

**T.C
ERCIYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**ZAMAN SERİLERİNİN PERİYODİKLİK ANALİZİ İÇİN
TEKNİKLERİN GELİŞTİRİLMESİ**

**Hazırlayan
Muneera Yousif Yaqoob MOHAMMED**

**Danışman
Dr. Öğr. Üyesi Mete ÇELİK**

Yüksek Lisans Tezi

**Temmuz 2019
KAYSERİ**

**T.C
ERCIYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**ZAMAN SERİLERİNİN PERİYODİKLİK ANALİZİ İÇİN
TEKNİKLERİN GELİŞTİRİLMESİ**

(Yüksek Lisans Tezi)

**Hazırlayan
Muneera Yousif Yaqoob MOHAMMED**

**Danışman
Dr. Öğr. Üyesi Mete ÇELİK**

**Temmuz 2019
KAYSERİ**

BİLİMSEL ETİĞE UYGUNLUK

Bu çalışmadaki tüm bilgilerin, akademik ve etik kurallara uygun bir şekilde elde edildiğini beyan ederim. Aynı zamanda bu kural ve davranışların gerektirdiği gibi, bu çalışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi belirtirim.



Muneera Yousif Yaqoob MOHAMMED

YÖNERGEYE UYGUNLUK

“Zaman Serilerinin Periyodiklik Analizi İçin Tekniklerin Geliştirilmesi” adlı Yüksek Lisans Tezi, Erciyes Üniversitesi Lisansüstü Tez Önerisi ve Tez Yazma Yönergesi’ ne uygun olarak hazırlanmıştır.

Hazırlayan

Muneera Yousif Yaqoob MOHAMMED

Danışman

Dr. Öğr. Üyesi Mete ÇELİK

Bilgisayar Mühendisliği ABD Başkanı

Prof. Dr. Veysel ASLANTAŞ

Dr. Öğr. Üyesi Mete ÇELİK danışmanlığında **Muneera Yousif Yaqoob MOHAMMED** tarafından hazırlanan “**Zaman Serilerinin Periyodiklik Analizi İçin Tekniklerin Geliştirilmesi**” adlı bu çalışma jürimiz tarafından Erciyes Üniversitesi Fen Bilimleri Enstitüsü **Bilgisayar Mühendisliği** Anabilim Dalında **Yüksek Lisans** tezi olarak kabul edilmiştir.

08/07/2019

JÜRİ:

Danışman : Dr. Öğr. Üyesi Mete ÇELİK

Üye : Dr. Öğr. Üyesi Ömer KAYAALTI

Üye : Dr. Öğr. Üyesi Serkan ÖZTÜRK

(Handwritten signatures of the jury members)

ONAY:

Bu tezin kabulü Enstitü Yönetim Kurulunun 23/04/2019 tarih ve 2019/52-19 sayılı kararı ile onaylanmıştır.

(Handwritten signature of Prof. Dr. Mehmet AKKURT)

23/04/2019

Prof. Dr. Mehmet AKKURT

Enstitü Müdürü

TEŞEKKÜR

İnsan hayatında, doğumundan ölümüne kadar önemli zaman dilimleri vardır. Kuşkusuz insanın tekâmülünde önemli anlardan birisi de eğitim ve ilim yolculuğudur.

Bu süreçte çocukluğumdan bu yana beni hiç yalnız bırakmayan ve beni hep destekleyen anneme, babama, aileme ve arkadaşlara özellikle Abbas Bayram’a teşekkür ediyorum.

Akademik hayatımda desteklerini esirgemeyen tez danışmanım Sayın Dr. Öğr. Üyesi Mete ÇELİK’e şükranlarımı sunarım.

Son olarak bana kapısını açan ve beni ağırlayan Türkiye Cumhuriyeti’ne, akademik hayatımı sürdürdüğüm ve bunun yanında bu çalışmamı hazırlamama vesile olan Yurtdışı Türkler ve Akraba Topluluklar Başkanlığı’na teşekkür ediyorum.

Muneera Yousif Yaqoob MOHAMMED

Temmuz 2019, KAYSERİ

ZAMAN SERİLERİNİN PERİYODİKLİK ANALİZİ İÇİN TEKNİKLERİN GELİŞTİRİLMESİ

Muneera Yousif Yaqoob MOHAMMED

**Erciyes Üniversitesi, Fen Bilimleri Enstitüsü
Yüksek Lisans Tezi, Temmuz 2019
Dr. Öğr. Üyesi Mete ÇELİK**

ÖZET

Zaman serilerinin periyodiklik analizi zamana göre düzenlenmiş bir veya daha fazla değişken için kaydedilen ölçümler kümesinin analizidir. Periyodiklik madenciliği meteoroloji, astronomi, ekonometri gibi dünyada birçok alanlarda kullanılabilir.

Periyodikliklerin bulunması için geliştirilen teknikler fourier dönüşümünü, dalgacık dönüşümünü ve dinamik zaman bükmesi algoritmasını esas almışlardır. Dinamik zaman bükmesi algoritması iyi performans vermesine rağmen işlem zamanı yüksektir.

Bu tez çalışmasında zaman serilerinin periyodiklik analizi için kullanılan fourier dönüşümü, dalgacık dönüşümü ve dinamik zaman bükmesi tabanlı algoritmalar incelenmiş ve daha sonra yeni periyodiklik analizi algoritmaları (HFD-DZB, DD-DZB) önerilmiştir. Önerilen algoritmalar hızlı fourier dönüşümü ile dinamik zaman bükmesinin birleştirilmesi (HFD-DZB) ve dalgacık dönüşümü ile dinamik zaman bükmesinin (DD-DZB) birleştirilmesi ile oluşturulmuştur. Önerilen algoritmaların performansları gerçek ve sentetik veritabanı üzerinde incelenmiş ve başarılı sonuçlar elde edilmiştir.

Anahtar Kelimeler: Veri madenciliği, periyodiklik analizi, zaman serileri, hızlı fourier dönüşümü, dalgacık dönüşümü, dinamik zaman bükmesi.

DEVELOPING TECHNIQUES FOR PERIODICITY ANALYSIS OF TIME SERIES

Muneera Yousif Yaqoob MOHAMMED

Erciyes University, Graduate School of Natural and Applied Sciences

Master Thesis, July 2019

Supervisor: Assist. Prof. Dr. Mete ÇELİK

ABSTRACT

The periodicity analysis of time series is the analysis of a set of measurements recorded for one or more variables arranged over time. Periodicity mining can be used in many application fields such as meteorology, astronomy, econometrics.

The techniques developed to find the periodicity are based on fourier transform, wavelet transform and dynamic time warping algorithm. Although the dynamic warping algorithm performs well, its processing time is high.

In this thesis, fourier transform, wavelet transform and dynamic time warping based algorithms used for periodicity analysis of time series are examined and new periodicity analysis algorithms (FFT-DTW, WT-DTW) are proposed. The proposed algorithms are formed by combining fast fourier transform with dynamic time warping (FFT-DTW) and wavelet transform with dynamic time warping (WT-DTW). The performances of the proposed algorithms were examined on real and synthetic database and successful results were obtained.

Keywords: Data mining, periodicity analysis, time series, meteorological data, dynamic time warping, fast fourier transformation, wavelet transformation.

İÇİNDEKİLER

ZAMAN SERİLERİNİN PERİYODİKLİK ANALİZİ İÇİN TEKNİKLERİN GELİŞTİRİLMESİ

BİLİMSEL ETİĞE UYGUNLUK	i
YÖNERGEYE UYGUNLUK.....	ii
ONAY	iii
TEŞEKKÜR.....	iv
ÖZET.....	v
ABSTRACT.....	vi
İÇİNDEKİLER	vii
KISALTMALAR ve SİMGELER	x
TABLolar LİSTESİ.....	xi
ŞEKİLLER LİSTESİ	xii
GİRİŞ	1

1. BÖLÜM

GENEL BİLGİLER

1.1. Veri Madenciliği Süreci	3
1.2. Veri Madenciliğinin Görevleri	5
1.2.1. Tahmin Edici Görevler	5
1.2.2. Tanımlayıcı Görevler	6
1.3. Literatür Özeti.....	6

2. BÖLÜM

PERİYODİKLİK ANALİZİ YÖNTEMLERİ

2.1. Zaman Serisi ve Periyodiklik	9
2.2. Periyodiklik Analiz Yöntemleri	9

2.2.1. Fourier Dönüşümü (FD)	10
2.2.1.1. Hızlı Fourier Dönüşümü (HFD).....	10
2.2.1.2. Filtre	11
2.2.2. Dalgacık Dönüşümü	12
2.2.2.1. Ortak Dalgacık Fonksiyonu Türleri.....	13
2.2.2.2. Dalgacık Aileleri.....	15
2.3. Dinamik Zaman Bükmesi.....	17

3. BÖLÜM

ÖNERİLEN YÖNTEMLER

3.1. HFD-DZB Periyodiklik Tespiti Yöntemi	19
3.2. DD-DZB Periyodiklik Tespiti Yöntemi.....	21

4. BÖLÜM

DENEYLER

4.1. Veri Kümeleri	23
4.2. Deneyler	25
4.2.1. DZB Algoritmasının Uygulanması	25
4.2.1.1. Sentetik Veri Deneyleri.....	25
4.2.1.2. Gerçek Veri Deneyleri	27
4.2.2. HFD-DZB Algoritmasının Uygulanması	28
4.2.2.1. Sentetik Veri Deneyleri.....	28
4.2.2.2. Gerçek Veri Deneyleri	28
4.2.3. DD-DZB Algoritmasının Uygulanması	29
4.2.3.1. Sentetik Veri Deneyleri.....	29
4.2.3.2. Gerçek Veri Deneyleri	31

