





**İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ**

**KABLOSUZ SPEKTRUM KULLANIMININ İSTATİSTİKSEL ANALİZİ**

**YÜKSEK LİSANS TEZİ**

**Uğur Ramazan KILAVUZ**

**Elektronik ve Haberleşme Mühendisliği Anabilim Dalı**

**Telekomünikasyon Mühendisliği Programı**

**Tez Danışmanı: Prof. Dr. Ahmet Hamdi KAYRAN**

**Haziran 2019**



**İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ**

**KABLOSUZ SPEKTRUM KULLANIMININ İSTATİSTİKSEL ANALİZİ**

**YÜKSEK LİSANS TEZİ**

**Uğur Ramazan KILAVUZ  
(504161336)**

**Elektronik ve Haberleşme Mühendisliği Anabilim Dalı**

**Telekomünikasyon Mühendisliği Programı**

**Tez Danışmanı: Prof. Dr. Ahmet Hamdi KAYRAN**

**Eş Danışman: Doç. Dr. Serhan YARKAN**

**Haziran 2019**



İTÜ, Fen Bilimleri Enstitüsü'nün 504161336 numaralı Yüksek Lisans Öğrencisi Uğur Ramazan KILAVUZ, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “KABLOSUZ SPEKTRUM KULLANIMININ İSTATİSTİKSEL ANALİZİ” başlıklı tezini aşağıdaki imzaları olan jüri önünde başarı ile sunmuştur.

**Tez Danışmanı :**      **Prof. Dr. Ahmet Hamdi KAYRAN** .....  
İstanbul Teknik Üniversitesi

**Eş Danışman :**      **Doç. Dr. Serhan YARKAN** .....  
İstanbul Ticaret Üniversitesi

**Jüri Üyeleri :**      **Prof. Dr. Ahmet Hamdi KAYRAN** .....  
İstanbul Teknik Üniversitesi

**Doç. Dr. Serhan YARKAN** .....  
İstanbul Ticaret Üniversitesi

**Doç. Dr. Ender Mete EKŞİOĞLU** .....  
İstanbul Teknik Üniversitesi

**Doç. Dr. Işın ERER** .....  
İstanbul Teknik Üniversitesi

**Doç.Dr. Hacı İLHAN** .....  
Yıldız Teknik Üniversitesi

**Teslim Tarihi :**      **3 Mayıs 2019**  
**Savunma Tarihi :**   **13 Haziran 2019**







*Aileme,*



## ÖNSÖZ

Haberleşmede kullanılan teknolojilerin gelişmesi ve haberleşme cihazlarının sayısının bu teknolojiyle birlikte gün geçtikçe artması bu alanda yapılan çalışmaların çeşitliliğini arttırmaktadır. Analog ve sayısal haberleşme için kullanılan spektrum kaynakları da bu sayının artmasından dolayı yoğunlaşmaktadır. Bu çalışmada da haberleşme için kullanılan spektrum kaynaklarının daha verimli bir şekilde kullanılabilmesi için araştırmalar yapılmıştır.

Beni danışman öğrencisi olarak kabul eden sayın Prof. Dr. Ahmet Hamdi Kayran'a, desteğini eksik etmeyen eşdanışmanım sayın Doç. Dr. Serhan Yarkan'a, çalışmaktan onur duyduğum kurumum Tübitak'daki sıralı amirlerim sayın Dr. Öğretim Üyesi Ali Rıza Ekti ile sayın Dr. Öğretim Üyesi Ali Görçin'e ve bu süreç zarfında beni sürekli motive eden ailem ve iş arkadaşlarıma çok teşekkür ederim.

Haziran 2019

Uğur Ramazan KILAVUZ  
( )



## İÇİNDEKİLER

### Sayfa

ÖNSÖZ .....	vii
İÇİNDEKİLER .....	ix
KISALTMALAR.....	xi
SEMBOLLER .....	xiii
ÇİZELGE LİSTESİ.....	xv
ŞEKİL LİSTESİ.....	xvii
ÖZET .....	xix
SUMMARY .....	xxi
<b>1. BİLİŞSEL RADYOLAR .....</b>	<b>1</b>
1.1 Tezin Amacı.....	3
1.2 Literatür Araştırması .....	3
1.3 Hipotez .....	5
<b>2. ENERJİ SEZİCİLER.....</b>	<b>7</b>
2.1 İkili Hipotez Testi .....	7
2.2 Kestirim ve Sezim .....	8
<b>3. ÇEVİRİMSSEL DURAĞANLIK .....</b>	<b>15</b>
3.1 Çevrimsel Durağan Süreçler.....	15
<b>4. DOĞRUSAL MODELLER .....</b>	<b>21</b>
4.1 AR(2) Model .....	23
4.2 AR(p) Model .....	24
4.3 MODEL DERECESİNİN BELİRLENMESİ.....	24
Otokorelasyon Fonksiyonu (ACF).....	25
Kısmı Otokorelasyon Fonksiyonu (PACF) .....	27
Akaike Bilgi Ölçütü (AIC) .....	28
4.4 İKİLİ ZAMAN SERİLERİ VE LOGIT MODEL .....	29
<b>5. LSTM.....</b>	<b>33</b>
5.1 Yinelemeli Sinir Ağları(RNN) .....	33
5.2 Model Eğitim .....	35
5.2.1 Zaman Ekseninde Geriye Yayılma.....	36
5.2.2 LSTM'in Yapısı .....	37
5.2.3 LSTM'in Çalışması .....	38
<b>6. SONUÇ VE ÖNERİLER .....</b>	<b>43</b>
<b>KAYNAKLAR.....</b>	<b>45</b>
<b>ÖZGEÇMİŞ .....</b>	<b>49</b>



## **KISALTMALAR**

<b>AIC</b>	: Akaike Information Criteria
<b>ANN</b>	: Artificial Neural Network
<b>RNN</b>	: Recurrent Neural Network
<b>LSTM</b>	: Long-Short Term Memory
<b>ACF</b>	: Autocorrelation Function
<b>PACF</b>	: Partial Autocorrelation Function
<b>RF</b>	: Radio Frequency
<b>GSM</b>	: Global System for Mobile Communications
<b>AR</b>	: Autoregressive
<b>AR</b>	: Autoregressive Moving Average
<b>SCF</b>	: Spectral Correlation Function
<b>BPSK</b>	: Binary Phase Shift Keying
<b>QPSK</b>	: Quadrature Phase Shift Keying
<b>QAM</b>	: Quadrature Amplitude Modulation
<b>EDGE</b>	: Enhanced Data rates for GSM Evolution





## SEMBOLLER

$x(t)$	: Zamanda alınan işaret
$x_k$	: Ayrık Zamanda Örneklenen İşaret
$T$	: Test İstatistiği
$\lambda$	: Eşik Değeri
$n_k$	: Ayrık Zamanda Örneklenen Gürültü
$s_k$	: Ayrık Zamanda Örneklenen Kullanıcı İşareti
$P_d$	: Sezim Olasılığı
$P_f$	: Yanlış Alarm Olasılığı
$P_m$	: Sezememe Olasılığı
$\mathbf{H}(1)$	: Kullanıcı Var Hipotezi
$\mathbf{H}(0)$	: Kullanıcı Yok Hipotezi
$\Gamma$	: Gamma İşlevi
$\mu$	: Ortalama Değer
$\mathbf{E}(\cdot)$	: Beklenen Değer İşlevi
$f(\cdot)$	: Olasılık Yoğunluk İşlevi
$\sigma^2$	: Varyans
<b>dB</b>	: Desibel
$C_{xx}$	: Otokovaryans Matrisi
$\tau$	: Zaman Kayması
$diag(\cdot)$	: Matris Diagonal
$R_x$	: Otokorelasyon Matrisi
$S_x$	: Spektral Korelasyon Matrisi
$C_x$	: Spektral Uyumluluk Matrisi
$z_t$	: Zaman Serisi
$\gamma$	: Otokovaryans Katsayısı
$\rho$	: Otokorelasyon Katsayısı
$\Theta$	: Kısmi Otokorelasyon Katsayısı
$h_t$	: Durum Bağlantı İşlevi
$c_t$	: Dahili Bağlantı İşlevi
$f_w$	: Unutma İşlevi
$W$	: Ağırlık Matrisi
$L$	: Kayıp İşlevi
$b_k$	: Yönelim
$C_t$	: Aday Güncelleme



## ÇİZELGE LİSTESİ

### Sayfa

<b>Çizelge 4.1:</b> Farklı model derecelerine ait AIC ve hata karelerinin toplam değerleri .....	29
--	----





## ŞEKİL LİSTESİ

	<u>Sayfa</u>
Şekil 1.1	: Bilişsel radyonun frekans uzayında çalışması ..... 1
Şekil 1.2	: Bilişsel radyonun fonksiyonları..... 2
Şekil 1.3	: Spektrum kullanımının çok boyutlu yapısı ve haritalanması ..... 6
Şekil 2.1	: Enerji sezicinin çalışma şeması ..... 7
Şekil 2.2	: Birincil kullanıcının aslında spektrumda var olup sistemin kullanıcı yok sonucunu üretmesi ..... 10
Şekil 2.3	: Spektrumda birincil kullanıcının aslında olmadığı ancak sistemin kullanıcı var sonucunu üretmesi ..... 10
Şekil 2.4	: -10 dB, yanlış alarm - sezim olasılığı ..... 11
Şekil 2.5	: Rayleigh kanalda BPSK işareti..... 12
Şekil 2.6	: Rician kanalda QPSK işareti ..... 12
Şekil 2.7	: Nakagami kanalda 16QAM işareti ..... 13
Şekil 3.1	: BPSK işaretine ait SCF ..... 18
Şekil 3.2	: Bant geçiren -5 dB Rayleigh kanalda BPSK işaretine ait SCF ..... 18
Şekil 3.3	: Bant geçiren 0 dB Rayleigh kanalda QPSK işaretine ait SCF ..... 19
Şekil 3.4	: Bant geçiren 0 dB Nakagami kanalda 64QAM işaretine ait SCF ..... 19
Şekil 3.5	: GSM bandından alınan işarete ait SCF..... 20
Şekil 3.6	: EDGE işaretine ait SCF..... 20
Şekil 4.1	: Gözlem süresi arttıkça, sistem parametresi $\phi$ 'nin kestirim doğruluğu ve gerçek süreç değerleriyle ve belirlenen parametre yardımıyla tahmin edilen süreç değerlerinin karşılaştırılması ..... 22
Şekil 4.2	: Gözlem süresi arttıkça, sistem parametreleri $\phi_1$ ve $\phi_2$ 'nin kestirim doğruluğu ve gerçek süreç değerleriyle ve belirlenen parametreler yardımıyla tahmin edilen süreç değerlerinin karşılaştırılması ..... 23
Şekil 4.3	: Gerçek süreç değerleriyle ve belirlenen parametreler yardımıyla tahmin edilen süreç değerlerinin karşılaştırılması ..... 24
Şekil 4.4	: Yönelim olan (trended), bir zaman serisiyle otoregresif bir zaman serisinin otokorelasyonları arasındaki farklılık ..... 25
Şekil 4.5	: Otoregresif bir zaman serisiyle kayan ortalamalı bir zaman serisinin otokorelasyon katsayıları arasındaki farklılık ..... 26
Şekil 4.6	: Dönemsel bir zaman serisinin, yönelimler çıkartıldıktan sonra (detrended) oluşan otokorelasyon katsayıları ..... 27
Şekil 4.7	: Otoregresif bir zaman serisiyle kayan ortalamalı bir zaman serisinin kısmi otokorelasyon katsayıları arasındaki farklılık ..... 27
Şekil 4.8	: ARMA(2,1) modele ait sistemin farklı model dereceleriyle olan kestirimlerinin karşılaştırılması ..... 29
Şekil 4.9	: AR(1) modele ilişkin logit modelin performansı ..... 30

<b>Şekil 4.10</b>	: GSM downlink kanalına ilişkin farklı model otoregresif model derecelerine ait kestirimlerin karşılaştırılması .....	31
<b>Şekil 4.11</b>	: Telsiz kanalından alınan verilerle yapılan kestirim .....	31
<b>Şekil 5.1</b>	: Standart ileri beslemeli sinir ağında veri akışı.....	34
<b>Şekil 5.2</b>	: Standart ileri beslemeli sinir ağı ile RNN yapısının karşılaştırılması	34
<b>Şekil 5.3</b>	: RNN yapısının zaman eksenini boyunca gösterimi.....	35
<b>Şekil 5.4</b>	: RNN yapısı üzerinde zaman eksenini boyunca geriye yayılma .....	36
<b>Şekil 5.5</b>	: RNN'in iç yapısı.....	37
<b>Şekil 5.6</b>	: LSTM'in iç yapısı.....	37
<b>Şekil 5.7</b>	: dahili hücre durumu.....	38
<b>Şekil 5.8</b>	: Kapı .....	38
<b>Şekil 5.9</b>	: Önceki hücre durumundan gelen bilginin unutmaya kapısından geçişi	39
<b>Şekil 5.10</b>	: Dahili hücre durumuna eklenecek aday bilginin belirlenmesi.....	40
<b>Şekil 5.11</b>	: Dahili hücre durumunun güncellenmesi.....	40
<b>Şekil 5.12</b>	: Hücre durumunun çıktı olarak üretilmesi.....	41
<b>Şekil 5.13</b>	: Orjinal veri ile tahmin edilen verinin karşılaştırılması .....	42
<b>Şekil 5.14</b>	: Epoch-kayıp işlevi .....	42

## KABLOSUZ SPEKTRUM KULLANIMININ İSTATİSTİKSEL ANALİZİ

### ÖZET

Kablosuz iletişim teknolojilerinin gelişimiyle birlikte frekans spektrumuna ait kullanıcı yoğunluğu artarak devam etmektedir. Spektrumun bu şekilde aşırı yoğun olması; lisanslı ve lisanssız kullanıcıların, spektrumu daha verimli bir şekilde kullanabilmesini sağlamak amacıyla çözüm ve önerileri de beraberinde getirmiştir. Bu maksatla, spektrumda kullanıcı varlığını tespit edip ardından çalışabileceği spektrum boşluğuna uygun frekans ve zaman alanlarında işlevlerini yerine getiren ve spektrumu daha verimli kullanabilme amacı taşıyan bilişsel radyolar Joseph Mitola tarafından önerilmiştir.

