

**T.C.
PAMUKKALE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM
DALI**

**ZAMANLA DEĞİŞEN ÖZBAĞLANIMLI MODELE DAYALI
OLARAK DURAĞAN OLMAYAN RASGELE İŞARETLERİN
MODELLENMESİ**

YÜKSEK LİSANS TEZİ

SİMGE ZEREY

DENİZLİ, HAZİRAN - 2014

KABUL VE ONAY SAYFASI

SİMGE ZEREY tarafından hazırlanan “**ZAMANLA DEĞİŞEN ÖZBAĞLANIMLI MODELE DAYALI OLARAK DURAĞAN OLMAYAN RASGELE İŞARETLERİN MODELLENMESİ**” adlı tez çalışmasının savunma sınavı 27.06.2014 tarihinde yapılmış olup aşağıda verilen jüri tarafından oy birliği / oy çokluğu ile Pamukkale Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı Yüksek Lisans Tezi olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Danışman
Doç. Dr. Aydın KIZILKAYA



Üye
Prof. Dr. Serdar İPLİKÇİ



Üye
Doç. Dr. Kadir KAVAKLIOĞLU



Pamukkale Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulu'nun 06/08/2014 tarih ve ..32/12.... sayılı kararıyla onaylanmıştır..



Prof. Dr. Orhan KARABULUT

Fen Bilimleri Enstitüsü Müdürü

Bu tezin tasarımı, hazırlanması, yürütülmesi, arařtırmalarının yapılması ve bulgularının analizlerinde bilimsel etięe ve akademik kurallara özenle riayet edildiđini; bu çalışmanın doğrudan birincil ürünü olmayan bulguların, verilerin ve materyallerin bilimsel etięe uygun olarak kaynak gösterildiđini ve alıntı yapılan çalışmalara atfedildiđine beyan ederim.



SİMGE ZEREY

ÖNSÖZ

Bu çalışmada zamanla değişen durağan olmayan rasgele işaretlerin modellenmesi işlemi gerçekleştirilmiş olup, bu anlamda zamanla değişen özbağımlı (TVAR) model tercih edilmiş ve TVAR parametrelerine sonlu sayıda zamanla değişen deterministik baz fonksiyonu kümesinin ağırlıklandırılmış doğrusal birleşimi ile yaklaşılmaya çalışılmıştır. Bu çalışmanın ortaya çıkış sürecinde desteklerini ve sevgilerini hiçbir zaman esirgemeyen, her zorlukta ve verdiğim her kararda yanımda olduklarını bildiğim anneme, babama ve kardeşime çok teşekkür ederim. Çalışmam boyunca manevi olarak her zaman yanımda olduklarını hissettiğim Nevin Sarıtepe ve Nebahat Yılıgıncı'ya da ayrı ayrı teşekkür ederim. İş hayatımın temellerini attığım ve çok şey öğrendiğim PAÜ Bilgi İşlem Daire Başkanlığı çalışanlarına çok teşekkür ederim. Çalışmada güvenini esirgemediği sabırla yol gösteren danışman hocam Doç. Dr. Aydın Kızılkaya'ya tüm emekleri için teşekkür ederim.

HAZİRAN 2014

Simge ZEREY

İÇİNDEKİLER

	<u>Sayfa</u>
ÖNSÖZ	i
İÇİNDEKİLER	ii
KISALTMALAR	iii
TABLO LİSTESİ	iv
ŞEKİLLER DİZİNİ	v
ÖZET	vii
SUMMARY	viii
1. GİRİŞ	1
1.1. Zaman-Sıklık Analizi.....	2
1.2. Parametrik Olmayan Yöntemler.....	3
1.3. Parametrik Yöntemler.....	5
1.4. TVAR Model Temelli Uygulamalar.....	7
1.4.1. Anlık frekans (IF) kestirimi.....	7
1.4.2. Biyomedikal işaretlerin analizi.....	7
1.4.3. Konuşma işaretlerinin analizi.....	8
1.4.4. Diğer uygulamalar.....	9
1.5. Tezin Amacı.....	9
2. RASGELE SÜREÇLERİN PARAMETRİK MODELLENMESİ	11
2.1. Durağan Rasgele Süreçler.....	11
2.2. Durağan Olmayan Rasgele Süreçler.....	13
3. DURAĞAN OLMAYAN RASGELE SÜREÇLERİN ANALİZİ	15
3.1. Parametrik olmayan analiz yöntemi: STFT	15
3.2. Parametrik TVAR modellemeye dayalı zaman-sıklık analizi	20
3.2.1. Uyarlamalı yöntem: RLS tabanlı TVAR modelleme.....	22
3.2.2. Deterministik yöntem: baz fonksiyonu gösterimi ile TVAR modelleme.....	25
3.2.3. Önerilen yöntem: baz fonksiyonu gösterimi temelinde iteratif TVAR modelleme.....	29
4. BENZETİM SONUÇLARI	34
KAYNAKLAR	49
ÖZGEÇMİŞ	53

KISALTMALAR

AIC	: Akaike Bilgi Ölçütü
AR	: Özbağlanımlı
ARMA	: Özbağlanımlı Kayan Ortalamalı
CWD	: Choi-Williams Dağılımı
dB	: Desibel
EEG	: Elektroensefalografi
FM	: Frekans Modülasyonu
Hz	: Hertz
IF	: Anlık Frekans
LMS	: En Küçük Ortalama Kareler
LPC	: Doğrusal Öngörülü Kodlama
MA	: Kayan Ortalamalı
MDL	: En Küçük Tanımlama Uzunluğu
Ms	: Milisaniye
NPEE	: Normalize Öngörü Hata Enerjisi
PSD	: Güç İzge Yoğunluk Fonksiyonu
RLS	: Yinelemeli En Küçük Kareler
sn	: Saniye
SSS	: Dar Anlamda Durağan
STFT	: Kısa Süreli Fourier Dönüşümü
TVAR	: Zamanla-Değişen Özbağlanımlı
TVMA	: Zamanla-Değişen Kayan Ortalamalı
TVARMA	: Zamanla-Değişen Özbağlanımlı Kayan Ortalamalı
WSS	: Geniş Anlamda Durağanlık
WVD	: Wigner-Ville Dağılımı

TABLO LİSTESİ

Tablo 3.1: Pencere tipleri ve özellikleri	17
Tablo 3.2: TVAR model parametrelerinin yinelemeli kestirimi için RLS algoritması	24
Tablo 3.3: Baz fonksiyonu gösterimi temelinde TVAR modelleme için kullanılabilir baz fonksiyonları	30

ŞEKİLLER DİZİNİ

Şekil 3.1: Zamanla değişen bir işaret üzerine STFT'nin uygulanması.....	16
Şekil 3.2: Dört farklı frekanstan oluşan zamanla değişen işaret	18
Şekil 3.3: Farklı genişliklere sahip dikdörtgen pencere ile elde edilen spektrogram sonuçları. (a) Pencere genişliği: 25 ms (10 örnek), (b) Pencere genişliği: 125 ms (50 örnek), (c) Pencere genişliği: 375 ms (150 örnek), (d) Pencere genişliği: 1000 ms (400 örnek).....	19
Şekil 3.4: Farklı pencerelerle elde edilen spektrogram sonuçları. (a) Pencere türü: Dikdörtgen, (b) Pencere türü: Hanning, (c) Pencere türü: Hamming, (d) Pencere türü: Blackman.....	21
Şekil 3.5: p ve m için güncelleme şeması.....	31
Şekil 4.1: TVAR rasgele işaretinin bir gerçekleştirilmesi; (a) Asıl işaret, (b) RLS yöntemiyle elde edilen kestirim sonucu, (c) Önerilen yöntem ile elde edilen kestirim sonucu	35
Şekil 4.2: TVAR rasgele işaretini üreten TVAR model katsayıları; (a) Asıl katsayılar, (b) RLS yöntemiyle üretilen katsayılar, (c) Önerilen yöntem ile üretilen katsayılar	36
Şekil 4.3: Örnek 1'deki işaret için PSD sonuçları; (a) Asıl işaret, (b) STFT, (c) RLS, (d) Önerilen yöntem.....	37
Şekil 4.4: Örnek 2'de Durum 1'e karşı düşen işaret; (a) Asıl işaret, (b) RLS yöntemiyle elde edilen kestirim sonucu, (c) Önerilen yöntem ile elde edilen kestirim sonucu	39
Şekil 4.5: Örnek 2'de Durum 1'e karşı düşen işaretin TVAR modellemesi; (a) RLS yöntemiyle üretilen TVAR model katsayıları, (b) Önerilen yöntem ile üretilen TVAR model katsayıları	40
Şekil 4.6: Örnek 2'de Durum 1'e karşı düşen işaret için PSD sonuçları; (a) STFT, (b) RLS, (c) Önerilen yöntem	41
Şekil 4.7: Örnek 2'de Durum 2'ye karşı düşen işaret; (a) Asıl işaret, (b) RLS yöntemiyle elde edilen kestirim sonucu, (c) Önerilen yöntem ile elde edilen kestirim sonucu	42

Şekil 4.8: Örnek 2’de Durum 2’e karşı düşen işaretin TVAR modellemesi; (a) RLS yöntemiyle üretilen TVAR model katsayıları, (b) Önerilen yöntem ile üretilen TVAR model katsayıları	43
Şekil 4.9: Örnek 2’de Durum 2’ye karşı düşen işaret için PSD sonuçları; (a) STFT, (b) RLS, (c) Önerilen yöntem stan oluşan zamanla değişen işaret.....	44
Şekil 4.10: İki chirp işaretinin toplamından oluşan zamanla değişen işaretin TVAR modellenmesi; (a) Asıl işaret, (b) RLS yöntemiyle elde edilen kestirim sonucu, (c) Önerilen yöntem ile elde edilen kestirim sonucu.....	46
Şekil 4.11: Örnek 3’de incelenen işaretin TVAR modellemesi; (a) RLS yöntemiyle üretilen TVAR model katsayıları, (b) Önerilen yöntem ile üretilen TVAR model katsayıları	47
Şekil 4.12: Örnek 3’deki işaret için PSD sonuçları; (a) STFT, (b) RLS, (c) Önerilen yöntem	48

ÖZET

ZAMANLA DEĞİŞEN ÖZBAĞLANIMLI MODELE DAYALI OLARAK DURAĞAN OLMAYAN RASGELE İŞARETLERİN MODELLENMESİ

Doğrusal zamanla değişen işaretlerin ve durağan olmayan rasgele işaretlerin frekans bölgesi analizinde geleneksel Fourier dönüşümü yetersiz kalmaktadır. Bu tip işaretlerin analizinde ve modellenmesinde kabul görmüş yöntemlerden birisi, zamanla-değişen özbağlanımlı (TVAR) parametrik model kullanımınıdır. Durağan olmayan dinamikleri tanımlamadaki üstünlüğü ve modelleme kolaylığı; konuşma işleme, haberleşme mühendisliği ve biyomedikal gibi birçok alanda çeşitli amaçlar için TVAR modellerin kullanımının tercih edilmesine yol açmıştır. TVAR modelin kullanıldığı uygulamalarda üstesinden gelinmesi gereken iki temel sorun söz konusudur. Bunlardan ilki, model parametrelerinin kestirimi için belirlenecek olan yöntem; ikincisi ise model mertebesinin belirlenmesidir. Bu çalışmada, zamanla değişen işaretlerin modellenmesi ve zaman-sıklık analizinde kullanılan doğrusal TVAR modelin parametrelerinin kestirimi için baz fonksiyonları gösterimine dayalı yaklaşım üzerinde odaklanılmıştır. Bu bağlamda, zamanla değişen model parametrelerine sonlu sayıda zamanla değişen deterministik baz fonksiyonu kümesinin ağırlıklandırılmış doğrusal birleşimi ile yaklaşılmaya çalışılır. Böylece TVAR model parametrelerinin kestirimi problemi, baz fonksiyonlarının zamandan bağımsız ağırlık katsayılarının tanımlanması problemine indirgenmiş olur. Bu katsayılar, bedel fonksiyonunun en küçüklenmesi ile oluşturulan doğrusal denklem sisteminin çözümünden elde edilir. TVAR modelin mertebesi (p) ve baz fonksiyonlarının sayısı (m), zamanla değişen işaretin olabildiğince doğru bir biçimde modellenmesi için son derece önemlidir. Literatürde mevcut olan çalışmalarda p ve m , ya sezgisel olarak belirlenmiş ya da bilgi ölçütlerine (Akaike bilgi ölçütü (AIC) ve en küçük tanımlama uzunluğu (MDL) gibi) dayalı olarak bulunmaya çalışılmıştır. Ancak p ve m parametrelerinin bu tip yollarla belirlenmesi özellikle gerçek zamanlı uygulamalar için kullanışlı değildir. Çünkü p ve m 'nin değerleri ya deneme yanılma ile elde edilmekte ya da önceden belirlenen bir değer aralığı üzerinden bilgi ölçütünü en küçükleyen p ve m değerlerinin araştırması yapılarak belirlenmektedir. Bu çalışmada, normalize edilmiş öngörü hata enerjisini dikkate alarak p ve m 'nin değerini belirleyen ve beraberinde TVAR model parametrelerinin ve işaretin kestirimini elde eden bir yöntem önerilmektedir. Zamanla değişen işaretlerin zaman-frekans analizinde kullanılan alışlagelmiş yöntemlerden olan kısa süreli Fourier dönüşümü (STFT) ve yinelemeli en küçük kareler (RLS) yöntemlerine göre önerilen yöntemin başarımı, çeşitli bilgisayar benzetimleri ile karşılaştırılmıştır. Elde edilen sonuçlar, zamanla değişen işaretlerin modellenmesinde önerilen yöntemin başarılı olduğunu göstermiştir.

Anahtar Kelimeler: Baz fonksiyonu, yinelemeli en küçük kareler, kısa süreli Fourier dönüşümü, parametrik modelleme, zamanla değişen özbağlanımlı model

SUMMARY

MODELLING THE NONSTATIONARY RANDOM SIGNALS BASED UPON THE TIME-VARYING AUTOREGRESSIVE MODEL

In the frequency domain analysis of linear time varying signals and non-stationary random signals, traditional Fourier transform has been insufficient. One of the approved methods in analyzing and modelling of this type of signals is to use the time-varying autoregressive (TVAR) model. Its superiority in the identification of non-stationary dynamics and its modelling simplicity have led to prefer to the use of TVAR models for various purposes in many areas such as speech processing, communications and biomedical engineering. There are two main problems to overcome in the applications that use TVAR models. The first one is the determination of method to be used for estimating model parameters and the second one is the determination of the model order. For the aim of estimating the parameters of TVAR model that are used in modelling and time-frequency analysis of time-varying signals, in this thesis, we focused on an approach based upon the basis function representation. In this context, we try to approximate to time-varying model parameters through the linear combination of a finite number of weighted time varying deterministic base function set. Thus, the problem of estimating the TVAR model parameters is reduced to the problem of identifying the time independent weighting coefficients of basis function. These coefficients are obtained by solving the system of linear equations that is built with the minimization of the cost function in the least squares sense. The order of TVAR model (p) and the number of base functions (m) are very important for modelling the time-varying signal as accurately as possible. In the literature, p and m are identified intuitively or found based on the information criteria called as Akaike Information Criterion (AIC) and Minimum Description Length (MDL). On the other hand, defining the p and m values by this way is not practical especially for real-time implementations. In this way, the values of p and m are obtained by either trial-and-error or searching p and m values that minimize the information criterion on a range stated beforehand. In this thesis, a method is proposed for specifying p and m values by considering the normalized prediction error energy and so obtaining the estimates of TVAR model parameters and signal is proposed. The performance of the proposed method to the standard time-frequency analysis methods like Short Time Fourier Transform (STFT) and Recursive Least Squares (RLS) are compared using several computer simulations. It is observed from the simulations that the proposed method provides satisfactory results in modeling and time-frequency analysis of time-varying signals.

Key Words: Basis function, recursive least squares method, short time Fourier transform, parametric modeling, time-varying autoregressive model

1. GİRİŞ

İşaret, fiziksel bir sistemin davranışı veya durumu ile ilgili bilgi taşıyan bir veya daha fazla bağımsız değişkene bağlı olarak değişim gösteren her türlü büyüklük olarak tanımlanır (Hayes 1996). Bağımsız değişkenlerini dikkate alarak işaretler, sürekli- ve ayrık-zamanlı olmak üzere iki ana grup altında değerlendirilebilir (Lathi 1987). Sürekli-zamanlı işaretlerin gösteriminde kullanılan bağımsız değişken reel sayılar kümesinin bir elemanı iken ayrık-zamanlı işaretlerde bağımsız değişken, tamsayılar kümesinin bir elemanıdır. Konuşma ve beyin hücrelerinin davranışını yansıtan elektroensefalografi (EEG) işaretleri sürekli-zamanlı işaretlere birer örnektir. Ayrık-zamanlı işaretler ise sürekli-zamanlı işaretlerin zamanda örneklenmiş halidir.

Sürekli- ve ayrık-zamanlı işaretler aynı zamanda kendi içerisinde deterministik ve rasgele olarak da sınıflandırılabilir (Lathi 1987). Deterministik işaretler, belirsizliğin olmadığı ve matematiksel bir gösterim ile tam olarak ifade edilebilen işaretler iken rasgele işaretler matematiksel bir gösterimden ziyade ortalama değer, standart sapma ve ilişki gibi istatistiksel verilerle yaklaşık olarak tanımlanabilen belirsizliğin olduğu işaretlerdir (Lathi 1987). Başka bir deyişle deterministik bir işaretin herhangi bir andaki değeri tam olarak bilinebilirken, rasgele işaretin herhangi bir andaki değerini kesin olarak belirleyebilmek mümkün değildir.

İşaret işleme, kabaca çeşitli amaçlar için işaretlerin işlenmesi olarak tanımlanabilir. Bir işarete taşınan bilgiyi ortaya çıkarmak, işaretin içeriğini değiştirmek, işareti temsil etmek veya başka bir biçime dönüştürmek amacıyla işaretler bir takım işlemlere tabi tutulur. Bu açıdan değerlendirildiğinde işaret işleme, hayatın neredeyse her alanında yaygın olarak kullanılan bir araçtır. Bu aracı etkin bir biçimde kullanabilmenin yolu, işaret içeriğinin uygun yöntemlerle değerlendirilmesi ile sağlanır. Zaman bölgesinde yapılan değerlendirme çoğu zaman işaret hakkında yeterli bir bilgi sunmaz. İşaretlerin zaman ve frekans bölgesi gösterimleri arasındaki ilişkiyi sağlayan matematiksel temel, Fourier dönüşümü'dür (Lathi 1987). Bu dönüşüm sayesinde işaretin frekans içeriği ve dolayısıyla işaretin davranışı hakkında önemli bilgilere ulaşmak mümkündür. Ancak bu dönüşüm sonucunda işaret ile ilgili

zaman bilgisi kaybolur. Bunun bir sonucu olarak doğrusal zamanla değişen işaretlerin ve durağan olmayan rasgele süreçlerin frekans bölgesi analizinde geleneksel Fourier dönüşümü yetersiz kalır. Bu tip işaretlerin analizini, hem zaman hem de frekans bilgisini aynı anda sunan zaman-sıklık analiz yöntemleri ile yapmak mümkündür.

