

YILDIZ TEKNİK ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

ÇOKLU SİLİNDİRİK HEDEFLERİN SINIFLANDIRILMASI

Elektronik Müh. Mustafa Melih TAŞANER

FBE Elektronik ve Haberleşme Mühendisliği Anabilim Dalı Haberleşme Programında Hazırlanan

YÜKSEK LİSANS TEZİ

Tez Danışmanı: Doç. Dr. Ahmet Kızılay

İSTANBUL, 2009

İÇİNDEKİLER

SİMGE LİSTESİ	iv
KISALTMA LİSTESİ	v
ŞEKİL LİSTESİ	vi
TABLO LİSTESİ	viii
ÖNSÖZ	ix
ÖZET	x
ABSTRACT	xii
1. GİRİŞ	1
2. SONSUZ UZUN MÜKEMMEL İLETKEN DÜZ YÜZEY ÜZERİNDE BULUNAN İKİ SİLİNDİRİK HEDEFTEN SAÇILAN ELEKTRİK ALANIN HESAPLANMASI.....	5
2.1 Moment Metodunun İki Cisimden Saçılma Problemine Uygulanması	7
2.2 Nümerik Sonuçlar	10
3. SİNYAL ANALİZ METODLARI	14
3.1 Sinyal Analizi	15
3.1.1 Fourier Teoremi	16
3.1.2 Fourier Dönüşümü	17
3.1.3 Kısa Zamanlı Fourier Dönüşümü.....	19
3.1.3.1 Pencere Çeşitleri.....	21
3.1.3.1.1 Dikdörtgen pencere.....	21
3.1.3.1.2 Hamming Pencere.....	21
3.1.3.1.3 Hanning Pencere.....	22
3.1.3.1.4 Blackman Pencere	22
3.1.4 Dalgacıklar.....	27
3.1.5 Dalgacık Analizi	28
3.1.6 Dalgacık Dönüşümleri.....	29
3.1.6.1 Sürekli Dalgacık Dönüşümü	30
3.1.6.2 Ayrık Dalgacık Dönüşümü	32
4. YAPAY SİNİR AĞLARI	36
4.1 Yapay Sinir Ağlarının Özellikleri.....	36
4.1.1 Doğrusal Olmama	36
4.1.2 Öğrenme	36
4.1.3 Genelleme	37
4.1.4 Uyarlanabilirlik	37
4.1.5 Hata Toleransı.....	37
4.1.6 Donanım ve Hız	38
4.1.7 Analiz ve Tasarım Kolaylığı.....	38

4.2 Çalışmada Kullanılan Yapay Sinir Ağı Yapısı.....	38
4.2.1 Genelleştirilmiş Regresyon Ağları (GRNN)	38
4.3 KZFD İle Oluşturulan Veri Kümesi	39
4.4 KZFD Analizinin GRNN Ağı Sonuçları.....	39
4.5 Dalgacık Dönüşüm ile Oluşturulan Veri Kümesi.....	40
4.6 Dalgacık Dönüşümünün GRNN Ağı Sonuçları	40
5. SONUÇLAR	43
KAYNAKLAR	44
EKLER	46
Ek 1 Kullanılan Kısa Zamanlı Fourier Dönüşümü İçin Simülasyon Programı	47
Ek 2 Kullanılan Dalgacık Dönüşümü İçin Simülasyon Programı.....	52
Ek 3 Kısa Zamanlı Fourier Dönüşümde Kullanılan Genelleştirilmiş Regresyon Sinir Ağı'nın Simülasyon Programı.....	53
Ek 4 Dalgacık Dönüşümü Katsayılarının Girişi Oluşturduğu Birinci Durum İçin Kullanılan Genelleştirilmiş Regresyon Sinir Ağı İçin Simülasyon Programı	55
Ek 5 Dalgacık Dönüşümü Katsayılarının Girişi Oluşturduğu İkinci Durum İçin Kullanılan Genelleştirilmiş Regresyon Sinir Ağı İçin Simülasyon Programı	57
ÖZGEÇMİŞ	59

SİMGE LİSTESİ

r_{t1}	1.Silindirin yarıçapı
r_{t2}	2.Silindirin yarıçapı
h_{t1}	1.Silindirin yerden yüksekliği
h_{t2}	2.Silindirin yerden yüksekliği
x_{t2}	İki silindir arasındaki mesafe
N_T	Hedef yüzeydeki nokta sayısı
ϕ_i	Gelen dalganın yatayla yaptığı açı
E_i	Gelen elektrik alan
E_s	Saçılan elektrik alan
k_o	Serbest uzayın dalga sayısı
H_o	Hankel fonksiyon
η_o	Serbest uzayın karakteristik empedansı
ϕ_s	Saçılma açısı
Hz	Hertz
φ	Dalgacık
s	Ölçekte kaydırma
τ	Zamanda kaydırma
W	Pencere fonksiyonu
w	Frekans parametresi
t'	Zaman parametresi
x	YSA' da hücrenin giriş vektörü
y	YSA' da hücrenin çıkış vektörü

KISALTMA LİSTESİ

PEC	Perfectly Electrical Conducting
GRNN	Generalized Regression Neural Network
KZFD	Kısa Zamanlı Fourier Dönüşümü
YSA	Yapay Sinir Ağı
DFT	Ayrık Fourier Dönüşümü
FFT	Hızlı Fourier Dönüşümü
SDD	Sürekli Dalgacık Dönüşümü
ADD	Ayrık Dalgacık Dönüşümü
AGF	Alçak Geçiren Filtre
YGF	Yüksek Geçiren Filtre