Spektrumdaki uygun boşlukların tespit edilmesi öncelikle birincil kullanıcıların incelenen spektrum alanında tespitiyle başlar. Literatürde spektrumdaki kullanıcıların tespiti için bazı metotlar bulunmaktadır. Bunlardan ilk akla gelen, işlem maliyetinin ve hesaplama karmaşıklığının düşük olmasından dolayı, spektrumdaki birincil kullanıcının sinyalinin enerjisinin sezilmesidir. Gözlemlenen alandaki sinyallerin enerjileri tespit edilerek belirlenen eşik değerlerine göre karşılaştırılması yapıldıktan sonra o alanda kullanıcının varlığı belirlenir. Ancak önerilen bu enerji sezici yönteminde; spektrum alanındaki gürültü, gelen sinyalin tespitini zorlaştırarak hatalı uyarılara veya var olan sinyalin tespit edilememesine sebep olmaktadır. Birincil kullanıcının sinyalinin tespit edilememesi de; enerji sezici kullanan radyo açısından, spektrumdaki o bölgede birincil kullanıcının tespitinin düzgün yapamamasına; böylece kullanıcı sinyallerinin bozucu girişimlerine sebep olur. Bu sorunun üstesinden gelmek için, sinyalin taşıyıcı işarete bindirilerek iletilmesinden dolayı, taşıyıcı işaretin frekansına bağlı istatistiksel parametrelerinden faydalanılması, çevrimsel durağanlık özelliği, önerilmiştir. Kullanıcı işaretini etkileyen gürültünün istatistiksel parametrelerinin tek başına geniş anlamda durağanlık özellikleri göstermesi ve kullanıcı işaretinin de istatistiksel parametrelerinin çevrimsel durağanlık özelliği taşıması, gürültüyle sinyalin birbirinden ayırt edilmesinde fayda sağlamaktadır. Spektrumdaki sinyallerin bir taşıyıcı işaretle gönderilmesi sonucu gözlemlenen alandaki işaretlerin istatistiksel özelliklerinin bu taşıyıcı işaretin frekansına bağlı olarak periyodik özellik göstermesinden faydalanmak, enerji sezici yönteminde karşılaşılan düz gürültünün etkisini azaltarak kullanıcı tespitini kolaylaştırır. Bir diğer öneri, gözlemlenen spektrumda gelen sinyallerin özellikleri bilindiği varsayımı altında uyumlu süzgeç tabanlı yaklaşımlardır. Uyumlu süzgeçler alıcı tarafına gelecek sinyale ait bütün özelliklerini kullandığı için daha etkili bir şekilde kullanıcı varlığını tespit eder. Ancak uyumlu süzgeç yaklaşımının kullanılması uyumlu süzgeç kullanan bilişsel radyonun maliyetini ve hesaplama karmaşıklığını arttırmakta ve tespit edebileceği kullanıcı işaretlerinin çeşitliliğini de azaltmaktadır. Çevrimsel durağanlık özelliğinden faydalanmada veya enerji sezici yaklaşımlarında kullanıcı işaretinin iletim parametere ayrıntılarının önemi olmamaktadır. Dolayısıyla , bilişsel radyo gerçeklemeleri

açısından, spektrumda var olan çok çeşitli sinyallerin varlığı her bir sinyal türü için uyumlu süzgeç kullanılmasını elverişsiz hale getirmektedir. Gözlemlenen alana uygun metotlar tek başına yeterli gelmediği veya sezim performansının artırılmak istendiği durumlarda birden fazla yöntemin birlikte kullanılacağı hibrid yapılardan da faydalanılabilir.

Kullanıcı işaretleri belirli aralıklarla tespit edildikten sonra gözlemlenen spektrum alanına uygun olacak biçimde, gelecekte kullanıcı varlığının tahmini için ilgili spektrum bölgesine uygun kestirim modelleri oluşturulur. Literatürde bilişsel radyo için kullanılacak spektrum boşluğu kestirim modelleri için kullanılan yöntemin yaklaşımı veya matematiksel altyapısının yaklaşımı açısından çeşitli gruplara ayrılır. Tasarım için en önemli iki ölçüt olan işlem maliyeti ve hız bakımından daha avantajlı olan doğrusal zaman modelleri öne çıkmaktadır. Spektrum alanında kullanıcıların bulunma durumları için belirli bir süre gözlemlendikten sonra elde edilen veriye uygun doğrusal zaman serisi modelleri oluşturulur. Doğrusal zaman serisi modelleri oluşturulurken eldeki verilerin istatistiksel parametrelerinden faydalanılır. Spektrumda kullanıcı mevcudiyetinin ikili olarak (mevcut ya da değil) sınıflandırılması yapılacağı için eldeki zaman serisi bu çerçevede oluşturulur. Böylelikle hızlı ve işlem maliyeti olarak ucuz kestirim yapılabilir. Ancak zaman serisinin değerleri ikili olarak sıkıştırıldığı için modelin veri çözünürlüğünün düşük olmasına dolayısıyla kestirim performansının azalmasına sebep olmaktadır. Bunun üstesinden gelebilmek için zaman serisi değerleri ikili olarak sıkıştırılmadan saf halde alınarak işlem yapılabilir ve sistem performansı artırılabilir. Doğrusal olmayan modellerde ise zaman serisi değerleri bir öğrenme algoritması yardımıyla işlenir, ardından kestirim sonucu modelden elde edilir. Doğrusal olmayan modellerin öğrenme süresi, işlem maliyeti ve hızı gibi parametreler doğrusal zaman serisi modellerine göre daha çok dezavantaj göstermektedir. Ancak, kestirilmek istenen spektrum bölgesine göre doğrusal modellerin yetersiz kaldığı durumlarda doğrusal olmayan modeller tercih edilebilir. Spektruma ait bölgelerin özelliğine bağlı olarak bu modellerden uygun olanı bilişsel radyo tarafından kullanılır ve bilişsel radyo sinyalleriyle birincil kullanıcı sinyallerinin karışması engellenmeye çalışılır.

Bu çalışmada, spektrumdaki sinyallerin tespiti ve kestirimi için önerilen yöntemler incelenmiştir. Gerçek ölçüm verileri üzerinde test edilerek kullanılan modeller ve yöntemler araştırılarak performans-maliyet analizleri ortaya konulmuştur.



# STATISTICAL ANALYSIS OF THE WIRELESS SPECTRUM OCCUPANCY

## SUMMARY

With the recent advances in wireless communication technologies, radio frequency spectrum becomes crowded. Despite such an overcrowd, the spectrum is underutilized. To remedy the under-utilization problem of the spectrum, cognitive radio, which is coined by Joseph Mitola, is proposed. Equipped with numerous adaptive features, cognitive radios could detect and identify white holes in radio frequency and let secondary users take advantage of such opportunities without causing harmful interference to the primary users.

Opportunistic spectrum usage starts with identification of the white holes in the band of interest. There are various methods present in the literature for white hole identification. Considering its computational complexity requirements along with design simplicity, energy detection is a prominent technique frequently investigated in the literature. In this technique, energy of the signals falling into the band of interest is measured and then compared to a pre-defined threshold to decide the presence/absence of any activity within. It is clear that ambient noise poses a severe problem for this technique since an inappropriate choice of threshold leads to high levels of false alarms. Due to several other problems, energy detector is considered to be insufficient for a generic transmission scenario and more sophisticated methods are proposed in the literature. Cyclostationarity analysis is one of the relatively sophisticated methods which benefits from the stationarity structures of both ambient noise and transmission signals. Considering the fact that passband signals inherently constitutes of at least one carrier, traces of this carrier are sought for in the higher-order statistics of the received signal and identification is established. Another alternative class of spectrum sensing methods is based on adaptive filters. Based on the a priori knowledge of the signals possibly present in the spectrum band of interest, adaptive filters perform almost optimally in detecting the presence/absence of them. It is evident that the use of adaptive filters leads to high levels of computational complexity and sophisticated designs at the receiver side. In light of the aforementioned discussions, it is obvious that hybrid solutions could be deployed in case sensing performance degrades for certain scenarios.

As a next step, prediction of the spectrum occupancy is established through the use of statistical models. There are several prediction categories for the models present in the literature based on their mathematical structures. It is clear that linear models are prominent due to their relatively less computationally complex nature and rapid deployment. Linear models rely on the time series formed by the spectrum occupancy patterns and driven by the statistical parameters of those occupancy patterns. The underlying occupancy pattern is generally binarized and used in that binary form. On the one hand, binarized data provide a very simple input for the models and are easy

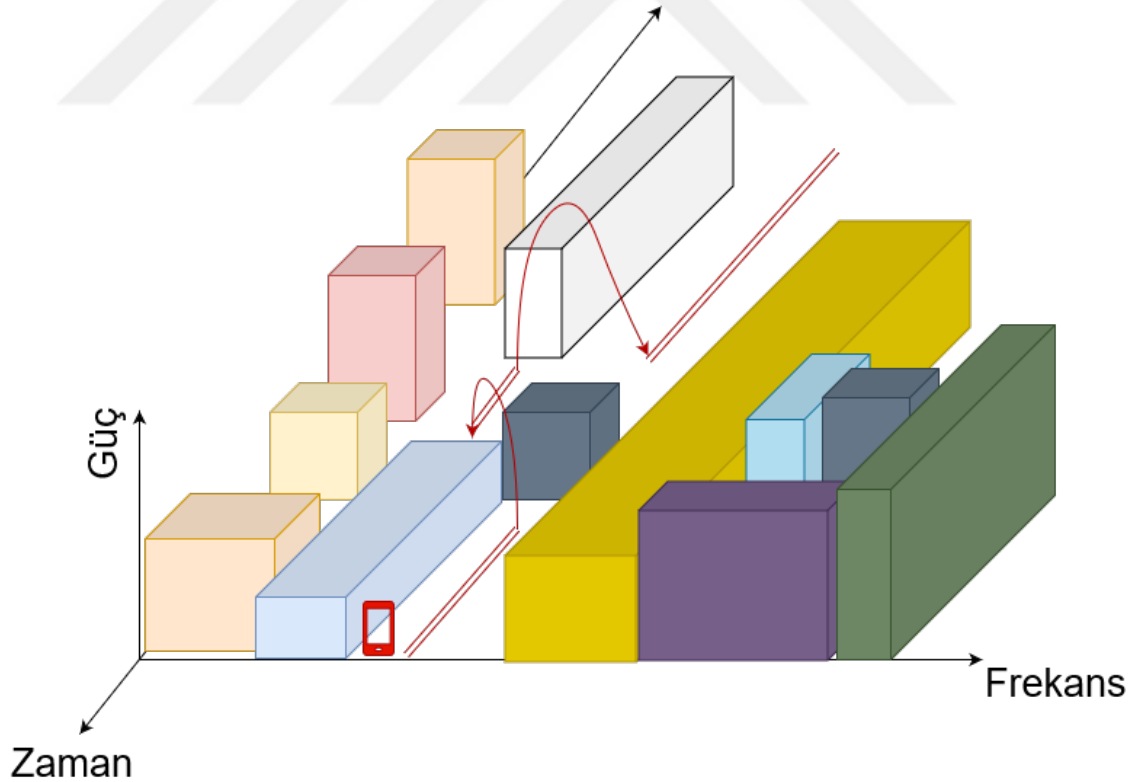
to process. On the other hand, binarization process removes valuable information obtained from the spectrum. In other categories; however, learning strategies are adopted. Critical parameters of this category are learning duration/period, running speed and computational complexity. These parameters render such models “difficult to implement.” Hence, the reasonable strategy is to take advantage of learning category methods in case linear models start perform poorly. Thus, cognitive radio needs to decide when to use what based on its environmental conditions.

In this thesis, prominent methods present in the literature for identification of signals in the spectrum band of interest. Performance analyses are provided for the methods of interest based on the real-world measurement data.



## 1. BİLİŞSEL RADYOLAR

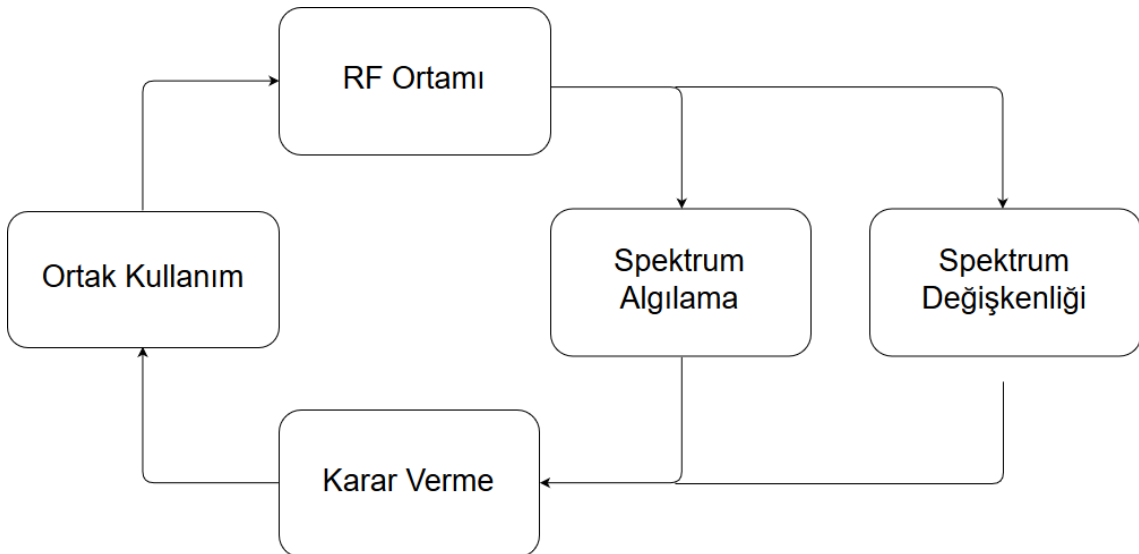
Bilişsel radyo, kablosuz spektrumda birincil kullanıcının kullanmadığı spektrum boşluklarını dinamik olarak tespit eden ve tespit ettiği bu boşluklardan faydalanarak kendi iletim parametrelerini adaptif bir şekilde ayarlayarak iletişim sağlayan, böylelikle spektrumu daha etkin kullanmayı amaçlayan yazılım tabanlı iletişim aracıdır. Kablosuz spektrumu kullanan iletişim araçlarının gün geçtikçe çoğalması, kısıtlı spektrum kaynağı, spektrumdaki ağ trafiğinin artması gibi sebepler bilişsel radyoların faydalandığı teknolojilerin iletişim cihazları tarafından kullanımını kaçınılmaz hale getirmektedir. Bilişsel radyonun bu bağlamda amacı verimsiz spektrum kullanımını daha da iyi hale getirerek elde var olan kısıtlı spektrum kaynağının daha etkin kullanılmasını sağlamaktır.



Şekil 1.1 : Bilişsel radyonun frekans uzayında çalışması

Bilişsel radyo terminolojisinde birincil kullanıcı spektrum kaynağının kullanımında bilişsel radyo kullanan ikincil kullanıcıdan daha çok önceliğe sahip olmaktadır. Bilişsel

radio da gözlemediği spektrum alanında birincil radyonun kullanmadığı bölgeleri tespit ederek kendi veri iletimini bu boşluklar üzerinden sağlar. Bilişsel radyonun tespit edebileceği spektrum uzayı zaman, frekans, kod, coğrafi konum, iletim açısı ... vb. olabilir. Birincil kullanıcı tarafından aynı zaman dilimi içerisinde kullanılmayan frekans alanı veya aynı frekans alanında kullanılmayan zaman alanının tespitiyle bilişsel radyo kendi iletişimini sağlayabilir. Aynı şekilde birincil kullanıcının bulunduğu konuma veya birincil kullanıcı işaretinin iletimeçısına göre bilişsel radyonun yararlanabileceği konum veya pozisyon ayarlamaları yapılarak iletişim sağlanabilir.



Şekil 1.2 : Bilişsel radyonun fonksiyonları

Bilişsel radyonun en temel fonksiyonları bulunduğu spektrum bölgesini ölçmesi, sezmesi, öğrenmesi ve kendi iletim parametrelerini buna göre ayarlayarak iletişim sağlamasıdır. Bu sayede gözlemediği spektruma ait kullanılmayan alanları kullanarak daha verimli bir şekilde spektrumdan faydalanır. Bilişsel radyolar kendisinin iletişimi için kullanacağı iletim parametrelerini ayarlar ve bir sonraki adım için iletişimini sağlayabileceği uygun spektrum bölgelerini tespit eder. Spektrumda oluşacak değişiklikleri sürekli kontrol ederek kendi iletim parametrelerini buna göre ayarlar. Ayrıca diğer kullanıcılar arasında spektrumu belirli bir şekilde paylaştırarak, spektrumun adil ve etkili bir şekilde kullanılmasını sağlar.