4.3. Algoritmaların Sonuçlarının Karşılaştırılması	30
---	-----------

5. BÖLÜM

TARTIŞMA-SONUÇ ve ÖNERİLER

5.1. Tartışma, Sonuç ve Öneriler	36
---	-----------

KAYNAKÇA	Hata! Yer işareti tanımlanmamış.35
-----------------------	---

ÖZGEÇMİŞ.....	36
----------------------	-----------



KISALTMALAR ve SİMGELER

DZB :	Dinamik Zaman Bükmesi
DTW:	Dynamic Time Warping
HFD:	Hızlı Fourier Dönüşümü
DD:	Dalgacık Dönüşümü
FFT:	Fast Fourier Transform
WT:	Wavelet Transform
1DDWT :	Bir Boyutlu Ayrık Dalgacık Dönüşümü
2DDWT:	İki Boyutlu Ayrık Dalgacık Dönüşümü
FIR:	Finite Impulse Response

TABLÖLAR LİSTESİ

Tablo 4.1 Ortalama maksimum sıcaklık. (°C).....	24
Tablo 4.2 Ortalama minimum sıcaklık. (°C).....	24
Tablo 4.3 Sentetik veri için DZB sonuçları.....	27
Tablo 4.4 Gerçek veri için DZB sonuçları	28
Tablo 4.5 Sentetik veri için HFD-DZB sonuçları	29
Tablo 4.6 Gerçek veri için HFD-DZB sonuçları	29
Tablo 4.7 Sentetik veri için DD-DZB sonuçları.....	31
Tablo 4.8 Gerçek veri için DD-DZB sonuçları	30

ŞEKİLLER LİSTESİ

Şekil 1.1	Veri madenciliği süreci.....	4
Şekil 2.1	Hızlı fourier dönüşümü frekans sinyali penceresi	10
Şekil 2.2	Fourier dönüşümü	11
Şekil 2.3	Fourier dönüşüm akış şeması	11
Şekil 2.4	Farklı ölçek ve pozisyonlarda kurucu dalgalanmalar	12
Şekil 2.5	Dalgacık dönüşümünün gösterimi	12
Şekil 2.6	Bir boyutlu ayrık dalgacık dönüşümü	13
Şekil 2.7	İki boyutlu ayrık dalgacık dönüşümü	14
Şekil 2.8	İki boyutlu ters ayrık dalgacık	14
Şekil 2.9	Haar dalgacık fonksiyonu	15
Şekil 2.10	Daubechies dalgacık fonksiyonları	15
Şekil 2.11	Symlets dalgacık foksiyonları	16
Şekil 2.12	Birorthogonal dalgacık fonksiyonları	16
Şekil 2.13	İki sentetik sinyal arasındaki DZB hesaplanması.....	17
Şekil 3.1	Periyodik örüntü madenciliği deney düzeni	19
Şekil 3.2	HFD-DZB algoritması kaba kodu	20
Şekil 3.3	DD-DZB algoritması kaba kodu.....	22
Şekil 4.1	Sentetik veri.....	23
Şekil 4.2	Bağdat 2005- 2017 yılları arası aylık ortalama maksimum sıcaklık (°C).....	25
Şekil 4.3	Bağdat 2005- 2017 yılları arası aylık ortalama minmum sıcaklık (°C).....	24
Şekil 4.4	Sentetik veriye min _max normalizasyonunun uygulanmış hali.....	26
Şekil 4.5	A ve B zaman serilerinin gösterimi	26
Şekil 4.6	Max _Min normalizasyondan sonra ortalama maksimum sıcaklık	27
Şekil 4.7	HFD işleminin uygulanması	29

Şekil 4.8 DD işleminin uygulanması	29
Şekil 4.9 Sentetik veri için algoritmaların karşılaştırılması	33
Şekil 4.10 Ortalama maksimum sıcaklık için algoritmaların karşılaştırılması	33
Şekil 4.11 Ortalama minimum sıcaklığı için algoritmaların karşılaştırılması	34
Şekil 4.12 Sentetik veri için algoritma çalışma zamanları	34
Şekil 4.13 Ortalama maksimum sıcaklığı için algoritma çalışma zamanları	35
Şekil 4.14 Ortalama minimum sıcaklığı için algoritma çalışma zamanları	35



GİRİŞ

Fiziksel dünyadaki birçok veri zaman serileri şeklindedir bu tür veriler her geçen gün artmaktadır. Verilerin analiz edilmesi için kullanılan tekniklerden birisi de veri madenciliği teknikleridir. Veriler değişik analiz işlemlerine tabi tutulabilmektedir. Bu analiz işlemlerinden birisi olan periyodiklik analizi tekrar eden olayların/verilerin bulunabilmesini amaçlar. Örnek olarak mevsimsel döngüler ve meteorolojik olaylar verilebilir.

Tez çalışmasında zaman serileri içerisinde bulunan periyodikliklerin bulunması için veri madenciliği teknikleri incelenmiş ve yeni teknikler geliştirilmiştir. Periyodiklik bir olayın veya verinin belirli periyotlar ile tekrar etmesi olarak tanımlanabilir.

Periyodiklik analizinde fourier dönüşümü, dalgacık dönüşümü (DD) ve dinamik zaman bükmesi (DZB) tabanlı algoritmalar kullanılmaktadır. Bu çalışmanın amaçlarından bir diğeri de DZB algoritmasının periyodiklik analizi işlemini hızlandırmaktır. DZB ile periyodiklik analizinde bir sinyal ile bu sinyalin p birim kaydırılmış bir versiyonu karşılaştırılarak benzerliğine bakılır. Eğer sinyal periyodik ise sinyalin orjinal hali ile p periyot kaydırılmış hali benzer çıkacaktır. Bu benzerlik DZB ile tespit edilir. Ancak bu işlemin hesaplama maliyeti yüksektir ve p periyodunu bulmak için sinyalin bütün olası kayması ile sinyalin orjinal hali karşılaştırılır. Buna karşılık fourier ve dalgacık dönüşümleri kullanarak DZB algoritmasının bütün periyotları incelemesi engellenebilir. Fourier ve dalgacık dönüşümü sonuçlarına göre bütün periyotları incelemek yerine DZB belirli periyotları inceler ve sinyalin periyodik olup olmadığını tespit eder.

Bu çalışmada hızlı fourier dönüşümü ile dinamik zaman bükmesi teknikleri birleştirilerek HFD-DZB algoritması ve dalgacık dönüşümü ile dinamik zaman bükmesi teknikleri birleştirilerek DD-DZB algoritması önerilmiştir.

Algoritmaların performanslarının incelenmesi için sentetik ve gerçek veriler kullanılmıştır. Kullanılan gerçek veriler bir istasyonun sıcaklık verilerini kapsamaktadır. Tez kapsamında bu sıcaklık verilerinin periyodikliği analiz edilmiştir. Buna ek olarak geliştirilen algoritmaların diğer zaman serilerini (borsa, sensör vb.) analiz etme potansiyeli ve elde edilen sonuçların karar destek sistemlerinde kullanıma potansiyelleri bulunmaktadır.

Tezin Organizasyonu

Bölüm 1’de veri madenciliği ve veritabanlarında bilgi keşifinin adımları hakkında genel bilgiler verilmiştir. Daha sonra veri madenciliğinin görevleri ve periyodiklik analizi literatür özeti verilmiştir.

Bölüm 2’de zaman serisi ve periyodiklik tartışılmış sonrada periyodiklik analiz yöntemleri anlatılmıştır.

Bölüm 3’te önerilen yöntemler (HFD-DZB, DD-DZB) hakkında detaylı bilgi verilmiştir.

Bölüm 4’te önerilen algoritmaların performansları sentetik ve gerçek veriler kullanılarak incelenmiş ve deneyler sonuçları verilmiştir.

Bölüm 5’te tezde elde edilen sonuçlar tartışılmış ve gelecek çalışmalar için öneriler verilmiştir.

1. BÖLÜM

GENEL BİLGİLER

Veri madenciliği, büyük miktardaki verilerden daha önce görülmemiş, örtük ve faydalı bilgileri keşfetmeyi amaçlayan bir bilimdir[1]. Gelişen teknoloji ile birlikte veri toplama hızı ve toplanan parametre sayısı her geçen gün artmaktadır dolayısı ile bu toplanan verilerin analiz edilerek faydaya dönüştürülmesi büyük önem arz etmektedir [2]. Bu veriler arasında web, e-ticaret siteleri, bankacılık, sensör, hareket, meteoroloji, borsa, gen verileri gibi veriler listelenebilir. Veriler gerçek-zamanlı olarak yüksek hızda üretilmekte ve toplanmaktadır. Bunlara ek olarak çeşitli simülatörler aracılığı ile veriler yüksek hızda elde edilebilmektedir. Verinin analiz edilmesi ve bilginin keşfi birçok alanda bilim adamlarının hipotezlerini üretmeleri ve hipotezlerini desteklemeleri için fırsatlar sunmaktadır.


Bu bölümde öncelikle veri madenciliği süreci ve görevleri tartışılmış ve daha sonra literatür özeti sunulmuştur.

1.1. Veri Madenciliği Süreci

Veri madenciliği ile daha önce görülmemiş, ilginç ve potansiyel olarak faydalı olabilecek örüntülerin/bilgilerin keşfi sağlanır [1]. Verinin benzerliklerine göre gruplandırılması, veriden periyodikliklerin ve/veya anomalilerin keşfi, parametreler arasındaki ilişkilerin keşfi ve verinin sınıflandırılması veri madenciliğinin ilgilendiği alanlardan birkaç tanesidir. Veri madenciliğinde, faydalı bilgi keşif işlemleri katmanlaştırılmış adımlar şeklinde yapılır. Bu adımları gösterir veri madenciliği süreci Şekil 1.1'de verilmiştir. Bu tez çalışmasında veriden periyodikliklerin keşfi için bu süreç takip edilmiştir. Veri madenciliği sürecinin adımları aşağıdaki gibidir.