ŞEKİL LİSTESİ

Şekil 1.1 Deniz çevresinde hedef tanıma problemi.....	3
Şekil 2.1 Sonsuz düz yüzey üzerindeki iki silindirik hedef.....	5
Şekil 2.2 Sonsuz düz yüzey üzerindeki iki silindir için Görüntü metodu çözümü	6
Şekil 2.3 Yarıçapları $r_{1l}=0.0127$ m, $r_{12}=0.0127$ m; yükseklikleri $h_{1l}=0.1016$ m, $h_{12}=0.1016$ m ve aralarındaki mesafe $x_{12}=0.635$ m olan silindirik hedeflerden saçılan toplam elektrik alanının frekans domenindeki cevabı	10
Şekil 2.4 Yarıçapları $r_{1l}=0.0127$ m, $r_{12}=0.0127$ m; yükseklikleri $h_{1l}=0.1016$ m, $h_{12}=0.1016$ m ve aralarındaki mesafe $x_{12}=0.635$ m olan silindirik hedeflerden saçılan toplam elektrik alanının zaman domenindeki cevabı.....	11
Şekil 3.1. Frekansı 5, 25 ve 50 Hz olan sinyaller.....	17
Şekil 3.2. x_1 , x_2 ve x_3 periyodik sinyallerinin Fourier dönüşümleri	18
Şekil 3.3. x_4 sinyali ve Fourier dönüşümü $x(t)$	18
Şekil 3.4. KZFD ile bir sinyalin pencerelemesi	20
Şekil 3.5 Hamming penceresi	22
Şekil 3.6 Hanning penceresi	22
Şekil 3.7 Elektrik alana Dikdörtgen pencere kullanarak Kısa Zamanlı Fourier Dönüşüm analizi.....	23
Şekil 3.8 Elektrik alana Hamming pencere kullanarak Kısa Zamanlı Fourier Dönüşüm analizi.....	24
Şekil 3.9 Elektrik alana Hanning pencere kullanarak Kısa Zamanlı Fourier Dönüşüm analizi.....	24
Şekil 3.10 Elektrik alana Blackman pencere kullanarak Kısa Zamanlı Fourier Dönüşüm analizi.....	25
Şekil 3.11 Wavelet toolbox ile analizi yapılan imaj.....	26
Şekil 3.12 İmajın Yaklaşıklık katsayılarının hesaplatılması.....	26
Şekil 3.13. Dalgacık dönüşümünün gösterimi	29
Şekil 3.14. Zaman-frekans düzleminde sinyal dönüşümlerinin gösterimi	29
(a)KZFD dönüşümü (b)Dalgacık dönüşümü	29

Şekil 3.15. Dalgacık örnekleri.....	30
Şekil 3.16. Dalgacığın sinyal üzerinde kaydırılması	31
Başlangıç durumu (b) Sağa kaydırılmış durum	31
Şekil 3.17. Ölçeğin değiştirilmesi	31
Şekil 3.18. Sinyal spektogramı.....	32
Sekil 3.19. Üç boyutlu gösterim.....	32
Şekil 3.20. Temel filtreleme uygulanması	33
Şekil 3.21. Sinyal ayrıştırma işlemi.....	34
Şekil 3.22. Frekans bantları ile yaklaşımlar ve detaylar arasındaki ilişkisi.....	34
Şekil 3.23. ADD zaman-frekans düzlemi	35
Şekil 4.1 GRNN ağ yapısı.....	39
Şekil 4.3 GRNN Ağının giriş ve çıkışlarını gösteren blok diyagram.....	40
Şekil 4.4 GRNN Ağının giriş ve çıkışlarını gösteren blok diyagram.....	41
Şekil 4.2 GRNN Ağının giriş ve çıkışlarını gösteren blok diyagram.....	41

TABLO LİSTESİ

Tablo 2.1 64 durum için iki silindirin yarıçapları ve konumları.....	11
--	----

ÖNSÖZ

Bu çalışmada iki silindirik cisimden yansıyan elektrik alanın Kısa Zamanlı Fourier Dönüşümü ve Dalgacık dönüşümü ile analizi yapılarak Genelleştirilmiş Regresyon Sinir Ağı modeline giriş özellikleri oluşturulmuştur. Saçılan sinyallerin durağan olmaması nedeniyle Fourier dönüşümü, yapay sinir ağının başarısı için yetersiz kalırken, durağan olmayan sinyallerin analizi için dalgacık dönüşümünün gayet başarılı olduğu görülmüştür. Atmosferde durağan olmayan sinyallerin çokluğu dalgacık dönüşümünü popüler yapmakta ve üzerinde çalışılması gereken güncel bir konu olmasını sağlamaktadır.

Öncelikle bu tezin hazırlanmasında bana sürekli destek olan, çalışma boyunca bilgilerini benden esirgemeyen ve çalışmanın tamamlanmasında katkısı büyük olan değerli hocalarım Doç. Dr. Ahmet KIZILAY' a ve Arş. Gör. Senem MAKAL' a teşekkürlerimi sunarım.

Bunun yanı sıra bana büyük maddi ve manevi destek sağlayan aileme teşekkür ederim.

ÖZET

Saçılan sinyallerden radar hedeflerini tanıma elektromagnetikğin önemli konularından biridir. Cisim tarafından saçılan elektromagnetik dalgalar, o cismin karakteristik bilgisini içermektedir ve saçılan dalgadan cismin tanınması oldukça zor bir problemidir. Bu bakımdan öğrenme ve genelleme yeteneklerinden dolayı yapay sinir ağları, birçok mühendislik uygulamalarında kullanıldığı gibi bu tür problemlerde de kullanılmaktadır [1]. Turhan, küresel dielektrik bir malzemeden saçılan elektromagnetik dalga'nın elektrik alan ifadesinden yararlanarak bir veri kümesi oluşturmuş ve Wigner dağılımını ile özellik çıkarımı yaparak bir hedef sınıflayıcı tasarlamıştır [2].