Ancak bu işlemler yapılırken karşılaşılan zorluklar bulunmaktadır. Öncelikle bilişsel radyonun işlemleri hızlı ve doğruluk yüzdesi yüksek olmalıdır. Gözlemediği spektrum alanında birincil kullanıcıların varlığını hızlı tespit edebilmelidir. Ardından gözlem-

lediği alanda kullanıcının olmadığı zaman alanında kendi verisini iletebilmelidir. Gözlemediği alana ait kullanım istatistiğini de düzgün bir şekilde yorumlanmasını sağlayarak bir sonraki adımda kullanıcı olup olmayacağını tahmin etmelidir. Bütün bu işlevsellikler maliyeti arttırmaktadır. Hızlı bir şekilde geniş bir spektrum alanında işaretleri toplayarak işlemesi için yüksek örnekleme frekanslarına sahip analog-sayısal dönüştürücelere, çevreden topladığı bu verileri hızlı bir şekilde analiz eden sinyal işleme birimlerine ve yazılımlarına ihtiyaç vardır. Bu özellik en başta donanım ve yazılım maliyetini arttırmaktadır. Düşük SNR seviyelerinde birincil kullanıcının düzgün bir şekilde tespit edilememesi durumunda iletilen işaretlerin birbirleriyle çakışması sorunu olmaktadır. Çok geniş spektrum alanında iletişimini sağlayan birincil kullanıcının varlığı, frekans atlamalı cihazlar, bilişsel radyonun işini zorlaştırmaktadır. Bilişsel radyonun birincil kullanıcının işaretini tespit etmesinde veya kullanım istatistiğini öğrenerek ve belirli bir kestirim modeli kullanarak tahmin yapmaya çalışmasında yararlandığı algoritmaların çalışma hızı, karmaşıklığı, bu işlemleri yapan donanımların maliyeti gibi sebepler de bilişsel radyo kullanımında karşılaşılan zorluklardandır.

## **1.1 Tezin Amacı**

Bilişsel radyoların yararlanabileceği frekans-zaman uzayında spektrumdaki birincil kullanıcıların tespit edilebilmesi, spektrumun kullanım istatistikleri yardımıyla kullanım modelinin oluşturulması, bu yöntemlerin incelendiği literatürdeki çalışmaların incelenmesi ve spektrumun bilişsel radyo tarafından, oluşturulan modeller yardımıyla daha etkili bir şekilde kullanılmasının sağlanmasıdır.

## **1.2 Literatür Araştırması**

Spektrumun verimli kullanımı amacıyla literatürde pek çok araştırma yapılmıştır. Spektrumda kullanıcı varlığını tespit edip iletişim parametrelerini değiştiren yazılım tabanlı radyo fikri 1999'da Mitola tarafından ortaya atılmıştır [1]. Ancak bilişsel radyonun gözlemediği spektrumda birincil kullanıcı sinyalinin tespiti için kullanılacak metodlar çok önceden araştırılmaya başlanmıştır [2–8].

H. Urkowitz'in 1967'de önerdiği önerdiği enerji sezici metodu spektrumda gözlemlenen sinyal hakkında herhangi bir bilgi gereksinimi olmadan tespitinin sağlanmasını

amaçlamaktadır [9]. Ancak bu önerilen metotta spektrumdaki gürültünün belirsizliği; kullanıcı tespiti için önerilen eşik değerinin belirlenmesinde ciddi sorunlar çıkarmakta ve gözlemlenen spektrum alanı için hatalı tespit yaparak veya işaretin tespitini yapamayarak yanlış sonuçlar üretmesine sebebiyet vermektedir. [10] 'de deneysel olarak hazırlanan test ortamlarında bilişsel radyoların bulunduğu konuma göre enerji sezicilerin aldığı sinyal parametrelerindeki değişikliklerinden performansını arttırmaya yönelik çalışma yapılmıştır. Aynı çalışmanın devamında [11], gerçek ölçümler alınarak kestirim performansı test edilmiştir. Gürültü belirsizliğine dayanarak enerji detektörünün çalışabileceği kestirim üst sınırları belirlenmiştir. İşbirlikli spektrum kestirimi [12]' de yapılmıştır ve enerji detektörünün kullanabileceği yeni bir kapalı formül türetilmiştir. Enerji sezicilerin performansını arttırmanın bir diğer yolu daalıcısındaki anten sayısını arttırarak uzaysal çoğullama sağlanmasıdır. Birden fazla kaynaktan işaret alınarak elde edilen spektrum verilerinin analizi [13]' de yapılmıştır. Aynı şekilde uzaysal çoğullama kullanılarak elde edilen işaret vektörlerinin özdeğer karşılaştırılmalarıyla da spektrum kestirimi [14]'de yapılmıştır. [15]'de spektrumda incelenen her bir bölge için farklı eşik değerleri tespit edilerek performans arttırılmaya çalışılmıştır. Spektrumdaki işaretlerin kestirimi yapıldıkça dinamik olarak eşik değeri değiştirilerek performans arttırımı [16]'da çalışılmıştır. [17]'de yapılan çalışmada çok yönlü sönümleme ve gölgeleme etkisi de göz önünde bulundurularak yapılan benzetim sonuçlarıyla elde edilen kapalı form denklemlerinin sağlanması yapıldı. [18]'de yapılan çalışmada eşik değerinin işaret girişim oranına bağlı olarak uyarlamalı bir şekilde doğrusal işlevle arttığı sonucuna ulaşılmıştır. Yapılan benzetim sonuçlarına göre ikincil kullanıcının veri oranı önemli derecede arttırılmıştır.


Spektrumdaki birincil kullanıcıların belirli bir frekans bölgesini belirli zaman aralıklarında ve düzende kullanımına ait verisi zaman serisi olarak düşünülebilir. Zaman serilerinin analizine yönelik çalışmalar [19–24]'dedir. Kullanım verilerini ikili zaman serisi olarak alıp değerlendiren [25]'de otoregresif zaman modeli kullanılarak GSM bandının analizi yapılmıştır. [25]'de önerilen yöntemle analiz yapan [26]'de birer dakika aralıklarla örnek alınan  $2.3GHz$ 'lik spektrum alanı incelenmiş ve sonuçlar gizlenmiş Markov modeliyle karşılaştırılmıştır. [27]'deki çalışmada otoregresif parametrelerin ileri ve geri yönlü doğrusal kestiriminde en küçük kare çözümü tabanlı spektrum kestirimi yapılmaktadır. Burg algoritmasına karşı spektrum

kestirimi için Marple'in en küçük kare kestirim algoritmasını önerilmiştir. Önerilen algoritma; Burg algoritmasıyla aynı hesaplama karmaşıklığına sahip olmasıyla birlikte, spektrumu daha etkili bir performansla kestirmiştir. [28]'de, bilişsel radyo sistemleri için spektrumdaki bilişsel radyonun kullanabileceği spektrum boşluklarını belirlemek amacıyla otoregresif kanal tahmin modeli sunulmuştur. İkinci dereceden AR modele uygun olarak Yule Walker denklemleri yardımıyla parametre kestirimleri yapılmıştır. Spektrumda olması muhtemel boşlukların uyarlamalı kalman filtresiyle kestirimi yapıldı. Simülasyon sonuçlarına göre spektrum boşluklarının tahmini için Gauss gürültülü ortamlarda uyarlamalı filtrenin kullanımı iyi sonuçlar vermektedir ancak Gauss gürültülü olmayan ortamlarda spektrum boşluklarının kestirimi hala sorun olmaktadır. Ayrıca [28–30]'deki çalışmalarda spektrum kullanımına ait zaman serisinin analizi için otoregresif modeller önerilmiştir. Ayrıca ileri ve geri yönlü kestirimlerden ve uyarlamalı filtreler yardımıyla kestirim performansları arttırılmaya çalışılmıştır. Kullanılan modellerde parametre ve model derecesine ait belirlemeler için ise Akaike Bilgi Kriteri ve Box-Jenkins modelleri kullanılmıştır [20, 31, 32].

LSTM modelleri genellikle ses tanıma, doğal dil işleme, ses tanıma veya veri sınıflandırma gibi alanlarda kullanılmaktadır [33–36]. Bu çalışmada haberleşme teknolojilerinde kullanılması üzerine çalışma yapılmıştır.

### **1.3 Hipotez**

Spektrum alanını çok geniş alana sahiptir. Ayrıca her bir frekans alanını kullanacak işaretlerin farklı istatistiksel özellikleri olacağından, her bir frekans bölgesine ait alanların ayrı ayrı düşünülmesi gerekmektedir. Bu yüzden gözlemlenen çok geniş frekans spektrum alanı ayrı ayrı frekans alanı bölmelerine ayrılır. Ardından her bir frekans bölgesine ait kullanım sezim kestirim karakteristiği incelenen bölge içinde ayrı ayrı değerlendirilir.



**Şekil 1.3 :** Spektrum kullanımının çok boyutlu yapısı ve haritalanması


Her bir frekans bölmesine ait belirli zaman aralıklarında ölçülen değerler bir zaman serisinin elemanı olarak düşünülür. Elde edilen bu zaman serisinin analiz edilmesiyle oluşturulacak olan doğrusal veya doğrusal olmayan modeller spektrum kullanımının tahmininde kullanılır. Farklı spektrum bölmelerine ait zaman serisi modelleri gözlemlenen her bir spektrum bölgesinde var olan işaretin özelliğine bağlı olarak birbirlerinden farklı karakteristik özellik gösterecektir.



## 2. ENERJİ SEZİCİLER

Enerji seziciler, spektrumda var olan sinyallerin kestirimi için akla ilk gelen en temel yöntemdir. Bunun sebebi çevreden aldığı sinyallerin iletim parametreleri hakkında herhangi bir ön bilgiye gerek duymaksızın işlemesi ve hesaplama karmaşıklığı en az olacak maliyetli şekilde sonuç üretmesidir.

Spektrumda alınan  $x(t)$  zaman sinyalinin öncesinde analog band geçiren süzgeçten geçirir. Ardından elde edilen band geçiren analog sinyali hızlı ve etkili bir şekilde işleyebilmesi için uygun analog-sayısal dönüştürücü yardımıyla sayısal işarete çevirir. Elde edilen ayrık işaretlerin mutlak karelerinin ortalamasını alarak enerji seviyesi üretir. Elde ettiği enerjiyi çevredeki sinyal gürültü oranı ve belirlenen yanlış alarm olasılığı parametrelerini kullanarak hesaplanan eşik değeriyle karşılaştırır. Bu enerji seviyesi eşik değerinden yüksek ise gözlemlenen spektrumda birincil kullanıcının işareti var olduğu sonucunu, düşükse birincil kullanıcıya ait sinyal olmadığı sonucunu üretir.



Şekil 2.1 : Enerji sezicinin çalışma şeması

### 2.1 İkili Hipotez Testi

$x_t$  çevrede gözlemlenen sinyal,  $x_k$  bant geçiren filtrenin çıkışından örneklenen sayısal işaret,  $n_k$  ortam gürültüsü ve  $s_k$  birincil kullanıcıya ait işaret olmak üzere,  $x_k$  işareti birincil kullanıcı işaretinin olduğu ve olmadığı durumlarda aşağıdaki şekilde oluşur.

$$x_k = \begin{cases} n_k, & \text{birincil kullanıcı yoksa } H_0 \\ s_k + n_k, & \text{birincil kullanıcı varsa } H_1 \end{cases} \quad (2.1)$$

Birincil kullanıcının olmadığı durum  $H_0$ , olduğu durum  $H_1$  hipotezi olarak adlandırılır.

## 2.2 Kestirim ve Sezim

Kestirim olasılığı  $P_d$  ve yanlış alarm olasılığı  $P_f$ , spektrumdaki birincil kullanıcının seziminde kullanılan iki metriktir.  $P_d$  bilişsel radyo kullanan ikincil kullanıcının spektrumda birincil kullanıcının var olduğunu belirleme olasılığıdır.  $P_f$  ise gerçekte birinci kullanıcı olmadığı halde birincil kullanıcının spektrumda birincil kullanıcı olduğunu belirtme olasılığı olarak tanımlanır. Hatalı kestirim olasılığı da  $P_m$ , gözlemlenen spektrumda birincil kullanıcı varken, birincil kullanıcının ortamda birincil kullanıcı işaretinin olmadığı sonucunu üretme olasılığıdır.

$$\begin{aligned} P_d &= P(T > \lambda/H_1) \\ P_f &= P(T > \lambda/H_0) \\ P_m &= 1 - P_d \end{aligned} \quad (2.2)$$

Yanlış alarm kestirim etkinliğini azaltarak spektrumun etkili şekilde kullanılmasını azaltır, hatalı tespit ise spektrumda birincil kullanıcı varken bilişsel radyonun işaretini spektrumdan göndermesine ve işaretlerin çakışmasına sebep olur. Sonuç olarak spektrum kestiriminin etkili bir şekilde yapılabilmesi için açıklanan bu iki terimin mümkün olduğunca optimize edilmesi gerekir.

Çevreden alınan işaretin içerisinde birincil kullanıcıya ait işaret bulunmadığında, gürültünün toplamsal beyaz Gauss gürültüsü olduğu varsayımında beklenen değeri 0 olacaktır. Aynı zamanda varyansı da gürültünün varyansına  $\sigma_n$ , eşit olacaktır. Dolayısıyla kareler toplamının çıkışında elde edilen test istatistiği de, normal dağılım değerlerinin karesinin toplamı olacağından, M'inci dereceden bağımsız ki-kare dağılımına sahiptir ve beklenen değeri gürültü varyansına eşittir. Test istatistiği önceden belirlenen eşik değerinden küçük olacaktır. Spektrumda birincil kullanıcının var olduğu durumda ise alınan işaretin beklenen değeri birincil kullanıcının sinyaline ait beklenen değer olacaktır. Kareler toplamının çıkışında elde edilen test istatistiği de, M'inci dereceden bağımsız ki-kare dağılımına sahiptir ve beklenen değeri birincil kullanıcı işaretinin varyansına eşittir. Test istatistiği önceden belirlenen eşik değerinden büyük olacaktır.

$$f(x, \mu) = \frac{1}{2^{\frac{M}{2}} \Gamma(\frac{M}{2})} x^{\frac{M}{2}-1} \exp^{-\frac{x}{2}} \quad (2.3)$$

$$f_u(x) = \begin{cases} \frac{\sigma_n^2}{M} f_x\left(\frac{x\sigma_n^2}{M}, M\right), & \text{birincil kullanıcı yoksa } H_0 \\ \frac{\sigma_s^2}{M} f_x\left(\frac{x\sigma_s^2}{M}, M\right), & \text{birincil kullanıcı varsa } H_1 \end{cases} \quad (2.4)$$

$$E_u = \begin{cases} \sigma_n^2, & \text{birincil kullanıcı yoksa } H_0 \\ \sigma_s^2, & \text{birincil kullanıcı varsa } H_1 \end{cases} \quad (2.5)$$

$$\sigma_u^2 = \begin{cases} \frac{2}{M} \sigma_n^2, & \text{birincil kullanıcı yoksa } H_0 \\ \frac{2}{M} \sigma_s^2, & \text{birincil kullanıcı varsa } H_1 \end{cases} \quad (2.6)$$

Eğer alınan örnek sayısı  $M$ , yeterince büyükse merkezi limit teoreminden spektrumda gözlemlenen işarete ait test istatistiği belirtilen varyans ve beklenen değere ilişkin normal dağılıma sahip olacaktır.

$$f_{\bar{u}}(x) = \begin{cases} \mathcal{N}\left(\sigma_n^2, \frac{2\sigma_n^4}{4}\right), & \text{birincil kullanıcı yoksa } H_0 \\ \mathcal{N}\left(\sigma_s^2, \frac{2\sigma_s^4}{4}\right), & \text{birincil kullanıcı varsa } H_1 \end{cases} \quad (2.7)$$