1.1 Zaman-Sıklık Analizi

İşaret analizinde, genellikle işaretin durağan olduğu varsayılır. Ancak gerçek dünyada karşılaşılan konuşma, radar, akustik, sismik ve biyomedikal türü işaretler için bu varsayım her zaman doğru olmaz. Çünkü bu tip işaretlerin genlik ve frekansları çoğunlukla zamanla değişir. Zamanla değişen frekanslara sahip işaretler büyük oranda durağan olmayan davranış sergilerler. Durağan olmayan işaretlerin frekans analizinde, işaretin frekans içeriğinin yanında zaman bilgisinin de bilinmesi son derece önemlidir. Durağan olmayan işaret ile ilgili zaman ve frekans bilgisinin birlikte değerlendirilmesi zaman-sıklık analizi ile mümkündür. Zaman-sıklık analizi, işaretlerin frekans içeriğinin zamana göre değişimi hakkında bilgi verir ve bu bilgi işaret enerjisinin iki-boyutlu zaman-frekans uzayındaki değişimini yansıtan bir harita veya görüntüye karşı düşer. Bu görüntü veya haritaya dayalı olarak işaret davranışı ile ilgili doğru bir değerlendirmenin yapılabilmesi için zaman ve frekans çözünürlüğünün kabul edilebilir bir düzeyde olması gerekir.

Durağan olmayan işaretlerin analizi için mevcut yöntemler; parametrik ve parametrik olmayan olmak üzere iki ana grupta değerlendirilebilir. Parametrik olmayan yöntemler, zaman bağımlı izge gösterimleri olup kısa süreli Fourier dönüşümü (STFT) (Hlawatsch ve Boudreaux-Bartels 1992), zaman-sıklık dağılımları (Cohen 1989) ve evrimsel izgeyi (Priestley 1988) içerisinde barındırır. Ancak belirsizlik ilkesinden dolayı parametrik olmayan yöntemleri kullanarak aynı anda hem zaman hem de frekansta yüksek çözünürlüğe ulaşmak mümkün değildir (Cohen 1995). Parametrik yöntemler ise zamanla değişen özbağlanımlı (TVAR), zamanla değişen kayan ortalamalı (TVMA) ve zamanla değişen özbağlanımlı kayan ortalamalı (TVARMA) doğrusal öngörü modellerini kullanır. Parametrik olmayan yöntemlerin aksine, parametrik yöntemler ile çoğunlukla hem zaman hem de frekansta yüksek çözünürlüğe ulaşılabilir ve ani değişimler içeren zamanla değişen dinamiklerin izlenebilmesi sağlanabilir. Parametrik yöntemlerde kullanılan modelleri tanımlayan

parametreler, gradyent ve Kalman süzgeçleme tabanlı uyarlamalı yöntemlerle ve baz fonksiyonu gösterimine dayalı yöntemlerle kestirilebilir (Luo 2005).

1.2 Parametrik Olmayan Yöntemler

Parametrik olmayan yöntemler, durağan olmayan işaretlerin zamanla değişen frekans davranışını elde etmede kullanılan doğrudan izge kestirim yaklaşımlarıdır ve bu yöntemler pencere kullanım durumuna göre iki grup altında toplanır. STFT ve dalgacık dönüşümü pencerelemeye dayalı yöntemler olup; Wigner-Ville dağılımı (WVD) ve Choi-Williams dağılımı (CWD) gibi zaman-sıklık dağılımları, pencerelemenin kullanılmadığı ve doğrudan doğruya işaretin bütününe uygulanan yöntemler grubunda değerlendirilir.

STFT, zamanla değişen izgenin elde edilmesinde kullanılan en genel yöntem olup incelenen işaretin küçük zaman dilimleri içerisinde durağan olduğu varsayımına dayanır. STFT'ye dayalı olarak işaretlerin frekans bölgesi analizinde geleneksel Fourier dönüşümünün kullanımı, işaret üzerinde kaydırılan belirli uzunluğa sahip bir pencere fonksiyonu üzerinden gerçekleştirilir. Her kaydırma esnasında pencere içerisindeki işaret örneklerinin ayrı Fourier dönüşümü alınır. Böylece frekans içeriğinin yanında işarete ilişkin zaman bilgisi de yakalanmaya çalışılır. İncelenen verinin örnek sayısı, pencere fonksiyonunun türü ve uzunluğu, işaret üzerinde pencerenin kaydırılma miktarı (her bir pencerelemede örtüşen örneklerin sayısı), zaman ve frekans çözünürlüğü anlamında STFT'nin başarımını etkileyen büyüklüklerdir.

Kullanımı ve uygulanması basit olan bir yöntem olmasına rağmen STFT de zaman ve frekans çözünürlüğü arasında bir ödünleşim söz konudur (Cohen 1995). Bu dönüşüm yönteminin özünü oluşturan pencere fonksiyonunun genişliği, işaretin zaman-sıklık analizinde belirleyici bir rol oynar. STFT'nin geniş bir pencere ile kullanımı frekans çözünürlüğünün artmasını sağlarken zaman çözünürlüğünün düşmesine neden olur. Bu durumda işaret frekans içeriğinin hangi anlarda değiştiği kesin olarak belirlenemez. Diğer taraftan, dar bir pencerenin kullanılması zaman çözünürlüğünü artırırken frekans çözünürlüğünün düşmesine neden olur. Bu durumun bir sonucu olarak işaretin davranış değişikliği gösterdiği anlar tam olarak belirlenebilmesine rağmen bu davranış değişikliğini temsil eden frekans içeriği belirginliğini kaybeder. STFT'deki bu olumsuz durum, dalgacık dönüşümünün doğmasına yol açmıştır.

Dalgacık dönüşümünde, STFT'dekinin aksine, değişken yapılı pencereler kullanılır. Farklı genişliklere sahip pencere fonksiyonlarına ihtiyaç duyulmasının nedeni, işareti oluşturan alçak ve yüksek frekanslı dinamiklerin davranışı ile açıklamak mümkündür. Örnekleme frekansının yüksek olması örnekleme için daha kısa sürelerle gerçekleştirilmesi ve dolayısıyla örnek sayısının daha fazla olması anlamına gelir. Örnek sayısı daha fazla olduğundan dolayı yüksek frekanslı işaretler zaman ekseninde daha kararlı bir davranış sergilerler ve bu işaretler için zaman çözünürlüğü örnekleme süresinin kısılalığı çerçevesinde olabildiğince iyidir. Diğer taraftan alçak frekanslarda, yüksek frekanslar kadar örnekleme yapmaya gerek olmadığından dolayı, zaman çözünürlüğünden ziyade frekans çözünürlüğü daha önemlidir. Bu yüzden STFT'den farklı olarak dalgacık dönüşümü zamanla değişen işaretlerin zaman-sıklık analizinde yüksek frekanslar için dar pencereler alçak frekanslar için ise geniş pencereler kullanır. Böylece zaman ve frekans çözünürlüğü arasındaki ödünleşimin de üstesinden gelinmiş olur. Ancak bu üstünlüğüne rağmen pencere fonksiyonunun incelenecek olan işarete göre genişliğinin ayarlanması dalgacık dönüşümüne dayalı analizde başlı başına bir problemdir.

Diğer taraftan, WVD ve CWD gibi zaman-sıklık dağılımları matematiksel olarak daha karmaşık olmasına rağmen herhangi bir pencereleme işlemine gerek duymadıklarından dolayı çoğunlukla zaman ve frekans çözünürlüğü yüksek olan zaman-sıklık gösterimleri sağlarlar. WVD, zamanla değişen sadece tek bir frekans bileşeninden oluşan işaretlerde hem zaman hem de frekansta yüksek çözünürlük sağlarken birden fazla zamanla değişen frekans bileşenine sahip işaretlerde yapay etkilerden ciddi bir biçimde etkilenir. CWD ise yapay etkileri veya bileşenler arası girişimi düzeltme yeteneğine sahiptir ve bu haliyle WVD'ye göre üstündür. Ancak zamanla değişen frekansları belirleyebilme yeteneği $\sigma_t \sigma_\omega \geq 1/2$ ile tanımlanan belirsizlik ölçütü ile kısıtlanır (Cohen 1995). Burada $\sigma_t^2 = \int (t - \langle t \rangle)^2 |s(t)|^2 dt$ olup zaman bölgesinde işaret enerjisinin varyansını ifade eder ve belirginliğin ölçüsüne karşı düşer. Buna karşılık, $\sigma_\omega^2 = \int (\omega - \langle \omega \rangle)^2 |S(\omega)|^2 d\omega$ olup frekans bölgesinde işaret enerjisinin varyansını ifade eder ve frekans bölgesi gösterimindeki belirginliğin ölçüsünü verir. Kısacası, belirsizlik kısıtı, hem zamanda hem de frekansta aynı anda yüksek çözünürlüğe ulaşmanın herhangi bir yolunun olmadığını ifade eder.

1.3 Parametrik Yöntemler

Hem STFT hem de dalgacık dönüşümü, parametrik olmayan zaman-sıklık analiz yöntemleridir. STFT basit ve gerçekleştirilmesi kolay bir yöntem olmasına rağmen yukarıda da ifade edildiği gibi çözünürlük anlamında yetersizliklere sahiptir. Dalgacık dönüşümü bu yetersizliklere çözüm sunmasına rağmen STFT'nin aksine daha karmaşıktır ve değişken uzunluklu pencere fonksiyonlarının belirlenmesini gerektirir. Buradaki zorluk frekans içeriği bilinmeyen bir işaret için pencere uzunluklarının nasıl belirleneceği ile ilgilidir. Alternatif bir çözüm olarak pencere fonksiyonlarına ihtiyaç duymamalarına rağmen WVD ve CWD yöntemlerinin sunduğu zaman ve frekans çözünürlükleri belirsizlik ölçütü ile sınırlıdır.

Diğer taraftan, ister durağan isterse durağan olmayan olsun, işaretlerin analizinde parametrik yöntemlerin parametrik olmayanlarına nazaran yüksek çözünürlük sundukları bilinen bir gerçektir. Bu yöntemlerde işaret; AR, MA veya ARMA modeller ile tanımlanmaya çalışılır. Durağan işaretlerin izgelerinin kestiriminde bu model türlerinin yüksek çözünürlük sağladıkları doğrulanmış ve hatta küçük veri boyutlarıyla bile yüksek frekans çözünürlüklerine ulaşıldığı gösterilmiştir (Kay 1988), (Marple 1987). Bu parametrik model türlerinin aynı zamanda durağan olmayan işaretlerin modellenmesinde de kullanılabileceği birçok çalışmayla desteklenmiştir (Kaipio ve Karjalainen 1997), (Grenier 1983), (Zheng ve diğ. 2001), (Wang ve diğ. 2008). AR, MA, ve ARMA modellerin zamanla değişen sürümlerine karşı düşen ve durağan olmayan işaretlerin parametrik modellenmesinde kullanılan modeller TVAR, TVMA ve TVARMA olarak adlandırılır. Bu modellerden herhangi birine dayalı olarak durağan olmayan işaretlerin gösterimi ve zaman-sıklık analizi, modele ilişkin zamanla değişen parametreler üzerinden gerçekleştirilir. Hem zamanla değişmeyen hem de zamanla değişen durumlarda parametrelerinin kestirimindeki kolaylıktan dolayı AR modele dayalı parametrik modelleme yöntemleri çoğu zaman diğer model türlerine nazaran daha çok tercih edilmektedir. Bu gerçeği göz önünde bulundurarak ve ayrıca zamanla değişen bir çok davranışı iyi bir biçimde modelleyebilme yeteneğinden dolayı bu çalışmada TVAR modele dayalı parametrik yöntemler üzerinde durulmuştur. Bu bağlamda, durağan olmayan $x(n)$ işaretinin parametrik gösterimi için

$$x(n) = \sum_{i=1}^p a_i(n)x(n-i) + e(n) \quad (1.1)$$

eşitliği kullanılacaktır. Burada $\{a_i(n)|i = 1,2, \dots, p\}$, p mertebeli TVAR model katsayılarına ve $e(n)$ ise sıfır-ortalamalı birim varyanslı beyaz Gauss gürültü sürecine karşı düşer.

Eşitlik (1.1)'den de görüldüğü üzere, durağan olmayan bir işaretin TVAR modele dayalı gösterimi, model katsayılarının elde edilmesini gerektirir. TVAR model parametrelerinin kestirimi için mevcut yöntemler, yukarıda da ifade edildiği gibi uyarlamalı ve deterministik olmak üzere iki ana grupta değerlendirilebilir (Kaipio ve Karjalainen 1997), (Wei ve diğ. 2008), (Ijima ve Grivel 2012). Uyarlamalı yöntemlerde $\mathbf{w}(n+1) = \mathbf{w}(n) + \Delta\mathbf{w}(n)$ biçiminde dinamik bir model tanımlanır. Burada $\mathbf{w}(n)$ bulunması gereken parametre vektörü olup $\mathbf{w}(n) = [a_1(n), a_2(n), \dots, a_p(n)]^T$ ile tanımlanır. Burada $[\cdot]^T$, transpoz işlevini ifade eder. Parametre vektörü; dik-iniş ve yinelemeli en küçük kareler (RLS) gibi uyarlamalı algoritmalara dayalı olarak güncellenir. Gürültü süzme gibi saf stokastik uygulamalar için de uygun olmalarına rağmen ani değişimler içeren dinamikleri modellemede yetersiz kalmaları ve hesapsal karmaşıklığın fazla olması uyarlamalı yöntemlerin kullanımını kısıtlayan etkenlerdir.

Deterministik yöntemlerde ise TVAR model parametrelerine, önceden belirlenmiş zamanla değişen baz fonksiyonlarının ağırlıklandırılmış doğrusal birleşimi ile yaklaşılır. Yani, $a_i(n) = \sum_{k=0}^{m-1} a_{i,k} \phi_k(n)$ biçiminde ifade edilmeye çalışılır. Burada $\{\phi_k(n)|k = 0,1, \dots, m-1\}$, m adet baz fonksiyonunu tanımlarken; $\{a_{i,k}|k = 0,1, \dots, m-1\}$, bu baz fonksiyonlarına ilişkin ağırlık katsayılarına karşı düşer. İlk olarak 1970 yılında Rao (Rao 1970) tarafından önerilen bu yaklaşıma göre doğrusal TVAR modelin parametrelerinin kestirimi problemi, önceden tanımlanmış baz fonksiyonlarının zamanla değişmeyen ağırlık katsayılarının tanımlanması problemine indirgenmiştir Eom (1999^{a,b}), (Grenier 1983), (Pachori ve Sircar 2008), (Chon ve diğ. 2005), (Zou ve diğ. 2003), (Girault ve diğ. 1998), (Ciftci ve Kahya 2008), (Hall ve diğ. 1983), (Nathan ve diğ. 1991), (Li ve Ji 2006), (Shan ve Beex 1998), (Xu ve diğ. 2003), (Conforto ve D'Alessio 1999), (Zhang ve diğ. 2010).

p . mertebeden TVAR modelin parametrelerinin kestiriminde baz fonksiyonları gösterimine dayalı yaklaşımın kullanımı durumunda toplamda $p \times m$ adet katsayının bulunması yeterli iken; uyarlamalı yöntemlerin tercih edilmesi durumunda, kestirimi yapılması gereken parametre sayısı $p \times N$ olacaktır. Burada N , modellenen veri boyutunu gösterir ve genel itibariyle m 'den daha büyük bir değere sahiptir (Zhang 2010).

1.4 TVAR Model Temelli Uygulamalar

Biyomedikal işaretler, konuşma işaretleri, haberleşme ve makine mühendisliği uygulamalarında karşılaşılan birçok işaret doğası gereği durağan olmayan yapıdadır. Bu tip işaretlerin analizi ve modellenmesinde çeşitli amaçlar için TVAR modelin yaygın olarak kullanıldığı görülmektedir.

1.4.1 Anlık Frekans (IF) Kestirimi

Bir işaretin anlık frekansı (IF), fazının zamana göre türevini alarak hesaplanır. Bir işaretin IF'nin kestirimi haberleşme, radar, biyomühendislik gibi bir çok işaret işleme uygulamasında karşılaşılan önemli bir problemdir. Sönümlemeli kanalın modellenmesi (Zheng ve diğ. 2001), yüksek çözünürlüklü radar izlerinin sınıflandırılması (Eom 1999b), hedef belirleme için radar yansımalarının IF'nin kestirimi (Li ve Ji 2006), birden fazla frekans modülasyonlu (FM) işaretin birleşiminden oluşan beyaz gürültü ile bozulmuş işarettaki her bir FM işaretin IF'nin kestirimi (Shan ve Beex 1999) ve gerisaçılımlı birçok radar gözleminden durağan olmayan parazitik yankıların modellenmesi (Abramovich 2007), IF kestirimi için TVAR modelin kullanıldığı haberleşme uygulamalarına örnek olarak verilebilir. IF kestirimi için model tabanlı yaklaşımın tercih edilmesinin sebebi, çoklu ve birbirine yakın işaret frekanlarında bile yüksek çözünürlük sağlayabilmesidir (Shan ve Beex 1998).

1.4.2 Biyomedikal İşaretlerin Analizi

Kafa derisi üzerine konumlandırılan elektrotlardan elde edilen işaret kayıtlarının değerlendirilmesi ile beyin aktivitesi hakkında bilgi sahibi olunur. Elektrotlardan toplanan bu kayıtlar EEG olarak adlandırılır. Biyomedikal işaretlerinin analizi ve modellenmesi ile ilgili çalışmalar çeşitlilik gösterir. EEG işaretlerinin zaman-sıklık

analizi (Kaipio ve Karjalainen 1997), (Pachori ve Sincar 2008), (Zhang ve diğ. 2011), (Gutierrez ve Salazar-Varas 2012), (Krystal ve diğ. 1999), (Panzica ve diğ. 2010), solunum frekanslarının belirlenmesi (Lee ve Chon 2011), kan akışının zaman-sıklık analizi (Zou ve diğ. 2003) bunlardan birkaçıdır.