Benim çalışmamda ise, en basit modellerden biri olan sonsuz uzun, düz yüzey üzerindeki 2 silindirik hedeften saçılma problemi ele alınmıştır. Deniz yüzeyi ve silindirik hedef hesaplamada kolaylık sağlaması açısından mükemmel iletken (PEC- Perfectly Electrical Conducting) kullanılmıştır. Hedef tanıma ve sınıflama uygulamalarında kullanılan hedef olarak 2 silindirik cisim seçilmiştir. Bu hedeflerden saçılan toplam elektrik alan hesaplanmış, saçılan sinyallere STFT (Short Time Fourier Transform – Kısa Zamanlı Fourier Dönüşümü - KZFD) ve WAVELET (Dalgacık dönüşümü) analizi uygulanmış ve sonuçta elde edilen katsayıların giriş verileri olarak kullanıldığı 4 farklı yapay sinir ağı (YSA) modeli MATLAB programı ile simüle edilmiştir. Çıkış verileri olarak 1. silindirin yarıçapı, 2. silindirin yarıçapı ve aralarındaki mesafe alınmıştır. YSA olarak Genelleştirilmiş Regresyon Sinir Ağı (Generalized Regression Neural Networks - GRNN) kullanılmıştır. Genelleştirilmiş Regresyon Ağları, radyal temelli ağların genellikle fonksiyon yaklaşırma problemleri için kullanılmakta olan özel bir halidir. Bu ağlar önemli ölçüde iyi başarı ile sürekli fonksiyonlara yaklaşımı sağlarlar. Giriş ve çıkış arasında, eğitim kümesinden elde ettiği bulgularla herhangi sıradan bir fonksiyona yaklaşabilir. Eğitim kümesinin boyutları büyüdükçe yaklaşımdaki hata oranı sifıra yakınsar. Bu 4 farklı GRNN modelinin biri Kısa Zamanlı Fourier Dönüşümü kullanılarak oluşturulan giriş değerleri ile modellenmiş, diğeri Kısa Zamanlı Fourier Dönüşümü uygulanan şekle Dalgacık araçkutusunu ile oluşturulan özelliklerin giriş olarak kullanılması ile modellenmiş, diğeri ikisi ise Dalgacık Dönüşümü kullanılarak farklı iki giriş veri seti oluşturularak modellenmiş YSA' dır. YSA' ların başarılarının karşılaştırılması sonucunda dalgacık

katsayılarının kullanıldığı modellerin Kısa Zamanlı Fourier Dönüşümü'nden elde edilen katsayıların kullanıldığı modelden çok daha başarılı olduğu gözlemlenmiştir.

Ayrıca geleneksel işaret işlemede kullanılan Fourier Dönüşümü'nün yetersizliklerinden bahsedilmiştir. Sinyal analizinin sadece frekans düzlemi veya zaman düzleminde yapılması, sinyal içerisindeki bir bilginin düşünülmemesi anlamına geldiğinden özellikle durağan olmayan sinyallerin analizinde, işaretin frekans ve zaman bilgilerini aynı anda elde etmek için geliştirilen Dalgacık Dönüşümü tekniğinin mükemmel sonuçlarına varılmıştır.

ANAHTAR KELİMELELER: Elektromagnetik hedef tanıma, elektromagnetik hedef sınıflama, Kısa Zamanlı Fourier Dönüşümü, Dalgacık Dönüşümü, Genelleştirilmiş Regresyon Sinir Ağı

ABSTRACT

Radar targets recognition from scattering signals is one of the important subjects of electromagnetic. The electromagnetic waves that scatter from object contains its characteristic knowledge and recognition of the object from the scatter wave is so difficult problem. In this regard, because of their ability to learn and generalize artificial neural networks are attractive for numerous engineering applications [1].Turhan has created a data cluster by the electric field expression of the electromagnetic wave that scatter from global dielectric material and he has designed Wigner distribution of a target by making the feature extraction sorter [2].

In my thesis, one of the simplest model, the scattering problem from infinite long, on the flat surface 2 cylindrical target was explained. PEC-Perfectly Electrical Conducting has been used to provide convenience to calculate sea surface and the cylindrical target. 2 cylindrical objects have been selected as the destination that is used target recognition and classification applications. The scattering aggregate electric field from these targets has been calculated, STFT (short time Fourier transform) and WAVELET analysis have been applicated to the scattering signals, the resulting data used as input coefficients are 4 different artificial neural networks model has been simulated by MATLAB program. First cylinder radius and second cylinder radius and the distance between them have been used as output data. Generalized Regression Neural Networks – GRNN has been used as artificial neural network. Generalized regression neural networks, radial based networks function approach generally used for the problem is a special case. These networks provide approach the continuous function with certain number of neurons in the hidden layer and significantly better success. Between input and output, it can come close to an ordinary functions with the findings derived from training. Training set sizes grow, the error rate will approach closer to zero. One of this 4 different GRNN models has been created by the input values using Short-Time Fourier Transform, one of this 4 different GRNN models has been created by the input values using Short-Time Fourier Transform with Matlab Wavelet Toolbox, the other two by using the Wavelet Transform by creating two different input data sets are modeled with artificial neural networks. As a result of comparison of the success of artificial neural networks, it has been observed that the Wavelet coefficients used models are more successful than coefficients obtained from Short-Time Fourier Transform used models.

Moreover, Fourier transform of the shortcomings that is used in traditional signal processing have been mentioned. Because of the signal analysis to be done only in the plane or the time-frequency plane means is considered information in signal, especially in non-stationary signal analysis, the excellent results of Wavelet transform technique has been reached to obtained sign frequency and time information at the same time.

Keywords: Electromagnetic target identification, electromagnetic target classification, Short-Time Fourier Transform, Wavelet Transform, Generalized Regression Neural Networks

1.GİRİŞ

Saçılan sinyallerden radar hedeflerini tanıma elektromagnetğin önemli konularından biridir. Cisim tarafından saçılan elektromagnetik dalgalar, o cismin karakteristik bilgisini içermektedir ve saçılan dalgadan cismin tanınması oldukça zor bir problemidir. Bu bakımdan öğrenme ve genelleme yeteneklerinden dolayı yapay sinir ağları, birçok mühendislik uygulamalarında kullanıldığı gibi bu tür problemlerde de kullanılmaktadır [1]. Turhan, küresel dielektrik bir malzemeden saçılan elektromagnetik dalganın elektrik alan ifadesinden yararlanarak bir veri kümesi oluşturmuş ve Wigner dağılımını ile özellik çıkarımı yaparak bir hedef sınıflayıcı tasarlamıştır [2]. Yuan, sualtı hedeflerinin parmak izinden yararlanarak hedefle ilgili özellikleri elde etmiş ve bunları genetik algoritma yardımıyla sualtı hedeflerini tanımada kullanmıştır. Benzer bir uygulama Zhihe ve Feng tarafından yapay sinir ağları kullanılarak yapılmıştır [3].