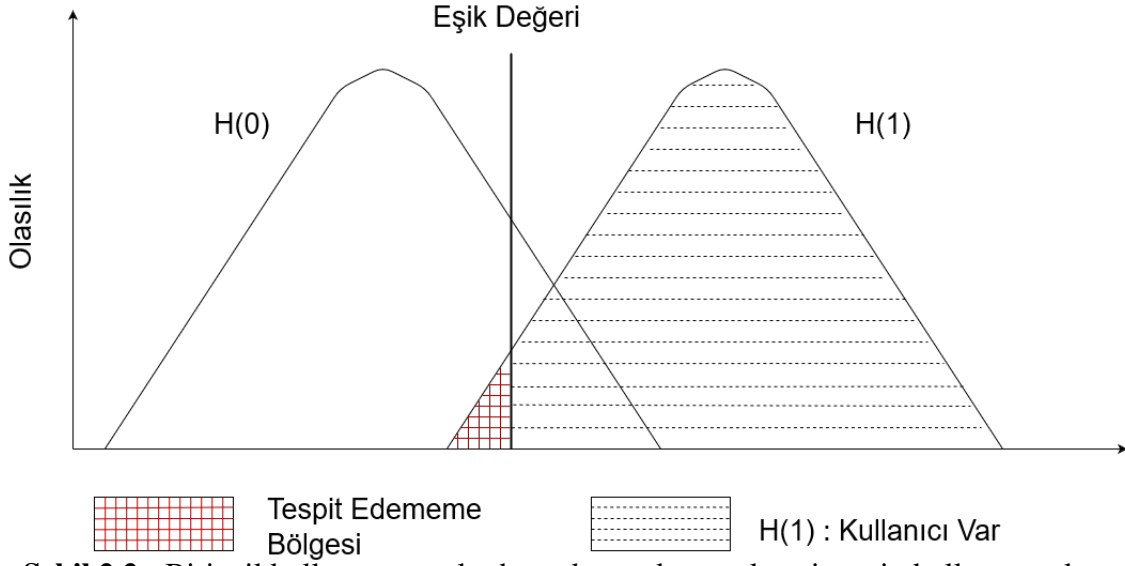
Belirlenen eşik değerine göre sistemin yanlış alarm olasılığı  $P_f$ ,

$$P_f(\lambda) = P(u > \lambda / H_0) = \Gamma\left(\frac{M}{2}, \frac{M\lambda}{2\sigma_n^2}\right) \quad (2.8)$$

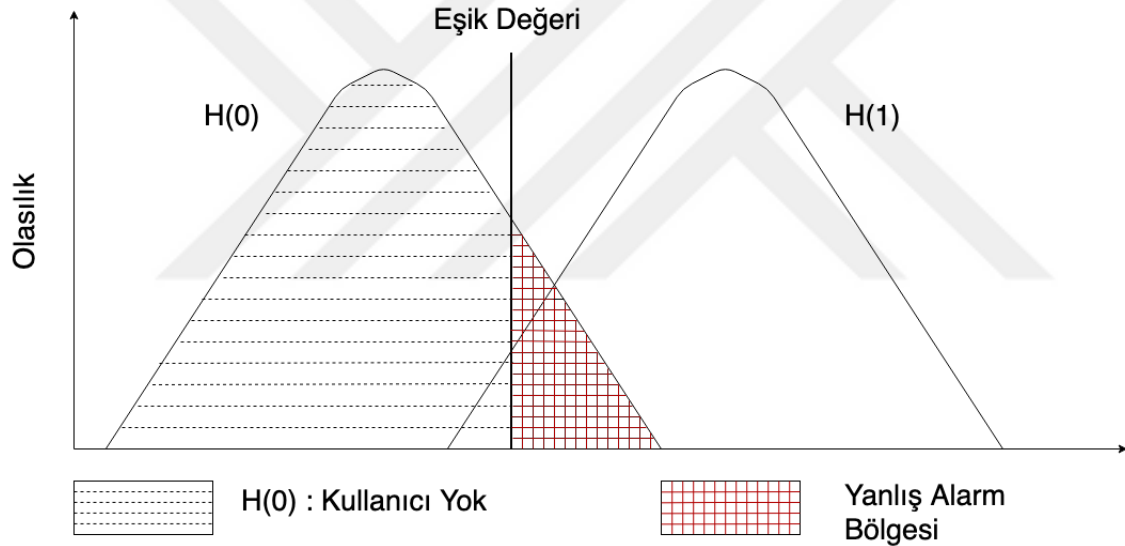
Yeteri kadar büyük örnek sayısı alındığında merkezi limit teoreminden yanlış alarm olasılığı aşağıdaki şekilde türetilir.

$$P_f(\lambda) = Q\left(\frac{\lambda - \sigma_n^2}{\sigma_n^2 / \sqrt{\frac{M}{2}}}\right) \quad (2.9)$$

Sonuç olarak enerji sezicilerde hataya sebep olabilecek iki çeşit olasılık vardır. Birincisi spektrumda kullanıcının aslında var olduğu ancak sezicinin kullanıcıyı tespit edememesi olasılığı  $P_m$ , ikincisi spektrumda kullanıcının aslında olmadığı ancak enerji sezicinin kullanıcı var sonucunu ürettiği yanlış alarm olasılığıdır,  $P_f$ . Her iki hata olasılığının da optimum sistemlerde olabildiğince düşürülmesi gerekmektedir.



**Şekil 2.2 :** Birincil kullanıcının aslında spektrumunda var olup sistemin kullanıcı yok sonucunu üretmesi

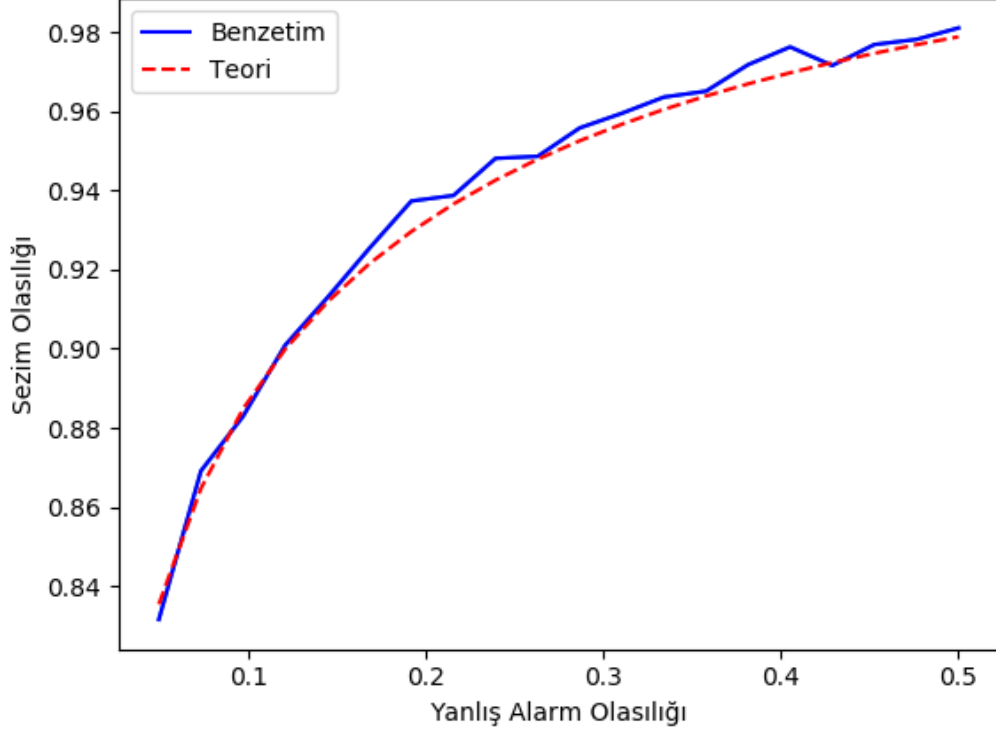


**Şekil 2.3 :** Spektrumunda birincil kullanıcının aslında olmadığı ancak sistemin kullanıcı var sonucunu üretmesi

Eşik değeri de bu durumda iki prensibin varsayımı koşulunda hesaplanmalıdır. Ortamda yanlış alarm olasılığının önemi daha yüksekse sabit yanlış alarm oranı dikkate alınarak, sinyal gürültü oranının düşük olduğu kestirim olasılığının önemi daha yüksek olduğu durumlarda sabit sezim oranı dikkate alınarak eşik değeri hesaplanır.


$$\lambda = \begin{cases} \sigma_n^2 \left(1 + \frac{Q^{-1}(P_f)}{\sqrt{M/2}}\right), & \text{sabit yanlış alarm olasılığı} \\ \sigma_n^2 \left(1 + SNR\right) \left(1 + \frac{Q^{-1}(P_d)}{\sqrt{M/2}}\right), & \text{sabit kestirim olasılığı} \end{cases} \quad (2.10)$$

Aşağıdaki grafikte kullanıcı işaretinin -10 dB'de ve normal dağılımlı olduğu durumda yapılan benzetimin teorik olarak sağlaması gösterilmektedir.




Şekil 2.4 : -10 dB, yanlış alarm - sezim olasılıđı


Aşağıda farklı kanal ve modülasyon çeşitlerinde var olan işaretlerin enerji seziciden 0.05 hatalı kestirim oranında SNR-performans grafikleri gösterilmiştir.



Şekil 2.5 : Rayleigh kanalda BPSK işareti



Şekil 2.6 : Rician kanalda QPSK işareti



**Şekil 2.7** : Nakagami kanalda 16QAM işareti





### 3. ÇEVİRİMSSEL DURAGANLIK

Sayısal iletişime veya belirli dalga formlarına ait işaretler spektrumda istatistiksel parametreleri hakkında bilgi içerirler. Frekansa veya zamana ait istatistiksel karakteristikler de iletişimdeki alıcı ve verici arasındaki iletişime dair bilgiler içerir. Örneğin, kablosuz iletişimde havadan alınan işaretler, iletişim trafiğinin kesikli olması, sürekli alıcı ve verici arasındaki iletişimin kısa kısa mesajlar halinde olması iletişimin aralıklı olduğu hakkında bilgiler içerir. Aynı şekilde; işaretin, çok yüksek bant genişliğinde ve sürekli olması durumunda bu iletişime ait işaretin eşzamanlı bir iletişime veya dosya indirme işlemine ait bir işaret olduğuna dair bir ön bilgi içerir.

Dalga formuna ait spektral karakteristikler, rastlantısal süreç olsa dahi iletişimde kullanılan alıcı ve vericilerin nasıl tasarlandığına dair pek çok bilgi içermektedir. Sadece fiziksel dalga formu gözlemlenerek iletişimin nasıl bir veri hızında gerçekleştiği, hangi modülasyon şeması kullanıldığı, hatta taşıyıcı frekansın çıkarılması durumunda işaretler arası girişimi engellemek için kullanılan koruyucu bantların nerelerde olduğu öğrenilebilir. Sonuç olarak spektrumda gözlemlenen rastlantısal süreçlerin istatistiksel parametrelerinde periyodik özellikler, sürecin yeteri kadar uzunlukta gözlemlenmesi sonucu elde edilebilir. Eğer spektrumda iletişime ait bir işaret bulunmazsa bu periyodik özellikler sergileyemeyeceği için kullanıcının olmadığı sonucuna ulaşılır.

#### 3.1 Çevrimsel Durağan Süreçler

Rastlantısal bir süreçte dar anlamda durağanlık, belirli bir zaman aralığında süreçte gözlemlenerek elde edilen olasılık yoğunluk fonksiyonlarının zamana bağlı olarak değişmemesidir. Dolayısıyla dar anlamda durağanlık, sürece ait olasılık yoğunluk fonksiyonunun tüm zaman örneklerinde aynı kalması olarak tanımlanır. Geniş anlamda durağanlık ise sürece ait otokorelasyon fonksiyonunun ve beklenen değerinin zamana farkına bağlı kalmaksızın sabit olmasıdır. Çevrimsel durağanlık ise sürecin belirli periyot aralıklarla incelenmesi sonucunda, aynı istatistiksel parametrelerin elde edilmesi durumudur.

Örneğin  $X(t)$  süreci aşağıdaki şekilde tanımlansın

$$X(t, w) = A(w) \cos(w_0 t) + B(w) \sin(w_0 t) \quad (3.1)$$

$A(w)$  ve  $B(w)$  birbirinden bağımsız sırasıyla  $\mu_1, \mu_2$  beklenen değerlerine ve  $\sigma_1^2$  ve  $\sigma_2^2$  varyanslarına sahip iki normal dağılıma sahip süreçler olsun.  $X(t, w)$  süreci  $t_0$  anında örneklenirse  $X(t_0, w)$  rastlantı değişkeni elde edilir.

$$X(t_0, w) = A(w) \cos(w_0 t_0) + B(w) \sin(w_0 t_0) \quad (3.2)$$

$A$  ve  $B$  Gauss rastlantı değişkenleri olduğu için,  $X(w)$  rastlantı süreci aşağıda verilen ortalama değer varyans parametrelerine sahip olacaktır.

$$\begin{aligned} \mu_x(t) &= \mu_1 \cos(w_0 t) + \mu_2 \sin(w_0 t) \\ \sigma_x^2 &= \sigma_1^2 \cos^2(w_0 t) + \sigma_2^2 \sin^2(w_0 t) \end{aligned} \quad (3.3)$$

$X(w)$  sürecine ait beklenen değer ve varyans parametreleri  $T_0 = \frac{2\pi}{w_0}$  periyodik olduğu için süreç birinci dereceden çevrimsel süreçtir.

Eğer  $X(t)$  süreci  $t_1$  ve  $t_2$  zamanlarında ayrı ayrı örneklenirse  $X(t_1, w)$  ve  $X(t_2, w)$  rastlantı değişkenleri elde edilir.

$$\begin{aligned} X(t_1, w) &= A(w) \cos(w_0 t_1) + B(w) \sin(w_0 t_1) \\ X(t_2, w) &= A(w) \cos(w_0 t_2) + B(w) \sin(w_0 t_2) \end{aligned} \quad (3.4)$$

Matrix formunda yazılırsa;

$$\begin{bmatrix} X(t_1, w) \\ X(t_2, w) \end{bmatrix} = \underbrace{\begin{bmatrix} \cos(w_0 t_1) & \sin(w_0 t_1) \\ \cos(w_0 t_2) & \sin(w_0 t_2) \end{bmatrix}}_M \begin{bmatrix} A(w) \\ B(w) \end{bmatrix} \quad (3.5)$$

Buradaki Gauss rastlantı değişkenine ait beklenen değer vektörü ve kovaryans matrisi,

$$\mu_x = M \begin{bmatrix} \mu_1 \\ \mu_2 \end{bmatrix}, \quad C_{xx} = M \text{diag}(\sigma_1^2, \sigma_2^2) M^T \quad (3.6)$$

Bu sürece ait olan otokovaryans işlevi de elde edilen kovaryans matrisinin diagonal olmayan elemanlarından çıkartılır.

$$C_{xx}(t_1, t_2) = \frac{\sigma_1^2 + \sigma_2^2}{2} \cos(w_0(t_2 - t_1)) + \frac{\sigma_1^2 - \sigma_2^2}{2} \cos(w_0(t_1 + t_2)) \quad (3.7)$$

$t_1 = t$  ve  $t_2 = t - \tau$  olarak alınırsa aşağıdaki sonuca ulaşılır.

$$C_{xx}(t, \tau) = \frac{\sigma_1^2 + \sigma_2^2}{2} \cos(w_0 \tau) + \frac{\sigma_1^2 - \sigma_2^2}{2} \cos(2w_0 t - w_0 \tau) \quad (3.8)$$

Elde edilen ifade zamanda temel periyotta  $T_0^{(2)} = 2\pi/2\omega_0$ , periyodiktir. Aynı zamanda sürece ait olan ikinci dereceden istatistikleri de periyodiktir.