1. Verinin toplanması
2. Hedef verinin hazırlanması
3. Verinin temizlenmesi ve yeniden yapılandırılması

4. Model oluřturma
5. Veri madencilięi algoritmalarının uygulanması
6. Bilginin keřfi ve sonuçların deęerlendirilmesi



Şekil 1.1 Veri madencilięi süreci

- 1) Verinin toplanması: Bu aşama deęişik kaynaklardan verilerin toplanmasını ve veritabanının oluřturulmasını kapsamaktadır. Ayrıca bu aşamada veri entegrasyonu ve eřleřtirme işlemleri de yapılır.
- 2) Hedef verinin hazırlanması: Bu aşamada veriden gereksiz veya veri madencilięi sürecine doğrudan katkısı olmayacak parametre ve kayıtlar silinerek üzerinde çalışılacak veri kümesi oluřturulur.
- 3) Verinin temizlenmesi ve yeniden yapılandırılması: Veri kümesinde bulunabilecek eksik, gürültülü ve yanlış veriler bu aşamada düzenlenir. Veriler, veri madencilięi yöntemlerinin gereklerini karřılamak üzere yeniden biçimlendirilebilir, gürültülü veriler giderilir/temizlenir veya eksik veriler tamamlanır. Gerekli olması durumunda bu aşamada veri normalizasyona tabi tutulur.
- 4) Model oluřturma: Bu aşamada hazırlanan veri üzerinde veri madencilięi işlemlerinin yapılabilmesi için modeller oluřturulur ve algoritma tasarımları yapılır.
- 5) Veri madencilięi algoritmalarının uygulanması: Bu aşamada belirlenen ve/veya geliştirilen algoritmalar hazırlanan verilere uygulanarak sonuçlar alınır.

- 6) Bilginin keşfi ve sonuçların değerlendirilmesi: Bu aşamada algoritma sonuçları yorumlanarak bilgi keşfedilir. Ayrıca kullanılan algoritmaların performansları ve doğrulukları bu aşamada analiz edilir.

Veri madenciliği süreci tekrarlamalı bir süreçtir. Gerekli olması durumunda herhangi bir aşamada bir önceki aşama veya aşamalar tekrar edilebilir. Bu durum Şekil 1.1'de ok işaretleri ile gösterilmiştir.

1.2. Veri Madenciliğinin Görevleri

Veri madenciliğinin görevlerini, temel olarak tahmin edici görevler ve tanımlayıcı görevler olarak ikiye ayırmak mümkündür [1].

1.2.1. Tahmin Edici Görevler

Tahmin edici görevler, hangi verinin hangi sınıfa ait olduğunu belirleme işlemi olarak tanımlanır. Tahmin edici görevin en popüler modelleri sınıflandırma (ayrık etiketler) ve regresyon (gerçek değerler) analizidir. Bu tür algoritmalarının ortak özelliği denetimli veya danışmanlı öğrenme ilkesi ile çalışmalarıdır. Denetimli veya danışmanlı öğrenmede modellerin oluşturulması için eğitim kümesine ihtiyaç duyulmaktadır. Daha sonra oluşturulan model ile giriş olarak verilen bir verinin sınıfı veya gerçek değeri tahmin edilir.

Sınıflandırma: Sınıflandırmada eğitim verisi kullanılarak bir model oluşturulur ve daha sonra sınıfı bilinmeyen verinin sınıfı bu model kullanılarak tespit edilir. Bu işleme tahmin işlemi de denilir. Sınıflandırma çeşitli uygulamalarda kullanılır. Tüketicilerin demografik bilgileri, yaşam tarzı ve geçmişteki satın alma davranışlarının analiz edilerek bir sonraki alış-verişte hangi ürün veya ürünleri alacağını tahmin edilmesi, herhangi bir iletiyi üstbilgi ve ileti içeriğine göre istenmeyen ileti ve istenen ileti olarak kategorilere ayırarak istenmeyen epostaların algılanması sınıflandırma örneklerinden iki tanesidir. Sınıflandırmada karar ağaçları, destek vektör makineleri, yapay sinir ağları gibi yöntemler kullanılır.

Regression: Regresyon bir tahmin işlemidir. Regresyon sınıflandırmaya benzer şekilde bir model oluşturur. Ancak oluşturulan bu model gerçek sayı değerlerini çıktı olarak verir. Sınıflandırmada ise model sonucu var olan sınıflardan birisinin giriş olarak verilen veriye atanması işlemidir. Pazarlamada yeni ürünün reklam harcamalarına göre satış tutarlarının tahmin edilmesi, çeşitli meteoroloji parametrelerinin göz önüne

alınarak (sıcaklık, nem, hava basıncı gibi) başka bir meteoroloji parametre değerinin (rüzgar hızı gibi) tahmin edilmesi, borsa endekslerinin zaman serileri tahmini ve toprak özelliğine ve hava durumuna göre ürün veriminin tahmin edilmesi regresyon örneklerinden birkaç tanesidir.

1.2.2. Tanımlayıcı Görevler

Tanımlayıcı görevler verilerin benzerliklerine göre gruplandırması veya parametreler arasındaki ilişkilerin ortaya konulması işlemi olarak tanımlanır. Tanımlayıcı görevler arasında kümeleme, birliktelik analizi ve anomali tespiti listelenebilir.

Kümelenme: Verilerin benzerliklerine göre gruplara ayrılması işlemidir. Küme içerisindeki veriler küme dışındaki verilere nazaran daha benzerdir. Benzerlik ölçütü olarak öklit mesafesi, blok mesafesi gibi ölçütler kullanılabilir. Kümelemeye örnek olarak müşterilerin ve belgelerin benzerliklerine göre gruplandırılması verilebilir. Kümelemede kaç kümenin olacağı ve hangi kümede hangi tipte verinin olacağı algoritmaya göre değişkenlik gösterir. Sınıflandırmada ise sınıflar bellidir ve hangi sınıfa hangi tipte verinin gireceği eğitim verisi kullanılarak belirlenir.

Birliktelik analizi: Bir veri kümesindeki parametreler arasındaki ilişkilerin bulunması işlemine birliktelik analizi denilir. Bir başka deyişle verinin analiz edilerek parametreler arasındaki neden-sonuç ilişkilerini gösteren kuralların ortaya çıkarılmasıdır. Birliktelik analizi uygulamalarına örnek olarak market sepet analizi, hastalık etmenlerinin analizi ve haberleşme sistemlerinin analizi verilebilir.

Anomali tespiti: Anomali çoğunluktan farklı olan olarak tanımlanır. Bu kapsamda anomali tespiti algoritmaları verilen verinin içerisinden farklı özellikte/özelliklerde olanları bulmayı amaçlar. İstenmeyen epostaların bulunması ve aşırı sıcak ve soğuk günlerin bulunması gibi uygulamalar anomali tespiti uygulamalarıdır.

1.3. Literatür Özeti

Literatürde yapılan çalışmalarda zaman serileri içerisinde bulunan periyodikliklerin ortaya çıkarılması için dinamik zaman bükmesi, dalgacık dönüşümü ve fourier dönüşümü yaklaşımları kullanılmıştır.

Dinamik zaman bükmesi (DZB) [3] periyodiklik tespiti algoritması (warping time dynamic) tekniği Elfeky ve arkadaşları tarafından ilk olarak kullanılmıştır. Bu çalışmada bir zaman serisi yine kendisinin kaymış bir zaman serisi ile dinamik zaman

bükmesi algoritması kullanılarak karşılaştırılmıştır. Bir zaman serisi, p periyot olarak kaymış zaman serilerinden hangisine en çok benziyor ise zaman serisi p periyot ile periyodiktir denilebilir. Çelik ve arkadaşları tarafından yapılan çalışmada [4] periyodik mekan-zamansal eş-oluşum örüntüsü modelinin keşfedilmesi için algoritmalar geliştirilmiştir. Önerilen algoritma dinamik zaman bükmesini kullanarak original zaman serisi ile zaman serisinin kaymış versiyonunu karşılaştırır ve sinyallerin benzerliğini tespit eder. Çalışmada, zaman serisinin p periyot ile periyodik olup olmadığını tespit etmek için güven değeri hesaplanır ve elde edilen sonuca göre zaman serisinin periyodik olup olmadığı belirlenir. Bemdt ve arkadaşlarının [5] yapmış olduğu çalışmada DZB algoritması iki zaman serisinin benzerliğini bulmak için zaman serilerinin elemanları arasındaki minimum mesafeyi hesaplamak için kullanılmıştır. Mesafe ne kadar küçük ise zaman serileri o kadar benzerdir denilir. Nurjahan Begum ve arkadaşları [6] DZB algoritmasının hızlandırılması için çalışmalar yapmışlar ve çeşitli kısıtlamalar kullanmışlardır. Sheng ve arkadaşları [7] yapmış oldukları çalışmada kısmi periyodikliklerin tespiti için DPMin algoritmasını geliştirmişlerdir. Algoritma yoğunluk tabanlıdır ve birinci aşamada yoğun bölgeler tespit edilir ve ikinci aşamada ise periyodik yoğun bölgeler tespit edilir.

Literatürde dalgacık dönüşümü (wavelet transform) yaklaşımı kullanılarak periyodiklik tespiti çalışmaları yapılmıştır. Otazu ve arkadaşları [8], periyodik sinyaller sinüzoidal olmadığına veya sinyal-gürültü oranı çok düşük olduğunda periyodiklik tespiti için dalgacık dönüşümü yaklaşımını kullanmışlardır. Benedetto ve arkadaşları [9] yapmış oldukları çalışmada hastaların epileptik periyodik örüntülerini ve gerçek zamanlı olarak bu periyodikliklerin oluşumunu tespit etmek için Haar dalgacık yaklaşımını kullanmışlardır. Norouzi ve arkadaşları [10] sinyallerin analizi için dalgacık dönüşümü kullanmışlardır. Chaovalit ve arkadaşları [11] ayrık dalgacık dönüşümü yaklaşımının uygulama alanlarını incelemiş ve zaman serisi analizleri için incelemelerini yapmışlardır.