Şekil 1.1’de görüldüğü üzere, küçük açılarda işaretler, radardan hedefe doğrudan ve dolaylı yoldan ulaşmakta ve böyle bir durumda hedeften doğrudan ve dolaylı yoldan geri dönen işaretler toplanmaktadır. Bu durum çoklu yol (multipath) problemini doğurmakta ve bu problem geniş bantlı radar sistemleri kullanılarak çözülebilmektedir. Şekil 1.1’de ele alınan yüzey modeli periyodik bir yapıdır ve yüzeye yakın hedeflerin bulunması için kullanılan basit modellerden biridir.

Çoklu yol kavramının ya da çoklu yansımanın ana prensiplerini anlayabilmek için en basit modellerden biri sonsuz uzun, düz yüzeydir. Deniz yüzeyi ve silindirik hedef hesaplamada mükemmel iletken (PEC-Perfectly Electrical Conducting) kolaylık sağlar. Silindirik hedeften saçılan sinyaller, durağan olmayan sinyallerdir. Dinamik bir yapıya sahiptirler, zamanla değişirler. Bu sinyallerin frekans ve genlik bileşenlerinin, sayısal olarak incelenmesi gerekir. Farklı zaman aralıklarında, frekans ve genlik bileşenlerinin elde edilmesinde, matematiksel dönüşüm fonksiyonları kullanılır.


Matematikte fonksiyonları temsil etme fikri 1800’lü yıllara dayanır. Bu yıllarda sinyallerin, sinüs ve kosinüs terimlerinin toplamı şeklinde ifade edilebileceği şeklinde bir teorem ortaya atılmıştı. Bu teoremi bulan Joseph Fourier adında bir matematikçidir. Bu teorem kullanılarak Fourier Dönüşümü uygulanan bir sinyalde, zaman-frekans

düzlemi arasında dönüşüm yapılabilir. Fourier dönüşümü, sinyal analizinde etkin bir şekilde kullanılmasına ve sinyal analizinde bir devrim olmasına karşın, özellikle dinamik sinyallerin incelenmesinde ve sinyal içerisindeki ani değişimlerde yetersiz kaldığı görülmüştür. Bu sorunu çözmek için farklı algoritmalara başvurulmuştur. Kısa Zamanlı Fourier Dönüşümü gelişmiş Fourier dönüşüm algoritması olup dönüşüm işlemini oldukça hızlandırmış ve sinyal analiz etkinliğini arttırmış olmasına karşın ani frekans değişimlerinin tespitinde istenilen sonuçları verememiştir.

Fourier dönüşümlerindeki bu eksiklik, sinyalin analizinde yetersiz kalmasına sebep olur. Çünkü cisimlerden saçılan sinyaller durağan olmayan sinyallerdir. Bu sinyaller içerisinde küçük geçici sinyaller olabileceği için Fourier metotlarının hiçbirisi dinamik sinyallerin analizinde uygun değildir. Bu eksikliği ortadan kaldırmak için kullanılan Dalgacık teoreminin, Kısa Zamanlı Fourier Dönüşümü' ne benzer bir mantığı vardır. Ancak Dalgacık Dönüşümü' nde, Kısa Zamanlı Fourier Dönüşümü' nde olduğu gibi sinyalin tamamı bir pencereden incelendikten sonra, sinyal, ikinin üsleri şeklinde ötelenerek tekrar incelenir. Bu işlem bize, sinyalin içerisindeki en küçük anlardaki bilgileri dahi verir. Bu sebepten dolayı dinamik sinyallerin incelenmesinde Dalgacık Dönüşümü mükemmel bir araçtır. Sinyallerin analizi hem zaman hem frekans düzleminde yapılabilir.

Bu amaçla sayısal hesaplamalardaki üstün gücü ile veri işleme ve analizinde yaygın kullanılan Matlab programı tercih edilmiştir. C++ programlama diline benzer bir kodlama biçimi vardır. Özellikle veri analizinde görsel öğeler içermesi ve kullanımının kolay olması sebebiyle oldukça tercih edilen bir programdır.

Bu çalışmada hedef tanıma ve sınıflama uygulamalarında kullanılan hedef olarak 2 silindirik hedef seçilmiştir. Bu hedeflerden saçılan toplam elektrik alan hesaplanmış, saçılan sinyallere Kısa Zamanlı Fourier Dönüşümü ve Dalgacık Dönüşümü zaman-frekans analizi uygulanmış ve sonuçta elde edilen katsayılar yapay sinir ağları için giriş vektörlerini oluşturmuştur.



Şekil 1.1 Deniz çevresinde hedef tanıma problemi ⁴

YSA, insan vücudundaki sinir sisteminin bazı fonksiyonlarını modelleyen ve bazı yeteneklerini yakalamak isteyen basit hesapsal birimlerin (nöronlar) yoğun bir paralel dizisidir. Başka bir deyişle, teorik hale getirilmiş zekâ ve beyin faaliyetlerinin matematiksel modelleridir. Ancak biyolojik sistemler o kadar karmaşıktır ki, yapay sinir ağı için kullanılan biyolojik modellerin fazlaca basite indirgenmiş biçimleri şeklindedir. Öğrenme algoritmalarının üstün uyum yeteneği, basit işlemsel elemanlara sahip olması, donanıma uygulanabilirlik, yüksek hızda hesaplama yapabilme ve hedef ile ilgili önceki verilerden yararlanarak hedef ile ilgili değişikliklere uyum sağlama özelliklerinden dolayı YSA hedef tanıma uygulamalarında sıkça kullanılmaktadır [5], [6].