Çevrimsel durağan süreçlerde otokorelasyon fonksiyonu zaman farkında periyodik karakteristik gösterir. Böylece aşağıdaki şekilde sürecin otokorelasyon ve beklenen değer işlevlerini aşağıdaki şekilde yazabiliriz.

$$\begin{aligned} R_x(t, \tau) &= R_x(t + T_0, \tau) \\ \mu_x(t) &= \mu_x(t + T_0) \end{aligned} \quad (3.9)$$

Otokorelasyon fonksiyonu periyodik olduğu için çevrimsel frekans  $\alpha$ 'nın alabildiği bütün değerlerde fourier serisi biçiminde yazılabilir.

$$R_x(t - \frac{\tau}{2}, t + \frac{\tau}{2}) = \sum_{\alpha} R_x^{\alpha}(\tau) e^{-j2\pi\alpha t} \quad (3.10)$$

Periyodik otokorelasyon işlevine ait fourier serisinin elamanları çevrimsel otokorelasyon işlevini oluşturur. Çevrimsel frekansın sıfır olduğu yer  $\alpha = 0$ , bilinen otokorelasyonun ifadesidir.

$$R_x^{\alpha}(\tau) = \lim_{T \rightarrow \infty} \frac{1}{T} \int_T x(t + \frac{\tau}{2}) x^*(t - \frac{\tau}{2}) e^{-j2\pi\alpha t} dt \quad (3.11)$$

Çevrimsel otokorelasyonun her bir elemanın fourier dönüşümü spektral korelasyon işlevini vermektedir.


$$S_x(f) = \int_{-\infty}^{\infty} R_x^{\alpha}(\tau) e^{-j2\pi f t} d\tau \quad (3.12)$$

Spektral korelasyon işlevi sinyalin  $f - \alpha/2$  ve  $f + \alpha/2$ 'deki çevrimsel frekans bileşenleri arasındaki çapraz korelasyonunu ifade eder. Spektral korelasyon fonksiyonunun normalize edilmesiyle de spektral koherans(uyumluluk) işlevi elde edilir.


$$C_x^{\alpha}(f) = \frac{S_x^{\alpha}(f)}{\sqrt{S_x^{\alpha}(f - \alpha/2) S_x^{\alpha}(f + \alpha/2)}} \quad (3.13)$$

Spektral koherans işlevi sıfırla bir arasında değer alır ve sinyal içerisindeki ikinci dereceden periyodik bileşenlerin gücünü temsil eder.


Bilgisayar benzetimi ve spektrumdan alınan gerçek ölçümlerle ilgili spektral korelasyon işlevlerine ait grafikler aşağıda verilmiştir.




Şekil 3.1 : BPSK işaretine ait SCF




Şekil 3.2 : Bant geçiren -5 dB Rayleigh kanalda BPSK işaretine ait SCF




**Şekil 3.3** : Bant geçiren 0 dB Rayleigh kanalda QPSK işaretine ait SCF



**Şekil 3.4** : Bant geçiren 0 dB Nakagami kanalda 64QAM işaretine ait SCF



Şekil 3.5 : GSM bandından alınan işarete ait SCF



Şekil 3.6 : EDGE işaretine ait SCF

#### 4. DOĞRUSAL MODELLER

Zaman serisinin içinde bulunduğu andaki değeri, zaman serisinin  $p$  zaman değeri kadar önceki değerlerinin birleşimi olarak ifade edilebiliyorsa kullanılabilir model otoregresif modeldir.

$$\begin{aligned} z_t &= \phi_1 z_{t-1} + \phi_2 z_{t-2} \cdots + \phi_p z_{t-p} + a_t \\ &= \sum_{k=1}^p \phi_k z_{t-k} + a_t \end{aligned} \quad (4.1)$$

Burada  $\phi_k$  model katsayısını,  $z_{t-k}$  zaman serisinin  $k$  zaman birimi önceki değerini,  $p$  model derecesini ve  $a_t$  sistemi  $t$  anında etkileyen gürültüyü ifade etmektedir. Belirlenecek olan model derecesi  $p$  ve model katsayıları  $\phi_k$  parametreleri sayesinde spektrumda gelecek zaman aralığında kullanıcının var olup olmama durumu tespit edilmeye çalışılır.

$$z_t = \phi z_{t-1} + a_t \quad (4.2)$$

Zaman serisinin içinde bulunduğu andaki değeri, sadece kendinden bir önceki değeriyle ve o andaki sistemi etkileyen gürültünün doğrusal birleşimi olarak ifade edilebiliyorsa sistem birinci dereceden otoregresif modelle  $AR(1)$ , modellenir.

$$\begin{aligned} z_t &= \phi z_{t-1} + a_t \\ &= \phi(\phi z_{t-2} + a_{t-1}) + a_t \\ &= \phi^2 z_{t-2} + \phi a_{t-1} + a_t \end{aligned} \quad (4.3)$$

Birinci dereceden otoregresif bir sürecin  $t$  anındaki ifadesi, sürecin bir birim zaman önceki ifadesi cinsinden yukarıdaki şekilde yazılabilir. Dolayısıyla, süreç devam ettiği müddetçe hangi zaman aralığında olursa olsun; sürecin o andaki değeri ile, ilk değeri arasında bir ilişki vardır yorumu yapılabilir. Sürecin  $k$  birim zaman sonraki ifadesi de aşağıdaki şekilde yazılabilir.

$$z_{t+k} = \phi^k z_t + \sum_{j=0}^{k-1} \phi^j a_{t+k-j} \quad (4.4)$$

Sürecin  $t$  anındaki ifadesiyle, bulunduğu zamandan  $k$  birim zamanı kaymış ifadesinin kovarsını aldığımızda; sürecin  $k$  birim zaman kaymış ifadesiyle, parametresi  $k$  olan üstel bir ilişkisi olduğu sonucuna varılır. Eşitliğin sağ tarafındaki toplam formülünün içerisindeki ifadeyle,  $z_t$  arasında herhangi bir korelasyon bulunmamaktadır.

$$\begin{aligned} \text{Cov}(z_t, z_{t+k}) &= \text{Cov}(z_t, \phi^k z_t + \sum_{j=0}^{k-1} \phi^j a_{t+k-j}) \\ &= \phi^k \text{Cov}(z_t, z_t) \end{aligned} \quad (4.5)$$

Yukarıdaki denklemde sürecin varyansını  $\sigma_z^2$ , belirten ifade  $\text{Cov}(z_t, z_t)$ , aşağıdaki şekilde hesaplanır.

$$\begin{aligned} \text{Var}(z_t) &= \text{Var}(\phi z_{t-1} + a_t) \\ \sigma_z^2 &= \phi^2 \sigma_z^2 + \sigma_a^2 \\ \sigma_z^2 (1 - \phi^2) &= \sigma_a^2 \\ \sigma_z^2 &= \frac{\sigma_a^2}{1 - \phi^2} \end{aligned} \quad (4.6)$$


Dolayısıyla yukarıdaki eşitlik tekrardan düzenlenebilir.

$$\gamma_k = \phi^k \frac{\sigma_a^2}{1 - \phi^2} \quad (4.7)$$

Sürecin  $k$ 'inci otokorelasyon katsayısı da,  $k$  zaman kaymasındaki kovaryansının sıfırcı kovaryansa oranı olarak yazılabildiği için, otokorelasyon katsayıları kendi aralarında üstel bir işleve sahiptir sonucuna varılır. Dolayısıyla, birinci otokorelasyon katsayısı da  $\rho_1$ , doğrudan model parametresi  $\phi$ 'ye eşittir.

$$\rho_1 = \phi \quad (4.8)$$

Aşağıda; bilgisayar ortamında benzetimi yapılan bir sistemin, model parametresi  $\phi$ 'yi gözlemlenen süreç arttıkça doğruya daha yakın bir şekilde kestirdiği gösterilmektedir.



**Şekil 4.1** : Gözlem süresi arttıkça, sistem parametresi  $\phi$ 'nin kestirim doğruluğu ve gerçek süreç değerleriyle ve belirlenen parametre yardımıyla tahmin edilen süreç değerlerinin karşılaştırılması



#### 4.1 AR(2) Model

$$z_t = \phi_1 z_{t-1} + \phi_2 z_{t-2} + a_t \quad (4.9)$$

Zaman serisi, kendinden bir ve iki zaman birimi önceki değerleriyle ve o andaki sistemi etkileyen gürültünün doğrusal birleşimi olarak ifade edilebiliyorsa sistem ikinci dereceden otoregresif modelle  $AR(2)$ , modellenabilir. Yukarıdaki denklemlerle verilen ikinci dereceden otoregresif sürecin her iki tarafını  $z_{t-k}$  ile çarpılıp, beklenen değer işlevini alınrsa sürecin  $k$ 'ncü zaman kaymasındaki otokovaryans ifadesi elde edilir.


$$\begin{aligned} E(z_t z_{t-k}) &= E(\phi_1 z_{t-1} z_{t-k} + \phi_2 z_{t-2} z_{t-k} + a_t z_{t-k}) \\ \gamma_k &= \phi_1 \gamma_{k-1} + \phi_2 \gamma_{k-2} \end{aligned} \quad (4.10)$$

Otokovaryans ifadesi, sıfırıncı zaman kaymasındaki terimine oranlanırsa otokorelasyon katsayısına ulaşılmış olur. Dolayısıyla; otokorelasyon katsayıları cinsinden elde edilecek Yule-Walker denklemleri aşağıdaki şekilde yazılabilir.

$$\begin{aligned} \rho_k &= \phi_1 \rho_{k-1} + \phi_2 \rho_{k-2} \\ \rho_1 &= \phi_1 + \phi_2 \rho_1 \\ \rho_2 &= \phi_1 \rho_1 + \phi_2 \end{aligned} \quad (4.11)$$

Yukarıdaki denklemlerin yardımıyla sistem için gerekli parametreler aşağıdaki şekilde hesaplanabilir.

$$\begin{aligned} \phi_1 &= \frac{\rho_1(1-\rho_2)}{1-\rho_1^2} \\ \phi_2 &= \frac{\rho_2 - \rho_1^2}{1-\rho_1^2} \end{aligned} \quad (4.12)$$



**Şekil 4.2 :** Gözlem süresi arttıkça, sistem parametreleri  $\phi_1$  ve  $\phi_2$ 'nin kestirim doğruluğu ve gerçek süreç değerleriyle ve belirlenen parametreler yardımıyla tahmin edilen süreç değerlerinin karşılaştırılması

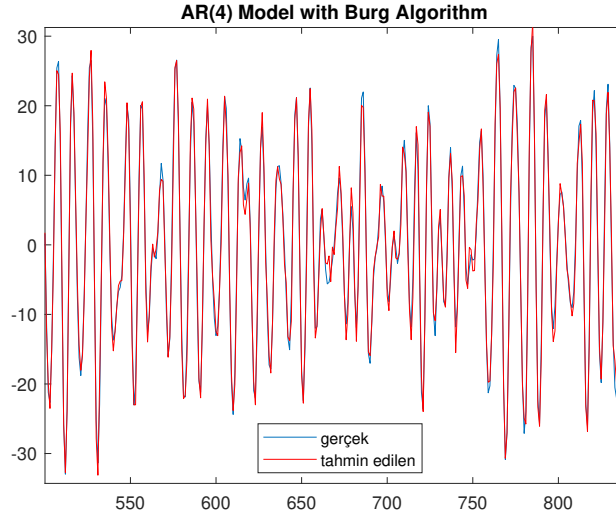
## 4.2 AR(p) Model

$$\begin{aligned} z_t &= \phi_1 z_{t-1} + \phi_2 z_{t-2} + \dots + \phi_p z_{t-p} + a_t \\ z_t &= \sum_{k=0}^p \phi_k z_{t-k} + a_t \end{aligned} \quad (4.13)$$

Süreç kendinden önce gelen  $p$  kadar önceki değerleriyle ilişkilidir. Dolayısıyla elde edilecek Yule-Walker denklemleri aşağıdaki şekilde hesaplanabilir.

$$\begin{aligned} \rho_1 &= \phi_1 \rho_0 + \phi_2 \rho_1 + \dots + \phi_p \rho_{p-1} \\ \rho_2 &= \phi_1 \rho_1 + \phi_2 \rho_0 + \dots + \phi_p \rho_{p-2} \\ &\vdots \\ \rho_p &= \phi_1 \rho_{p-1} + \phi_2 \rho_{p-2} + \dots + \phi_p \rho_0 \end{aligned} \quad (4.14)$$

Yukarıdaki doğrusal denklemleri kullanarak elde edilecek olan sistem parametrelerinin yardımıyla zaman serisi tahmini yapılır. Model derecesi  $p$ , arttıkça bu denklemlerin çözümlenmesi zor olacaktır. Dolayısıyla yenilemeli (recursive), yöntemlerden olan Levinson algoritması kullanılarak model parametreleri kestirilir.



Şekil 4.3 : Gerçek süreç değerleriyle ve belirlenen parametreler yardımıyla tahmin edilen süreç değerlerinin karşılaştırılması

## 4.3 MODEL DERECESİNİN BELİRLENMESİ

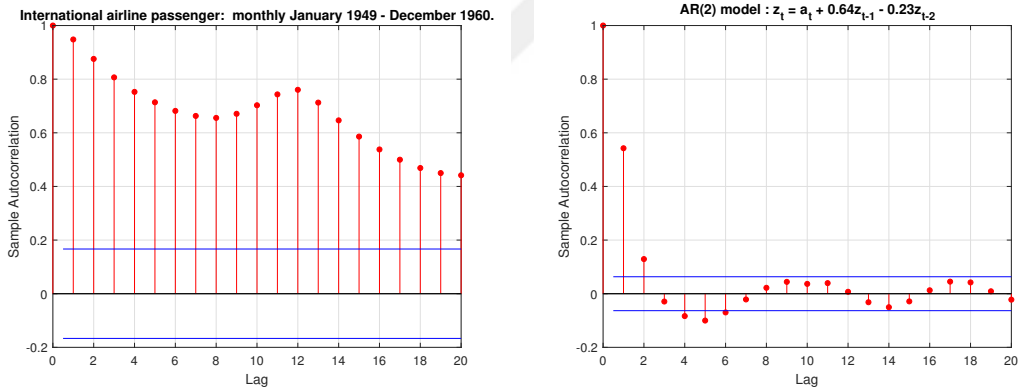
Modele ait parametreler kestirilmeden önce modele uygun derecelerin  $(p,q)$ , belirlenmesi ve bu derecelere uygun parametrelerin kestirilmesi gerekmektedir. Model derecesinin yetersiz olduğu durumlarda süreci gelecek zamanlar için takip edememe, gereğinden yüksek olduğu durumlarda incelenen ayrık data üzerinde aşırı uyma

(overfitting), sorunları ortaya çıkar. Bu tip sorunlardan kaçınmak ve model derecesinin en uygun şekilde belirlenebilmesi için sürece ait istatistiksel özelliklerden yararlanır.

### Otokorelasyon Fonksiyonu (ACF)

Otokorelasyon katsayıları sürece ait modelde yönelimi (trend)  $d$ 'yi, kayan ortalamalı modelde, model derecesi  $q$ 'yu, dönemsel zaman serileri üzerinde dönemsel bileşen  $s$ 'yi tespit etmek için kullanılır.

Sürecin herhangi bir zamandaki değeri ( $z_t$ ), kendisinden bir birim zaman öncesinde gelen değeri ( $z_{t-1}$ ), olduğu gibi eklenerek alırsa, sürecin anlık değeri ( $z_t$ ), bir zaman birimi önceki değeriyle ( $z_{t-1}$ ), yüksek oranda ilişkili durumda olur. İki zaman birimi önceki değeriyle ( $z_{t-2}$ ), de bir zaman birimi önceki değeri ( $z_{t-1}$ ), arasında yüksek ilişki olursa, doğal olarak sürecin şimdiki değeri ile ( $z_t$ ), iki zaman birimi öncesindeki değeri ( $z_{t-2}$ ), arasındaki bu yüksek ilişki devam edecektir. Otopregresif bir süreçten bu durumu ayıran özellik, otopregresif süreçte bu ilişkinin üstel olarak azalmasıdır. Aşağıdaki grafik bu farklılığı göstermektedir.