Literatürde fourier dönüşümü yaklaşımı kullanılarak periyodiklik tespiti çalışmaları yapılmıştır. Elfeky ve arkadaşları [12] yapmış oldukları çalışmada segment ve sembol periyodikliği olarak iki tür periyodiklik tanımlanmışlardır ve bu periyodiklikleri keşfetmek için algoritmalar önermişlerdir. Sembol periyodiklik algoritması iki aşamada çalışır. Birinci aşamada semboller elde edilir, eşleşen semboller ve bunlara karşılık

gelen pozisyonlar belirlenir ve ikinci aşamada ise konvolüsyon işlemi uygulanarak periyodik olan bölgeler bulunmaya çalışılır. Benzer mantık kullanılarak segment tabanlı algoritma geliştirilmiştir. Berberidis ve arkadaşları [13] bir zaman dizisindeki tüm periyodiklikleri bulmak için yeni bir algoritma önermişlerdir. Önerilen algoritmada hızlı fourier dönüşümü kullanılmıştır. Hatkar ve arkadaşları [14] çalışmalarında periyodikliği sembol, kısmi ve segment periyodikliği olarak üçe ayırmışlardır. Bu periyodikliklerin keşfi için çeşitli algoritmaları kullanmışlardır ve bu algoritmaların performansları karşılaştırmışlardır. Khanna ve arkadaşları [15] zaman sinyallerinden periyodiklik keşfi için çeşitli çalışmalar yapmışlardır.

Akin [16] yapmış olduğu çalışmada dalgacık ve fourier dönüşümü tekniklerini periyodikliklerin keşfi açısından karşılaştırmıştır ve özellikle dalgacık dönüşümü yönteminin beyin hastalıklarını saptamada hızlı fourier dönüşümünden daha iyi olduğunu tespit etmiştir. Leda [17] ve Fan ve arkadaşları [18] tarafından yapılan çalışmalarda da hızlı fourier dönüşümü ve dalgacık dönüşümü algoritmalarının performanslarını karşılaştırmıştır.

2. BÖLÜM

PERİYODİKLİK ANALİZİ YÖNTEMLERİ

Bu çalışmanın amacı zaman serilerinden periyodik örüntülerin keşfi için algoritmaların geliştirilmesidir.

Bölümde periyodiklik analizi yöntemleri tartışılmıştır. Periyodiklik analizi için fourier dönüşümü, dalgacık dönüşümü ve dinamik zaman bükmesi yaklaşımları kullanılmıştır.

2.1. Zaman Serisi ve Periyodiklik

Zaman serisi belirli bir olayın veya parametrenin zaman içindeki oluşumuna göre sırayla kaydedildiği değerlerin kümesidir. Matematiksel olarak bağımlı değişken Y 'nin bağımsız değişken t zamanındaki bir fonksiyonu olarak ifade edilebilir (Eşitlik 2.1) .

$$Y = f(t) \quad (2.1)$$

Periyodiklik ise belirli periyotlar ile tekrar eden olaylar veya parametre değerleri olarak tanımlanabilir.

Zaman serileri çeşitli uygulama alanlarında üretilmekte ve toplanmaktadır. Bunlar arasında meteoroloji, deprem, finans, sağlık, ekonometri gibi uygulama alanlarında toplanan zaman serileri listelenebilir.

2.2. Periyodiklik Analiz Yöntemleri

Literatürde çeşitli periyodiklik analizi yöntemleri bulunmaktadır. Bu teknikler dinamik zaman bükmesi, dalgacık dönüşümü ve fourier dönüşümü tabanlı teknikler olarak listelenebilir. Bu yöntemleri uygulandıkları domene göre frekans domeni ve zaman domeni yöntemleri olarak da ikiye ayırmak mümkündür.

2.2.1. Fourier Dönüşümü (FD)

Frekans bir olayın birim zaman içerisindeki tekrarlanma sayısını verir ve hertz cinsinden ölçülür. Frekans domenini veriden özelliklerin çıkarılmasında yaygın olarak kullanılır. Bir zaman sinyalinin frekans domenine dönüştürmek için kullanılan en yaygın yöntemlerden birisi fourier dönüşümüdür. Fourier dönüşümü özellikle periyodik, zamanla değişmeyen veya durağan olayların analizinde önemli bir yere sahiptir. Fourier dönüşümünde sinyal sinüs ve kosinüs sinyalleri koleksiyonu olarak ifade edilir. Çeşitli fourier dönüşümü türleri vardır ve bunlar genel olarak ayırık fourier dönüşümü, hızlı fourier dönüşümü (HFD) ve kısa süreli fourier dönüşümü olarak listelenebilir. Şekil 2.1’de hızlı fourier dönüşümü frekans zaman penceresi gösterilmiştir.



Şekil 2.1 Hızlı fourier dönüşümü frekans zaman penceresi [19]

2.2.1.1. Hızlı Fourier Dönüşümü (HFD)


Hızlı fourier dönüşümü, bir sinyali veya zaman serisini zaman domeninden frekans domenine dönüştürmek için kullanılan yöntemlerden birisidir. Hızlı fourier dönüşümü 1965 yılında Cooley ve Tukey tarafından geliştirilmiştir. Hızlı fourier dönüşümünün amacı standart veya ayırık fourier dönüşümü tarafından yapılan karmaşık hesaplamaları indirgemektir. Standart bir ayırık fourier dönüşümü Eşitlik 2.2’de verilmiştir. Ayırık fourier dönüşümü büyük bir matris çarpımını ve karmaşık hesaplamaları gerektirir. Hızlı fourier dönüşümü karmaşık hesapları indirgeyerek süreci hızlandırır (Eşitlik 2.3) [20].

$$x_k = \sum_{n=0}^{N-1} x_n \cdot e^{-i2\pi kn/N} \quad \text{Ayırık fourier dönüşümü (2.2)}$$

$$X_f = \int_{-\infty}^{\infty} x(t) e^{-i2\pi ft} dt \quad \text{Hızlı fourier dönüşümü (2.3)}$$

Eşitliklerde N sinyaldeki örnek sayısı, n ve t sırasıyla indeksi ve zamanı, k ve f sinyaldeki frekansı miktarlarını göstermektedir [20].

Şekli 2.2’de fourier dönüşümü uygulanan bir sinyalin farklı frekanslarda eşleştirilmiş sinüs fonksiyonu eşdeğerleri görülmektedir.



Şekil 2.2 Fourier dönüşümü [21]

Fourier dönüşümünün bir zaman sinyaline uygulanışının aşamaları Şekil 2.3’de gösterilmiştir. Öncelikle giriş sinyali verilir ve kullanıcı tarafından bir k frekansı seçilir. Daha sonra sinyal seçilen frekansa göre düzenlenir. Düzenlenen sinyalin ortalama vektörlerinin uzunlukları ve açısı k frekansına göre hesaplanır. Son olarak frekans domenine çevrilen sinyal çıktı olarak verilir.



Şekil 2.3 Fourier dönüşüm akış şeması

2.2.1.2. Filtre

Yüksek frekanslı dalgalanmaları gideren veya belirli bir frekansın periyodik trendlerini verilerden kaldıracak olan veri işleme teknikleridir. Bu işlem konvolüsyon yoluyla (Sonlu Dürtü Yanıtı - FIR) sağlanır. Bu tip frekansı kesme işlemi belirli bir frekansı aşmayan düşük frekanslı sinyallerin iletilmesine ve kesme frekansından daha yüksek bir frekansa sahip tüm sinyallerin bloke edilmesine izin verir (Eşitlik 2.4) [22].

$$h[n] = \sum_{i=0}^N b_i \cdot f[n-i] \quad (2.4)$$

Eşitlik 2.4'te $h[n]$ değişkeni çıkış sinyalini ve $f[n-i]$ giriş sinyali gösterir. N filtre sırasıdır, b_i sıradaki filtrenin $0 < i < N$ için impuls cevabının değeridir.


2.2.2. Dalgacık Dönüşümü (DD)

Bir zaman serisinin veya bir sinyalin hem farklı frekanslara hem de farklı zaman dilimlerine göre analizini sağlar. Bir ana dalgacık fonksiyonunun öteleme ve yayılması ile oluşturulan fonksiyonlara, zaman serisinin izdüşümünün alınması ile dalgacık dönüşümü yapılır. Dalgacık dönüşümü farklı zaman çözünürlüklerinde ölçekleme yapar (Şekil 2.4). Dalgacık dönüşümünde uzun süreli dalgacıklar düşük frekanslarla ve kısa süreli dalgacıklar yüksek frekanslar ile bulunabilir. Bu nedenle dalgacık dönüşümü zaman çözünürlüğü daha iyidir.



Şekil 2.4 Farklı ölçek ve pozisyonlarda kurucu dalganmalar [21]

Dalgacık dönüşümü Şekil 2.5'te görüldüğü gibi ana dalganın sıkışması ve genişlemesi temeli üzerinedir. Bu sıkışma ve genişleme korelasyon katsayıları ile sağlanır. Küçük ölçekler sinyal hakkında ayrıntılı bilgi vermek için yüksek frekanslara karşılık gelir ama büyük ölçekler sinyal hakkında genel bilgi vermek için düşük frekanslara karşılık gelir. Dalgacık dönüşümündeki ofset katsayısı göre dalganın zaman sinyali boyunca kaydı yapılır.



Şekil 2.5 Dalgacık dönüşümünün gösterimi [21]

2.2.2.1. Ortak Dalgacık Fonksiyonu Türleri


Dalgacık dönüşümü giriş fonksiyonuna göre yaygın türleri sürekli dalgacık dönüşümü ve ayrık dalgacık dönüşümüdür.