Beş bölümden oluşan bu tez aşağıdaki şekilde düzenlenmiştir:

Tezin giriş bölümünde saçılan elektrik alanın sınıflandırılması ile ilgili geçmişte yapılan bazı çalışmalardan bahsedilmiştir.

İkinci bölümünde, moment metodu ve görüntü metodu kullanılarak sonsuz uzun mükemmel iletken düz yüzey üzerinde bulunan iki silindirik hedeften saçılan elektrik alan hesaplanmıştır.


Üçüncü bölümde, Sinyal-frekans analizi geleneksel yöntemleri ve bunların yetersizlikleri incelenmiştir. İşaret analizi yöntemlerinden Kısa Zamanlı Dalgacık Dönüşümü'nden bahsedilmiştir. Dalgacık Dönüşümü temel ilkeleri anlatılmış, Dalgacık Dönüşümü'nün geleneksel yöntemlerle karşılaştırılması yapılarak sunduğu avantajlara değinilmiştir.

Dördüncü bölümde, yapay sinir ağından bahsedilmiş bu çalışmada kullanılan Genelleştirilmiş Regresyon Sinir Ağı'nın yapısı anlatılmıştır. Ayrıca Kısa Zamanlı Fourier Dönüşümü ve Dalgacık Dönüşümü ile saçılan sinyallerin analizi yaptırılmış ve elde edilen görüntünün özellikleri ve katsayılar ile Genelleştirilmiş Regresyon Sinir Ağı yapısı oluşturulmuştur. Yapay sinir ağının test başarısızlığı ile KZFD bağdaştırılmıştır. Dalgacık zaman-frekans analiz yöntemi ile yapay sinir ağının başarısının KZFD'ye göre çok yükseldiği gözlemlenmiştir.

Tezin sonuçlar kısmında ise, elde edilen verilerin analizi ile sonuçlar değerlendirilmiştir.

2. SONSUZ UZUN MÜKEMMEL İLETKEN DÜZ YÜZEY ÜZERİNDE BULUNAN İKİ SİLİNDİRİK HEDEFTEN SAÇILAN ELEKTRİK ALANIN HESAPLANMASI

Bu bölümde mükemmel iletken sonsuz düz bir yüzey üzerinde bulunan iki silindirik cisimden saçılan elektrik alan hesaplanacaktır. Şekil 2.1’de görüldüğü gibi yarıçapı r_{t1} , yüksekliği h_{t1} olan birinci hedef T_1 ile gösterilmiş; yarıçapı r_{t2} , yüksekliği h_{t2} olan ikinci hedef T_2 ile gösterilmiştir. İki cisim arasındaki mesafe x_{t2} ’dir.



Şekil 2.1 Sonsuz düz yüzey üzerindeki iki silindirik hedef⁴


Görüntü metodu yardımı ile sonsuz düz yüzey, silindirler ve gelen dalganın görüntüsü ile yer değiştirir. Saçılan elektrik alan ise silindirlerin üzerinde oluşan akımlar ile görüntülerin akımlarının toplamına eşittir ve

$$E_z^s(\vec{r}) = M_{T_1}(\vec{r}, \vec{r}_1') K_z^{T_1}(\vec{r}_1') + M_{T_{i1}}(\vec{r}, \vec{r}_1') K_z^{T_{i1}}(\vec{r}_1') + M_{T_2}(\vec{r}, \vec{r}_2') K_z^{T_2}(\vec{r}_2') + M_{T_{i2}}(\vec{r}, \vec{r}_2') K_z^{T_{i2}}(\vec{r}_2') \quad (2.1)$$

şeklinde ifade edilir. Silindir akımları ile görüntü akımları arasındaki ilişki

$$\begin{aligned} M_{T_{i1}}(x, y|x_1', y_1') &= M_{T_1}(x, y|x_1', -y_1') \\ M_{T_{i2}}(x, y|x_2', y_2') &= M_{T_2}(x, y|x_2', -y_2') \end{aligned} \quad (2.2)$$

şeklinde. Burada x_1, y_1 birinci hedef üzerindeki noktaları, x_2, y_2 ise ikinci hedef üzerindeki noktaları göstermektedir. Bu eşitlik kullanılarak



Şekil 2.2 Sonsuz düz yüzey üzerindeki iki silindir için Görüntü metodu çözümü ⁴

$$\begin{aligned} K_z^{T_{i1}}(\vec{r})|_{T_{i1}} &= -K_z^{T_1}(\vec{r})|_{T_1} \\ K_z^{T_{i2}}(\vec{r})|_{T_{i2}} &= -K_z^{T_2}(\vec{r})|_{T_2} \end{aligned} \quad (2.3)$$

yazılabilir. Sınır koşulu olan

$$E_z^i(x, y) + E_z^s(x, y) = 0 \quad (2.4)$$

(2.1) eşitliğine uygulanırsa

$$\begin{aligned} & (M_{T_1}(x_1, y_1|x'_1, y'_1) - M_{T_1}(x_1, y_1|x'_1, -y'_1))K_z^{T_1}(x'_1, y'_1) + (M_{T_2}(x_1, y_1|x'_2, y'_2) - M_{T_2}(x_1, y_1|x'_2, -y'_2))K_z^{T_2}(x'_2, y'_2) \\ &= -E_z^i(x_1, y_1) \end{aligned} \quad (2.5)$$

$$\begin{aligned} & (M_{T_1}(x_2, y_2|x'_1, y'_1) - M_{T_1}(x_2, y_2|x'_1, -y'_1))K_z^{T_1}(x'_1, y'_1) + (M_{T_2}(x_2, y_2|x'_2, y'_2) - M_{T_2}(x_2, y_2|x'_2, -y'_2))K_z^{T_2}(x'_2, y'_2) \\ &= -E_z^i(x_2, y_2) \end{aligned} \quad (2.6)$$

şeklinde birinci ve ikinci silindirden saçılan elektrik alan integral denklemleri elde edilir.