**Şekil 4.4 :** Yönelim olan (trended), bir zaman serisiyle otopregresif bir zaman serisinin otokorelasyonları arasındaki farklılık

Kayan ortalamalı model incelenirse,

$$z_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (4.15)$$

Yukarıdaki denklemin her iki tarafının serinin  $k$  zaman birimi kaymış ifadesiyle ( $z_{t-k}$ ), çarpılıp, beklenen değer işlevi  $E(\cdot)$ , uygulanırsa sürece ait  $k$  birim zaman kaymasına


ilişkin otokovaryans terimine ulaşılır.

$$\begin{aligned}
 E(z_t z_{t-k}) &= E(a_t z_{t-k}) - E(\theta_1 a_{t-1} z_{t-k}) - E(\theta_2 a_{t-2} z_{t-k}) - \dots - E(\theta_q a_{t-q} z_{t-k}) \\
 \gamma_k &= \begin{cases} (-\theta_k + \theta_1 \theta_{k+1} + \theta_2 \theta_{k+2} + \dots + \theta_{q-k} \theta_q) \sigma_a^2, & k = 0, 1, \dots, q \\ 0, & k > q \end{cases} \\
 \gamma_0 &= (1 + \theta_1^2 \theta_k + \theta_2^2 \theta_{k+2} + \dots + \theta_q^2) \sigma_a^2
 \end{aligned} \tag{4.16}$$

Otokorelasyon teriminde otokovaryansın her bir teriminin sıfıncı otokovaryansa oranıdır. Dolayısıyla bütün zaman serilerinde sıfıncı otokorelasyon her daim 1'e eşit olacaktır. Kayan ortalamalı modelde zaman kayması  $k$ , model derecesi olan  $q$ 'yu geçtiği anda otokorelasyon fonksiyonunun terimini sıfıra indirgeyecektir .

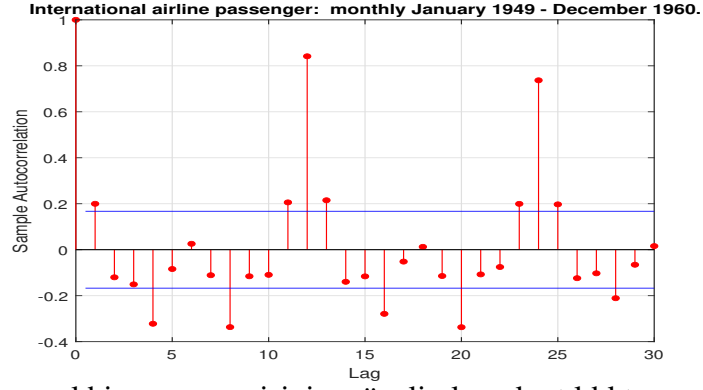
$$\rho_k = \begin{cases} \frac{-\theta_k + \theta_1 \theta_{k+1} + \theta_2 \theta_{k+2} + \dots + \theta_{q-k} \theta_q}{1 + \theta_1^2 \theta_k + \theta_2^2 \theta_{k+2} + \dots + \theta_q^2}, & k = 0, 1, \dots, q \\ 0, & k > q \end{cases} \tag{4.17}$$

Otoregresif süreçle kayan ortalamalı süreci birbirinden ayıran bu özellik sayesinde eldeki kayan ortalamalı zaman serisinin kaçınıcı dereceden kayan ortalamalı sürece ait olduğu tespit edilir. Aşağıdaki grafikte bu durum gösterilmektedir.



**Şekil 4.5 :** Otoregresif bir zaman serisiyle kayan ortalamalı bir zaman serisinin otokorelasyon katsayıları arasındaki farklılık

Otokorelasyon fonksiyonu incelenerek dönemsel olarak gelen zaman serilerinin de model dereceleri kestirilebilir. Otokorelasyon katsayıları dönem parametresi olan  $s$  periyotta bir benzer özellik gösterecektir. Aşağıdaki grafikte bu durum gösterilmektedir. Her 12 zaman örneğinde bir kendini tekrar eden otokorelasyon özelliği gözlemlendiğinden dönem parametresi  $s$ , 12 olarak belirlenir. Her dönemsel periyotta bir zaman kaymasından sonra otokorelasyon katsayısı sıfıra indirgeendiği için de, dönemsel kayan ortalama derecesi  $Q$  da 1 olarak belirlenebilir.




**Şekil 4.6 :** Dönemsel bir zaman serisinin, yönelimler çıkartıldıktan sonra (detrended) oluşan otokorelasyon katsayıları

### Kısmi Otokorelasyon Fonksiyonu (PACF)

Kısmi otokorelasyon katsayıları  $\Phi_{kk}$ , sürecin yakın zaman kaymalarıyla olan ilişkilerini inceler. Otoregresif bir sürecin otokorelasyonları üzerinden tanımlanabilir. Otokorelasyon katsayılarının Yule Walker denklemlerini sağlamasından dolayı kısmi otokorelasyon katsayıları ve otokorelasyon katsayıları kullanılarak buna uygun bir denklem sistemi yazılabilir.  $\Phi_{kj}$ ,  $k$ 'nci dereceden otoregresif bir sürecin  $j$ 'inci model parametresi olmak üzere, aşağıdaki gibi Yule-Walker denklemi yazılabilir.

$$\rho_j = \Phi_{k1}\rho_{j-1} + \Phi_{k2}\rho_{j-2} + \dots + \Phi_{k(k-1)}\rho_{j-k+1} + \Phi_{kk}\rho_{j-k} \quad (4.18)$$

Yukarıdaki eşitlikten de anlaşılacağı üzere model derecesi  $p$  olan otoregresif sürecin, kısmi otokorelasyon katsayısı  $\Phi_{kk}$ ,  $k$ 'nın model derecesi  $p$ 'den büyük değerleri için 0'a eşit olacaktır. Bu özellik yardımıyla otoregresif model kayan ortalamalı modelden ayrılmakta ve otoregresif model derecesi  $p$  kısmi otokorelasyon katsayıları üzerinden belirlenebilmektedir.



**Şekil 4.7 :** Otoregresif bir zaman serisiyle kayan ortalamalı bir zaman serisinin kısmi otokorelasyon katsayıları arasındaki farklılık

### Akaike Bilgi Ölçütü (AIC)

Akaike Bilgi Ölçütü model derecesi belirlemede kullanılan ve en kesin sonucu veren metottur. Model derecesinin gereğinden düşük belirlenmesi durumunda, tahmin edilen zaman serisinin daha düşük çözünürlükte olmasına sebebiyet verir. Gereğinden fazla model derecesinin belirlenmesi durumunda ise işlem maliyetini artırır ve gerekenden daha yavaş bir şekilde modelin kestirilmesine neden olur. Otokorelasyon ve kısmi otokorelasyon katsayıları kullanılarak model derecesi belirlenen tamamen otoregresif veya tamamen kayan ortalamalı modellerde, Akaike Bilgi Ölçütünün kullanılması da aynı model derecesini verir. Ancak otoregresif kayan ortalamalı bir sistemin otokorelasyon ve kısmi otokorelasyon katsayılarına bakıldığında, kısmi otokorelasyon katsayıları kayan ortalamalı bir sürecin kısmi otokorelasyonu gibi davranış gösterir. Otokorelasyon katsayılarına bakarak da model dereceleri  $p$  ve  $q$  kesin bir şekilde kendini belli etmemektedir.


Akaike Bilgi Ölçütü, belirlenen modeldeki derecelerin toplamı  $k$ , modelin benzerlik işlevinin maksimum değeri  $L$  ve doğal tabanda logaritma işlevi  $\log(\cdot)$  olmak üzere aşağıdaki şekilde tanımlanır. Her bir model için benzerlik fonksiyonu hesaplamak karmaşık olacağı için benzerlik fonksiyonu, hata kovaryans matrisinin determinantı olarak da alınabilir. Akaike Bilgi ölçütünün en düşük olarak hesaplandığı  $p$  ve  $q$  parametreleri, sistem için uygun olan model derecelerini belirtir.

$$AIC = 2k - 2\log(L) \quad (4.19)$$

Aşağıdaki tabloda  $ARMA(2,1)$  olarak modellenen zaman serisinin farklı model parametreleri kullanılarak elde edilen ortalama hataların karesi ve hesaplanan Akaike Bilgi Ölçütleri gösterilmektedir. Şekillerde ise kestirim performansı gösterilmektedir. Hataların ortalama karesi model parametresi arttıkça azalma gösterebilir ancak gereğinden fazla eklenen model parametresi hesaplama karmaşıklığının artmasına ve sistemin daha yavaş çalışmasına sebebiyet verir.

**Çizelge 4.1** : Farklı model derecelerine ait AIC ve hata karelerinin toplam değerleri

p	q	Hataların Karesi	AIC
1	1	5.4598	9.3948
2	1	0.973	7.9453
3	1	40.712	17.4131
1	2	5.4598	11.3948



**Şekil 4.8** : ARMA(2,1) modele ait sistemin farklı model dereceleriyle olan kestirimlerinin karşılaştırılması

#### 4.4 İKİLİ ZAMAN SERİLERİ VE LOGIT MODEL

Spektrumda ölçüm alınan zamana göre, kullanıcının var veya yok bilgisinin (0/1), bir süreç içerisinde tutulması sonucunda ikili zaman serileri elde edilmiş olur. Bu bilgilerin kullanılarak uygun doğrusal model yardımıyla spektrumda gelecek zaman birimlerinde kullanıcı varlığının tespiti yapılmaya çalışılır.

Bir sonraki zaman aralığında gözlemlenen spektrum bölmesine ait kullanıcının var olma olasılığı Sigmoid dönüşümü kullanılarak hesaplanır. İkili zaman serilerinde sistemi etkileyen gürültü sıfır ortalamalı,  $\pi^2/3$  varyanslı logistik dağılıma sahiptir. Bağlantı fonksiyonu olarak tanımlanan Sigmoid fonksiyonu da bu dağılıma ait birikimli olasılık dağılım fonksiyonudur. İkili zaman serileri oluşturulurken sürecin

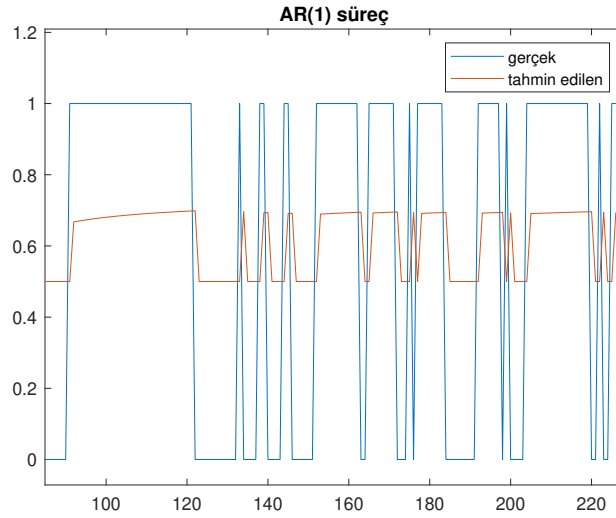
gerçek değerleri önce bu fonksiyondan geçirilir, ardından belirli bir eşik değeri uygulanarak ikili zaman serisi elde edilir.

$$F(x) = \frac{1}{1 + e^{-x}} \quad (4.20)$$

Elde edilen ikili zaman serisi için uygun olan doğrusal model belirlendikten sonra gelecek zaman aralığında kullanıcının var olma olasılığı ikili zaman serisinin değerleri kullanılarak hesaplanır. Burada  $p$  belirlenen otoregresif modelin derecesini,  $S_t$   $t$  anındaki ikili zaman serisinin mevcut değerini ve  $\phi_k$   $k$ 'inci model parametresini belirtmektedir.

$$P(S_{t+1} = 1) = \frac{1}{1 + e^{-(\sum_{k=0}^p \phi_k S_{t-k})}} \quad (4.21)$$

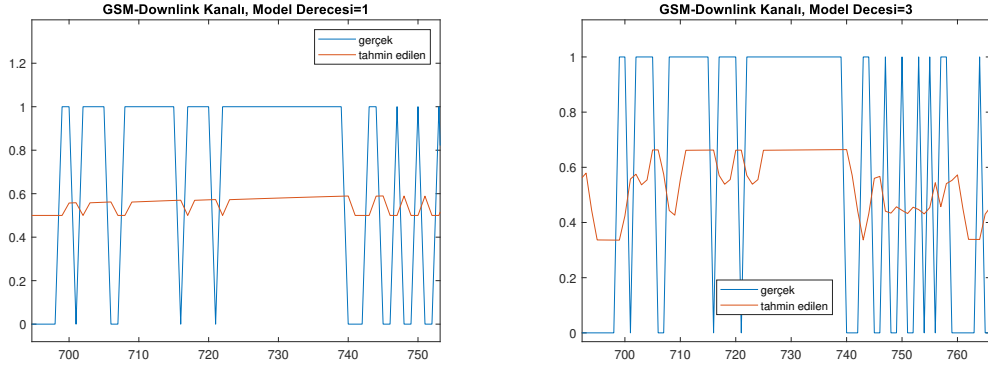
Bu yaklaşımla elde edilen birinci dereceden otoregresif süreçten çıkartılan ikili zaman serisi ve kestirim performansı aşağıdaki grafikte verilmiştir. Grafikten de anlaşılacağı üzere model geçiş noktalarını düzgün takip edememektedir.



**Şekil 4.9** : AR(1) modele ilişkin logit modelin performansı


Aynı şekilde GSM downlink kanalına ait ölçümlere ilişkin iki farklı model derecesindeki kestirim performansı aşağıdaki grafiktedir. Aynı şekilde model sürecin değişim noktalarını tespit edememekte ve performansı birinci dereceden Markov sürecinin performansını geçememektedir.





**Şekil 4.10** : GSM downlink kanalına ilişkin farklı model otoregresif model derecelerine ait kestirimlerin karşılaştırılması

Yukarıdaki GSM bandına ait kestirimlere ait şekillerde alınan verinin dakikada 1 ölçüm olacak şekilde alınması veri çözünürlüğünü kötü etkilemiştir. Dolayısıyla hem doğrusal modelin yetersizliği hem de mevcut verinin yetersizliğinden dolayı sistem performansı birinci dereceden Markov durumunun performansını geçememektedir ve işareti bir zaman kayması geriden takip edebilmektedir. Aşağıda daha sıkı zaman aralıklarında örneklenen telsiz kanalına ilişkin doğrusal modelle yapılan kestirim grafiği bulunmaktadır.



**Şekil 4.11** : Telsiz kanalından alınan verilerle yapılan kestirim

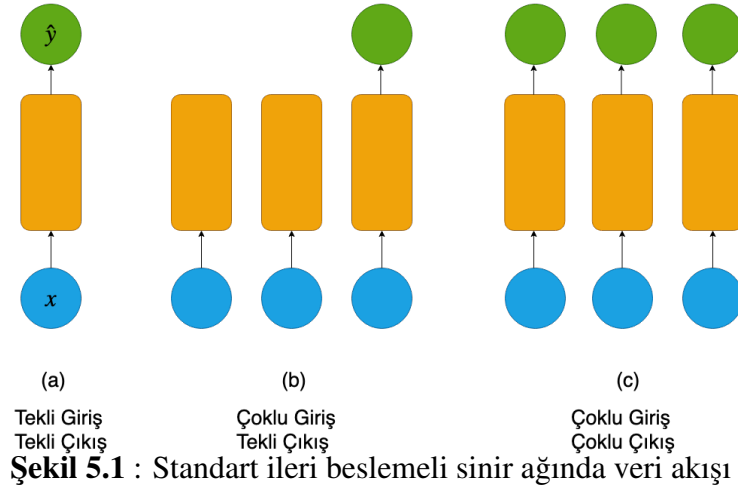


## 5. LSTM

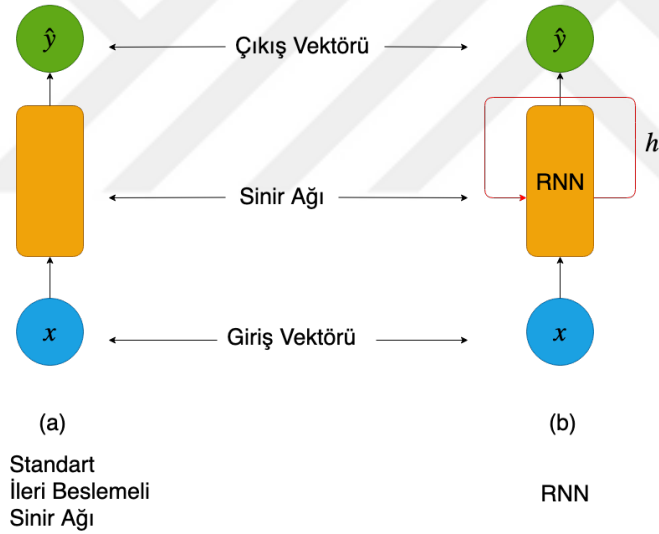
LSTM yapısının ve işlevlerinin özelliklerinden önce tahmin işlemlerinin ve hafıza yapısının nasıl çalıştığı hakkında örnek olması bakımından basit bir durum incelenir. İstenen kestirim, ekranda beliren bir topun nereye gideceği hakkında tahmin yapılmasıdır. Topun geçmişteki hareketlerinden herhangi bir bilgi sahibi olmadan bir sonraki adımda nereye yöneleceği hakkında tahmin yapmak oldukça zor ve belirsiz olacaktır. Fakat bu topun bir kaç adım önceki durumları bilirse yapılmaya çalışılacak olan tahminler daha da kolaylaşacaktır. Örneğin; topun her 3 saniyede bir yer değiştirdiği son örneklerden algılanabilirse ve topun en son hareketi 1 saniye önce gerçekleşmişse, 1 veya 2 saniye sonraki durumu için yapılacak olan tahmin yine aynı yerde olacağı yönünde olur. Aynı şekilde topun her 15 saniyede gideceği yönü belli bir açıda ve örüntüde değiştirdiği geçmişteki hareketleri gözlemlenerek öğrenilirse bulunulan zamandan daha ileriki zamanlarda nerede olacağını tahmini daha da kolaylaşacaktır. Bu arada topun hareketlerinin çok kısa zaman aralıklarında alınması gerekenden fazla veri içermesi modelin hafızasını doldurarak işlemleri zorlaştıracaktır. Bu yüzden topun hareketi hakkında alınacak verinin çözünürlüğünün de önemi oldukça fazladır.

