasıdır. Sonuç olarak, önerilen hibrit CNN+LSTM mimarisi, çok kanallı haberleşme sistemlerinde hem uzaysal hem de zamansal örüntüleri birlikte öğrenerek daha doğru ve kararlı kararlar üretebilen üstün bir yaklaşım sunmaktadır. Bu zorluklara rağmen model, tüm kanallar genelinde tutarlı biçimde yüksek F1-skorları sergileyerek hem hassasiyet hem de geri çağırma metrikleri açısından kararlı bir performans ortaya koymuştur. Hassasiyet ve geri çağırma arasındaki yakın denge, sınıflandırıcının iyi kalibre edildiğini, hata dağılımının dengeli olduğunu ve

herhangi bir sınıfa yönelik belirgin bir önyargı taşımadığını göstermektedir. Literatürle kıyaslandığında, önerilen yaklaşım bilişsel radyo ağlarında kanal seçimi, araçlar arası iletişimde kanal kestirimi ve anlamsal iletişim sistemlerinde veri bütünlüğünün korunması gibi öncü çalışmalarla teknik uyum içerisindedir. Ancak bu çalışmanın ayırt edici yönü, farklı haberleşme katmanlarını aynı çatı altında değerlendirerek askeri deniz platformlarının kompleks operasyonel gereksinimlerine yanıt verebilen bütünlük bir sistem mimarisi sunmasıdır [3,4,9].

Bu çalışma, askeri deniz platformlarında kullanılan haberleşme altyapılarına yönelik çok kanallı, derin öğrenme tabanlı bir karar destek sistemi geliştirerek literatüre önemli katkılar sunmaktadır. Geleneksel haberleşme sistemleri genellikle tek bir kanal türüne veya sınırlı sayıda çevresel değişkene bağlı olarak optimize edilmektedir. Oysa bu çalışmada, Ka bant, UHF/VHF, GSM ve gemi içi KİM gibi birbirinden farklı kanal türleri, ortak bir karar mimarisi altında analiz edilmiştir. Bu yönüyle, farklı bant genişlikleri ve operasyonel koşullara sahip iletişim altyapılarının aynı sistem içerisinde bütüncül olarak değerlendirildiği nadir çalışmalardan biridir.

Model, sinyal gücü, paket kaybı oranı, gecikme süresi, elektromanyetik parazit seviyesi, görüş hattı durumu ve çevresel faktörler gibi çok boyutlu parametreleri aynı anda değerlendirerek, mevcut haberleşme kanalları arasında optimal seçim yapmaktadır. Böylece hem iletişimin sürekliliği sağlanmakta hem de insan müdahalesine olan bağımlılık azaltılarak operasyonel verimlilik artırılmaktadır.

Çalışmanın en önemli katkılarından biri, önerilen sistemin gerçek zamanlı olarak çalışabilmesi ve kanal geçişlerini dinamik şekilde yönetebilmesidir. Bu bağlamda model, derin sinir ağları mimarisiyle desteklenmiş ve farklı operasyon senaryolarından toplanmış verilerle eğitilmiştir. Modelin eğitiminde hem normal haberleşme koşullarını hem de sinyal kesintisi, parazit, kanal çakışması gibi olağandışı durumları içeren etiketlenmiş veri kümeleri kullanılmıştır. Bu sayede önerilen yapı, öngörülemeyen senaryolara karşı dayanıklı ve uyarlanabilir bir sistem olarak tasarlanmıştır.

Ayrıca çalışmada elde edilen performans sonuçları da literatürle karşılaştırmalı olarak sunulmuştur. Kanal türlerine göre doğruluk (%93.2'ye kadar), F1-skoru (0.921'e kadar) ve düşük kayıp (0.18) değerleriyle modelin yüksek doğruluk ve kararlılıkla çalıştığı gösterilmiştir. Bu nicel bulgular, önerilen yapının sadece teorik değil, aynı zamanda pratik uygulamalarda da güçlü bir alternatif olduğunu ortaya koymaktadır.