2.1 Moment Metodunun İki Cisimden Saçılma Problemine Uygulanması

Elektrik alan integral denklemlerinden de anlaşılacağı gibi silindirlerin birbiriyle ve görüntüleriyle olan etkileşimleri söz konusudur. Bu denklemleri çözebilmek için $K_z^{T_1}(x'_1, y'_1)$ ve $K_z^{T_2}(x'_2, y'_2)$ yani silindirler üzerinde indüklenen akım ifadeleri

$$K_z^{T_1}(x'_1, y'_1) = \sum_{n=1}^{N_{T_1}} a_n^{T_1} K_n^{T_1}(x'_1, y'_1) \quad (2.7)$$

$$K_z^{T_2}(x'_2, y'_2) = \sum_{m=1}^{N_{T_2}} a_m^{T_2} K_m^{T_2}(x'_2, y'_2) \quad (2.8)$$

şeklinde darbe fonksiyonları cinsinden yazılır. Birinci hedefin yüzeyinde N_{T_1} , ikinci hedefin yüzeyinde N_{T_2} tane nokta bulunmaktadır ve $K_z^{T_1}(x'_1, y'_1)$ L_n segmentinde, $K_z^{T_2}(x'_2, y'_2)$ L_m segmentinde tanımlıdır. Bu durumda (2.5) ve (2.6) eşitlikleri

$$\begin{aligned} & \sum_{n=1}^{N_{T_1}} a_n^{T_1} [M_{T_1}(x_l, y_l | x'_1, y'_1) - M_{T_1}(x_l, y_l | x'_1, -y'_1)] K_n^{T_1}(x'_1, y'_1) + \sum_{m=1}^{N_{T_2}} a_m^{T_2} [M_{T_2}(x_l, y_l | x'_2, y'_2) - M_{T_2}(x_l, y_l | x'_2, -y'_2)] K_m^{T_2}(x'_2, y'_2) \\ & = -E_z^i(x_l, y_l) \end{aligned} \quad (2.9)$$

$$l = 1, 2, 3, \dots, N_{T_1}$$

$$\begin{aligned} & \sum_{n=1}^{N_{T_1}} a_n^{T_1} [M_{T_1}(x_k, y_k | x'_1, y'_1) - M_{T_1}(x_k, y_k | x'_1, -y'_1)] K_n^{T_1}(x'_1, y'_1) + \sum_{m=1}^{N_{T_2}} a_m^{T_2} [M_{T_2}(x_k, y_k | x'_2, y'_2) - M_{T_2}(x_k, y_k | x'_2, -y'_2)] K_m^{T_2}(x'_2, y'_2) \\ & = -E_z^i(x_k, y_k) \end{aligned} \quad (2.10)$$

$$k = 1, 2, 3, \dots, N_{T_2}$$

(2.9) eşitliği matrisel formda yazılacak olursa

$$Aa_{T_1} + Ba_{T_2} = b_{T_1} \quad (2.11)$$

burada A, $N_{T_1} \times N_{T_1}$ matrisini, B ise $N_{T_1} \times N_{T_2}$ matrisini göstermekte ve b_{T_1}

$$b_{T_1} = \frac{8j}{k_0 \eta_0} E_0 e^{jk_0(x_l \cos \phi_l)} \sin(k_0 y_l \sin \phi_l) \quad (2.12)$$

şeklinde ifade edilmektedir.

(2.10) eşitliği matrissel formda yazılacak olursa

$$Ca_{T_1} + Da_{T_2} = b_{T_2} \quad (2.13)$$

burada C $N_{T_2} \times N_{T_1}$ matrisini, D ise $N_{T_2} \times N_{T_2}$ matrisini göstermekte ve b_{T_2}

$$b_{T_k} = \frac{8j}{k_0 \eta_0} E_0 e^{jk_0(x_k \cos \phi_k)} \sin(k_0 y_k \sin \phi_k) \quad (2.14)$$

şeklinde dir. En genel halde matrissel formda

$$\begin{bmatrix} A_l & B_l \\ C_k & D_k \end{bmatrix} \begin{bmatrix} a_{T_1} \\ a_{T_2} \end{bmatrix} = \begin{bmatrix} b_{T_1} \\ b_{T_k} \end{bmatrix} \quad (2.15)$$

şeklinde ifade edilmektedir. A, B, C ve D numerik integrasyon metodu ile

$$A_{l,n} = \int_{L_n}^{T_1} K_n^{T_1}(x'_1, y'_1) \left(H_0^{(2)} \left(k_0 \sqrt{(x_l - x'_1)^2 + (y_l - y'_1)^2} \right) - H_0^{(2)} \left(k_0 \sqrt{(x_l - x'_1)^2 + (y_l + y'_1)^2} \right) \right) dl' \quad (2.16)$$

$$B_{l,m} = \int_{L_m}^{T_2} K_m^{T_2}(x'_2, y'_2) \left(H_0^{(2)} \left(k_0 \sqrt{(x_l - x'_2)^2 + (y_l - y'_2)^2} \right) - H_0^{(2)} \left(k_0 \sqrt{(x_l - x'_2)^2 + (y_l + y'_2)^2} \right) \right) dl' \quad (2.17)$$

$$C_{k,n} = \int_{L_n}^{T_1} K_n^{T_1}(x'_1, y'_1) \left(H_0^{(2)} \left(k_0 \sqrt{(x_k - x'_1)^2 + (y_k - y'_1)^2} \right) - H_0^{(2)} \left(k_0 \sqrt{(x_k - x'_1)^2 + (y_k + y'_1)^2} \right) \right) dk' \quad (2.18)$$

$$D_{k,m} = \int_{L_m} K_m^{T_2}(x'_2, y'_2) \left(H_0^{(2)} \left(k_0 \sqrt{(x_k - x'_2)^2 + (y_k - y'_2)^2} \right) - H_0^{(2)} \left(k_0 \sqrt{(x_k - x'_2)^2 + (y_k + y'_2)^2} \right) \right) dk' \quad (2.19)$$

olarak hesaplanırlar. Yüzey segmentleri boyunca hedefler üzerindeki akımlar

$$K_n^{T_1}(x'_1, y'_1) = \begin{cases} 1 & (x'_1, y'_1) \in L_n \\ 0 & \text{diger yerlerde} \end{cases} \quad (2.20)$$

$$K_m^{T_2}(x'_2, y'_2) = \begin{cases} 1 & (x'_2, y'_2) \in L_m \\ 0 & \text{diger yerlerde} \end{cases} \quad (2.21)$$