Durağan olmayan EEG işaretlerinin modellenmesine 1970'li yılların sonlarına doğru başlanmıştır (Bodenstein ve Praetorius 1977), (Hasman ve diğ. 1978). Parametrik olarak modellenmesi ise 1996 yılında Kaipio tarafından önerilmiştir (Kaipio 1996). Bu bağlamda, sara nöbeti geçiren bir hastaya ait EEG verilerinin analizi TVAR modele dayalı olarak yapılmıştır (Krystal ve diğ. 1999). İlerleyen yıllarda, çeşitli EEG işaretlerinin analizi ve modellenmesi, baz fonksiyonları gösterimi temelinde TVAR model ile sağlanmıştır (Kaipio ve Karjalainen 1997), (Wei ve diğ. 2008), (Pachori ve Sincar 2008), (Amir ve Gath 1989). Sırasıyla biyolojik dokulardaki sesötesi zayıflamaların izgesel analizinde ve solunumla ilgili hava akışının kestiriminde de parametreleri baz fonksiyonu gösterimine dayalı olarak kestirilen TVAR modelden faydalanılmıştır (Girault 1998), (Ciftci ve Kahya 2008).

1.4.3 Konuşma İşaretlerinin Analizi

Parametrik TVAR modelleme birçok işarete uygulama alanı bulmuştur. Bunlardan biri de konuşma işaretidir. Konuşma işaretinin zamana bağlı modellenmesi 70'li yılların ortasındaki çalışmalarda karşımıza çıkmaktadır (Liporace 1975). Konuşma işaretini, alt parçalara bölerek durağanlık varsayımı altında analiz etmede kullanılan geleneksel doğrusal öngörülü kodlama (LPC) yönteminin zamanla değişen sürümü durağan olmayan konuşma işaretlerini analiz etmek amacıyla geliştirilmiştir. Burada zamanla değişen öngörücü katsayılarına karşı düşen TVAR model parametreleri baz fonksiyonu gösterimine dayalı olarak kestirilmiştir (Hall ve diğ. 1983). Durağan olmayan stokastik süreçlerin modellenmesi üzerine çalışmalar gelişerek devam etmiştir. Bu anlamda Grenier'in durağan olmayan işaretlerin zamanla değişen ARMA model tabanlı zaman-sıklık analizi büyük önem taşımakta olup aynı zamanda da birçok çalışmaya yön vermiştir (Grenier 1983). Konuşma işaretinin, ortogonal baz fonksiyonları kullanarak TVAR modellemesi ile ilgili birçok çalışma gelişmeye devam etmiştir. Flaherty 1988 yılında sunduğu çalışması ile yapay ve gerçek konuşma işareti üzerinde çalışmış, baz fonksiyonları yardımı ile TVAR modelleme yaklaşımını kullanmıştır (Flaherty 1988). Konuşma işaretlerinin TVAR modele

dayalı analizi ile ilgili kuramsal temeller için Rudoy ve arkadaşlarının çalışmasına başvurulabilir (Rudoy 2011).

1.4.4 Diğer Uygulamalar

TVAR model, makine mühendisliğinde karşılaşılan problemlerin üstesinden gelmek amacıyla da yaygın olarak kullanılmıştır. Döner elemanlı rulmanda hata tespiti ve sınıflandırma için zaman-sıklık analizi (Wang 2008), doğrusal zamanla değişen sistemlerin üretmiş olduğu durağan olmayan titreşimlerin parametrik modellenmesi (Xu ve diğ. 2003), mekanik sistemlerden elde edilen işaret ölçümlerinin zaman-sıklık analizi (Conforto ve D'Alessio 1999), ve hata tespiti ve sınıflandırılması amacıyla deneysel rotor titreşim işaretlerinin analizi (Zhang ve diğ. 2010) bunlara örnek olarak verilebilir.

Ayrıca, hareket halindeki araçlardan elde edilen araç tipi, hızı ve yol koşulları gibi geribildirimlerin sınıflandırılması (Eom 1999a) ve düzlemsel şekil hatlarının tespit edilmesi ve sınıflandırılması (Eom 2000) için de TVAR modelden yararlanılmıştır.

1.5 Tezin Amacı

Modele dayalı analizde önemli olan, modelleme için kullanılacak parametrelerin sayısı (model mertebesi) ve bu parametreleri kestirmek için izlenecek olan yoldur. TVAR model parametrelerinin kestirimi, özünde eksik tanımlı bir kestirim problemidir ve bu yüzden makul kestirimler elde etmek için başlangıçta bazı kısıtlar koymayı gerektirir. Bu çalışmada TVAR parametrelerine sonlu sayıda zamanla değişen deterministik baz fonksiyonu kümesinin ağırlıklandırılmış doğrusal birleşimi ile yaklaşılmaya çalışılmıştır. Bu yaklaşım ile başlangıçta eksik tanımlı olan kestirim problemi fazladan tanımlı kestirim problemine dönüştürülmüş olur. Başka bir deyişle TVAR model parametrelerinin kestirimi, baz fonksiyonlarının zamandan bağımsız ağırlık katsayılarının tanımlanması problemine indirgenmiş olur. Bu katsayılar, bedel fonksiyonunun en küçüklenmesi ile oluşturulan doğrusal denklem sisteminin çözümünden elde edilir. TVAR modelin mertebesi (p) ve baz fonksiyonlarının sayısı (m), zamanla değişen verinin olabildiğince doğru bir biçimde modellenmesi için son derece önemlidir. Literatürde mevcut olan çalışmalarda p ve m , ya sezgisel olarak belirlenmiş ya da bilgi ölçütlerine (Akaike bilgi ölçütü (AIC) ve en küçük tanımlama uzunluğu (MDL) gibi) dayalı olarak bulunmaya çalışılmıştır. Ancak p ve m

parametrelerinin bu tip yollarla belirlenmesi özellikle gerçek zamanlı uygulamalar için kullanışlı değildir. Çünkü p ve m 'nin değerleri ya deneme yanılma ile elde edilmekte ya da önceden belirlenen bir değer aralığı üzerinden bilgi ölçütünü en küçükleyen p ve m değerlerinin araştırması yapılarak belirlenmektedir. Bu çalışmada, normalize edilmiş öngörü hata enerjisini dikkate alarak p ve m 'nin değerini belirleyen ve beraberinde TVAR model parametrelerinin ve işaretin kestirimini etkin bir biçimde elde eden bir yöntem önerilmiştir.

2. RASGELE SÜREÇLERİN PARAMETRİK MODELLENMESİ

Sayısal işaret işleme, işaretlerin bilgisayar ya da özel amaçlı sayısal donanımda bir sayılar dizisi olarak gösterilmesi ve bu işaret dizisi üzerinde çeşitli işlemler yaparak istenen bilgi ya da büyüklüğün diziden elde edilmesine dayanır. Sayısal işaret işlemeye giriş, deterministik işaretleri işleyen sistemlerin tasarımı ve analizi ile ilgilidir. Deterministik işaret, genliği matematiksel bir ifade veya kural ile tam olarak tanımlanabilen, belirsizliğin olmadığı işarettir. Basit deterministik işaretler birim örnek işaretini, karmaşık üstel işaretleri ve verilen bir giriş işaretine sayısal bir süzgecin cevabını içerir. Ancak herhangi bir uygulamada, rasgele süreç olarak bilinen en genel işaret tipini incelemek gerekir. Deterministik bir işarettten farklı olarak rasgele bir işaret, tam olarak matematiksel bir ifade ile tanımlanmayan ve bunun sonucunda da tekrar tekrar yeniden elde edilmeyen, belirsizliğin olduğu işaretlerdir. Rasgele işaretler, istatistiksel özellikleri yoluyla tanımlanabilen işaretler topluluğudur. Adından da anlaşılacağı üzere, rasgele olduğundan veya deterministik olmadığından rasgele bir süreç deterministik işarettten ayrı bir konumdadır. Bu nedenle, topluluk içerisinde bir işaret seçilene veya gözlemlenene kadar sürecin gerçek değerini genellikle bilmek imkansızdır. Analog'dan sayısal'a dönüşüm sonucunda üretilen kuantalama gürültüsü, yapay açıklıklı radar görüntülerindeki benek gürültüsü, bir uçağın pilot kabininden yapılan konuşmaların iletimini etkileyen motor gürültüsü ve radar görüntülerindeki arka plan parazit yansımaları rasgele süreçlere örnek olarak verilebilir.

Rasgele süreçler, durağan ve durağan olmayan olmak üzere iki grupta değerlendirilir.

2.1 Durağan Rasgele Süreçler

Rasgele bir $x(n)$ süreci için tanımlanan istatistikler, her k değeri için $x(n+k)$ için de geçerli ise $x(n)$ rasgele sürecine 'durağan süreç' adı verilir. Buna göre k 'nın herhangi bir değeri için

$$p_x(x_1, \dots, x_N; n_1, \dots, n_N) = p_x(x_1, \dots, x_N; n_{1+k}, \dots, n_{N+k})$$

eşitliğini sağlayan $x(n)$ rasgele sürecine N . mertebeden ‘dar anlamda durağan (SSS) süreç’ adı verilir. Buna göre, bağımsız ve benzer dağılımlı bir rasgele dizi SSS’dir.

Diğer taraftan, SSS özelliği sınırlı uygulamalar için kullanılabilir olduğundan dolayı birçok gerçek dünya problemlerinde varsayılan durağanlık biçimi ‘geniş anlamda durağanlık (WSS)’ olarak bilinir. Bir WSS $x(n)$ sürecinin; (i) Ortalaması zamandan bağımsızdır, $\mu_x(n) = E\{x(n)\} = \mu_x$, (ii) Varyansı zamandan bağımsızdır, $var[x(n)] = \sigma_x^2 < \infty$, (iii) Özilişki dizisi $r_x(n_1, n_2)$, sadece $l = n_1 - n_2$ farkına bağlı olmalıdır, $r_x(n_1, n_2) = r_x(n_1 - n_2) = r_x(l)$.

SSS bir süreç aynı zamanda WSS’dir. Ancak bunun tersi her zaman doğru değildir. İşaretin Gaussian olması durumunda bunun tersi de geçerlidir.

Wold ayrıştırma kuramına göre herhangi bir $x(n)$ süreci, birbiriyle ilişkisiz iki sürecin toplamı biçiminde ifade edilebilir, $x(n) = x_r(n) + x_p(n)$. Burada $x_r(n)$; $h_0 = 1$, $\sum_{i=0}^{\infty} h_i^2 < \infty$ ve beyaz gürültü dizisi $v(n)$ ile $x_r(n) = \sum_{i=1}^{\infty} h_i v(n - i)$ eşitliği kullanılarak kestirilebilen deterministik olmayan süreci belirtir. $x_p(n)$ ise deterministik veya öngörülebilir süreci tanımlar ve $x_p(n) = \sum_{i=1}^{\infty} a_i x_p(n - i)$ ile kestirim hatası olmadan sonsuz sayıda geçmişteki değerlerinden elde edilebilir (Hayes 1996).

Wold ayrıştırma kuramı, herhangi bir WSS $x(n)$ sürecinin; örnek değerleri istatistiksel olarak bağımsız, sıfır ortalamalı ve σ_v^2 varyanslı beyaz Gauss gürültüsünü temsil eden $v(n)$ sürecinin doğrusal zamanla değişmeyen nedensel bir süzgeçten geçirilmesi ile elde edildiğini kabul eder.

Wold ayrıştırmasının önermiş olduğu süzgeç sonsuz sayıda katsayının kullanımını gerektirdiğinden dolayı uygulamaya yönelik sistem modellemesi için uygun değildir. Bu yüzden rasgele bir modelin kısmi gösterimi sonlu mertebelerle aşağıdaki gibi verilebilir:

$$x(n) = \sum_{i=1}^p a_i x(n - i) + \sum_{j=0}^q b_j v(n - j) \quad (2.1)$$

Burada a_i ve b_j zamanla değişmeyen model parametreleridir. (2.1) ile belirtilen eşitlik, üç çeşit doğrusal rasgele modeli ortaya çıkarır:

- AR: Girişin geçmişteki değerlerini kullanmayan yinelemeli model. Buna göre (2.1) eşitliği $\{b_j = 0 | j = 1, 2, \dots, q\}$ ile AR modele karşı düşer.
- MA: Çıkışın geçmişteki değerlerini kullanmayan yinelemesiz model. Buna göre (2.1) eşitliği $\{a_i = 0 | i = 1, 2, \dots, p\}$ ile MA modele karşı düşer.
- ARMA: Hem giriş ve hem de çıkışın geçmişteki değerlerinin kullanıldığı en genel yinelemeli model. Buna göre (2.1) eşitliği $a_i \neq 0$ ve $b_j \neq 0$ ile ARMA modele karşı düşer.

AR veya ARMA modelde kutupların varlığı MA modele göre sistem tanılamada daha iyi başarımın elde edilmesini sağlayabilir. Ancak AR veya ARMA modelin kullanımı kararlı olmayan sistem gösterimine neden olabilir. Buna ek olarak, MA veya ARMA model doğası gereği doğrusal olmayan yapıdadır ve bunun sonucu olarak genel itibari ile parameterlerinin kestirimi doğrusal olmayan denklem çözümünü gerektirir. Diğer taraftan AR modele dayalı sistem tanılamada AR parametrelerinin kestirimini doğrusal denklem sisteminin çözümüyle elde edebilmek mümkündür. Bu sebeple AR model daha yaygın bir kullanıma sahiptir.

2.2 Durağan Olmayan Rasgele Süreçler

Dar anlamda durağanlık, bütün istatistiksel büyüklüklerin zamandan bağımsız olmasıdır. SSS olan bir sürecin aynı zamanda WSS olabilmesi için sürece ilişkin enerjinin sonlu olması gerekir. Bu koşul genel olarak mühendislik ve temel bilimlerde karşılaşılan rasgele süreçler tarafından sağlanır. Bir rasgele sürece ilişkin dağılım Gaussian ise, WSS durumu aynı zamanda SSS durumuna karşılık düşer. Durağanlık varsayımı, gerçek zamanlı uygulamalar için uygun değildir. Bu zorluğun üstesinden gelmek için ortaya konan bir yaklaşım da, durağan olmayan sürecin belirli zaman aralıkları üzerinden bloklara ayrılması ve her bir zaman bloğu içinde sürecin yaklaşık olarak durağan olduğunun varsayılmasıdır. Bu şekilde istatistiksel bilgiler blok veriden kestirilebilir. Ancak çeşitli sebeplerden dolayı bu yaklaşımın başarımı sınırlıdır. Şöyle ki; (i) İçerisinde ani değişimleri barındıran süreçler için istatistiksel özelliklerin değişmediğinin varsayıldığı zaman aralığı ilgili parametrelerin yeterli doğruluk ve çözünürlükte kestirimi için küçük olabilir, (ii) Analiz aralığı içerisindeki ani değişikliklere kolayca uyum sağlamayabilir, (iii) Blok veri için doğru olmayan bir model elde edilebilir.

Tüm bu nedenlerden dolayı gerçek-zamanlı uygulamalar için durağanlık varsayımı yapmak yerine, durağan olmadığının kabul edilip geliştirilen çözümün buna göre yapılması gerçeğe çok daha yakın sonuçlar doğuracaktır. İşaret işleme çalışmalarına bakıldığında işaretler genel olarak durağan varsayımı altında analiz edilir. Bununla birlikte doğal ortamda örneğin; EEG veya konuşma işaretleri bu genel durumun dışında kalmaktadır. Bu işaretler zamanla değişen frekans ve genlik bilgisine sahip olduklarından, işaretlerin çoğu durağan bir yapıya sahip değildir.

Durağan olmayan rasgele süreçler zamanla değişen olasılık dağılımına sahiptir ve sırasıyla $E\{x(n)\} = m_x(n)$ ve $E\{[x(n) - m_x(n)][x(n-i) - m_x(n-i)]^*\}$ ile tanımlanan zamanla değişen ortalama ve kovaryansa sahip işaretlerden oluşur. Burada $E\{\cdot\}$, beklenen değer işlemcisini belirtir. Uygulamada genellikle, yerel ortalamalar işaretten çıkarılarak, işaretin zamanla değişen ortalaması sıfırlanır. Bu durumda sıfır-ortalamalı durağan olmayan sürecin zamanla değişen kovaryansları yerine zamanla değişen özilişkilerinden bahsedilir, $E\{x(n)x^*(n-i)\} = r_x(n, i)$.

Durağan süreçtekinе benzer biçimde, Cramer-Wold ayrıştırmasına göre deterministik olmayan zamanla değişen $x(n)$ süreci, sıfır-ortalamalı ve σ_v^2 varyanslı beyaz gürültü süreci $v(n)$ ile $x(n) = \sum_{i=0}^{\infty} h_i(n)v(n-i)$ biçiminde ifade edilebilir, burada $\forall n$ için $\sum_{i=0}^{\infty} h_i^2(n) < \infty$. Bu gösterim esasen $H(n, z) = \sum_{i=0}^{\infty} h_i(n)z^{-i}$ biçiminde zamanla değişen transfer fonksiyonuna sahip nedensel bir süzgeçten $v(n)$ sürecinin geçirilmesine eşdeğerdir. Bu gürültü şekillendirme süzgeci sonsuz sayıda katsayıya sahip olduğundan dolayı Cramer-Wold ayrıştırması uygulamada kullanılamaz. Bunun yerine aynı durağan süreç gösteriminde yapıldığı gibi, sonlu sayıda katsayılar kullanarak durağan olmayan süreç aşağıdaki gibi ifade edilebilir.

$$x(n) = \sum_{i=1}^p a_i(n)x(n-i) + \sum_{j=0}^q b_j(n)v(n-j) \quad (2.2)$$

Burada $a_i(n)$ ve $b_j(n)$ zamanla değişen model parametrelerini tanımlar. (2.2) eşitliğine karşı düşen zamanla değişen transfer fonksiyonu ise aşağıdaki gibi verilir:

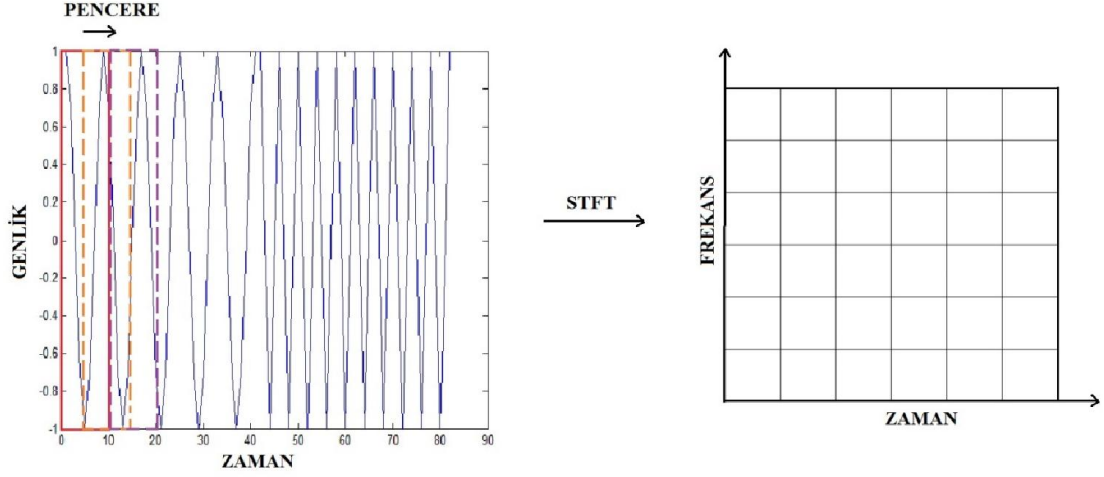
$$H(n, z) = \frac{\sum_{j=0}^q b_j(n)z^{-j}}{1 + \sum_{i=1}^p a_i(n)z^{-i}} \quad (2.3)$$

3. DURAĞAN OLMAYAN RASGELE SÜREÇLERİN ANALİZİ

Zamanla değişmeyen (durağan) rasgele süreçlerin modellenmesinde olduğu gibi durağan olmayan rasgele işaretlerin analizi ve modellenmesi parametrik ve parametrik olmayan yöntemlerle gerçekleştirilebilir. Bu tez çalışması kapsamında zamanla değişen dinamiklerin zaman-sıklık analizi için parametrik olmayan yöntem olarak STFT üzerinde durulacaktır. Parametrik yöntemler bağlamında ise TVAR model temelinde RLS ve baz fonksiyonu gösterimine dayalı yaklaşımlara odaklanılacak ve baz fonksiyonu gösterimini kullanan iteratif bir algoritma önerilecektir.