Sonuç olarak, bu çalışma; çok kanallı askeri haberleşme sistemlerinin derin öğrenme destekli yönetimi, karar verme süreçlerinin otomatikleştirilmesi ve haberleşme sürekliliğinin güvenli şekilde sağlanması gibi açılardan hem literatürdeki mevcut eksiklikleri tamamlamakta hem de yeni bir uygulama perspektifi sunmaktadır.

Gelecek çalışmalar kapsamında, sistemin diğer askeri platformlara entegrasyonu, tehdit algılama modülleriyle birleştirilmesi ve uçtan uca güvenlik katmanlarıyla desteklenmesi hedeflenmektedir. Ayrıca, taktik seviye ağlarda düşük gecikmeli

iletişim sağlayabilecek kuantum tabanlı güvenlik protokollerinin bu yapıya entegre edilmesi, sistemin operasyonel güvenliğini bir üst düzeye taşıyabilir.

Sonuç olarak, derin öğrenme destekli bu yaklaşım; modern askeri haberleşme sistemlerinin esneklik, dayanıklılık ve adaptasyon kabiliyetlerini artırarak gelecekteki ağ merkezli savaş konseptlerine entegre edilebilecek yüksek potansiyelli bir çözüm olarak öne çıkmaktadır.

#### 4. SONUÇ VE ÖNERİLER (CONCLUSIONS AND RECOMMENDATIONS)

Bu çalışmada, askeri deniz platformlarında kullanılan çok kanallı haberleşme altyapılarının, derin öğrenme temelli bir karar destek sistemi aracılığıyla dinamik olarak yönetilmesi hedeflenmiştir. Farklı karakteristiklere sahip iletişim kanallarının (Ka bant, UHF/VHF, kablosuz iletişim modülleri ve GSM) sinyal kaliteleri, çevresel etkiler ve operasyonel parametreler üzerinden analiz edilerek, en uygun kanalın otomatik seçimini sağlayan bir yapay zeka mimarisi geliştirilmiştir.

Model, sinyal gücü, gecikme, parazit seviyesi, paket kaybı ve görüş hattı gibi çok boyutlu parametreleri dikkate alarak, iletişim sürekliliği ve güvenliğini artırmayı hedeflemektedir. Yapılan deneysel çalışmalar sonucunda, geliştirilen sistem %91.4 genel doğruluk ve 0.906 F1-skoru ile başarılı bir sınıflandırma performansı sergilemiştir. UHF/VHF ve Ka bant gibi daha stabil karakteristiklere sahip kanallarda başarı oranı %93'ün üzerine çıkarken, GSM ve KİM kanallarında elektromanyetik parazit ve

benzer sinyal örüntüleri nedeniyle kısmen daha düşük doğruluklar gözlenmiştir. Bu durum, sistemin gelecekte daha heterojen ve gerçek-zamanlı veri setleriyle desteklenmesi gerektiğini ortaya koymaktadır.

Önerilen modelin, geleneksel kanal seçim süreçlerine kıyasla operasyonel çeviklik ve tepki süresi açısından önemli avantajlar sunduğu tespit edilmiştir. Derin öğrenme temelli yaklaşım, yalnızca mevcut ağ durumunu analiz etmekle kalmayıp, geçmiş verilerden öğrenerek gelecekteki kanal davranışlarını öngörebilmekte ve olası iletişim kesintilerine karşı önleyici aksiyonlar alabilmektedir. Bu yönüyle, sistemin hem kararlılığı hem de esnekliği artırılmıştır.

#### TEŞEKKÜR (ACKNOWLEDGMENTS)

#### ETİK STANDARTLARIN BEYANI (DECLARATION OF ETHICAL STANDARDS)

Bu makalenin yazar(lar)ı çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal özel bir izin gerektirmediğini beyan ederler.

#### YAZARLARIN KATKILARI (AUTHORS' CONTRIBUTIONS)

Yalçın KAPLAN: Çalışmaları gerçekleştirmiş, sonuçları analiz ederek makaleyi yazmıştır.