şeklinde sabit değerler alır. $l = n$ durumunda kaynak noktasına gelindiğinden hesap zorlaşır ve Hankel fonksiyonu küçük değerler için yaklaşık olarak

$$H_0^{(2)}(k_0 u_L) \approx 1 - j \frac{2}{\pi} \left(\ln \left(\frac{k_0 \mathcal{U}_L}{2} \right) - 1 \right) \quad k_0 u_L \ll 1 \quad (2.22)$$

olur ve köşegen matris

$$A_{n,n} = \Delta_{T_1} \left[1 - j \frac{2}{\pi} \left(\ln \left(\frac{k_0 \gamma}{4} \Delta_{T_1} \right) - 1 \right) \right] - \int_{L_n} H_0^{(2)} \left(k_0 \sqrt{(x_n - x'_1)^2 + (y_n + y'_1)^2} \right) dl' \quad (2.23)$$

olarak hesaplanır.

$k = m$ durumunda da

$$D_{m,m} = \Delta_{T_2} \left[1 - j \frac{2}{\pi} \left(\ln \left(\frac{k_0 \gamma}{4} \Delta_{T_2} \right) - 1 \right) \right] - \int_{L_k} H_0^{(2)} \left(k_0 \sqrt{(x_m - x'_2)^2 + (y_m + y'_2)^2} \right) dk' \quad (2.24)$$

olarak hesaplanır. Bu ifadeler ve Hankel fonksiyonları ifadeleri


$$H_0^2(k_0 |\vec{r} - \vec{r}'|) \cong \sqrt{\frac{2j}{k_0 \pi}} \frac{e^{-jk_0 r}}{\sqrt{r}} e^{jk_0 (x' \cos \phi_s - y' \sin \phi_s)} \quad |\vec{r}| \gg |\vec{r}'| \quad (2.25)$$

yerine konulduğunda saçılan elektrik alan ifadesi

$$E_z^s(\vec{r}) = -\eta_0 \sqrt{\frac{-jk_0}{8\pi}} \frac{e^{jkr}}{\sqrt{r}} \left[\sum_{n=1}^{N_{T1}} a_n^{T_1} \int_{L_n} e^{jk_0(x' \cos \phi_s + y' \sin \phi_s)} dl' + \sum_{m=1}^{N_{T2}} a_m^{T_2} \int_{L_m} e^{jk_0(x' \cos \phi_s + y' \sin \phi_s)} dk' \right] \quad (2.26)$$


2.2 Nümerik Sonuçlar

Sonsuz uzun düz bir yüzey üzerinde bulunan iki silindirden saçılan elektrik alanının hesaplanması için Görüntü metodu ve Moment metodu yöntemleri kullanılmıştır. Görüntü metodu ile sınır koşulları kullanılarak integral denklemleri elde edilir. Moment metodu ile de bu denklemler çözülür. Frekans domeninde 1 GHz'den 30 GHz'e kadar 0.04 GHz aralıklarla değişen 726 tane frekans noktası elde edilmiştir. Saçılan toplam elektrik alanının frekans domenindeki ifadesi Şekil 2.3' te gösterilmiştir.



Şekil 2.3 Yarıçapları $r_{t1}=0.0127$ m, $r_{t2}=0.0127$ m; yükseklikleri $h_{t1}=0.1016$ m, $h_{t2}=0.1016$ m ve aralarındaki mesafe $x_{t2}=0.635$ m olan silindirik hedeflerden saçılan toplam elektrik alanının frekans domenindeki cevabı

Ters Fourier Dönüşümü kullanılarak zaman domeni ifadesi elde edilmiştir. Şekil 2.4'ten de anlaşılacağı üzere birinci grup yansıma ilk cisimden, ikinci grup yansıma ikinci cisimden kaynaklanmaktadır.



Şekil 2.4 Yarıçapları $r_{t1}=0.0127$ m, $r_{t2}=0.0127$ m; yükseklikleri $h_{t1}=0.1016$ m, $h_{t2}=0.1016$ m ve aralarındaki mesafe $x_{t2}=0.635$ m olan silindirik hedeflerden saçılan toplam elektrik alanının zaman domenindeki cevabı

Silindirik hedeflerin yarıçapları, yükseklikleri ve aralarındaki mesafe 64 farklı durum için kullanılarak bu hedeflerden saçılan elektrik alanının frekans ve zaman domenindeki cevapları ayrı ayrı hesaplatılmıştır. Daha sonra bu sinyallere GRNN ' ye özellik çıkarmak için sırasıyla sinyal analiz metotları Kısa Zaman Fourier Dönüşümü ve Dalgacık Dönüşümü uygulanmıştır.