3.1 Parametrik olmayan analiz yöntemi: STFT

Doğrusal zamanla değişen işaretlerin ve durağan olmayan rasgele süreçlerin frekans bölgesi analizinde geleneksel Fourier dönüşümü yetersiz kalır. Bunun nedeni zaman bilgisinin kaybolmasıdır. Başka bir deyişle, işarete ilişkin frekans içeriğinin hangi anlarda meydana geldiği doğrudan doğruya işaret izgesinden anlaşılamaz. Bu sorunun üstesinden gelmek için Dennis Gabor (1946), pencereleme yöntemi ile işareti küçük parçalara ayırarak her bir parçanın frekans bölgesi analizini gerçekleştirme fikrini ortaya koymuştur (Cohen 1989). STFT olarak bilinen bu yöntemde göre, incelenen zamanla değişen işaret küçük zaman aralıklarına ayrılır ve bu zaman aralığı içerisinde kalan örnek değerlerinin üzerine geleneksel Fourier dönüşümü uygulanır. Böylece zamana bağlı olarak işarete ilişkin frekans içeriği elde edilmiş olur ki bu işlem işaretin parametrik olmayan zaman-sıklık analizine karşı düşer. Daha önce de ifade edildiği gibi zaman-sıklık analizi, zamanla değişen işaretlerin frekans içeriğinin zamana göre değişimi hakkında bilgi verir ve bu bilgi işaret enerjisinin iki-boyutlu zaman-frekans uzayındaki değişimini yansıtan *spektrogram* olarak ifade edilen bir harita veya görüntüye karşı düşer. Dikdörtgen bir pencere üzerinden STFT'nin uygulanışı Şekil 3.1'de kabaca gösterilmiştir.



Şekil 3.1: Zamanla değişen bir işaret üzerine STFT'nin uygulanması.

Zamanla değişen bir $x(n)$ işaretinin STFT' si için analiz denklemi,

$$X(k, n_0) = \sum_{n=0}^{N_p-1} x(n + n_0)p(n)e^{-j\frac{2\pi kn}{N_p}} \quad (3.1)$$

ile tanımlanır. Burada n_0 pencerenin kaydırma anını, $p(n)$ pencere fonksiyonunu ve N_p ise örnek sayısı anlamında pencere büyüklüğünü belirtir. (3.1) eşitliği aynı zamanda $k = 0, 1, \dots, N_p - 1$ ile N_p -noktalı ayrık Fourier dönüşümüne karşı düşer.

STFT ile elde edilen zaman-frekans gösteriminden işaret davranışı ile ilgili doğru bir değerlendirmenin yapılabilmesi için hem zaman hem de frekans çözünürlüğünün kabul edilebilir bir düzeyde olması gerekir. Başka bir deyişle STFT de zaman ve frekans çözünürlüğü arasında bir ödünleşim söz konudur (Cohen 1995). Bu dönüşüm yönteminin özünü oluşturan pencere fonksiyonun genişliği, işaretin zaman-sıklık analizinde belirleyici bir rol oynar. İşaret frekans içeriğinde meydana gelen değişikliklerin hangi an veya anlara karşı geldiğini belirleyebilmek için kullanılacak olan pencerenin genişliği yeteri kadar dar ve frekans içeriğini olabildiğince iyi yansıtabilecek kadar da geniş olmalıdır. Bir başka deyişle zaman bilgisinin doğru bir biçimde elde edilmesi isteniyorsa dar pencere kullanma zorunluluğu vardır. Ancak dar bir pencerenin kullanılması zaman çözünürlüğünü artırırken frekans çözünürlüğünün düşmesine neden olur. Eğer ki frekans içeriğinin mümkün olduğunca iyi bir şekilde yansıtılması isteniyorsa, bu durumda da geniş bir pencerenin kullanılması gerekir. Geniş pencere kullanımı frekans çözünürlüğünün artmasını sağlarken zaman çözünürlüğünün azalmasına neden olur. Bu durumda

işaret frekans içeriğinin hangi anlarda değiştiği kesin olarak belirlenemez. Bunun sebebi zaman ve frekans arasındaki belirsizlik prensibi (Cohen 1995) ile ifade edilir. Belirsizlikten kasıt, (3.1) ile hesaplanan dönüşüm toplamının tüm işaret için değil, sadece pencere içerisini kapsamasıdır. Yani işaretin genelinden gelecek frekans bilgisinden yoksun bir şekilde bölgesel olarak işlem yapılmaktadır.

STFT’de pencere genişliği kadar pencere tipi de önemlidir. Zaman-sıklık analizi için uygulamalarda sıklıkla kullanılan dört çeşit pencere fonksiyonu mevcuttur. Bu pencere fonksiyonlarını tanımlayan matematiksel ifadeler ve herbir pencere için 3-dB bant genişliği ile yan loblarının dB cinsinden değeri Tablo 3.1’de listelenmiştir (Hayes 1996).

Tablo 3.1: Pencere tipleri ve özellikleri

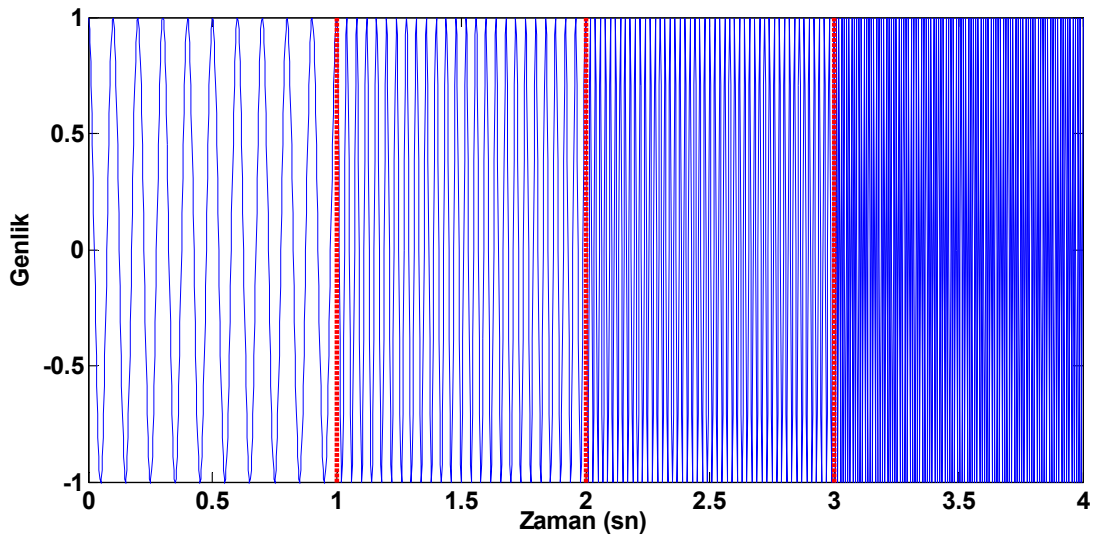
Pencere fonksiyonu, $p(n); 0 \leq n \leq N_p - 1$	Yan lob seviyesi (dB)	3-dB bant genişliği $(\Delta\omega)_{3dB}$
Dikdörtgen 1	-13	$0.89(2\pi / N_p)$
Hanning $0.5 - 0.5 \cos\left(\frac{2\pi n}{N_p}\right)$	-32	$1.44(2\pi / N_p)$
Hamming $0.54 - 0.46 \cos\left(\frac{2\pi n}{N_p}\right)$	-43	$1.30(2\pi / N_p)$
Blackman $0.42 - 0.5 \cos\left(\frac{2\pi n}{N_p - 1}\right) + 0.08 \cos\left(\frac{4\pi n}{N_p - 1}\right)$	-58	$1.68(2\pi / N_p)$

Tablo 3.1’deki değerlerden görüldüğü üzere dikdörtgen pencerenin frekans çözünürlüğü diğer pencerelere göre daha yüksektir. Diğer taraftan, frekans çözünürlüğünün pencere uzunluğu N_p ile ters orantılı olduğu görülmektedir. Yani

örnek sayısı eğer az ise bu durumda frekans çözünürlüğü düşük olacağından dolayı dikdörtgen pencere kullanmanın bir anlamı olmayacaktır. Bu durumda zaman çözünürlüğünün de düşük olmasının önüne geçmek için dikdörtgen pencere dışındaki pencerelerin kullanımına başvurulur. Çünkü diğer pencerelerle karşılaştırıldığında dikdörtgen pencerenin yan loblarının etkisi büyüktür. Bu ise zaman-frekans düzleminde işaret frekans içeriğinin başlangıç ve bitiş anlarının keskinliğinin ortadan kalkmasına neden olur. Zaman-frekans arasındaki ödünleşimi ve kullanılan pencere türünün etkisini


$$x(t) = \begin{cases} \cos(2\pi \times 10t), & 0 \leq t < 1 \text{ sn} \\ \cos(2\pi \times 25t), & 1 \leq t < 2 \text{ sn} \\ \cos(2\pi \times 50t), & 2 \leq t < 3 \text{ sn} \\ \cos(2\pi \times 100t), & 3 \leq t \leq 4 \text{ sn} \end{cases}$$

ile tanımlanan işaret üzerinden değerlendirerek görmek mümkündür. İşaret 400 Hz'de örneklenecek ayrık-zamanlı hale getirilmektedir. İşaretin değişimi Şekil 3.2'de verilmiştir. Örnekleme frekansı 400 Hz olduğuna göre işaret örnekleme aralığı 2.5 ms'ye karşı düşmektedir.



Şekil 3.2: Dört farklı frekanstan oluşan zamanla değişen işaret.

25ms (10 örnek), 125ms (50 örnek), 375ms (150 örnek) ve 1000 ms (400 örnek) genişlikli dikdörtgen pencere kullanımıyla elde edilen zaman-sıklık genlik haritaları (spektrogramlar) Şekil 3.3'de gösterilmiştir.



Şekil 3.3: Farklı genişliklere sahip dikdörtgen pencere ile elde edilen spektrogram sonuçları; (a) Pencere genişliği: 25 ms (10 örnek), (b) Pencere genişliği: 125 ms (50 örnek), (c) Pencere genişliği: 375 ms (150 örnek), (d) Pencere genişliği: 1000 ms (400 örnek).


Şekil 3.3'deki sonuçlardan görüldüğü üzere küçük pencere genişliklerinde işaret ile ilgili zaman bilgisi oldukça iyi bir biçimde yakalanabilirken frekans bilgisi kaybolmaktadır. Başka bir deyişle, zaman çözünürlüğü yüksek frekans çözünürlüğü düşük olan sonuçlara ulaşılmaktadır. Diğer taraftan, pencere genişliği artırıldığında işaret ile ilgili frekans bilgisi doğru bir biçimde belirlenebilirken bu frekans bilgisinin hangi zaman anlarına karşı geldiği belirginliğini kaybetmektedir. Şekil 3.3'de elde edilen sonuçlar daha önce STFT için ifade edilen zaman ve frekans çözünürlüğü arasındaki ödünleşimi doğrulamaktadır.

Pencere genişliğinin yanında pencere türünün STFT tabanlı zaman-sıklık analizine etkisini görmek amacıyla 500 ms (200 örnek) genişlikli olacak şekilde Tablo 3.1'de tanımlanan dört farklı pencerenin kullanımıyla elde edilen spektrogram sonuçları Şekil 3.4'de gösterilmiştir. Tablo 3.1'deki pencere türlerine ait yan lob seviyeleri ve bant genişliklerinin etkisi, Şekil 3.4'de verilen benzetim sonuçları ile desteklenmiştir.

3.2 Parametrik TVAR modellemeye dayalı zaman-sıklık analizi

Daha önce Bölüm 1.3'te ifade edildiği üzere model tabanlı işaret analiz yöntemleri yüksek çözünürlüklü sonuçlar ürettiklerinden dolayı parametrik olmayan yöntemlere tercih edilirler. Durağan olmayan işaretlerin analizinde ve modellenmesinde çoğunlukla TVAR model kullanılır. Böyle bir seçimin yapılmasındaki en önemli etken, durağan olmayan dinamikleri tanımlamadaki başarısı ve modelleme kolaylığıdır (Chon ve diğ. 2005).

Buna göre verilen bir zamanla değişen $x(n)$ süreç örnekleri giriş-çıkış ilişkisi (1.1) eşitliği ile tanımlanan p . mertebeden bir TVAR model ile temsil edilir. Bu gösterimin yapılabilmesi için model mertebesi p 'nin ve buna dayalı olarak bilinmeyen $N \times p$ adet model katsayısının belirlenmesi gerekir. Model mertebesinin bilindiği varsayımı altında parametre kestiriminde iki farklı yola başvurulabilir. Bunlardan ilki doğrudan doğruya $N \times p$ adet model katsayısını bulmaya yönelik uyarlamalı yöntem olup bu yöntemde parametreler heran için güncellenerek kestirilir. İkinci yöntem ise deterministik olup bu yöntemde, TVAR model parametrelerinin kestirimi problemi önceden tanımlanmış baz fonksiyonları olarak adlandırılan m adet zaman fonksiyonlarının doğrusal birleşimine dayanan $m \times p$ adet bilinmeyen elde edilmesi problemine indirgenir. Daha sonra bulunan bu parametreler zamanla değişen model katsayılarının kestiriminde kullanılır.



Şekil 3.4: Farklı pencerelerle elde edilen spektrogram sonuçları. (a) Pencere türü: Dikdörtgen, (b) Pencere türü: Hanning, (c) Pencere türü: Hamming, (d) Pencere türü: Blackman.

3.2.1 Uyarlamalı yöntem: RLS tabanlı TVAR modelleme

Rasgele işaretlerin modellenmesinde; kullanılan parametrik modelin türü ve işaret ile ilgili istatistiksel bilgiler, modellemenin iyi sonuç vermesi açısından oldukça önemlidir. Gerçek-zamanlı uygulamalarda işaretlere ilişkin istatistiki bilgi çoğu zaman mevcut olmayıp işaret örnekleri çeşitli varsayımlar (durağanlık gibi) üzerinden kestirilmeye çalışılır. Ancak durağanlık varsayımı gerçek zamanlı sistemler için uygun değildir. Bu zorluğun üstesinden gelmek için bir yaklaşım, durağan olmayan sürecin belirli zaman aralıkları üzerinden bloklara ayrılması ve her bir zaman bloğu içerisinde sürecin yaklaşık olarak durağan olduğunun varsayılmasıdır. Bu şekilde istatistiksel bilgiler blok veriden kestirilebilir. Ancak çeşitli sebeplerden dolayı bu yaklaşımın başarımı kısıtlıdır. Şöyle ki

- Hızlı değişen süreçler için istatistiksel özelliklerin değişmediğinin varsayıldığı zaman aralığı, parametrelerin yeterli doğrulukta ve çözünürlükte kestirimi için küçük olabilir.
- Analiz aralığı içerisindeki ani değişikliklere kolayca uyum sağlanmayabilir.
- Blok veri için doğru olmayan model elde edilebilir.

Tüm bu nedenlerden dolayı gerçek-zamanlı işaretler için en iyi yaklaşım başlangıçta sürecin durağan olmadığını varsayarak kestirimin yapılmasıdır. Bu amaca yönelik tasarlanan yöntemler uyarlamalı yöntemler olarak adlandırılır ve işareti modelleyen model katsayıları, kestirim hatasına dayalı olarak devamlı güncellenir. Bu güncelleme işlemi, uyarlama algoritması ile gerçekleştirilir. Uyarlamalı yöntemlerin en önemli özelliği, zamanla değişen durumlara rahatlıkla uygulanabilmesi ve yeni durumlara kendini ayarlayabilmesidir. Herhangi bir uyarlamalı yöntemin tasarımı, işaret çalışma ortamı hakkında geniş bir önbilgiye sahip olunması gerektirir. Bu bilgi, başarımlı ölçütünün ve yöntemin seçimi için gereklidir. Net olmayan önbilgi veya işaret çalışma ortamı hakkında doğru olmayan varsayımlar ciddi başarımlı düşüklüğüne ve düşük doğruluklu kestirimlerin elde edilmesine neden olabilir. Eğer işaret çalışma ortamının davranışı zamanla değişmiyorsa uyarlamalı yöntemin amacı, en iyi başarımlı sağlayan parametreleri bulmak ve daha sonra uyarlama işlemini durdurmaktır. Ancak işaret çalışma ortamının davranışı zamanla değişiyorsa bu durumda uyarlama algoritması ilk olarak parametreleri bulmalı ve daha sonra değişimleri takip etmek için sürekli olarak bu parametreleri güncellemelidir.

Uyarlamalı algoritmaların yaygın olarak kullanılanları en küçük ortalama kareler (LMS) ve RLS algoritmalarıdır. LMS algoritması, bir azaltım arama algoritması kullanarak kestirim hatasının karesinin ortalamasını en küçükleme mantığına göre çalışır. Hesapsal karmaşıklığının az olması, topluluk ortalamaları yerine işaret ani değerlerinin kullanılması ve matris tersine ihtiyaç duyulmaması tercih sebepleri arasında gösterilebilir. Diğer taraftan, geniş-anlamda durağanlık varsayımını dikkate alarak işaret kestirimini gerçekleştirdiğinden dolayı gerçek-zamanlı uygulamalar için çoğu zaman yeterli yakınsama hızı sağlamayabilir ve sonuçta doğru bir işaret kestirimi üretmeyebilir. RLS ise hatanın karesinin üstel olarak ağırlıklandırılmış sürümünün toplamını en küçüklemeye dayanır. RLS algoritması genel itibari ile LMS algoritmasına nazaran yüksek yakınsama hızına sahiptir ve ağırlıklandırma katsayısı sayesinde zamanla değişen dinamiklerin takibinde LMS'ye göre çoğu zaman yüksek başarımlar sergiler. Diğer taraftan, ağırlıklandırma katsayısının zamana göre değişecek biçimde seçimi ile ilgili belirgin bir tanımlamanın olmaması ve hesapsal karmaşıklığının yüksek olması RLS algoritmasının kullanımını sınırlayan etkenler olarak sıralanabilir.