### 5.1 Yinelemeli Sinir Ağları(RNN)

Standart ileri beslemeli sinir ağında data girdiden çıktıya doğru tek yönlü hareket eder. Veriler modele girildikçe model kendini eğitir ve sonuç üretmeye başlar. Gelen veriler oldukça da geçmişteki verileri ve tahmin ettiği değerleri unuttur.



RNN’de buna ek olarak modelin yaptığı tahminler ve geçmişte girilen veriler döngüyle birlikte tekrardan modele girdi olarak yeni veriler ile birlikte verilir ve sistemin geçmişini unutmaması sağlanır. RNN seri üzerinde işlem yapıp, çıktı için tahmin yapabilmek için bu yenileme bağlantısını  $h_t$ , kullanır.



Sistem, içinde bulunulan zaman adımında girdi olarak verilen veriyi ve bir önceki bağlantı işlevini de kullanarak yineleme bağlantı işlevini üretir.

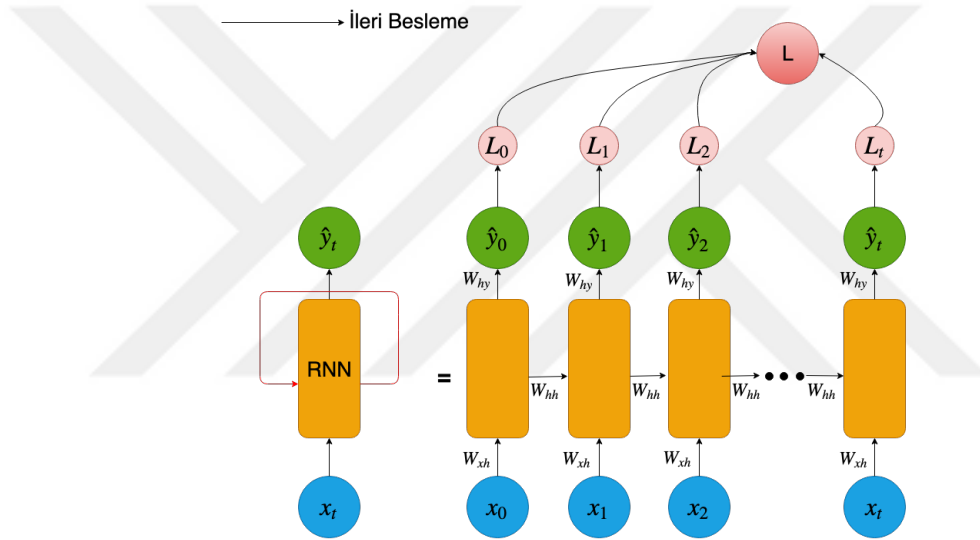
$$h_t = f_w(h_{t-1}, x_t) \quad (5.1)$$

Daha ayrıntılı olarak incelenecek olursa gizli durumda olan yinelemeli bağlantı fonksiyonu,  $W_{hh}$  olarak belirlenen ağırlık matrisiyle önceki işlevin ve girdilerle ağırlık girdiye ait ağırlık matrisi  $W_{xh}$ ’in çarpımlarının doğrusal olmayan bir işlevle tanh,

işleme sokulmasını içerir. Elde edilen bu bağlantı işlevinin çıktıya ait başka bir ağırlık matrisiyle çarpımından sonuç üretilir.

$$\begin{aligned} h_t &= \tanh(W_{hh}h_{t-1} + W_{xh}x_t) \\ y_t &= W_{hy}h_t \end{aligned} \quad (5.2)$$

RNN yapısı zaman eksenini boyunca açılırsa birbirini takip eden sinir ağının düğümleri görülür. Bu yüzden seri olarak gelen verilerin işlenilip sonuç üretmesi için uygun modeldir. Burada girdi, çıktı ve yineleme işleviyle çarpılan ağırlık matrisleri her düğümde aynıdır. Her bir zaman adımında sistemin ürettiği çıktılardan kayıp işlevi hesaplanır. Toplam kayıp işlevinin de her bir kayıp işlevinin toplamıyla hesaplanır. Toplam kayıp işlevi zaman adımları boyunca her bir kayıp işlevinin toplamı olarak tanımlandığından, oluşturulan öğrenme modeli zaman bileşeni de içermelidir.



Şekil 5.3 : RNN yapısının zaman eksenini boyunca gösterimi


## 5.2 Model Eğitime

Spektrumun birincil kullanıcılar tarafından nasıl bir karakteristikte kullanıldığı öğrenilip gelecek hakkındaki kullanım tahminlerinin yapılabilmesi için;

- Spektrumu kullanımına ait seri kümesinin veri çözünürlüğünün uygun şekilde sağlanması
- Uzun döneme ait hareketin takibinin olması
- Model derecesi ve parametrelerinin sürekli olarak güncel tutulması
- Veri alındıkça öğrenilen parametrelerin seri ve tahmin modeli arasında sürekli paylaşılması gerekmektedir.

### 5.2.1 Zaman Ekseninde Geriye Yayılma


Öncelikli olarak modele ileri beslemeli olarak girdiler verilir. Ardından geriye yayılım için(backpropagation) çıkışta oluşan kayıp işlevinin her parametreye göre türevi alınır. Kaybı azaltmak için eldeki parametreler kesme uygulanır(shift-tweaking). Zaman eksenini boyunca her bir hücre için eldeki hatalar sistemin başlangıcına kadar kaydırılır.



Sistemden de anlaşılacağı üzere yinelemeli bağlantı fonksiyonunun  $h_t$ ,  $t = 0$  zamanındaki durumuna kadar gradient hesaplaması bir sürü  $W_{hh}$  ile matris çarpımı gerektirmektedir. Matris çarpım işlemlerinin sonucu birden büyük olduğu durumda ilk duruma gelene kadar olan işlemler exploding gradient sorunu oluşturacaktır. Gradient değerleri bu şekilde toplanarak geldiğinde çok büyük değerler alırsa iyileştirme yapılamaz hale gelmektedir. Bu sorunun üstesinden gelebilmek için eldeki sonuçları her bir zaman adımında kontrol edilerek tekrardan ölçeklendirilir. Aynı şekilde matris çarpım değerleri çok küçük olursa da, vanishing gradient sorunu oluşacaktır.

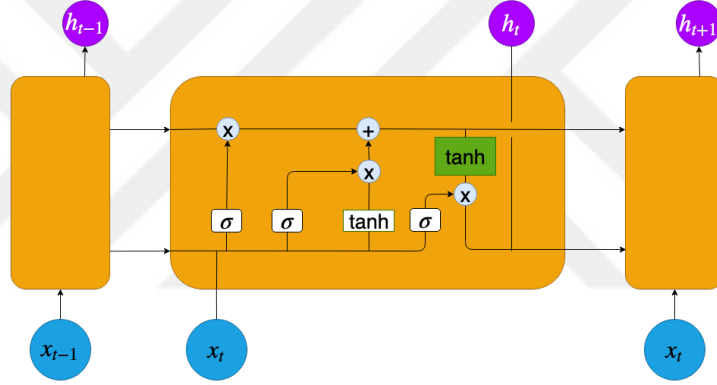
Vanishing gradient in sebebi çok küçük sayıların birbirleriyle sürekli çarpılmasıdır. Dolayısıyla başlangıç durumuna gelene kadar sonucu etkileyen hatanın etkisi kaybolmaya başlar. Böylece sistem oluşacak hatayı gözardı ederek sürekli yanlış sonuçlar üretecektir. Bu sorunun üstesinden gelebilmek için de modele ait aktivasyon fonksiyonu değiştirilebilir, ağırlık değerleri tekrardan oluşturulabilir ya da ağ yapısı değiştirilebilir(LSTM).

## 5.2.2 LSTM'in Yapısı



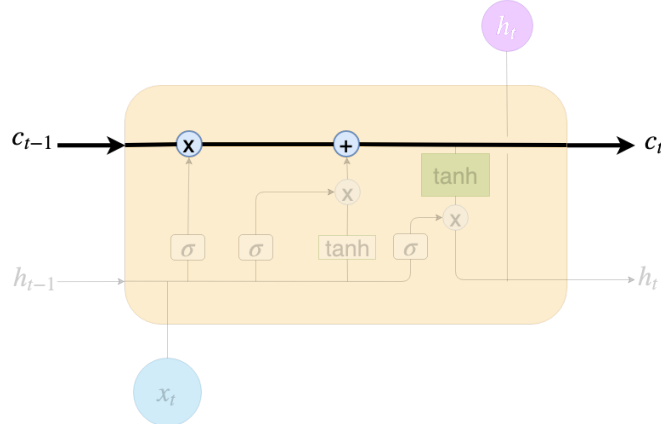
Şekil 5.5 : RNN'in iç yapısı

Standart bir RNN yapısı zaman eksenini boyunca yinelenen ve sadece basit bir hesaplama işlemi yapan  $\tanh$ , modüller içerir.




Şekil 5.6 : LSTM'in iç yapısı

LSTM'de de buna benzer bir yapı bulunmaktadır ancak yinelenen modüllerin yapısı RNN'e göre daha karmaşıktır. LSTM hücreleri içinde bulunan bu yapılar sayesinde zaman akışı boyunca bilgiyi takip edip hafızasında tutabilir. Bu sayede LSTM modülünün içerisindeki birbirlerini etkileyen katmanlar arasındaki bilgi akışı kontrol altında tutulur.



**Şekil 5.7** : dahili hücre durumu

LSTM yapısının içindeki ilk değişiklik dahili hücre durumudur,  $c_t$ . Bu dahili hücre durumu yineleyen modüller arasında birbirlerine aktarılır ve hücre durumunu güncelleyen toplama ve çıkarma işlemlerinden oluşur.



**Şekil 5.8** : Kapı

LSTM'in kullandığı ikinci değişiklik hücre durumundan bilgiyi çıkartan veya ekleyen kapılardır. Kapılar sigmoid sinir ağı katmanı ve çarpım işleminden oluşur. Sigmoid, bilginin kapıdan geçmesini veya geçmemesini sağlayan 0'la 1 arasında değer alan işlevdir. LSTM ağı boyunca bilgi akışını düzenler. Bilginin ne kadarının içeriye geçeceğine karar verir. 0 olduğunda bilginin kapıdan içeriye geçmesini engeller, 1 olduğunda bilginin tamamının içeriye geçmesini sağlar.

### 5.2.3 LSTM'in Çalışması

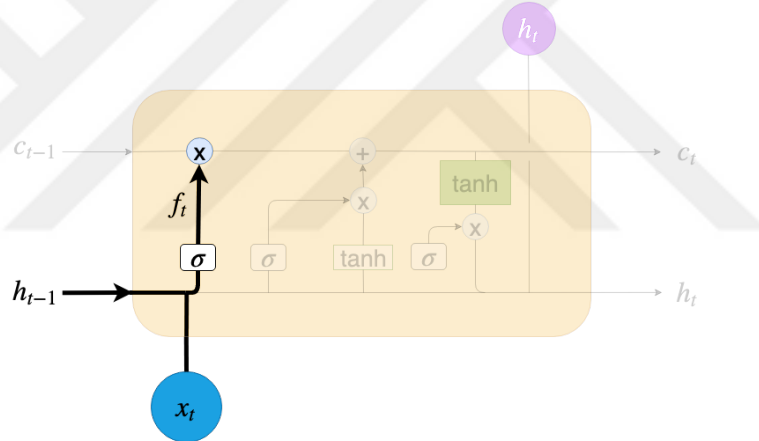
LSTM'in çalışma prensibi üç gruba ayrılır. İlk olarak önceki hücre durumundan ne kadarlık bir bilginin geçeceğine karar verilir ve içinde bulunulan zaman dilimiyle ilgili olmayan bilgilerin geçişi engellenir. İkinci adım, önceki durumdan gelen



bilgi ve girdinin seçilerek belirli işlemlerden geçmesiyle dahili hücre durumunun güncellenmesidir. Son adım ise değiştirilen hücre durumu ve ağa giren yeni bilginin kullanılarak çıktı üretilmesidir.

İlk aşamada yapılması gereken hangi geçmiş durumların sistemin içinde bulunduğu durumla ilgisi olup olmadığını belirlemektir. Bunu sigmoid kapısını yani unutma işlevini  $f_t$ , kullanarak yapar. Unutma işlevi parametrelerini sistemin hangi duruma ne kadar meyilli olacağını belirleyen ağırlık değerlerinden oluşturur. Bu katman önceki modülden gelen bilgiyi  $h_{t-1}$ , ve sisteme o anda verilen girdiyi  $x_t$ , kullanarak 0'la 1 arasında çıktı üretir. 0 üretmesi önceden gelen bilginin tamamen unutulması, 1 üretmesi önceki bilginin tamamen kullanılması anlamına gelir.

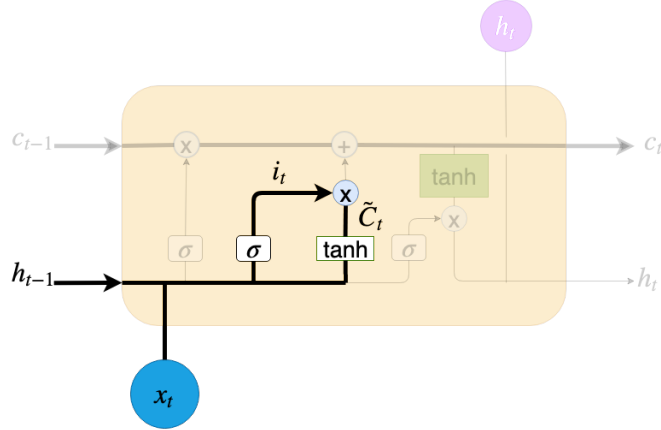
$$f_t = W_f \cdot \sigma(h_{t-1}, x_t) + b_f \quad (5.3)$$



**Şekil 5.9** : Önceki hücre durumundan gelen bilginin unutma kapısından geçişi

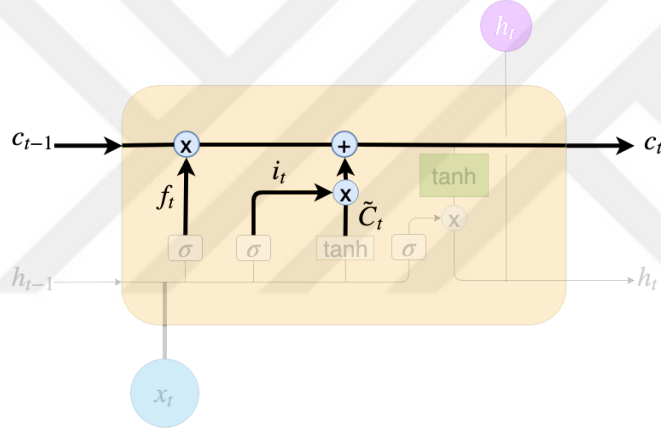
İkinci aşama sisteme yeni gelen bilginin güncellenen hücre durumunda depolanması ve sistem için gerekli asıl güncellemelerin yapılmasıdır. Bu işlemi iki adımda yapılmaktadır. İlki hangi değerlerin güncelleneceğini belirleyen sigmoid işlevidir. İkincisi duruma eklenmesi muhtemel aday değerleri içeren yeni vektörü üreten  $\tanh$  işlevidir.

$$\begin{aligned} i_t &= \sigma(W_i(h_{t-1}, x_t) + b_i) \\ \tilde{c}_i &= \tanh(W_c(h_{t-1}, x_t) + b_c) \end{aligned} \quad (5.4)$$



Şekil 5.10 : Dahili hücre durumuna eklenecek aday bilginin belirlenmesi


$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (5.5)$$



Şekil 5.11 : Dahili hücre durumunun güncellenmesi

Dahili hücre durumu güncellemesi için, bir önceki dahili hücre durumuna unutma işlevi uygulanır ve eklenmesi muhtemel aday değer ne kadarının güncellemeye gireceği tespit edilir. Elde edilen iki değer toplamından da dahili hücre durumu güncellenir.