1. Sürekli dalgacık dönüşümü: Zaman eksenini boyunca dalgacık ile çarpılan sinyalin integralinin alınmasıdır. Eşitlik 2.5 ve 2.6 formlarında temsil edilir [21, 23]. Eşitlikteki a ölçekleme faktörünü, b zaman gecikmesini, Ψ ana dalgacığı, $a^{-1/2}$ farklı standartların enerji ayar katsayısını gösterir ve $*$ karmaşık konjugasyonu gösterir.

$$C(\text{ölçek, pozisyon}) = \int_{-\infty}^{\infty} f(t) \cdot \Psi C(\text{ölçek, pozisyon}) dt \quad (2.5)$$

$$\Psi_{a,b}(t) = |a|^{-\frac{1}{2}} \Psi^* \left(\frac{t-b}{a} \right) \Psi \quad (2.6)$$


2. Ayrık dalgacık dönüşümü: Temel fikir her iki türde de aynıdır tek fark olarak dönüşüm sürecinin gerçekleştiği yoldur. Şekil 2.6'da ayrık dalgacık dönüşümü işlemleri yüksek geçiş filtresi (H) ile gösterilmektedir ve alçak geçiş filtresi (L) ile gösterilmektedir. Yüksek geçiş filtresi yani ayrıntılar olarak adlandırılan yüksek frekans elemanlarının ortaya çıkmasına neden olur, alçak geçiş filtresi olarak adlandırılan alçak/düşük frekanslı öğeleri elemanlarının ortaya çıkmasına neden olur. Ayrık dalgacık dönüşümü sinyali analiz etmek için bir boyutlu ayrık dalgacık dönüşümü (1DDWT) kullanılır, Şekil 2.7 ve Şekil 2.8'deki iki boyutlu ayrık dalgacık dönüşümü(2DDWT) görüntülü işlem için kullanılır.




Ayrıştırma

Yeniden kurma

Şekil 2.6 Bir boyutlu ayrık dalgacık dönüşümü [21]



Şekil 2.7 İki boyutlu ayırık dalgacık dönüşümü [19]




Şekil 2.8 İki boyutlu ters ayırık dalgacık

2.2.2.2. Dalgacık Aileleri


Dalgacık dönüşümleri hem sürekli hem de kesikli analizler için kullanılabilir. Farklı dalgacık aileleri temel fonksiyonları farklı dönüşümler ortaya çıkarır. Dalgacık seçimi, zaman serisinin veya sinyalin özelliklerine ve uygulama alanına göre belirlenir [21]. Literatürde çok fazla sayıda dalgacık fonksiyonu vardır. Bunlardan bazıları Haar dalgacık, Daubechies dalgacık, Symlets dalgacık ve biorthogonal dalgacık fonksiyonlarıdır.

- **Haar dalgacık fonksiyonu:** Haar dalgacık fonksiyonu eski ve basit bir fonksiyondur. Bu fonksiyon hızlı ve basit olması, tersine çevrilebilir olması ve hesaplaması ucuz olması nedeniyle avantajlıdır. Şekil 2.9' da Haar dalgacık fonksiyonu gösterilmiştir.




Şekil 2.9 Haar dalgacık fonksiyonu [24]

- **Daubechies dalgacık fonksiyonları:** Daubechies dalgacığının hesaplama maliyeti ve karmaşıklığı Haar dalgacığına göre yüksektir ve mühendislik uygulamalarında sıklıkla kullanılır. Farklı filtre uzunluklarına sahip Daubechies dalgacık fonksiyonları Şekil 2.10'da görülmektedir.




Şekil 2.10 Daubechies dalgacık fonksiyonları [24, 25]

- **Symlets dalgacık fonksiyonları:** Symlets dalgacıkları, Daubechies dalgacıklarının modifikasyonu ile elde edilmiştir ve Daubechies dalgacıklarıyla simetrik olarak sunulur. Bu nedenle özellikleri Daubechies dalgacıklarına benzerdir (Şekil 2.11) [21].



Şekil 2.11 Symlets dalgacık fonksiyonları [21, 25]

- **Biorthogonal dalgacık fonksiyonları:** Bu dalgacık fonksiyonları lineer faz özelliğini gösterir. Bir modelde ayrıştırma için bir dalga ve yeniden oluşturmak için ikinci bir dalga kullanır ve doğrusal faz özelliklerini gösterir. Şekil 2.12’de biorthogonal dalgacık fonksiyonları gösterilmiştir.



Şekil 2.12 Biorthogonal dalgacık fonksiyonları [21, 25]

2.3. Dinamik Zaman Bükmesi

Dinamik zaman bükmesi konuşma tanıma için tasarlanmış bir yaklaşımdır [26]. Bu yaklaşım iki sinyali veya zaman serisinin benzerliğini belirler. Veri madenciliğinde kümeleme, sınıflandırma ve anomali tespiti gibi birçok problemde kullanılmaktadır. Dinamik zaman bükmesi, periyodiklik analizinde de kullanılmıştır. Bir zaman serisinin p periyot kaymış hali yine zaman serisinin kendisi ile karşılaştırılmıştır. Eğer p periyot yapmış zaman serisi ile zaman serisinin benzerliği yüksek ise zaman serisi p periyot ile periyodiktir denilir.

Dinamik zaman bükmesi yaklaşımında A ve B zaman serilerinin benzerliğinin bulunması için dinamik zaman bükmesi matrisi (DZB matrisi) oluşturulur (Şekil 2.13). Matristeki A satır boyutunu ve B sütun boyutunu gösterir. Matrisin herbir hücresi zaman serilerinin birbirleri arasındaki uzaklığı gösterir.


$$d(A_i, B_j) = |A_i - B_j| \text{ veya } d(A_i, B_j) = \sqrt{(A_i - B_j)^2} \quad (2.7)$$

Şekil 2.13'teki DZB mesafe matrisi kullanılarak, bükülme yolu w aşağıdaki şekilde hesaplanır (Eşitlik 2.8 ve Eşitlik 2.9)

$$d(A, B) = \min \sum_{i=1}^k w_i \quad (2.8)$$

Burada k bükülmüş yolunun uzunluğunu gösterir ve hesaplamada dinamik programlama kullanılır ve kümülatif mesafe hesaplanır (Eşitlik 2.9). En son hücre kümülatif uzaklığı DZB ($d(A,B)$) mesafesini verir.

$$Y(i, j) = d(A_i, B_j) + \min\{Y(i-1, j-1), Y(i-1, j), Y(i, j-1)\} \quad (2.9)$$



Şekil 2.13 İki Sentetik sinyal arasındaki DZB hesablanması


3. BÖLÜM

ÖNERİLEN YÖNTEMLER

Tez kapsamında bir zaman serisindeki periyodikliği tespit etmek için iki algoritma önerilmiştir. Önerilen algoritmalar hızlı fourier dönüşümü ile DZB'nin birleştirilmesi (HFD-DZB) dalgacık dönüşümü ile DZB'nin (DD-DZB) birleştirilmesi ile oluşturulmuştur (Şekil 3.1).

Periyodiklik analizinde fourier dönüşümü, dalgacık dönüşümü (DD) ve dinamik zaman bükmesi (DZB) tabanlı algoritmalar kullanılmaktadır. DZB algoritmasının periyodiklik analizi performansı iyidir ancak çok fazla zaman almaktadır. Bu çalışmanın amaçlarından bir diğeri de DZB algoritmasının periyodiklik analizi işlemini hızlandırmaktır. DZB ile periyodiklik analizinde bir sinyal ile bu sinyalin p birim kaydırılmış versiyonu karşılaştırılarak benzerliğine bakılır. Eğer sinyal periyodik ise sinyalin orjinal hali ile p periyot kaydırılmış hali benzer çıkacaktır. Bu benzerlik DZB ile tespit edilir. Ancak bu işlemin hesaplama maliyeti yüksektir ve p periyodunu bulmak için sinyalin bütün olası kayması ile sinyalin orjinal hali karşılaştırılır. Buna karşılık fourier ve dalgacık dönüşümleri kullanılarak DZB algoritmasının bütün periyotları incelemesi engellenebilir. Bu amaçla bu çalışmada fourier ve dalgacık dönüşümleri ile DZB algoritmaları birleştirilerek DZB algoritmasının maliyetinin düşürülmesine çalıştırılmıştır.

Önerilen algoritmalar normalize edilmiş zaman serilerini giriş olarak alırlar (Şekil 3.1). Bu çalışmada normalizasyon için min-max normalizasyonu kullanılmıştır. Daha sonra normalize edilmiş veriler hızlı fourier dönüşüm veya dalgacık dönüşümü ile analiz edilir. Analiz işlemi sinyalin periyodik olabilecek frekanslarının bulunmasına yardımcı olur. Tespit edilen frekanlara bağlı olarak DZB çalıştırılır ve zaman serisinin periyodik olup olmadığı tespit edilir.



Şekil 3.1 Periyodik örüntü madenciliği deney düzeneği

Önerilen HFD-DZB ve DD-DZB algoritmalarının detayları aşağıdaki bölümlerde verilmiştir.

3.1. HFD-DZB Periyodiklik Tespiti Yöntemi

Önerilen algoritmada sinyal normalize edildikten sonra sinyale hızlı fourier dönüşümünü uygulanır ve FIR filtre ile bir frekans keşfedilir. Daha sonra DZB tekniği kullanılarak elde edilen frekansa ve bu frekansın katlarına göre sinyalin periyodikliği belirlenir. Algoritmanın kaba kodu Şekil 3.2’te verilmiştir.

Algoritmaya giriş olarak sinyal verilir ve algoritmadan çıkış olarak ise sinyalin periyodik olduğu p periyodu alınır.

Min-max normalizasyonu (adım 2): Min-max normalizasyonunda verilen sinyal 0 ile 1 arasında ölçeklenir. (Eşitlik 3.1) [27]. Başka bir aralıkta ölçekleme yapmak istendiğinde yeni minimum ve maksimum değerleri new_min ve new_max değişkenleri aracılığı ile belirtilir.

$$v' = \frac{(v - Min)}{(Max - Min)} * (new_max - new_min) + new_min \quad (3.1)$$

Eşitlikteki v girişi sinyalini, v' istenen aralıktaki yeni değeri veya normalizasyon sonucunu, Min giriş sinyalin en küçük eleman değerini ve Max ise giriş sinyalin en büyük değerini gösterir. Bu çalışmada eşitlikteki $new_min=0$ ve $new_max =1$ değerini almıştır.