RLS algoritması, durağan olmayan $x(n)$ işaretini (1.1) eşitliği gösteriminde modellemek için kullanılan p . mertebeden TVAR modeli tanımlayan $\mathbf{w}(n) = [a_1(n), a_2(n), \dots, a_p(n)]^T$ parametre vektörünü her bir n anı için güncellemek amacıyla en küçük kareler yöntemini kullanır. En küçük kareler yönteminde $\mathbf{w}(n)$ süzgeç ağırlık katsayı vektörü, bir zaman penceresindeki hataların karesinin toplamından oluşan

$$J(n) = \sum_{i=1}^n \lambda^{n-i} |e(i)|^2 \quad (3.2)$$

ile tanımlanan bedel fonksiyonunu en küçükleyecek şekilde elde edilir: Burada,

$$e(i) = x(i) - \mathbf{w}^T(n)\mathbf{x}(n) \quad (3.3)$$

olup

$$\mathbf{x}(n) = [x(n-1), x(n-2), \dots, x(n-p)]^T \quad (3.4)$$

ile tanımlı p uzunluklu sütun vektörüdür.

(3.3) ve (3.4)'deki tanımlamalar çerçevesinde (3.2) ile verilen bedel fonksiyonunun $\mathbf{w}(n)$ parametre vektörüne göre en küçüklenmesine karşı düşen RLS algoritması Tablo 3.2'de özetlenmiştir (Hayes 1996).

Tablo 3.2: TVAR model parametrelerinin yinelemeli kestirimi için RLS algoritması

Parametreler	
p	: TVAR model mertebesi
λ	: Üstel ağırlıklandırma katsayısı
$\mathbf{P}(n)$: Korelasyon matrisi $\mathbf{R}_x(\mathbf{n})$ 'nin tersine karşı düşen matris.
δ	: $\mathbf{P}(0)$ 'i oluşturmak için kullanılan sabit <ul style="list-style-type: none"> • Yüksek SNR değerleri için küçük pozitif bir sabittir. • Düşük SNR değerleri için büyük pozitif bir sabittir.
Yineleme için başlangıç koşulları	
$\mathbf{w}(0) = [0, 0, \dots, 0]^T$	
$\mathbf{P}(0) = \delta^{-1}\mathbf{I}$	
Hesaplama adımları: $n = 1, 2, \dots, N - 1$	
$\mathbf{K}(n) = \frac{\mathbf{P}(n-1)\mathbf{x}(n)}{\lambda + \mathbf{x}^T(n)\mathbf{P}(n-1)\mathbf{x}(n)},$ (Kazanç vektörü)	
$e(n) = x(n) - \mathbf{w}^T(n-1)\mathbf{x}(n)$	
$\mathbf{w}(n) = \mathbf{w}(n-1) + \mathbf{K}(n)e(n)$	
$\mathbf{P}(n) = \lambda^{-1}[\mathbf{P}(n-1) - \mathbf{K}(n)\mathbf{x}^T(n)\mathbf{P}(n-1)]$	

Durağan durumda $\lambda = 1$ alınarak model parametrelerinin kestirimi gerçekleştirilir. Diğer taraftan, üstel ağırlıklandırma olmaksızın ($\lambda = 1$ durumu) RLS algoritması durağan olmayan süreçlerin takibinde çok iyi sonuçlar vermez. Durağan olmayan işaretlerin RLS algoritması ile modellenmesinde $\lambda < 1$ olarak alınır. Ancak belirtmekte fayda var ki $\lambda < 1$ ile tüm anlar için elde edilen parametre kestirimleri istatistiksel olarak optimal olmayan izge kestirimi ile sonuçlanacaktır. Bunun nedeni

olarak korelasyon kestiriminde tüm verinin eşit olarak ağırlıklandırılacak olması gösterilir (Hayes 1996). Üstel ağırlıklandırma, RLS algoritmasının takip edilebilme özelliğini iyileştirmesine rağmen ağırlıklandırma katsayısı λ 'nın seçimi için kesin bir yöntem mevcut değildir. Ayrıca zamanla değişen verinin modellenmesinde başarıyı artırmak (optimale yakın izge kestirimi) için ağırlıklandırma katsayısının zamanla değişecek şekilde belirlenmesi gerekir. Bununla ilgili olarak kısıtlı çalışmalar olmasına rağmen (Cho ve diğ. 1991) bu konu şu an itibari ile halâ açık bir problem olarak durmaktadır. Bu nedenle bu tez çalışmasındaki benzetime dayalı karşılaştırmalarda Tablo 3.2'de tanımlanan RLS algoritması $\lambda < 1$ seçimi yapılarak gerçekleştirilmiştir.

3.2.2 Deterministik yöntem: Baz fonksiyonu gösterimi ile TVAR modelleme

Saf stokastik uygulamalar için uygun olmalarına rağmen ani değişimler içeren dinamikleri modellemede yetersiz kalmaları ve hesapsal karmaşılığın fazla olması uyarlamalı yöntemlerin kullanımını kısıtlayan etkenlerdir.

Uyarlamalı yöntemlerin aksine deterministik yöntemde TVAR model parametrelerine, önceden belirlenmiş zamanla değişen baz fonksiyonlarının ağırlıklandırılmış doğrusal birleşimi ile yaklaşılır. Buna göre, (1.1) ile tanımlanan gösterimde TVAR model parametrelerine

$$a_i(n) = \sum_{j=0}^{m-1} b_{i,j} \phi_j(n) \quad (3.5)$$

ile yaklaşılır. Burada $\{\phi_j(n) | j = 0, 1, \dots, m-1\}$, baz fonksiyonu kümesi olarak adlandırılan ve zamanın işlevi olan deterministik fonksiyon ailesi olup; $\{b_{i,j} | j = 0, 1, \dots, m-1\}$, bu baz fonksiyonlarına ilişkin ağırlık katsayılarına karşı düşer. (3.5) ile yapılan yaklaşırma sayesinde TVAR model parametrelerinin kestirimi problemi, önceden tanımlanmış baz fonksiyonlarının zamanla değişmeyen ağırlık katsayılarının tanımlanması problemine indirgenir. Bu katsayılar (1.1) eşitliğine dayalı olarak

$$e(n) = x(n) - \hat{x}(n) \quad (3.6)$$

ile tanımlanan öngörü (modelleme) hatasının enerjisini en küçükleyerek elde edilebilir. Burada $\hat{x}(n)$, $x(n)$ 'nin p . mertebeden doğrusal öngörüsü (kestirimi) olup TVAR model parametreleri cinsinden

$$\hat{x}(n) = \sum_{i=1}^p a_i(n)x(n-i) \quad (3.7)$$

ile ifade edilir.

Önerilen iteratif algoritmada da kullanılacağından dolayı baz fonksiyonu gösterimi temellinde TVAR model parametrelerinin kestirimi için yapılacak türetimler, başlangıçta sırasıyla TVAR model mertebesi ve baz fonksiyonlarının sayısına karşı düşen keyfi p ve m değerleri için verilecektir. Buna göre, eşdeğer olarak, (3.5) eşitliği vektör gösteriminde aşağıdaki gibi yeniden ifade edilebilir:

$$a_i(n) = \boldsymbol{\phi}^{(m)T}(n)\mathbf{b}_i^{(p,m)} \quad (3.8)$$

Burada,

$$\boldsymbol{\phi}^{(m)}(n) = [\phi_0(n), \phi_1(n), \dots, \phi_{m-1}(n)]^T, \quad (3.9)$$

$$\mathbf{b}_i^{(p,m)} = [b_{i,0}, b_{i,1}, \dots, b_{i,m-1}]^T \quad (3.10)$$

ile tanımlıdır. (3.9) ve (3.10) eşitliklerindeki vektörler m uzunluklu sütun vektörleridir. (3.8) eşitliği (3.7)'de yerine konursa

$$\hat{x}(n) = \boldsymbol{\varphi}^{(p,m)T}(n)\mathbf{b}^{(p,m)} \quad (3.11)$$

yazılabilir. Burada,

$$\boldsymbol{\varphi}^{(p,m)}(n) = [\boldsymbol{\phi}^{(m)T}(n)x(n-1) \quad \boldsymbol{\phi}^{(m)T}(n)x(n-2) \quad \dots \quad \boldsymbol{\phi}^{(m)T}(n)x(n-p)]^T \quad (3.12)$$

$$\mathbf{b}^{(p,m)} = [\mathbf{b}_1^{(p,m)T} \quad \mathbf{b}_2^{(p,m)T} \quad \dots \quad \mathbf{b}_p^{(p,m)T}]^T \quad (3.13)$$

ile tanımlıdır. Dikkat edilirse (3.12) ve (3.13) eşitliklerindeki mp uzunluklu sütun vektörleri (3.9) ve (3.10)'daki sütun vektörlerini kullanarak oluşturulur. (3.13) eşitliği ile tanımlanan sütun vektörü kestirilecek olan katsayıları içerir.

Buna göre (3.11) eşitliğinin $n = 1, 2, \dots, N-1$ için değerlendirilmesi durumunda mp bilinmeyenli $N-1$ denklemeden oluşan aşağıdaki doğrusal denklem sistemine ulaşılır:

$$\hat{\mathbf{x}}^{(p,m)} = \boldsymbol{\varphi}^{(p,m)T} \mathbf{b}^{(p,m)} \quad (3.14)$$

Burada,

$$\hat{\mathbf{x}}^{(p,m)} = [\hat{x}(1) \quad \hat{x}(2) \quad \dots \quad \hat{x}(N-1)]^T \quad (3.15)$$

ve

$$\boldsymbol{\varphi}^{(p,m)} = [\boldsymbol{\varphi}^{(p,m)}(1) \quad \boldsymbol{\varphi}^{(p,m)}(2) \quad \dots \quad \boldsymbol{\varphi}^{(p,m)}(N-1)] \quad (3.16)$$

ile tanımlıdır. (3.15) eşitliği herhangi bir p ve m ile asıl verinin bir kestirimine karşı düşerken; (3.16) eşitliği $mp \times (N-1)$ büyüklüklü bir dikdörtgen matrise karşı düşer.

Benzer şekilde (3.6) eşitliğinin $n = 1, 2, \dots, N-1$ için değerlendirilmesi ile öngörü hatası ile ilgili olarak aşağıdaki vektör gösterimine ulaşılır:

$$\mathbf{e}^{(p,m)} = \mathbf{x} - \hat{\mathbf{x}}^{(p,m)} \quad (3.17)$$

Burada

$$\mathbf{x} = [x(1) \quad x(2) \quad \dots \quad x(N-1)]^T \quad (3.18)$$

ile tanımlı $N-1$ uzunluklu sütun vektörü olup modellenmek istenen veriye ilişkin örnek değerlerinden oluşur.

TVAR model parametrelerinin ve incelenen veriye ilişkin örnek değerlerinin kestirimini gerçekleştirmek için öncelikle (3.13) ile tanımlanan bilinmeyen katsayı vektörünün kestirimini elde etmek gerekir. Bunun için izlenecek olan yollardan birisi (3.17) eşitliği ile verilen öngörü hata vektörünün enerjisine karşı düşen

$$J(\mathbf{b}^{(p,m)}) = \|\mathbf{e}^{(p,m)}\|^2 = \mathbf{e}^{(p,m)T} \mathbf{e}^{(p,m)} \quad (3.19)$$

bedel fonksiyonunu en küçükleyecek şekilde $\mathbf{b}^{(p,m)}$ 'in elde edilmesini sağlamaktır. En küçükleme işlemi,

$$\frac{\partial J(\mathbf{b}^{(p,m)})}{\partial \mathbf{b}^{(p,m)T}} = 0 \quad (3.20)$$

hesabı ile gerçekleştirilir. Buna göre, (3.14) eşitliğinin (3.17)'de kullanılması ile

oluşturulan öngörü hata vektörü gösterimini (3.19)'da kullanarak bedel fonksiyonu aşağıdaki gibi ifade edilebilir:

$$\begin{aligned} J(\mathbf{b}^{(p,m)}) &= [\mathbf{x} - \boldsymbol{\varphi}^{(p,m)T} \mathbf{b}^{(p,m)}]^T [\mathbf{x} - \boldsymbol{\varphi}^{(p,m)T} \mathbf{b}^{(p,m)}] \\ &= \mathbf{x}^T \mathbf{x} - \mathbf{x}^T \boldsymbol{\varphi}^{(p,m)T} \mathbf{b}^{(p,m)} - \mathbf{b}^{(p,m)T} \boldsymbol{\varphi}^{(p,m)} \mathbf{x} + \mathbf{b}^{(p,m)T} \boldsymbol{\varphi}^{(p,m)} \boldsymbol{\varphi}^{(p,m)T} \mathbf{b}^{(p,m)} \end{aligned} \quad (3.21)$$

(3.21) eşitliğini (3.20)'de kullanarak bilinmeyen katsayı vektörünün kestirimine ilişkin

$$\mathbf{b}^{(p,m)} = [\boldsymbol{\varphi}^{(p,m)} \boldsymbol{\varphi}^{(p,m)T}]^{-1} \boldsymbol{\varphi}^{(p,m)} \mathbf{x} \quad (3.22)$$

sonucuna ulaşılır. Katsayı vektörü ile ilgili olarak çözümün tekliğini garantilemek için (3.22) eşitliğindeki matris tersi *Tekil değer ayrıştırması*'na dayalı olarak hesaplanır. Bu çerçevede matris tersi için MATLAB'in `pinv` gömülü fonksiyonundan faydalanılmıştır.

Böylece (3.22) eşitliği ile elde edilen kestirim sonucunu (3.14) eşitliğinde yerine koyarak $n = 1, 2, \dots, N - 1$ için $x(n)$ 'nin kestirimine ulaşılmış olur.

Son olarak (3.8) ile tanımlanan TVAR model parametrelerini elde etmek amacıyla $i = 1, 2, \dots, p$ için (3.10) eşitliğine karşı düşen $\mathbf{b}_i^{(p,m)}$ vektörleri, (3.22) eşitliğinden elde edilen değerleri kullanarak aşağıdaki gibi oluşturulur:

$$\mathbf{b}_i^{(p,m)} = [\mathbf{b}^{(p,m)}(k) \quad \mathbf{b}^{(p,m)}(k+1) \quad \dots \quad \mathbf{b}^{(p,m)}(l)]^T \quad (3.23)$$

Burada $i = 1, 2, \dots, p$ için $k = (i-1)m + 1$ ve $l = im$ olup $\mathbf{b}^{(p,m)}(k)$, $\mathbf{b}^{(p,m)}$ vektörünün k . değerini ifade eder.

Böylece (3.8) ve (3.23) eşitliklerini göz önünde bulundurarak $n = 1, 2, \dots, N - 1$ için TVAR model parametreleri herhangi bir p ve m değeri için

$$\mathbf{a}_i^{(p,m)} = \boldsymbol{\Phi}^{(m)T} \mathbf{b}_i^{(p,m)}; \quad i = 1, 2, \dots, p \quad (3.24)$$

Burada,

$$\mathbf{a}_i^{(p,m)} = [a_i(1), a_i(2), \dots, a_i(N-1)]^T \quad (3.25)$$

ve

$$\Phi^{(m)} = [\Phi^{(m)}(1), \Phi^{(m)}(2), \dots, \Phi^{(m)}(N - 1)], \quad (3.26)$$

ile tanımlıdır.

(3.5)-(3.26) eşitlikleri ile verilen baz fonksiyonu gösterimine dayalı TVAR modelleme yönteminin esasını oluşturan kısım baz fonksiyonu seçimidir. Literatürde yaygın olarak kullanılan baz fonksiyonları; düşük dereceli polinomlar (Nathan ve diğ. 1991), derecesi isteğe bağlı seçilen polinomlar (Rao 1970), Legendre polinomları (Kozin 1977), Chebyshev polinomları (Pachori ve Sircar 2008), Walsh fonksiyonu (Chon ve diğ. 2005), Taylor serileri açılımı (Conforto ve D'Alessio 1999), ayrık kosinüs fonksiyonu (Eom 2000), sinüzoidal (Fourier) fonksiyonlar (Ijima ve Grivel 2012), (Pachori ve Sincar 2008) olarak göze çarpmaktadır.

Durağan olmayan işaretin doğasına göre TVAR model gösteriminde tercih edilecek baz fonksiyonu değişiklik gösterir. Legendre polinomları, Chebyshev polinomları, sinüzoidal fonksiyonlar ve ayrık kosinüs fonksiyonu yavaş ve yumuşak değişimler gösteren işaretleri modellemede kullanılırken; Walsh ve Haar fonksiyonları, ani ve hızlı değişimler içeren işaretlerin TVAR gösteriminde iyi sonuçlar ürettiği bilimsel bulgularla doğrulanmıştır. Baz fonksiyonlarının matematiksel ifadeleri Tablo 3.3'de verilmiştir.

3.2.3 Önerilen yöntem: Baz fonksiyonu gösterimi temelinde iteratif TVAR modelleme

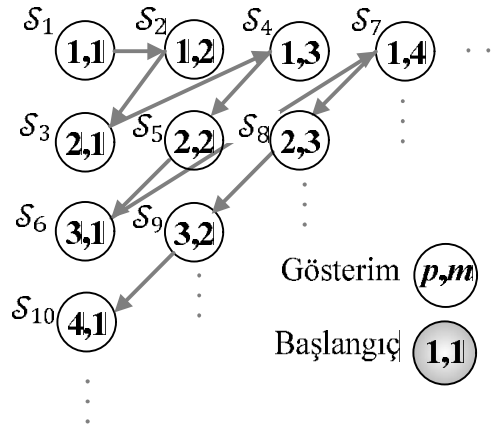
Bir önceki alt bölümde TVAR model parametrelerinin kestirimi amacıyla (3.5)-(3.26) eşitlikleri keyfi p ve m değerleri için türetilmiştir. Diğer taraftan, TVAR model ile durağan olmayan verinin yeterince doğru bir biçimde modellenebilmesi ve dolayısıyla veriye ilişkin zaman-sıklık haritasının olabildiğince anlamlı elde edilebilmesi, TVAR model mertebesi p 'ye ve kullanılan baz fonksiyonu sayısı m 'ye bağlıdır. Literatürde mevcut olan çalışmalarda p ve m , ya sezgisel olarak belirlenmiş ya da AIC ve MDL gibi bilgi ölçütlerine dayalı olarak elde edilmeye çalışılmıştır. Ancak p ve m 'nin bu yolla belirlenmesi özellikle gerçek zamanlı uygulamalar için pek kullanışlı değildir. Çünkü bu yolla p ve m 'nin değerleri, ya deneme yanılma ya da önceden belirlenen bir değer aralığı üzerinden bilgi ölçütünü en küçükleyen p ve m değerlerinin araştırması yapılarak belirlenmektedir.