Umut SARAY: Verileri Toplamaya yardım etmiş, çalışmaları gerçekleştirmiş, sonuçları analiz ederek makaleyi yazımına katkı sağlamıştır.

#### ÇIKAR ÇATIŞMASI (CONFLICT OF INTEREST)

Yazarlar, herhangi bir çıkar çatışması olmadığını beyan eder.

#### KAYNAKLAR (REFERENCES)

- [1] B. Zhao et al., "Multi-agent deep reinforcement learning for RIS-assisted secure UAV communication," *Journal of King Saud University - Computer and Information Sciences*, vol. 37, no. 133, pp. 1-17, 2025, doi: 10.1007/s44443-025-00145-9.
- [2] W. Lei, Y. Ye, and M. Xiao, "Deep Reinforcement Learning-Based Spectrum Allocation in Integrated Access and Backhaul Networks," *IEEE Trans. Cogn. Commun. Netw.*, vol. 6, no. 3, pp. 970-979, Sep.2020, doi: 10.1109/TCCN.2020.2992628.
- [3] H. Farhi, A. Messai and T. Berghout, "Enhancing Spectrum Utilization in Cognitive Radio Networks Using Reinforcement Learning with Snake Optimizer: A Meta-Heuristic Approach," *Electronics*, vol. 14, no. 13, p. 2525, 2025, doi: 10.3390/electronics14132525.
- [4] M. Kulin, T. Kazaz, E. De Poorter and I. Moerman, "A Survey on Machine Learning-Based Performance Improvement of Wireless Networks: PHY, MAC and Network Layer," *Electronics*, vol. 10, no. 3, p. 318, 2021, doi: 10.3390/electronics10030318.
- [5] H. Xie, Z. Qin, G. Y. Li and B. -H. Juang, "Deep Learning Enabled Semantic Communication Systems," in *IEEE Transactions on Signal Processing*, vol. 69, pp. 2663-2675, 2021, doi: 10.1109/TSP.2021.307121.
- [6] T. O'Shea and J. Hoydis, "An Introduction to Deep Learning for the Physical Layer," in *IEEE Transactions on Cognitive Communications and Networking*, vol. 3, no. 4, pp. 563-575, Dec. 2017, doi: 10.1109/TCCN.2017.2758370.
- [7] R. Safavinejad, H.-H. Chang and L. Liu, "Deep Reinforcement Learning for Dynamic Spectrum Access: Convergence Analysis and System Design," in *IEEE Transactions on Wireless Communications*, vol. 23, no. 12, pp. 18888-18902, Dec. 2024, doi: 10.1109/TWC.2024.3414428.
- [8] T. -D. Le and G. Kaddoum, "LSTM-Based Channel Access Scheme for Vehicles in

Cognitive Vehicular Networks With Multi-Agent Settings," in *IEEE Transactions on Vehicular Technology*, vol. 70, no. 9, pp. 9132-9143, Sept. 2021, doi: 10.1109/TVT.2021.3100591.

[9] A. Arsalan, T. Umer, R. A. Rehman, B.-S. Kim, M. Murtaza, and C.-T. Cheng, "Semantic-aware communication and computation co-optimization in digital twin-assisted Internet of Drones networks using federated deep reinforcement learning," *ICT Express*, vol. 12, no. 2, pp. 517-522, Apr. 2026, doi: 10.1016/j.icte.2026.02.001.

[10] W. Cao, F. Chu, L. Jia, H. Zhou, and Y. Zhang, "A Multi-Agent Deep Reinforcement Learning Anti-Jamming Spectrum-Access Method in LEO Satellites," *Electronics*, vol. 14, no. 16, p. 3307, 2025, doi: 10.3390/electronics14163307.

[11] J. Sormayli, M. Darvishi, K. Zarrinnegar, et al., "Real-Time jamming detection using windowing and hybrid machine learning models for pre-saturation alerts," *Scientific Reports*, vol. 15, no. 1, p. 24748, 2025, doi: 10.1038/s41598-025-10567-0.