Giriş	S=Zaman serisi $s_1, s_2, \dots, s_n$.
Değişkenler	k: Şu andaki frekans A: Referans zaman serisi B: Referans zaman serisi kaydıldıktan sonraki sinyal N: Zaman örneklerinin sayısı cut_off: Kesme frekansı sıra: Filtre sırası
Çıktı	D:İki sinyal arasındaki benzerlik değeri %DWT p:İki sinyal benzerliğinin maksimum olduğu periyot
	<pre> 1 Başlangıç i=0, j=0, 2 Y= Min-Max_Norm (S) % Min-Max Normalizasyon 3 f[k]=HFD_hesaplama(Y); % HFD 4 h= fir1_hesaplama(sıra,cut_off(f)) %FIR filtreleme 5 con= conv(f[k], h) 6 for t=2:length(con)-1 7 p= tepe_sayısı(con(t)) 8 end for 9 A= con % A değeri HFD'den sonra 10 for i=p:p:length(S) 11 B= kaydırma_işlemi (A,p) 12 A= A(1:end-p); 13 for i = 1: length(A) 14 for j = 1: length(B) 15 D(i,j)= DZB_mesafe_hesapla(A,B) 16 end for 17 end for 18 end for </pre>

Şekil 3.2 HFD-DZB algoritması kaba kodu

HFD analiz aşması (adım 3): Bu aşamada zaman serileri üzerinde hızlı fourier dönüşümü kullanılır ve sinyalin periyodik frekanslarının nerede olabileceği tespit edilir

FIR filtre uygulanması (adım 4): Hızlı fourier dönüşüm çıktısı frekanslar kesme frekansı adı verilen belirli bir frekansı aşmayan düşük frekanslı sinyallerin iletilmesine ve kesme frekansından daha yüksek frekansın iletilmemesine sebep olur.

Tepe sayısını hesaplama aşaması (adım 7): Bu aşamada (Eşitlik 3.2)'te kullanılan formül ile tepe sayısı belirlenir. Bu sayısı sinyalin ne kadar kaydırılacağını gösterir. Yani p değerini verir. Tepe değeri hesabında aşağıdaki formülde gösterildiği gibi bir noktanın öncesine ve sonrasına bakılır. Eğer bir noktanın öncesi ve sonrası bu noktadan küçük ise $S(sayacı)$ değeri bir arttırılır.

$$S(Sayacı)=[S[k]>S[k-1]\&S[k]>S[k+1]] \quad (3.2)$$

Dinamik zaman bükme aşaması (adım 15): Bu adımda DZB algoritması FIR filtre aşamasından çıkan sinyali referans olarak alır. Orijinal sinyali ve sinyalin belirlenen değer kadar kaydırarak elde edilen sinyalin karşılaştırılması bu aşamada gerçekleştirilir. İki sinyal arasındaki mesafe minimum ise sinyal p periyodu ile periyodiktir denilir.

Karşılaştırma işlemi bütün p periyodu ve katları için yapılır. Elde edilen en küçük DZB mesafesine sahip p periyodu ile sinyal periyodiktir denilir. Bu şekilde bütün kaymalar için değil sadece p periyodu ve katları için DZB çalıştırılır.

3.2. DD-DZB Periyodiklik Tespiti Yöntemi

Bu yaklaşımda dalgacık dönüşümü ve dinamik zaman bükmesi algoritmaları birleştirilmiştir. Algoritmanın kaba kodu Şekil 3.3’de verilmiştir.

Algoritmaya öncelikle sinyal ve kayma değeri giriş olarak verilir. Normalizasyon veri dönüşümünün bir parçasıdır ve sinyalin belirli bir aralığa uyacak şekilde yeniden değerlendirilmesi için önemlidir. Çalışmada min-max normalizasyon kullanılmıştır.

Dalgacık dönüşümü aşaması (adım 3) : Bu aşamada sinyale ayrık dalgacık dönüşümü uygulanır.

Dinamik zaman bükme aşaması (adım 13): Bu adımda DZB algoritması dalgacık dönüşümü aşamasından çıkan DD sinyali referans olarak alır. Orijinal sinyali ve sinyalin belirlenen değer kadar kaydırarak elde edilen sinyalin karşılaştırılması bu aşamada gerçekleştirilir. İki sinyal arasındaki mesafe minimum ise sinyal p periyodu ile periyodiktir denilir.

Karşılaştırma işlemi bütün p periyodu ve katları için yapılır. Elde edilen en küçük DZB mesafesine sahip p periyodu ile sinyal periyodiktir denilir. Bu şekilde bütün kaymalar için değil sadece p periyodu ve katları için DZB çalıştırılır.

Giriş	S= Zaman serisi $s_1, s_2, \dots, s_n$.
Değişkenler	A: Referans zaman serisi B : Referans zaman serisi kaydırdıktan sonra sinyaldir N : zaman örneklerinin sayısı Lo_A: Düşük frekanslı filtre[.5 .5] ; Hi_D: Yüksek frekanslı filtre[.5 -.5];
Çıkış	D: İki sinyal arasındaki benzerlik değeri %DTW p:İki sinyal benzerliğinin maksimum olduğu periyot
	<pre> 1 Başlangıç i=0, j=0, 2 Y= Min-Max_Norm (S) % Min-Max Normalizasyon 3 FS= wavelet_transform(Y, Lo_A, Hi_D)%dalgacık dönüşümü 4 for t=2:length(Fs)-1 5 p =tepe_sayısı(Fs(t)) 6 end for 7 A=Fs 8 for i=p:p:length(S) 9 B= kaydırma_işlemi (A,p) 10 A=A(1:end-p); 11 for i = 1:I 12 for j = 1:J 13 D(i,j)=DZB_mesafe_hesaplama(A,B) 14 end for 15 end for 16 end for </pre>

Şekil 3.3 DD-DZB algoritması kaba kodu

4. BÖLÜM


DENEYLER

Bu bölümde algoritma performansları incelenmiştir. Algoritmaların performanslarını test etmek için sentetik ve gerçek veriler kullanılmıştır. Performans deneylerinde algoritmaların doğrulukları, normalizasyonun etkisi ve algoritmaların hızları incelenmiştir. Bu bölümde öncelikle veriler tartışılmış ve daha sonra deneyler sunulmuştur.

4.1. Veri Kümeleri

Çalışmada kullanılan sentetik veri 5 ve 30 frekanslarına sahip iki sinyalin birleştirilmesi ile elde edilmiştir (Şekil 4.1).


Gerçek veri ise ortalama aylık maksimum ve minimum sıcaklık parametre değerlerine sahiptir ve 2005- 2017 arası Bağdat istasyonuna aittir (Tablo 4.1 ve 4.2). Şekil 4.2’de ortalama maksimum sıcaklık ve Şekil 4.3’de ortalama minimum sıcaklık görüntülenmiştir.



Şekil 4.1 Sentetik veri


Tablo 4.1 Ortalama maksimum sıcaklık. (°C)

	Ortalama maksimum sıcaklık(°C) (Bağdat)											
Yıl	Ocak	Şub.	Mart	Nis.	May.	Haz.	Tem.	Ağu.	Eyl.	Ekim	Kas.	Ara
2005	16.3	18.1	24.0	31.4	36.7	40.8	44.1	43.6	39.4	32.3	23.1	21.5
2006	16.1	19.6	26.6	30.3	38.2	44.2	45.2	42.7	40.0	34.0	22.6	15.7
2007	14.0	19.1	24.8	28.4	39.1	42.8	44.7	44.8	42.0	40.0	25.0	18.5
2008	13.1	18.7	29.4	33.2	36.9	41.7	44.2	45.5	40.8	32.5	24.1	18.4
2009	16.4	21.7	24.3	29.3	37.6	42.6	42.5	43.7	38.5	34.4	23.2	19.9
2010	20.2	20.8	26.1	31.3	37.5	42.8	45.5	46.6	41.7	35.5	27.7	20.7
2011	15.6	18.5	24.3	30.2	36.1	41.9	45.0	44.3	40.2	31.5	21.2	17.5
2012	16.8	18.4	22.4	32.7	37.7	43.0	46.1	44.2	40.7	34.0	24.4	18.5
2013	16.7	20.7	24.8	31.1	33.8	40.5	43.3	43.4	39.5	31.8	22.5	15.9
2014	16.4	19.1	25.6	31.8	37.9	41.7	44.0	45.1	31.6	32.9	22.8	19.6
2015	17.4	20.6	25.4	30.8	38.3	42.1	46.1	45.8	42.6	34.3	25.3	17.1
2016	16.2	21.5	25.1	32.3	37.2	42.4	45.5	46.7	40.1	35.3	24.7	15.8
2017	16.1	18.0	23.8	30.4	38.1	42.7	47.5	47.4	43.5	33.7	25.4	21.0

**Şekil 4.2** Bağdat 2005- 2017 yılları arası aylık ortalama maksimum sıcaklık (°C)**Tablo 4.2** Ortalama minimum sıcaklık. (°C)

	Ortalama minimum sıcaklık(°C) (Bağdat)											
Yıl	Ocak	Şub.	Mart	Nis.	May.	Haz.	Tem.	Ağu.	Eyl.	Ekim	Kas.	Ara
2005	4.2	6.2	11.0	17.4	20.8	24.8	26.9	25.6	21.4	15.6	10.0	7.3
2006	3.0	7.2	10.4	15.3	23.7	25.6	27.5	27.0	23.0	18.5	8.1	3.1
2007	3.0	7.2	10.4	15.3	23.7	25.6	27.5	27.0	23.0	18.3	9.0	4.5
2008	1.3	5.7	12.6	17.2	20.0	25.2	26.2	27.1	24.6	18.2	10.2	5.3
2009	2.0	9.0	11.6	15.7	21.7	25.6	26.3	32.9	22.0	18.7	11.0	9.0
2010	8.3	9.6	13.3	17.0	23.2	26.8	28.8	28.4	24.6	19.4	10.1	6.9
2011	5.7	7.5	10.5	17.0	22.5	26.7	28.7	27.3	22.9	16.6	7.2	3.6
2012	3.4	6.3	8.1	17.1	22.8	25.4	28.0	25.9	22.0	18.9	13.2	7.9