Tablo 3.3: Baz fonksiyonu gösterimi temelinde TVAR modelleme için kullanılacak baz fonksiyonları

Baz fonksiyonu	Matematiksel gösterim
	$n = 0, 1, 2, \dots, N - 1; k = 0, 1, \dots, m - 1$
Chebyshev	$\phi_k(n) = \cos \left[k \cos^{-1} \left(\frac{2n}{N-1} - 1 \right) \right]$
Ayrık Kosinüs dönüşümü	$\phi_k(n) = \sqrt{\frac{1 + \text{sgn}(n)}{N}} \cos \left[\frac{\pi k (2n + 1)}{2N} \right]$
Fourier serisi	$\phi_k(n) = \begin{cases} \cos \left(\frac{\pi n k}{N-1} \right); & k = 0, 2, 4, \dots \\ \sin \left(\frac{\pi n k}{N-1} \right); & k = 1, 3, 5, \dots \end{cases}$
Legendre	$\phi_0(n) = 1; \quad \phi_1(n) = \frac{2n}{N-1} - 1$ $\phi_{k+1}(n) = \left[\frac{(2n - N + 1)(2k + 1)}{(N-1)(k+1)} \right] \phi_k(n) - \frac{k}{k+1} \phi_{k-1}(n), k \geq 1$
Walsh	$\phi_k(n) = \prod_{r=0}^{s-1} \text{sgn} \left[\cos \left(\frac{\pi n k_r 2^r}{N-1} \right) \right], \quad k = \sum_{r=0}^{s-1} k_r 2^r$ $(k$ 'nın değerine göre $k_r = 0$ veya 1 olarak belirlenir)
Haar	$\phi_0(n) = 1$ $\phi(n) = \begin{cases} 1, & n \in [0, \text{fix}(N-1)/2] \\ -1, & n \in [N/2, N-1] \\ 0, & \text{diğer} \end{cases}$ $\phi_k(n) = 2^{l/2} \phi \left(\frac{n 2^l}{N-1} - z \right); \quad k = 1, 2, \dots, m - 1$ $l = \text{fix}(\log_2 k), \quad z = k - 2^l$
	$\text{sgn}[x] = \begin{cases} 1, & x > 0 \\ 0, & x = 0 \\ -1, & x < 0 \end{cases} \quad \text{fix}(x): x$ 'in tamsayı kısmı

Bu tez çalışmasında, normalize edilmiş öngörü hata enerjisini dikkate alarak p ve m 'nin değerini belirleyen ve beraberinde TVAR model parametrelerinin ve işaretin kestirimini etkin bir biçimde elde eden bir yöntem önerilmektedir.

p ve m 'nin uygun değerleri ile TVAR model parametrelerini ve $n = 1, 2, \dots, N - 1$ için verilen durağan olmayan işaret $x(n)$ 'nin bir kestirimini elde etmek için bir önceki alt bölümde türetilen (3.5)-(3.26) eşitlikleri, normalize öngörü hata enerjisi (NPEE) temelinde p ve m 'nin değerlerini Şekil 3.5'deki gösterime göre güncelleyerek kullanılır.



Şekil 3.5 : p ve m için güncelleme şeması.

Güncelleme işlemine p ve m 'nin değerlerinin 1 alınmasıyla başlanır. Buna ek olarak, Şekil 3.5'deki güncelleme şemasında S_l , ilgili p ve m değerlerini temsil eden l . duruma karşı düşer.

Şekil 3.5'deki gösterimi dikkate alarak p ve m 'nin değerlerini güncellemede kullanılan ölçüt olan NPEE, (3.17) eşitliği ile tanımlanan hata vektörünü kullanarak S_l durumu için aşağıdaki gibi verilir:

$$E^{(S_l)} = \frac{1}{N-1} \|\mathbf{e}^{(p,m)}\|^2; \quad l = 1, 2, \dots \quad (3.27)$$

Önerilen yöntem çerçevesinde eğer ardışık iki duruma ilişkin NPEE'lerin mutlak farkı önceden tanımlanan ε gibi bir eşik değerden büyükse güncelleme işlemine devam edilir. Aksi durumda algoritmanın koşumu sona erdirilir ve S_l durumuna karşı düşen p ve m 'nin değerleri en uygun değerler olarak belirlenmiş olur.

Sonuç olarak, belirlenen baz fonksiyonu üzerinden durağan olmayan N örnekli

verinin son $N - 1$ örneğinin TVAR modellemesi için önerilen iteratif algoritma adımları aşağıdaki gibi özetlenebilir:

Adım 1. $l = 1$ için algoritmanın koşumuna \mathcal{S}_l durumuyla başlanır. Bu durumda $(p, m) = (1, 1)$.

Adım 2. (3.9) ve (3.12) eşitliklerinden faydalanarak oluşturulan (3.16) eşitliğindeki $\varphi^{(p,m)}$ matrisini ve (3.18)'deki \mathbf{x} vektörünü kullanarak bilinmeyenler vektörü $\mathbf{b}^{(p,m)}$ (3.22) eşitliği ile elde edilir.

Adım 3. (3.22) ile elde edilen kestirim vektörünün (3.16) eşitliği ile oluşturulan matris ile birlikte (3.14) eşitliğinde kullanılmasıyla $n = 1, 2, \dots, N - 1$ için \mathbf{x} 'in kestirimine karşı düşen $\hat{\mathbf{x}}^{(p,m)}$ vektörü elde edilir. Sonrasında (3.17) ile tanımlanan öngörü hata vektörü $\mathbf{e}^{(p,m)}$ 'e ulaşılır.

Adım 4. Öngörü hata vektörü $\mathbf{e}^{(p,m)}$ 'i (3.27)'de kullanarak \mathcal{S}_l durumu için $E^{(\mathcal{S}_l)}$ NPEE değeri hesaplanır.

Adım 5. $l \leftarrow l + 1$ için Şekil 3.5'deki düzende ilgili p ve m değerleri ile \mathcal{S}_l durumuna geçiş yapılır.

Adım 6. Adım 2-4'deki işlemler tekrarlanır ve $E = |E^{(\mathcal{S}_{l-1})} - E^{(\mathcal{S}_l)}|$ hesabı yapılır.

Adım 7. Önceden belirlenen sıfıra yakın bir ε değeri için eğer $E > \varepsilon$ ise bu durumda Adım 5'e geri dönülür. Aksi takdirde \mathcal{S}_{l-1} durumuna karşı düşen p ve m değerleri uygun değerler olarak belirlenir.

Adım 8. Adım 7'de belirlenen p ve m değerlerine karşı düşen $\mathbf{b}^{(p,m)}$ vektörünü kullanarak $\mathbf{b}_i^{(p,m)}$ vektörü $i = 1, 2, \dots, p$ için (3.23) eşitliğindeki gibi oluşturulur. Buna ek olarak (3.9) eşitliğinden faydalanarak (3.26) ile $\Phi^{(m)}$ matrisi elde edilir.

Adım 9. Adım 8'deki matris ve vektör ifadelerini (3.24)'de yerine koyarak $i = 1, 2, \dots, p$ için (3.25) eşitliği ile tanımlanan TVAR model katsayılarının kestirimine ulaşılır.

Açıklama 3.1: p ve m 'nin değerlerini AIC ve MDL gibi bilgi ölçütlerine dayalı olarak belirlemeye çalışan mevcut yöntemlerden farklı olarak önerilen yöntemde p ve m için başlangıçta bir değer aralığının belirlenmesine gerek duyulmaz. AIC veya MDL'nin kullanılması durumunda, p ve m için önceden belirlenmiş değer aralığı

üzerinden bu aralıkta p ve m 'nin tüm kombinasyonlarına karşı düşen AIC veya MDL değerleri hesaplanır ve en küçük değeri sağlayan p ve m kombinasyonu uygun p ve m değerleri olarak belirlenir. Diğer taraftan belirlenen aralığın dışında olma ihtimali göz önünde bulundurulduğunda p ve m 'nin belirlenmesi için izlenen bu yolun yeterince verimli olmayacağı ihtimal dahilindedir.

Açıklama 3.2: Zamanla değişen işaretin doğru bir biçimde modellenmesi ve zaman-sıklık haritasının işaret davranışı ile ilgili bilgiyi olabildiğince doğru biçimde yansıtılması, TVAR modellemenin uygun p ve m değerleri ile gerçekleştirilmesine bağlıdır. (3.17) ile tanımlanan öngörü hata vektörünün enerjisini ciddi bir biçimde azaltan parametre değerlerini sağlayan p ve m 'nin belirlenmesi önerilen yöntemin ana fikrini oluşturmaktadır. Bu bağlamda ardışık iki duruma karşı düşen NPEE'lerin farkının mutlak değeri, $E = |E^{(\mathcal{S}_{l-1})} - E^{(\mathcal{S}_l)}|$, değerlendirilmiştir. Önceden belirlenen sifıra yakın bir ε değeri için $E < \varepsilon$ olduğunda p ve m için uygun değer arama işlemi sonlandırılmakta ve zamanla değişen veriyi temsil eden TVAR modele ulaşılmaktadır.

Kestirilen TVAR model parametreleri üzerinden zamanla değişen işarete ilişkin zaman-sıklık değerlendirmesi

$$P(n, f) = \frac{\sigma_e^2}{|1 - \sum_{i=1}^p a_i(n) e^{-j2\pi i f / f_s}|^2} \quad (3.28)$$

ile tanımlanan zamanla değişen güç izge yoğunluk fonksiyonu (PSD) ifadesinden $n = 1, 2, \dots, N - 1$ ve $f = [0, f_s/2]$ için oluşturulan haritaya dayalı olarak gerçekleştirilir. (3.28) eşitliğinde σ_e^2 , (3.17) eşitliği ile elde edilen öngörü hatasının varyansı olup f_s örnekleme frekansını ifade eder.

4. BENZETİM SONUÇLARI

Bu bölümde önerilen yöntemin başarımı, birbirinden farklı zamanla değişen üç işaret üzerinden STFT ve RLS yöntemlerine göre değerlendirilmektedir. Değerlendirme işlemi, incelenen her bir zamanla değişen işarete ilişkin örnek sayısını (N) ve örnekleme frekansını (f_s) dikkate alarak $n = 1, 2, \dots, N - 1$ ve $f = [0, f_s/2]$ için (3.28) tanımı ile oluşturulan işaretlerin PSD'leri üzerinden görsel olarak yapılmaktadır. RLS yönteminde δ ve λ parametreleri $\delta = 0.0002$ ve $\lambda = 0.95$ olarak alınmıştır. STFT yönteminde ise pencere büyüklüğü 200 olan Hamming penceresi kullanılmıştır.

Örnek 1. Bu örnekte zamanla değişen katsayıları,


$$a_1(n) = \begin{cases} 2 \cos(2\pi \times 0.3), & n = 1, 2, \dots, 333 \\ 2 \cos \left[2\pi \left(0.15 - 0.1 \sin \left(2\pi \frac{n - 333}{N - 333} \right) \right) \right], & n = 334, \dots, N - 1 \end{cases}$$
$$a_2(n) = -1, \quad n = 1, \dots, N - 1$$

olan ikinci mertebeden bir TVAR modeli temsilen (1.1) eşitliğinde $p = 2$ olarak $N=1001$ ile $n = 0, 1, \dots, N - 1$ için

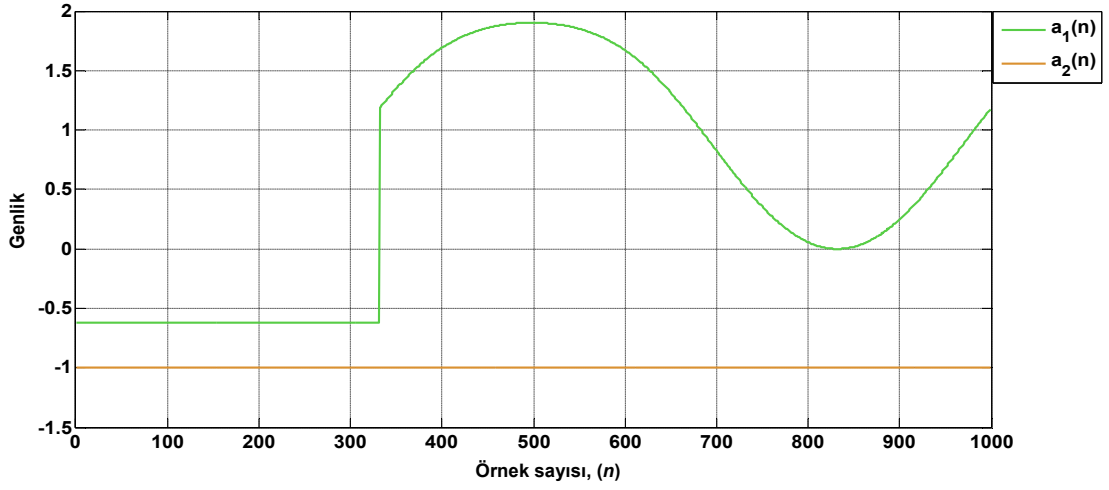
$$x(n) = a_1(n)x(n - 1) + a_2(n)x(n - 2) + e(n)$$

fark denkleminde yapay olarak üretilen 1 sn süreli verinin zaman-sıklık modellenmesi incelenmektedir.

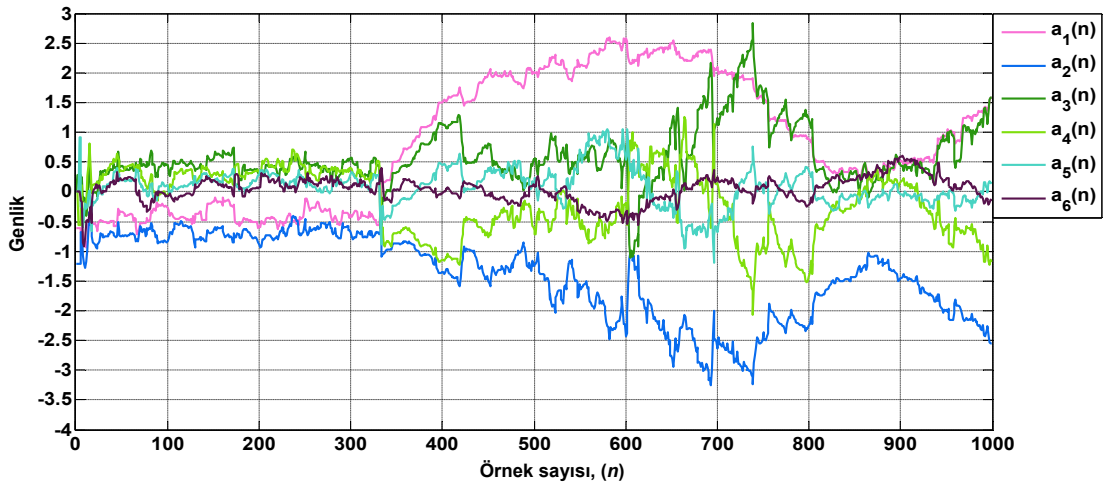
TVAR rasgele işaretinin bir gerçekleşmesinin değişimi ve bu işarete karşı düşen RLS ve önerilen yöntem ile elde edilen kestirim sonuçları Şekil 4.1'de gösterilmiştir. Şekil 4.1b ve Şekil 4.1c'deki işaret kestirimlerini üreten RLS ve önerilen yöntemler ile bulunan TVAR model katsayılarının değişimi ise Şekil 4.2'de verilmiştir. TVAR rasgele işaretinin bir gerçekleşmesinin PSD görüntüsü ve STFT, RLS ve önerilen yöntemle ulaşılan PSD kestirim sonuçları Şekil 4.3'de görüntülenmiştir.




Şekil 4.1: TVAR rasgele işaretinin bir gerçekleşmesi; (a) Asıl işaret, (b) RLS yöntemiyle elde edilen kestirim sonucu, (c) Önerilen yöntem ile elde edilen kestirim sonucu.



(a)




(b)



(c)

Şekil 4.2: TVAR rasgele işaretini üreten TVAR model katsayıları; (a) Asıl katsayılar, (b) RLS yöntemiyle üretilen katsayılar, (c) Önerilen yöntem ile üretilen katsayılar.



Şekil 4.3: Örnek 1'deki işaret için PSD sonuçları; (a) Asıl işaret, (b) STFT, (c) RLS, (d) Önerilen yöntem.

Şekil 4.1 ve Şekil 4.3’de RLS yöntemiyle bulunan kestirim sonuçları önerilen yöntemin ürettiği TVAR model mertebesi ile elde edilmiştir. Dikkat edilirse asıl işaret ikinci mertebeden bir TVAR modele karşı düşerken önerilen yöntemle fazladan dört adet TVAR model katsayısı üretilmiştir. Yani, önerilen yöntem Şekil 4.1 ve Şekil 4.3’deki kestirim sonuçlarına $\varepsilon = 10^{-3}$ seçimi ile otomatik olarak bulunan $p = 6$ ve $m = 11$ değerleri üzerinden ulaşmıştır. Burada baz fonksiyonu olarak Legendre fonksiyon ailesi kullanılmıştır. TVAR model katsayısı aslına nazaran büyük bulunmasına rağmen önerilen yöntem ile asıl işaret kestirimine daha çok yaklaşıldığı Şekil 4.1’deki kestirim hatası çiziminden görülebilir. Ayrıca Şekil 4.3’de verilen PSD kestirimleri de bu düşüncüyü desteklemektedir. TVAR model mertebesinin aslından büyük olarak belirlenmesi yan loblar oluşturmaya rağmen, önerilen yöntem ile zaman ve frekans çözünürlüğü STFT ve RLS’ye nazaran daha iyi olan sonuçlara ulaşılmıştır. Yan loblar, önerilen yöntem ile bulunan PSD’yi ciddi bir biçimde etkilememektedir. Dikkat edilirse Şekil 4.2’de önerilen yöntem ile $k > 2$ için fazladan elde edilen $\{a_k(n)\}$ TVAR model katsayıları sıfır civarında değişim gösteren ortalaması yaklaşık olarak sıfır olan salınımlardan oluşmaktadır. Diğer taraftan, yan lobların etkisi RLS’de daha da göze çarpmaktadır.


Örnek 2. Bu örnek çerçevesinde farklı genlik ve frekanslara sahip sinüzoidal işaretlerin birleşiminden oluşan iki farklı süreye sahip sürekli-zamanlı bir $x(t)$ işaretinin $f_s = 400$ Hz’de $t = nT$ ile örneklenmesi sonucu ayrık-zamanlı hale getirilmesi sonrasında zaman-sıklık değerlendirme yapılmıştır. Burada T örnekleme aralığı olup $T = 1/f_s$ ile tanımlıdır.