Son aşama sistemin hücre durumunu üretmesidir. Bir önceki hücre durumuna uygulanan sigmoid işleviyle, eski durumla birlikte gelen yeni girdinin yeni durumu ne kadar etkileyeceği belirlenir. Daha önce güncellenen dahili hücre durumu tanh işlevinden geçirilir. Elde edilen iki değer çarpımından da hücre durumu üretilir.



Şekil 5.12 : Hücre durumunun çıktı olarak üretilmesi


$$\begin{aligned} o_t &= \sigma(W_o(h_{t-1}, x_t) + b_o) \\ h_t &= o_t * \tanh(C_t) \end{aligned} \quad (5.6)$$

Sistemi optimize etmek için kurulan yapı geriye doğru yayılım yaptığında dahili hücre durumları arasında geçiş yaptığında,  $c_t$  durumundan  $c_{t-1}$  durumuna giderken, sistem sadece çarpma ve toplama işleminden geçer. Hücre durumu, dahili hücre durumundan ayrıldığı için matris çarpımına ihtiyaç olmayacaktır. Bu sayede vanishing gradient sorunu yaşamayacaktır.


Sonuç olarak LSTM yapısı çalışma prensibi aşağıda sıralanmıştır.

1. Hücre çıkışı olarak dahili hücre durumunun ve dahili hücre durumunun ayrı olarak üretilmektedir.
2. Bilgi akışının kontrolü kapılar kullanılarak yapılır.
  - Unutma kapısı gereksiz bilginin geçişinin engeller.
  - Hücre durumu gelen bilgilerden seçmeli olarak güncellenir.
  - Çıkış kapısı hücre durumunun filtrelenmiş sonucunu üretir.
3. Dahili hücre durumları arasındaki geriye doğru yayılım, matris çarpımları gerektirmediğinden vanishing gradient sorunu oluşmaz.

Aşağıda LSTM kullanılarak telsiz verisi üzerinde tahmin edilen sonuçlar ve orijinal değerler gösterilmiştir. Epoch (öğrenme turu) sayısı arttıkça kayıp işlevinin azaldığı aşağıdaki grafikte görülmektedir.



**Şekil 5.13 :** Orjinal veri ile tahmin edilen verinin karşılaştırılması



**Şekil 5.14 :** Epoch-kayıp işlevi

## 6. SONUÇ VE ÖNERİLER

Bu çalışmada bilişsel radyo teknolojilerinde kullanılan spektrumdaki işaretlerin tespiti ve spektrumun kullanımının tahmin modellerine ilişkin araştırmalar yapılmıştır.

Birincil kullanıcının varlığının tespiti için kullanılan yöntem olan enerji seziciler, gerek maliyeti, gerekse hesaplama işlemlerinin kolaylığı ve hızı bakımından kullanılabilir yöntemler arasında akla ilk gelendir. Gözlemlenen spektrum bölmesindeki işarete ait önceden bir bilgi gerektirmemesi de enerji sezicileri kullanmayı cazip hale getirmektedir. Ancak benzetim sonuçları ve gerçek ölçümlere dayalı yapılan testlerde ortamda bulunan gürültünün karakteristiğinin kesin olarak bilinmemesinden dolayı sistem performansı ciddi oranda azalmaktadır.

Spektrumda gözlemlenen işaretin bir taşıyıcı işaretle modüle edilerek gönderilmesinden dolayı ortaya çıkan işarete ait çevrimsel durağanlık özelliği işaretin tespitinde kolaylık sağlamaktadır. İşareti etkileyen gürültünün bu özelliği göstermemesinden dolayı spektrumda kullanıcıya ait olan işaretler gürültüden bağımsız olarak tespit edilebilmektedir ve enerji sezicilere göre daha iyi performans göstermektedir. Ayrıca spektral korelasyon işlevinde ortaya çıkan ayırt edici yükseklikler sinyallerin hangi taşıyıcı frekansta ilerlediği veya hangi modülasyon tipine ait olduğu hakkında bilgiler de içermektedir. Dolayısıyla çevrimsel durağanlık özelliği sadece kullanıcıya ait işaretlerin tespitinde değil, aynı zamanda kablosuz spektrumdaki işaretin sınıflandırılmasında da kullanılmaktadır. Bu özelliği bakımından da enerji sezicilere göre daha üstündür.

Kullanım verisi elde edilen frekans bölmesi üzerinde yapılacak olan tahmin yöntemleri üzerinde de çalışılmıştır. Doğrusal modellerle ilgili olarak yapılan işlemler hızlı ve basittir. Ancak kullanım durumu çok hızlı değişen frekans bantlarının takibinde yetersiz kalmaktadır.

LSTM modelleri ise doğrusal modellere göre daha iyi sonuçlar üretmekte ve frekans bantlarının kullanımını daha iyi kestirebilmektedir. Ancak sistemin veriyi öğrenmesi

uzun sürmekte ve üzerinde çalışabilmesi için çok veriye ihtiyaç duymaktadır. İşlem maliyetinin ve hesaplama karmaşıklığının fazla olması olumsuz özelliklerinden sayılabilir. LSTM modelini kullanırken dikkat edilmesi gereken hususlar vardır. Çıkışta istenen sonuca göre optimize edilmesi gerekir. Ayrıca fazla öğrenme döngüsü çalıştırıldığında model aşırı öğrenmeye (overfitting), maruz kalacaktır. Verinin tamamını ezberleyecek ve farklı bir veri tipi geldiğinde yanlış sonuç üretecektir.

Haberleşme teknolojilerinin gelişmesiyle birlikte spektrumdaki işaretlerin çeşitliliği de artmaktadır. Dolayısıyla, frekans bölmeleme işlemi yapılırken incelenen alandaki işaretlerin bant genişliği, zamanda kesik kesik gitmesi veya frekans uzayında atlama yapması gibi özellikleri yan frekans bölmeleriyle olan ilintisini arttırmaktadır. Buna uygun olacak şekilde ölçümlerin alınması ve elde edilen verilerin işlenmesi de önemlidir. Aksi takdirde yapılacak olan işlemler ve oluşturulan modeller elde edilecek olan veriyi öğrenmede yetersiz kalacaktır ve hatalı sonuçlar çıkartacaktır. Ayrıca spektrumdaki kullanım durumunun 0 ile 1'e haritalanması elde edilen verinin çözünürlüğünü düşürmekte, model oluştururken eksik bilgiyle modelin kurulmasına ve modelin bu kısıtlanmış veri üzerinde çalışırken yanlış karar vermesine sebep olmaktadır.

## KAYNAKLAR

- [1] **Mitola, J., Maguire, G.Q. ve diğ erleri** (1999). Cognitive radio: making software radios more personal, *IEEE personal communications*, 6(4), 13–18.
- [2] **Yucek, T. ve Arslan, H.** (2009). A survey of spectrum sensing algorithms for cognitive radio applications, *IEEE communications surveys & tutorials*, 11(1), 116–130.
- [3] **Akyildiz, I.F., Lee, W.Y., Vuran, M.C. ve Mohanty, S.** (2008). A survey on spectrum management in cognitive radio networks.
- [4] **Subhedar, M. ve Birajdar, G.** (2011). Spectrum sensing techniques in cognitive radio networks: A survey, *International Journal of Next-Generation Networks*, 3(2), 37–51.
- [5] **Ariananda, D., Lakshmanan, M. ve Nikookar, H.** (2009). A survey on spectrum sensing techniques for cognitive radio, *2009 Second International Workshop on Cognitive Radio and Advanced Spectrum Management*, IEEE, s.74–79.
- [6] **Akyildiz, I.F., Lo, B.F. ve Balakrishnan, R.** (2011). Cooperative spectrum sensing in cognitive radio networks: A survey, *Physical communication*, 4(1), 40–62.
- [7] **Zeng, Y., Liang, Y.C., Hoang, A.T. ve Zhang, R.** (2010). A review on spectrum sensing for cognitive radio: challenges and solutions, *EURASIP journal on advances in signal processing*, 2010(1), 381465.
- [8] **Sun, H., Nallanathan, A., Wang, C.X. ve Chen, Y.** (2013). Wideband spectrum sensing for cognitive radio networks: a survey, *IEEE Wireless Communications*, 20(2), 74–81.
- [9] **Urkowitz, H.** (1967). Energy detection of unknown deterministic signals, *Proceedings of the IEEE*, 55(4), 523–531.
- [10] **Cabric, D., Tkachenko, A. ve Brodersen, R.W.** (2006). Experimental study of spectrum sensing based on energy detection and network cooperation, *Proceedings of the first international workshop on Technology and policy for accessing spectrum*, ACM, s. 12.
- [11] **Cabric, D., Tkachenko, A. ve Brodersen, R.W.** (2006). Spectrum sensing measurements of pilot, energy, and collaborative detection, *MILCOM 2006-2006 IEEE Military Communications conference*, IEEE, s.1–7.

- [12] **Zhang, W., Mallik, R.K. ve Letaief, K.B.** (2009). Optimization of cooperative spectrum sensing with energy detection in cognitive radio networks, *IEEE transactions on wireless communications*, 8(12), 5761–5766.
- [13] **Zeng, Y., Liang, Y.C. ve Zhang, R.** (2008). Blindly combined energy detection for spectrum sensing in cognitive radio, *IEEE Signal Processing Letters*, 15, 649–652.
- [14] **Zeng, Y. ve Liang, Y.C.** (2009). Eigenvalue-based spectrum sensing algorithms for cognitive radio, *IEEE transactions on communications*, 57(6), 1784–1793.
- [15] **Liu, Y., Zeng, C., Wang, H. ve Wei, G.** (2010). Energy detection threshold optimization for cooperative spectrum sensing, *2010 2nd International Conference on Advanced Computer Control*, cilt 4, IEEE, s.566–570.
- [16] **Plata, D.M.M. ve Reátiga, Á.G.A.** (2012). Evaluation of energy detection for spectrum sensing based on the dynamic selection of detection-threshold, *Procedia Engineering*, 35, 135–143.
- [17] **Atapattu, S., Tellambura, C. ve Jiang, H.** (2011). Energy detection based cooperative spectrum sensing in cognitive radio networks, *IEEE Transactions on wireless communications*, 10(4), 1232–1241.
- [18] **Ling, X., Wu, B., Wen, H., Ho, P.H., Bao, Z. ve Pan, L.** (2012). Adaptive threshold control for energy detection based spectrum sensing in cognitive radios, *IEEE Wireless Communications Letters*, 1(5), 448–451.
- [19] **Hayes, M.H.** (2009). *Statistical digital signal processing and modeling*, John Wiley & Sons.
- [20] **Box, G.E., Jenkins, G.M., Reinsel, G.C. ve Ljung, G.M.** (2015). *Time series analysis: forecasting and control*, John Wiley & Sons.
- [21] **Kedem, B. ve Fokianos, K.** (2005). *Regression models for time series analysis*, cilt488, John Wiley & Sons.
- [22] **Das, S.** (1994). *Time series analysis*, Princeton University Press, Princeton, NJ.
- [23] **Priestley, M.B.** (1981). *Spectral analysis and time series*, cilt 1, Academic press London.
- [24] **Cox, D.R.** (1958). The regression analysis of binary sequences, *Journal of the Royal Statistical Society: Series B (Methodological)*, 20(2), 215–232.
- [25] **Yarkan, S. ve Arslan, H.** (2007). Binary time series approach to spectrum prediction for cognitive radio, *2007 IEEE 66th vehicular technology conference*, IEEE, s.1563–1567.
- [26] **Gorcin, A., Celebi, H., Qaraqe, K.A. ve Arslan, H.** (2011). An autoregressive approach for spectrum occupancy modeling and prediction based on synchronous measurements, *2011 IEEE 22nd International Symposium on Personal, Indoor and Mobile Radio Communications*, IEEE, s.705–709.



- [27] **Marple, L.** (1980). A new autoregressive spectrum analysis algorithm, *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 28(4), 441–454.
- [28] **Wen, Z., Luo, T., Xiang, W., Majhi, S. ve Ma, Y.** (2008). Autoregressive spectrum hole prediction model for cognitive radio systems, *ICC Workshops-2008 IEEE International Conference on Communications Workshops*, IEEE, s.154–157.
- [29] **Hwang, C.H., Lai, G.L. ve Chen, S.C.** (2010). Spectrum sensing in wideband OFDM cognitive radios, *IEEE Transactions on Signal Processing*, 58(2), 709–719.
- [30] **Schlögl, A.** (2006). A comparison of multivariate autoregressive estimators, *Signal processing*, 86(9), 2426–2429.
- [31] **Akaike, H.** (1969). Fitting autoregressive models for prediction, *Annals of the institute of Statistical Mathematics*, 21(1), 243–247.
- [32] **Akaike, H.**, (1974). A new look at the statistical model identification, *Selected Papers of Hirotugu Akaike*, Springer, s.215–222.
- [33] **Graves, A., Fernández, S. ve Schmidhuber, J.** (2005). Bidirectional LSTM networks for improved phoneme classification and recognition, *International Conference on Artificial Neural Networks*, Springer, s.799–804.
- [34] **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*, IEEE, s.273–278.
- [35] **Sundermeyer, M., Schlüter, R. ve Ney, H.** (2012). LSTM neural networks for language modeling, *Thirteenth annual conference of the international speech communication association*.
- [36] **Greff, K., Srivastava, R.K., Koutník, J., Steunebrink, B.R. ve Schmidhuber, J.** (2017). LSTM: A search space odyssey, *IEEE transactions on neural networks and learning systems*, 28(10), 2222–2232.



## ÖZGEÇMİŞ



**Ad Soyad:** Uğur Ramazan KILAVUZ

**Doğum Tarihi ve Yeri:** 17/07/1991-Andırın

**E-Posta:** kilavuzugur@gmail.com

### ÖĞRENİM DURUMU:

- **Lisans:** 2015, Marmara Üniversitesi, Mühendislik Fakültesi, Elektrik Elektronik Mühendisliği Bölümü
- **Orta Öğrenim:** 2009, Maltepe Askeri Lisesi, Fen Bilimleri

### MESLEKİ DENEYİMLER VE ÖDÜLLER:

- TÜBİTAK/BİLGEM - Araştırmacı (11/2017- ...)
- Arkenom Teknoloji Hizmetleri San. ve Tic. A.Ş. - Yazılım Mühendisi (11/2016-/02/2017)
- Desmer Bilgi ve İletişim Hiz. Tic. Aş. - Yazılım Mühendisi (09/2015-/09/2016)