2013	6.4	9.4	11.8	16.0	20.8	24.9	26.3	24.3	20.9	13.9	13.3	5.1
2014	6.5	6.1	12.3	17.4	22.3	25.2	27.3	27.5	23.2	17.9	9.9	8.1
2015	4.4	6.9	9.3	14.1	21.6	25.0	28.2	27.9	25.1	20.8	11.2	5.0
2016	5.2	8.4	11.8	16.2	21.5	25.1	27.3	26.2	21.6	17.0	7.6	4.6
2017	3.6	3.0	11.7	15.6	21.4	24.9	28.8	28.3	23.7	17.0	11.7	6.7



Şekil 4.3 Bağdat 2005- 2017 yılları arası aylık ortalama minmum sıcaklık (°C)

4.2. Deneyler


4.2.1. DZB Algoritmasının Uygulanması

4.2.1.1. Sentetik Veri Deneyleri

Sentetik veri max-min normalizasyonundan geçirilir. Max-min normalizasyonu formülünde değişkenlerin aldığı değerler aşağıda verilmiştir.


$$v' = \frac{(v - Min)}{(Max - Min)} * (new_max - new_min) + new_min$$

v girişi sentetik sinyaldir (0:600), v' istenen aralıktaki yeni değeri gösterir, $Min = -9.5106$ en küçük sinyal değeridir, $Max = 9.5106$ en büyük sinyal değeridir. $new_min = 0$, $new_max = 1$ olarak alınmış ve sinyal 0-1 arasında ölçeklendirilmiştir (Şekil 4.4)



Şekil 4.4 Sentetik veriye min-max normalizasyonunun uygulanmış hali

Analiz algoritmasına girmeden önce tepe sayısı hesaplanır. Sinyalin periyodik olup olmadığını tespit etmek için sinyal p birim kaydırılır ve daha sonra sinyalin orijinali ile karşılaştırılır. Bu işlem bütün p birim kaydırma işlemleri için tekrarlanır. Sentetik zaman serisinin (sinyal A ile gösterilmiştir) ve zaman serisinin $p=25$ birim kaydırılmış hali (B sinyali) aşağıdaki şekilde verilmiştir. (Şekil 4.5).



Şekil 4.5 A ve B zaman serilerinin gösterimi

A ve B arasındaki benzerliği ölçmek için sinayaller DZB' ye girdi olarak verilir ve aradaki minimum mesafe hesaplanır. Daha sonra p değerleri artırılarak sinyal


karşılaştırma işlemleri tekrar edilir. DZB algoritması birer birim kaydırmalar için tekrarlanacaktır. DZB 25'er birim kaydırılarak çalıştırılmıştır. Her 100 birim kaydırma miktarlarına göre elde edilen minimum DZB mesafe ve zaman değerleri Tablo 4.3'te verilmiştir. Burada sinyalin 100 birim ve 100 birimin katlarında periyodik olduğu söylenebilir.

Tablo 4.3 Sentetik veri için DZB sonuçları

Kayma_miktari	Min_mesafe	Zaman
100	0.0013	12.9708
200	0.0017	8.859
300	0.0022	6.291
400	0.0033	3.6411
500	0.0066	1.3804

4.2.1.2. Gerçek Veri Deneyleri

Gerçek veri önce normalizasyondan geçirilir. Ortalama maksimum sıcaklık değeri üzerine normalizasyon uygulanması sonucunda Şekil 4.6'daki sonuç elde edilmiştir. Sinyaldeki minimum değer 13.1 ve maksimum değer ise 47.5'tir.



Şekil 4.6 Min-max normalizasyondan sonra ortalama maksimum sıcaklık

Algoritma her 3 aylık kaydırma için çalıştırılmıştır. Yapılan analiz sonucunda 12 ve katlarında sinyalin periyodik olduğu algoritma tarafından tespit edilmiştir. 12 aylık periyotla sıcaklıkların tekrar ettiği düşünülürse elde edilen sonuç mantıklıdır. Tablo 4.4’de 12 ve katlarında elde edilen minimum DZB mesafe ve zaman değerleri verilmiştir.

Tablo 4.4 Gerçek veri için DZB sonuçları


Kayma_miktari	Min_mesafe	Zaman
12	0.0270	1.2914
24	0.0443	1.0563
36	0.0405	0.2751
48	0.0427	0.2564
60	0.0444	0.1925
72	0.0418	0.1465
84	0.0441	0.1137
96	0.0392	0.0754
108	0.0402	0.0493
120	0.0485	0.0276
132	0.0452	0.0127
144	0.0374	0.0052

4.2.2. HFD-DZB Algoritmasının Uygulanması

Bu deneyde HFD-DZB algoritması sentetik ve gerçek veri üzerine uygulanmıştır.

4.2.2.1. Sentetik Veri Deneyleri

Sentetik sinyal yüklenir ve normalizasyon uygulanır (Şekil 4.7). Sinyali zaman alanından frekans alanına dönüştürür ve filtreleme uygulanması aşağıdaki şekilde sunulmuştur.



Şekil 4.7 HFD işleminin uygulanması

Sentetik veriye HFD-DZB algoritması uygulanması sonucunda 100 ve 100'ün katları kayma değerleri için elde edilen minimum mesafe değerleri Tablo 4.5'te verilmiştir.

Tablo 4.5 Sentetik veri için HFD-DZB sonuçları

Kayma_miktari	Min_mesafe	Zaman
100	0.0368	2.5616
200	0.0157	1.7425
300	0.0206	1.1708
400	0.0300	0.6896
500	0.0553	0.4251

4.2.2.2. Gerçek Veri Deneyleri

Ortalama maksimum sıcaklık parametresi üzerine HFD-DZB algoritması uygulanmıştır. 12 ve 12'in katları kayma değerleri için elde edilen minimum DZB mesafe ve zaman değerleri Tablo 4.6'da verilmiştir.

Tablo 4.6 Gerçek veri için HFD-DZB sonuçları


Kayma_miktar	Min_mesafe	Zaman
12	0.0373	0.3814
24	0.0543	0.3325
36	0.0614	0.2824
48	0.0632	0.2443
60	0.0670	0.1856
72	0.0760	0.1406
84	0.0775	0.1132
96	0.0920	0.0707
108	0.1017	0.0454
120	0.1236	0.0278
132	0.1675	0.0127
144	0.2480	0.0057

4.2.3. DD-DZB Algoritmasının Uygulanması

Bu deneyde DD-DZB algoritması sentetik ve gerçek veri üzerinde çalıştırılmıştır.

4.2.3.1. Sentetik Veri Deneyleri

Sentetik sinyal yüklenir ve normalizasyon uygulanır. Sinyale dalgacık dönüşüm uygulandıktan sonra elde edilen sonuçlar Şekil 4.8’de gösterilmiştir.



Şekil 4.8 DD işleminin uygulanması

Sentetik veriye DD-DZB algoritması uygulanması sonucunda 100 ve 100'ün katları kayma değerleri için elde edilen minimum mesafe değerleri ve algoritma çalışma zamanı Tablo 4.7'de verilmiştir.

Tablo 4.7 Sentetik veri için DD-DZB sonuçları

Kayma_miktar	Min_mesafe	Zaman
100	0.0042	2.2961
200	0.0053	1.5713
300	0.0070	1.0086
400	0.0105	0.5950
500	0.0209	0.4181

4.2.3.2. GerçekVeri Deneyleri

Ortalama maksimum sıcaklık parametresi üzerine DD-DZB algoritması uygulanmıştır. Farklı kayma değerleri için elde edilen minimum DZB mesafe değerleri Tablo 4.8'de sunulmuştur.

Tablo 4.8 Gerçek veri için DD-DZB sonuçları


Kayma_miktar	Min_mesafe	Zaman
12	0.0409	0.3782
24	0.0609	0.3235
36	0.0682	0.2823
48	0.0664	0.2217
60	0.0684	0.1847
72	0.0697	0.1390
84	0.0679	0.1023
96	0.0781	0.0497
108	0.0807	0.0282
120	0.0943	0.0124
132	0.1210	0.0122
144	0.1854	0.0035

4.3. Algoritmaların Sonuçlarının Karşılaştırılması


Bu bölümde DZB ve önerilen HFD-DZB, DD-DZB algoritmalarının performanslarının karşılaştırılması sunulmuştur.

4.3.1 Minimum Mesafe Değerlerine Göre Algoritmaların Karşılaştırılması


Bu bölümde DBZ, HFD-DZB ve DD-DZB algoritmalarının minimum DZB mesafe değerleri karşılaştırılmıştır. Sinyal ile p periyot kayma sonucunda elde edilen sinyalin karşılaştırılması sonucunda elde edilen minimum mesafe değeri ne kadar sıfıra yakın ise sinyalin p periyot ile periyodikliği o kadar iyidir demektir. Dinamik zaman bükmesinde orjinal sinyal ve bu sinyalin kaydırılmış versiyonu karşılaştırılmıştır. HFD-DZB algortmasında orjinal sinyal FIR filtresi ile konvolusyondan geçirilmiş ve daha sonra elde edilen sinyal ile bu sinyalin kaydırılmış versiyonu karşılaştırılmıştır. DD-DZB algortmasında ise orjinal sinyal dalgacık dönüşümünden geçirilmiş ve daha sonra elde edilen sinyal ile bu sinyalin kaydırılmış versiyonu karşılaştırılmıştır. Bu nedenle bütün algoritmalarda DZB kullanılmasına rağmen minimum mesafe değerleri farklıdır. Sonuçlar Şekil 4.9, Şekil 4.10 ve Şekil 4.11'de verilmiştir. Şekiller incelendiğinde DZB algoritmasının performansı diğer algoritmalara göre iyidir. Ancak DZB'nin zaman karmaşıklığı yani tükettiği zaman yüksektir. En kötü erformansı HFD-DZB algoritması vermiştir. Algoritma performansları örnekleme zamanı (veya yıl) değerleri arttıkça kötüleşmektedir. Çünkü karşılaştırılacak sinyal boyutu azaldığı için periyodiklik azalmaktadır.