Durum 1: Sürekli-zamanlı $x(t)$ işaretinin aşağıdaki gibi tanımlanan 1 sn süreli durumu üzerinde çalışılmaktadır.

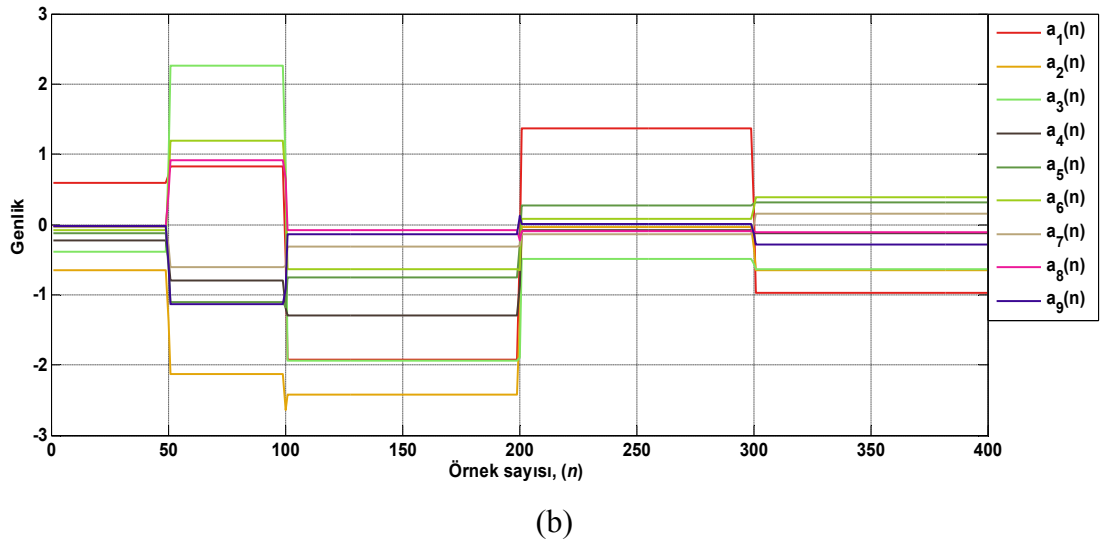
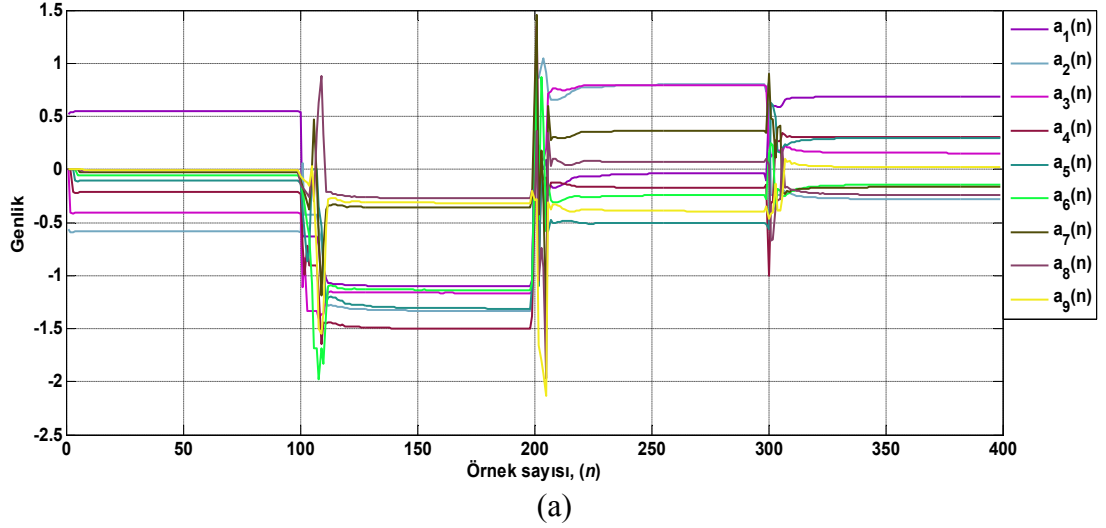
$$x(t) = \begin{cases} 0.15\cos(2\pi \times 60t), & 0 \leq t < 0.25 \text{ sn} \\ 0.15\cos(2\pi \times 120t) - 0.25\sin(2\pi \times 160t), & 0.25 \leq t < 0.5 \text{ sn} \\ -0.25\cos(2\pi \times 12t), & 0.5 \leq t < 0.75 \text{ sn} \\ 0.15\cos(2\pi \times 80t), & 0.75 \leq t \leq 1 \text{ sn} \end{cases}$$

Sonuç olarak değerlendirilen ayrık-zamanlı $x(n)$ işareti $N=401$ örnekten oluşmaktadır. $x(n)$ işaretinin değişimi ve bu işarete karşı düşen RLS ve önerilen yöntem ile elde edilen kestirim sonuçları Şekil 4.4’de gösterilmiştir. Şekil 4.4b ve Şekil 4.4c’deki işaret kestirimlerini sağlayan RLS yönteminin ve önerilen yöntemin

ürettiği TVAR model katsayıları Şekil 4.5’de verilmiştir. STFT, RLS ve önerilen yöntemle elde edilen PSD sonuçları Şekil 4.6’de görüntülenmiştir.



Şekil 4.4: Örnek 2’de Durum 1’e karşı düşen işaret; (a) Asıl işaret, (b) RLS yöntemiyle elde edilen kestirim sonucu, (c) Önerilen yöntem ile elde edilen kestirim sonucu.




Şekil 4.5: Örnek 2’de Durum 1’e karşı düşen işaretin TVAR modellemesi; (a) RLS yöntemiyle üretilen TVAR model katsayıları, (b) Önerilen yöntem ile üretilen TVAR model katsayıları.

Durum 2: Sürekli-zamanlı $x(t)$ işaretinin aşağıdaki gibi tanımlanan 4 sn süreli durumu incelenmektedir.

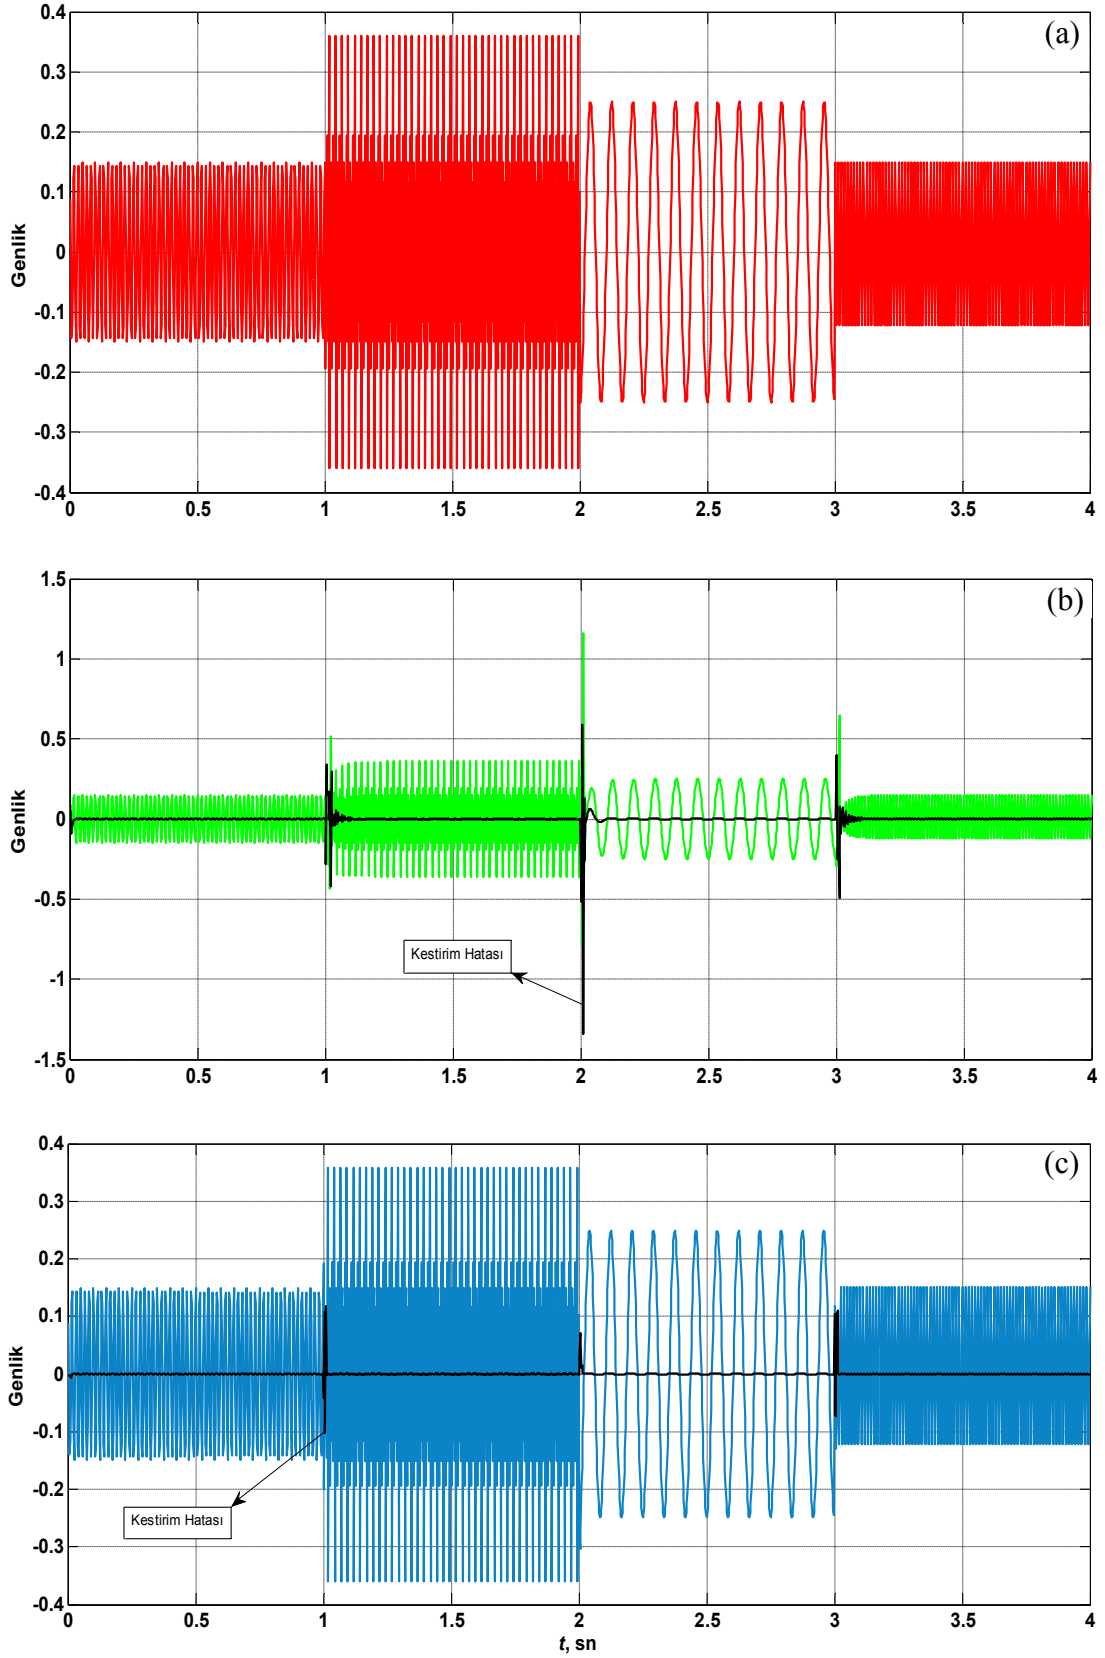
$$x(t) = \begin{cases} 0.15\cos(2\pi \times 60t), & 0 \leq t < 1 \text{ sn} \\ 0.15\cos(2\pi \times 120t) - 0.25\sin(2\pi \times 160t), & 1 \leq t < 2 \text{ sn} \\ -0.25\cos(2\pi \times 12t), & 2 \leq t < 3 \text{ sn} \\ 0.15\cos(2\pi \times 80t), & 3 \leq t \leq 4 \text{ sn} \end{cases}$$

Sonuç olarak değerlendirilen ayrık-zamanlı $x(n)$ işareti $N=1601$ örnekten oluşmaktadır.

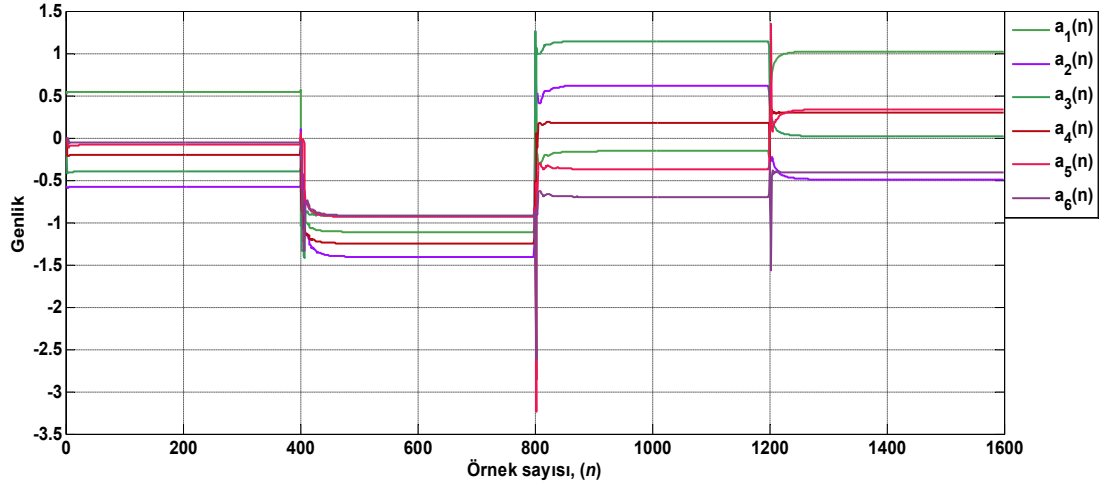


Şekil 4.6: Örnek 2’de Durum 1’e karşı düşen işaret için PSD sonuçları; (a) STFT, (b) RLS, (c) Önerilen yöntem.

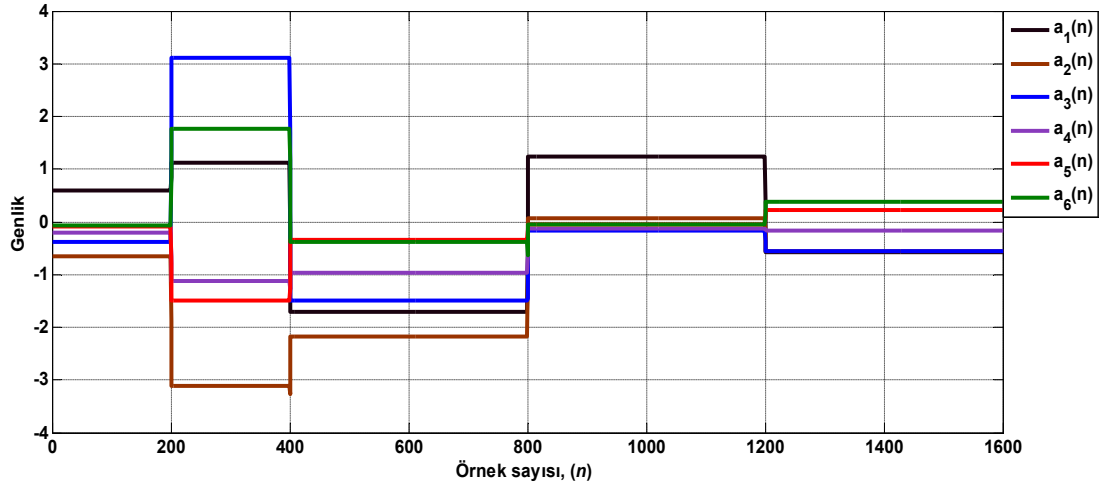
Durum 2 kapsamında ele alınan $x(n)$ işaretinin değişimi ve bu işarete karşı düşen RLS ve önerilen yöntem ile elde edilen kestirim sonuçları Şekil 4.7’de gösterilmiştir. Şekil 4.7b ve Şekil 4.7c’deki işaret kestirimlerini sağlayan RLS yönteminin ve önerilen yöntemin ürettiği TVAR model katsayıları Şekil 4.8’de verilmiştir. STFT, RLS ve önerilen yöntemle elde edilen PSD sonuçları ise Şekil 4.9’da görüntülenmiştir.



Şekil 4.7: Örnek 2’de Durum 2’ye karşı düşen işaret; (a) Asıl işaret, (b) RLS yöntemiyle elde edilen kestirim sonucu, (c) Önerilen yöntem ile elde edilen kestirim sonucu.




(a)



(b)

Şekil 4.8: Örnek 2’de Durum 2’ye karşı düşen işaretin TVAR modellemesi; (a) RLS yöntemiyle üretilen TVAR model katsayıları, (b) Önerilen yöntem ile üretilen TVAR model katsayıları.

Örnek 1’de olduğu gibi Şekil 4.4, Şekil 4.6, Şekil 4.7 ve Şekil 4.9’da RLS yöntemiyle bulunan kestirim sonuçları önerilen yöntemin ürettiği TVAR model mertebesi ile elde edilmiştir. Her iki durumda incelenen işaretler için önerilen yöntem ile elde edilen kestirim sonuçlarına $\varepsilon = 10^{-6}$ seçimi ve baz fonksiyonu olarak Haar fonksiyon ailesinin kullanımı ile ulaşılmıştır. Bu bağlamda Durum 1’deki işaret için $p = 9$ ve $m = 5$ olarak elde edilirken Durum 2’deki işaret için $p = 6$ ve $m = 5$ olarak bulunmuştur. Şekil 4.6’daki sonuçlardan görüldüğü üzere örnek sayısının azlığından dolayı STFT yöntemi elde edilen PSD kestiriminde zaman bilgisinin kaybolduğu ve frekans çözünürlüğünün düşük olduğu görülmektedir.



Şekil 4.9: Örnek 2’de Durum 2’ye karşı düşen işaret için PSD sonuçları; (a) STFT, (b) RLS, (c) Önerilen yöntem.