[12] A. S. M. Mohammed, A. I. A. Taman, A. M. Hassan, et al., "Deep Learning Channel Estimation for OFDM 5G Systems with Different Channel Models," *Wireless Personal Communications*, vol. 128, no. 4, pp. 2891-2912, Feb. 2023, doi: 10.1007/s11277-022-10077-6.

[13] N. Guo and X. Wang, "Deep Learning-Based Optimization for Maritime Relay Networks," *Applied Sciences*, vol. 15, no. 3, p. 1160, 2025, doi: 10.3390/app15031160.

[14] S. Wang, S. A. R. Zaidi, M. Hafeez, et al., "Deep Transfer Learning: A Smarter Approach to Wireless Communication Networks," *IEEE Commun. Stand. Mag.*, 2025 (Accepted for publication)

[15] D. Liu, K. Su, N. Yang, and J. Zhang, "Joint Resource Allocation for Maritime RIS-RSMA Communications Using Fractal-Aware Robust Deep Reinforcement Learning," *Fractal Fract.*, vol. 10, no. 4, p. 223, 2026, doi: 10.3390/fractalfract10040223.

[16] J. Jena and P. K. Sahu, "Rain fade and Ka-band Spot Beam Satellite communication in India," in *Proc. Recent Adv. Space Technol. Services Climate Change (RSTS & CC)*, Chennai, India, 2010, pp. 304-306, doi: 10.1109/RSTSCC.2010.5712816.

[17] P. M. Kalaivaanan et al., "Evaluation of Ka-Band Rain Attenuation for Satellite Communication in Tropical Regions Through a Measurement of Multiple Antenna Sizes," in *IEEE Access*, vol. 8, pp. 18007-18018, 2020, doi: 10.1109/ACCESS.2020.2966873.

[18] D. P. Wright and E. A. Ball, "IoT focused VHF and UHF propagation study and comparisons," *IET Microw. Antennas Propag.*, vol. 15, no. 8, pp. 871-884, June 2021, doi: 10.1049/mia2.12101.

[19] A. Lopes, L. Fernandes, and P. Chaves, "Detection of Communications Channels in VHF Band for Enhanced Maritime Surveillance," *Sensors*, vol. 25, no. 23, p. 7258, 2025, doi: 10.3390/s25237258.

[20] H. Ismiyanto, Kemalsyah, and Bastari, "Intelligence Interconnect Communication System (IICS) pada Network Centric Warfare Operasi Udara," *Jurnal Strategi Pertahanan Udara*, vol. 9, no. 1, pp. 25-37, 2023.

[21] M. Z. Chowdhury, M. Shahjalal, S. Ahmed, and Y. M. Jang, "6G Wireless Communication Systems: Applications, Requirements, Technologies, Challenges, and Research Directions," in *IEEE Open J. Commun. Soc.*, vol. 1, pp. 957-975, 2020, doi: 10.1109/OJCOMS.2020.3010270.

[22] M. Krichen and A. Mihoub, "Long Short-Term Memory Networks: A Comprehensive Survey," *AI*, vol. 6, no. 9, p. 215, 2025, doi: 10.3390/ai6090215.

[23] K. Greff, R. K. Srivastava, J. Koutník, B. R. Steunebrink, and J. Schmidhuber, "LSTM: A Search Space Odyssey," *IEEE Trans. Neural Netw. Learn. Syst.*, vol. 28, no. 10, pp. 2222-2232, Oct. 2017, doi: 10.1109/TNNLS.2016.2582924.

[24] L. Shang et al., "CNN-LSTM Hybrid Model to Promote Signal Processing of Ultrasonic Guided Lamb Waves for Damage Detection in Metallic Pipelines," *Sensors*, vol. 23, no. 16, p. 7059, 2023, doi: 10.3390/s23167059.

[25] G. Luo, X. Wang, W. Zhao, S. Tao, and Z. Tang, "ReLU Neural Networks and Their Training," *Mathematics*, vol. 14, no. 1, p. 39, 2026, doi: 10.3390/math14010039.