Şekil 4.9 Sentetik veri için algoritmaların karşılaştırılması




Şekil 4.10 Ortalama maksimum sıcaklık için algoritmaların karşılaştırılması




Şekil 4.11 Ortalama minimum sıcaklık için algoritmaların karşılaştırılması

4.3.2 Algoritmaların Çalışma Zamanlarına Göre Karşılaştırılması


DBZ, HFD-DZB ve DD-DZB algoritmaları çalışma zamanlarına göre karşılaştırıldıklarında en hızlı algoritma DD-DZB olarak ve en yavaş algoritma ise DZB olarak tespit edilmiştir. DZB bütün olası periyot kaymaları analiz etmesinden dolayı işlem maliyeti artmaktadır. Buna karşılık diğer algoritmalar DZB ile zaman serisi karşılaştırma işlemini tespit ettikleri periyot ve bu periyotların katsayıları için yapmaktadır. Şekil 4.12'de sentetik veri için algoritma zamanları verilmiştir. Şekil 4.13 ve 4.14'de ise sırasıyla ortalama maksimum sıcaklık ve ortalama minimum sıcaklık için algoritma çalışma zamanları verilmiştir.



Şekil 4.12 Sentetik veri için algoritma çalışma zamanları



Şekil 4.13 Ortalama maksimum sıcaklık için algoritma çalışma zamanları



Şekil 4.14 Ortalama minimum sıcaklık için algoritma çalışma zamanları

5. BÖLÜM

TARTIŞMA, SONUÇ ve ÖNERİLER

5.1. Tartışma, Sonuç ve Öneriler

Tez çalışmasında zaman serileri içerisinde bulunan periyodikliklerin bulunması için veri madenciliği teknikleri geliştirilmiştir.

Periyodiklik analizinde fourier dönüşümü(FD), dalgacık dönüşümü (DD) ve dinamik zaman bükmesi (DZB) tabanlı algoritmalar kullanılmaktadır. Bu çalışmada analiz maliyeti yüksek olan DZB algoritmasının hızlandırılması için DZB algoritması hızlı fourier dönüşümü (HFD) birleştirilerek HFD-DZB algoritması ve dalgacık dönüşümü ile birleştirilerek DD-DZB algoritması önerilmiştir. DZB ile periyodiklik analizinde bir sinyal ile bu sinyalin p birim kaydırılmış versiyonu karşılaştırılarak benzerliğine bakılır. Eğer sinyal periyodik ise sinyalin orjinal hali ile p periyot kaydırılmış hali benzer çıkacaktır. Ancak bu işlemin hesaplama maliyeti yüksektir çünkü bütün kaydırmaların analiz edilmesi gerekir. Fourier ve dalgacık dönüşümleri kullanılarak DZB algoritmasının bütün periyotları incelemesi durumu giderilmiştir.

Algoritmaların performanslarının incelenmesi için sentetik ve gerçek veriler kullanılmıştır.

Gelecekteki çalışmalarda önerilen algoritmaların performanslarını arttırma çalışmaları ve DZB dışında başka sinyal benzerliğini bulma algoritmalarının incelenmesi çalışmaları yapılabilir.

KAYNAKÇA

- 1- Han, J., Kamber, M. & Pei, J., 2012. Data Mining Concepts And Techniques. **Third Edition**, c 2012 by Elsevier Inc,740/pp.
- 2- Cass,S., .Afoundation of knowledege, <https://spectrum.ieee.org/computing/software/winner-a-fountain-of-knowledge>, (Data Accessed: June 2019).
- 3- Elfeky, M. G., Aref, W. G., & Elmagarmid, A. K., 2005. WARP: time warping for periodicity detection. Proceedings of the Fifth IEEE International Conference on Data Mining (ICDM'05), 1550-4786/05.
- 4- Celik, M., Azginogul, N. & Terzi, R., 2012. Mining periodic spatio –temporal co-occurrence pattens: a summary of result. Int'l Symp. **On Innovvation in Intelligent System and Applications**, Trabzon, Turkey.
- 5- Bemdt, D. J., Donald, J., & lifford, J.,1994. Using dynamic time warping to find patterns in time series. **From: AAAI Technical Report** WS-94-03, New York 10012-1126.
- 6- Begum,N., Ulanova,L., Wang, J. & Keogh, E., 2015. Accelerating dynamic time warping clustering with a novel admissible pruning strategy, **KDD '15, August 10-13**, Sydney, NSW, Australia.
- 7- Sheng, C., Hsu, W. & Li Lee, M., 2006. Data mining dense periodic patterns in time series data, Engineering, Proceedings of the 22nd International **Conference on Data Engineering (ICDE'06)**, 8-7695-2570-9/06.
- 8- Otazu, X., Ribo, M., Peracaula, M., Paredes, J. M. & Nunez, J., 2002. Detection of superimposed periodic signals using wavelets. **Mon. Not. R. Astron. Soc.** **333**, 365–372.
- 9- Benedetto, J. J. & Pfander, G. E., 2002. Periodic wavelet transforms and periodicity detection. SIAM J. APPL. MATH. **Society for Industrial and Applied Mathematics Vol. 62**, No. 4, pp. 1329–1368.

- 10- Sani S. N., Roscoe B. J, Cai, X., Alamgir, Z. M., Wang, R., Robinson C. J., 2013. Wavelet decomposition to detect periodic signals in head accelerometry measures, **39th Annual Northeast Bioengineering Conference**, 978-0-7695-4964-4/13.
- 11- Chaovalit,P., Gangopadhyay A., Karabatis, G. & Chen, Z., 2011. Discrete wavelet transform-based time series analysis and mining, **ACM Computing Surveys**, Vol. 43, No. 2, Article 6 (January 2011).
- 12- Aref, W.G. & Elmagarmid, A.K., 2005. Periodicity detection in time series databases, **IEEE Transactions on Knowledge and Data Engineering**, Vol. 17, No.
- 13- Berberidis,C., Aref, W.G., Atallah, M., Vlahavas, I., Elmagarmid, A. K., 2002. Multiple and partial periodicity mining in time series databases, ECAI 2002 .
- 14- Hatkar,S.P., Kadam S.H. & Syed A.H, 2014. **Analysis of various periodicity detection algorithms in time series data with design of new algorithm**, ISSN: 2319–8656, Volume 3– Issue 4, 228 - 238.
- 15- Khanna, S. & Kasurkar, S.A., 2013. Study of various periodicity detection techniques in time series data and primary level plan for new technique, **IJARCET**, Volume 2, Issue 11, November.
- 16- Akin, M., 2002. Comparison of wavelet transform and FFT methods in the analysis of **EEG signals**,**journal of medical systems**, Vol. 26, No. 3, June.
- 17- Leda, J., 2011. Power quality identification using fast fourier transform and wavelets, Vol. 5, No. 1, **Mei**, ISSN 1829 – 8044.
- 18- Fan, N., Balan, R., Rosca, J., Comparison of Wavelet and FFT Based Single Channel Speech Signal Noise Reduction Techniques, Siemens Corporate Research Inc.
- 19- Mastriani, M., Quantum Spectral Analysis: Bandwidth At Time. qunb LLC, 16192 Coastal Hwy, Lewes, DE 19958, USA.

- 20- An Interactive Guide To The Fourier Transform ,
<https://betterexplained.com/articles/an-interactive-guide-to-the-fourier-transform/> (Data Accessed: June 2019)
- 21- Misiti, M., Misiti, Y., Oppenheim, G. & Poggi, J. M., 1997. Wavelet Toolbox : For Use With Matlab, The Mathworks, Inc.
- 22- Hatfied, C. 1980 , The Analysis of Time Series : An Introduction. Chapman and Hall, ISBN 978-1-4899-2923-5 (eBook) 282/pp.
- 23- Al-Norri, S. M. Y., 2004. Digital Image Segmentation Baseds on Wavelet Transform and Fractals, Computer Science Department Mosul university, M. Sc. Thesis.84pp.
- 24- Dixit, A., Majumdar, S., 2013. Comparative analysis of coiflet and daubechies wavelets using global threshold for image de-noising, International Journal of Advances in Engineering & Technology ©IJAET, ISSN: 22311963, Vol. 6, Issue 5, pp. 2247-225.
- 25- Misiti, M., Misiti, Y., Oppenheim, G., Michel Poggi, J., 2003 . Wavelets And Their Applications. **British Library Cataloguing-in-Publication Data, ISBN: 978-1-905209-31-6, 352/ pp.**
- 26- SAKOE,H., CHIBA, S., 1978. Dynamic Programming Algorithm Optimization for Spoken Word Recognition. **IEEE Transactions On Acoustics, Speech, And Signal Processing, Vol. ASSP-26, NO.**
- 27- Saranya, C. & Manikandan, G., 2013. Study on normalization techniques for privacy preserving data mining. **International Journal of Advances in Engineering & Technology (IJET)**, ISSN : 0975-4024,Vol 5 No 3 .

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı: Muneera Yousif Yaqoob MOHAMMED
Uyruğu: Irak
Doğum Tarihi ve Yeri: 21/7/1991- Musul
E-posta: muneera.y.y91@gmail.com
Adres: Mevlana Mah. Turgut Özal Cad. İzzet Bayraktar Camii Yanı
 No:31 Talas/Kayseri, TÜRKİYE

EĞİTİM

Derece	Kurum	Mezuniyet Tarihi
Yüksek Lisans	Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Müh. Böl. Anabilim Dalı , Kayseri, TÜRKİYE	Devam Ediyor.
Lisans	Musul Üniversitesi, Bilgisayar ve Matematik Fakültesi, Musul, IRAK	2013
Lise	Reşidiye Fen Lisesi, Musul, IRAK	2009

YABANCI DİL

İngilizce
 Türkçe