Diğer taraftan parametrik (RLS ve önerilen) yöntemlerle STFT’ye nazaran daha iyi sonuçlara ulaşılmıştır. RLS ve önerilen yöntem ile elde edilen PSD kestirimleri (Şekil 4.6b ve Şekil 4.6c) karşılaştırıldığında RLS’ye nazaran önerilen yöntem ile

hem zaman hem de frekans çözünürlüğü anlamında tatminkâr sonuçlar söz konusudur. Şekil 4.4’de verilen işaret kestirim sonuçları da bu düşünceyi destekler niteliktedir. İşaret süresi dolayısıyla işaret örnek sayısının arttırıldığı Durum 2’de incelenen işaret için STFT yönteminin başarımında beklendiği üzere artış sağlanmıştır. Şekil 4.6a ve Şekil 4.9a’daki PSD görüntülerinden bunu görebilmek mümkündür —Durum 2’de incelenen işaret için frekans bilgisinin yanında zaman bilgisinin de Durum 1’dekine nazaran daha iyi yakalandığı görülmektedir. Ancak yine de frekans değişimlerinin başladığı ve bittiği anlar anlamında bir kesinlik mevcut değildir. Benzer durum RLS ile elde edilen PSD kestiriminde de söz konusudur (Şekil 4.9b). Diğer taraftan frekans çözünürlüğü olarak RLS en iyi sonucu vermesine rağmen önerilen yöntem ile hem zaman hem de frekans olarak kabul edilebilir PSD kestirimine ulaşılmıştır (Şekil 4.9c).


Örnek 3. Bu örnekte $t = 1$ sn anında 150 Hz ani frekansında kesişen 2 sn süreli iki chirp işaretin birleşiminden oluşan zamanla değişen işaretin modellenmesi ve zaman-sıklık değerlendirilmesi üzerinde durulmuştur. İncelenen sürekli-zamanlı işaretin matematiksel ifadesi aşağıdaki gibi tanımlıdır:

$$x(t) = \cos(150\pi t^2) + \cos(150\pi t^2 - 600\pi t + 600\pi), \quad 0 \leq t \leq 2 \text{ sn}$$

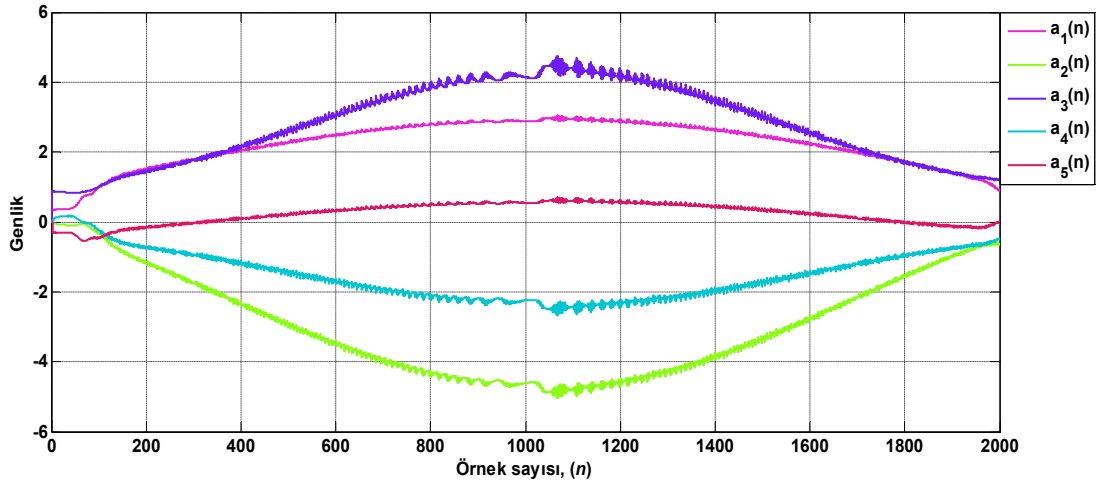
$x(t)$ işaretinin $f_s = 1$ kHz’de $t = nT$ ile örneklenmesi sonucu ayrık-zamanlı hale getirilen işaret üzerinde çalışılmıştır. Burada T örnekleme aralığı olup $T = 1/f_s$ ile tanımlıdır.

İncelenen işaretin değişimi ve bu işaretin kestirimlerine karşı düşen RLS ve önerilen yöntem ile bulunan sonuçlar Şekil 4.10’da verilmiştir. Şekil 4.10b ve Şekil 4.10c’deki kestirim sonuçlarını üreten RLS yöntemi ve önerilen yöntemin ulaştığı TVAR model katsayıları Şekil 4.11’de gösterilmiştir. İşarete ilişkin STFT, RLS ve önerilen yöntemle elde edilen PSD kestirimleri ise Şekil 4.12’de görüntülenmiştir.

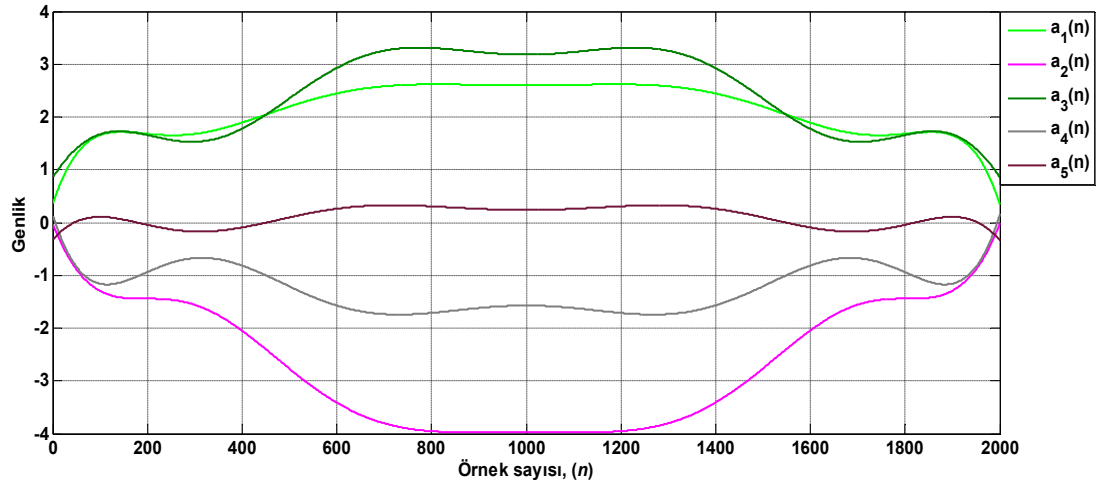
Diğer örneklerde olduğu gibi Şekil 4.10 ve Şekil 4.12’de RLS yöntemiyle bulunan kestirim sonuçları önerilen yöntemin ürettiği TVAR model mertebesi üzerinden elde edilmiştir. Önerilen yöntem ile kestirim sonuçlarına $\varepsilon = 10^{-5}$ seçimi ve baz fonksiyonu olarak Tablo 3.3’de tanımlanan Fourier serisi fonksiyon ailesinin kullanımı ile ulaşılmıştır. Bu bağlamda $p = 5$ ve $m = 7$ olarak belirlenmiştir.



Şekil 4.10: İki chirp işaretinin toplamından oluşan zamanla değişen işaretin TVAR modellenmesi; (a) Asıl işaret, (b) RLS yöntemiyle elde edilen kestirim sonucu, (c) Önerilen yöntem ile elde edilen kestirim sonucu.




(a)



(b)

Şekil 4.11: Örnek 3’de incelenen işaretin TVAR modellemesi; (a) RLS yöntemiyle üretilen TVAR model katsayıları, (b) Önerilen yöntem ile üretilen TVAR model katsayıları.

Şekil 4.10’deki işaret kestirim sonuçları, önerilen yöntemin başarımının RLS’ye göre daha iyi olduğunu göstermektedir. Kestirim hatalarından da bu sonuca varılabilir. STFT yönteminin üretmiş olduğu PSD kestirimi (Şekil 4.12a) ani frekans değişimleri civarında yan loblar içermemesine rağmen frekans çözünürlüğü parametrik yöntemlere nazaran düşüktür. Hem RLS hem de önerilen yöntemin PSD kestirimleri (Şekil 4.12b ve Şekil 4.12c) ani frekans değişimleri civarında yan loblara sahiptir. Ancak her iki yöntemde PSD kestirimlerinin frekans çözünürlüğü yüksektir. Dikkat edilirse önerilen yöntemle $t = 1$ sn anı civarındaki ani frekans değişimlerinin RLS ile elde edilene nazaran daha belirgin (keskin) olduğu görülmektedir.



Şekil 4.12: Örnek 3'deki işaret için PSD sonuçları; (a) STFT, (b) RLS, (c) Önerilen yöntem.

KAYNAKLAR

Abramovich, Y. I., Spencer, N. K., Turley, M. D. E., “Time-varying autoregressive (TVAR) models for multiple radar observations”, *IEEE Transactions Signal Processing*, Vol. 55(4), pp. 1298–1311, (2007).

Amir, N., Gath I., “Segmentation of EEG during sleep using time-varying autoregressive modeling”, *Biological Cybernetics*, Vol. 61(6), pp. 447–455, (1989).
Bodenstein, G., Praetorius, H.M., “Feature extraction from the electroencephalogram by adaptive segmentation”, *Proceedings of the IEEE*, Vol. 65(5), pp.642–652, (1977).

Cho, Y. S., Kim, S. B., Powers, E. J., “Time-varying spectral estimation using AR models with variable forgetting factors”, *Signal Processing, IEEE Transactions*, Vol. 20(6), pp. 1422-1426, (1991).

Choi, H. I., Williams, W. J., “Improved Time-Frequency Representation of Multi-Component Signals Using Exponential Kernels”, *IEEE Trans. Acoust. Speech Signal Process.* Vol. 37(6), pp. 862-871, (1989).

Chon, K. H., Zhao, H., Zou, R., “Multiple time-varying dynamic analysis using multiple sets of basis functions”, *IEEE Transactions On Biomedical Engineering*, Vol. 52(5), pp. 956–960, (2005).

Ciftci, K., Kahya, Y. P., “Respiratory airflow estimation by time varying autoregressive modeling”, in *Proc. 30th Ann. Int. Conf. IEEE-EMBC*, Vancouver, British Columbia, Canada, pp. 347–350, (2008).

Cohen, L., “Time-frequency Distributions—A Review”, *Proceedings of the IEEE*, vol. 77(7), pp. 941–981, (1989).

Cohen, L., “*Time-Frequency Analysis*”, Prentice-Hall, NewYork, (1995).

Conforto, S., D’Alessio, T., “Spectral analysis for non-stationary signals from mechanical measurements: a parametric approach”, *Mechanical Systems Signal Processing*, Vol. 13(3), pp. 395–411, (1999).

Eom, K. B., “Analysis of acoustic signatures from moving vehicles using time-varying autoregressive models”, *Multidimensional Systems Signal Processing*, Vol. 10(4), pp. 357–378, (1999a).

Eom, K. B., ”Time-varying autoregressive modeling of HRR radar signatures”, *IEEE Transactions on Aerospace Electronic Systems*, Vol. 35(3), pp. 974–988, (1999b).

Eom, K. B., “Contour analysis using time-varying autoregressive model”, in *Proc. IEEE Int. Conf. Image Process.*, Vancouver, British Columbia, Canada, pp. 891–894, (2000).

Flaherty, M.J., “Application of polynomial splines to a time-varying autoregressive model of speech”, *Proceedings of IEEE international conference on Acoustics*, Vol.41, pp. 2220-2223, (1988).

Girault, J. M., Ossant, F., Ouahabi, A., Kouamé, D., Patat, F., “Time-varying autoregressive spectral estimation for ultrasound attenuation in tissue characterization”, *IEEE Transactions on Ultrasonics, Ferroelectrics, Frequency Control*, Vol. 45(3), pp. 650–659, (1998).

Grenier, Y., “Time-dependent ARMA modeling of nonstationary signals”, *IEEE Transactions on Acoustics, Speech and Signal Processing*, Vol. 31(4), pp. 899-911, (1983).

Gutierrez, D., Salazar-Varas, R., “Using eigenstructure decompositions of time-varying autoregressions in common spatial patterns-based EEG signal classification”, *Biomedical Signal Processing and Control*, Vol. 7(6), pp. 622–631, (2012).

Hall, M. G., Oppenheim, A. V., Willsky, A. S., “Time-varying parametric modeling of speech”, *Signal Processing*, Vol. 5(3), pp. 267–285, (1983).

Hasman, A., Jansen, B.H., Landeweerd, G.H., Blokland-Vogeleang A.W., “Demonstration of segmentation techniques for EEG records”, *International Journal of Bio-Medical Computing*, Vol. 9(4), pp. 311–321, (1978).

Hayes, M. H., “*Statistical Digital Signal Processing and Modeling*”, NY: John Wiley & Sons, Inc., (1996).

Hlawatsch, F., Boudreaux-Bartels, G. F., “Linear and quadratic time-frequency signal representations”, *IEEE Signal Processing Mag.*, Vol. 9(2), pp. 21-67, (1992).

Ijima, H., Grivel, E., “Deterministic regression methods for unbiased estimation of time-varying autoregressive parameters from noisy observations”, *Signal Processing*, Vol. 92(4), pp. 857-871, (2012).

Kaipio, J., “*Simulation and estimation of nonstationary EEG*”, Ph.D. thesis, Univ. Kuopio, Kuopio, Finland, (1996).

Kaipio, J. P., Karjalainen, P. A., “Estimation of event-related synchronization changes by a new TVAR method”, *IEEE Transactions on Biomedical Engineering*, Vol. 44(8), pp. 649–656, (1997).

Kay, S. M., “*Modern Spectral Estimation*”, Prentice Hall, Englewood Cliffs, (1988).

Krystal, A. D., Prado, R., West, M., “New methods of time series analysis of non-stationary EEG data: eigenstructure decompositions of time varying autoregressions“, *Clinical Neurophysiology*, Vol. 110(12), pp. 2197–2206, (1999).

- Kozin, F., “Estimation and modelling of nonstationary time-series”, in *Proceedings of the Symposium on Computational Methods in Engineering*, Vol. 1, pp. 603-612, (1977).
- Lathi, B. P., “*Signals and Systems*”, Berkeley Cambridge Pr, (1987).
- Lee, J., Chon, K. H., “Time-varying autoregressive model based multiple modes particle filtering algorithm for respiratory rate extraction from pulse oximeter”, *IEEE Transactions On Biomedical Engineering*, Vol. 58(3), pp. 790–794, (2011).
- Li, L., Ji, H. B., “Radar targets detection in formation based on time-varying AR model”, *Int. Conf. Radar*, Shanghai, China, pp. 1-4, (2006).
- Liporace, L.A., “Linear estimation of nonstationary signals”, *Journal of the Acoustical Society of America*, Vol.58(6), pp. 1288-1295, (1975).
- Luo, X., “*Time-varying Autoregressive Modeling of Nonstationary Signals*”, Masters Thesis, University of Tennessee, (2005).
- Marple, S. L., “*Digital Spectral Analysis with Applications*”, Prentice Hall, Englewood Cliffs, (1987).
- Nathan, K. S., Lee, Y. T., Silverman, H. F., “A time-varying analysis method for rapid transitions in speech”, *IEEE Transactions on Signal Processing*, Vol. 39(4), pp. 815–824, (1991).
- Pachori, R. B., Sircar, P., “EEG signal analysis using FB expansion and second-order linear TVAR process”, *Signal Processing*, Vol. 88(2), pp. 415–420, (2008).
- Panzica, F., Varotto, G., Canafoglia, L., Sebastiano, D. R., Visani, E., Franceschetti, S., “EEG–EMG coherence estimated using time-varying autoregressive models in movement-activated myoclonus in patients with progressive myoclonic epilepsies”, in *Proc. 32nd Annual International Conference IEEE Engineering Medicine Biology Society*, Buenos Aires, Argentina, pp. 1642–1645, (2010).
- Priestley, M. B., “*Non-linear and Non-stationary Time Series Analysis*”, Academic Press Inc, (1988).
- Rao, T. S., “The fitting of nonstationary time-series models with time-dependent parameters”, *J. Royal Stat. Soc. - Series B*, Vol. 32(2), pp. 312–322, (1970).
- Rudoy, D., Quatieri, T. F., Wolfe, P. J., “Time-varying autoregressions in speech: Detection theory and applications”, *IEEE Transactions on Audio, Speech, Language Processing*, Vol. 19(4), pp. 977–989, (2011).
- Shan, P. J., Beex, A. A., “High-resolution instantaneous frequency estimation based on time-varying AR modeling”, in *Proceedings IEEE International Symposium Time-Frequency Time-Scale Analysis*, Pittsburg, PA, pp. 109–112, (1998).

Shan, P. J., Beex, A. A., “FM interference suppression in spread spectrum communications using time-varying autoregressive model based instantaneous frequency estimation”, in *Proc. IEEE Int. Conf. Acoust., Speech, Signal Process.*, Phoenix, Arizona, pp. 2559–2562, (1999).

Xu, X., Zhang, Z., Hua, H., Chen, Z., “Identification of time varying modal parameters using a time-varying autoregressive approach”, in *Proc. 21st IMAC Conf. Expo. Structural Dynamics*, Kissimmee, Florida, pp. 1030–1034, (2003).

Wang, G., Luo, Z., Qin, X., Leng, Y., Wang, T., “Fault identification and classification of rolling element bearing based on time-varying autoregressive spectrum”, *Mech. Syst. Signal Process.*, Vol. 22(4), pp. 934–947, (2008).

Wei, H. L., Liu, J., Billings, S. A., “Time-varying parametric modeling and time-dependent spectral characterization with applications to EEG signals using multi-wavelets”, *Dept. Automat. Control Syst. Eng.*, Univ. Sheffield, UK, Research Rep. 977, (2008).

Zhang, L., Xiong, G. L., Liu, H. S., Zou, H. J., Guo, W. Z., “Time-frequency representation based on time-varying autoregressive model with applications to non-stationary rotor vibration analysis”, *Sadhana*, Vol. 35(2), pp. 215–232, (2010).

Zhang, Z. G., Hung, Y. S., Chan, S. C., “Local Polynomial Modeling of Time-Varying Autoregressive Models With Application to Time-Frequency Analysis of Event-Related EEG”, *IEEE Transactions on Biomedical Engineering*, Vol. 58(3), pp. 557–566, (2011).

Zheng, Y. J., Tay, D. B. H., Lin, Z. P., “Modeling general distributed nonstationary process and identifying time-varying autoregressive system by wavelets: theory and application”, *Signal Processing*, Vol. 81(9), pp. 1823–1848, (2001).

Zou, R., Wang, H. L., Chon, K. H., “A robust time-varying identification algorithm using basis functions”, *Annals Biomedical Engineering*, Vol. 31(7), pp. 840–853, (2003).

ÖZGEÇMİŞ



Adı Soyadı : Simge ZEREY
Doğum Yeri ve Tarihi : İzmir - 12.11.1987
Adres : Pamukkale Üniversitesi Kınıklı Kampüsü Bilgi İşlem
Daire Başkanlığı DENİZLİ
Lisans Üniversite : Pamukkale Üniversitesi
Elektronik Posta : simge@pau.edu.tr