Tablo 2.1 64 durum için iki silindirin yarıçapları ve konumları

	Yarıçap1 (metre)	Yarıçap2 (metre)	Yükseklik1 (metre)	Yükseklik2 (metre)	Mesafe (metre)
1	0.0127	0.0127	0.0127	0.0127	0.0254
2	0.0127	0.0127	0.0127	0.0254	0.0508
3	0.0127	0.0127	0.0254	0.0127	0.1016
4	0.0127	0.0127	0.0127	0.0381	0.127
5	0.0254	0.0127	0.0127	0.0127	0.0254
6	0.0254	0.0127	0.0127	0.0254	0.0508

7	0.0254	0.0127	0.0254	0.0127	0.1016
8	0.0254	0.0127	0.0127	0.0381	0.127
9	0.0127	0.0254	0.0127	0.0127	0.0254
10	0.0127	0.0254	0.0127	0.0254	0.0508
11	0.0127	0.0254	0.0254	0.0127	0.1016
12	0.0127	0.0254	0.0127	0.0381	0.127
13	0.0254	0.0254	0.0127	0.0127	0.0254
14	0.0254	0.0254	0.0127	0.0254	0.0508
15	0.0254	0.0254	0.0254	0.0127	0.1016
16	0.0254	0.0254	0.0127	0.0381	0.127
17	0.0127	0.0381	0.0127	0.0127	0.0254
18	0.0127	0.0381	0.0127	0.0127	0.0508
19	0.0127	0.0381	0.0254	0.0127	0.1016
20	0.0127	0.0381	0.0127	0.0381	0.127
21	0.0381	0.0127	0.0127	0.0127	0.0254
22	0.0381	0.0127	0.0127	0.0254	0.0508
23	0.0381	0.0127	0.0254	0.0127	0.1016
24	0.0381	0.0127	0.0127	0.0381	0.127
25	0.0254	0.0381	0.0127	0.0127	0.0254
26	0.0254	0.0381	0.0127	0.0254	0.0508
27	0.0254	0.0381	0.0254	0.0127	0.1016
28	0.0254	0.0381	0.0127	0.0381	0.127
29	0.0381	0.0254	0.0127	0.0127	0.0254
30	0.0381	0.0254	0.0127	0.0254	0.0508
31	0.0381	0.0254	0.0254	0.0127	0.1016
32	0.0381	0.0254	0.0127	0.0381	0.127
33	0.0381	0.0381	0.0127	0.0127	0.0254
34	0.0381	0.0381	0.0127	0.0254	0.0508
35	0.0381	0.0381	0.0254	0.0127	0.1016
36	0.0381	0.0381	0.0127	0.0381	0.127
37	0.0127	0.0508	0.0127	0.0127	0.0254
38	0.0127	0.0508	0.0127	0.0254	0.0508
39	0.0127	0.0508	0.0254	0.0127	0.1016
40	0.0127	0.0508	0.0127	0.0381	0.127
41	0.0508	0.0127	0.0127	0.0127	0.0254
42	0.0508	0.0127	0.0127	0.0254	0.0508
43	0.0508	0.0127	0.0254	0.0127	0.1016
44	0.0508	0.0127	0.0127	0.0381	0.127
45	0.0254	0.0508	0.0127	0.0127	0.0254
46	0.0254	0.0508	0.0127	0.0254	0.0508
47	0.0254	0.0508	0.0254	0.0127	0.1016
48	0.0254	0.0508	0.0127	0.0381	0.127
49	0.0508	0.0254	0.0127	0.0127	0.0254
50	0.0508	0.0254	0.0127	0.0254	0.0508
51	0.0508	0.0254	0.0254	0.0127	0.1016
52	0.0508	0.0254	0.0127	0.0381	0.127
53	0.0381	0.0508	0.0127	0.0127	0.0254
54	0.0381	0.0508	0.0127	0.0254	0.0508
55	0.0381	0.0508	0.0254	0.0127	0.1016
56	0.0381	0.0508	0.0127	0.0381	0.127

57	0.0508	0.0381	0.0127	0.0127	0.0254
58	0.0508	0.0381	0.0127	0.0254	0.0508
59	0.0508	0.0381	0.0254	0.0127	0.1016
60	0.0508	0.0381	0.0127	0.0381	0.127
61	0.0508	0.0508	0.0127	0.0127	0.0254
62	0.0508	0.0508	0.0127	0.0254	0.0508
63	0.0508	0.0508	0.0254	0.0127	0.1016
64	0.0508	0.0508	0.0127	0.0381	0.127

3. SİNYAL ANALİZ METODLARI

19.Yüzyılda Fourier herhangi bir periyodik fonksiyonun sonsuz sayıdaki kompleks üstel fonksiyonların toplamıyla ifade edilebileceğini söylemiştir. Fourier temelli dönüşüm teknikleri daha sonraki yıllarda Ayırık Fourier Dönüşümü (DFT) ve Hızlı Fourier Dönüşümü (FFT) algoritmalarının geliştirilmesiyle bilgisayarlarda veri işleme için önemli bir basamak atlanmıştır.

Denis Gabor 1946 yılında Gabor Dönüşümü olarak bilinen Fourier temelli analiz yöntemini sunmuştur. Bu metot da pencereleme yöntemini kullanarak ki pencere fonksiyonu Gauss Hata fonksiyonudur, işaretin küçük bir parçasını zaman tanım aralığında ele alınmış, işaret zaman ve frekansın fonksiyonu olarak iki boyutta ifade edilmiştir. Böylece durağan olmayan sinyallerin işlenmesi daha sağlıklı hale gelmiştir. Gabor Dönüşümü bugün Kısa Zaman Fourier Dönüşümü olarak bilinen yöntemin kaynağı olarak görülmektedir. Fourier temelli analiz yaklaşımlarının dezavantajları (zaman ve/veya Frekans çözünürlüğü sorunu, her zaman var olacak olan Gibbs olayı..vb) sinyal analizcileri daha farklı yollara, modern ve parametrik yöntemlere yöneltmiştir.

Bu şekilde Fourier serisi yaklaşımıyla başlayan sinyal frekans analizi kavramı günümüze değin ölçek analizi kavramına ve bununla sıkı sıkıya bağlı Dalgacık Dönüşümü' ne kadar gelişmiştir. Ölçek analizi, basitçe bir $f(x)$ fonksiyonunun ölçeği değişen matematiksel yapılar oluşturarak analiz edilmesidir. Önce basit bir temel fonksiyon tasarlanır, sonra bir miktar ötelenir ve ölçeği değiştirilir. Bu yapı her hangi bir fonksiyonun yaklaşımında kullanılır ve aynı işlemler tekrar edilir böylelikle yeni yaklaşımlar aynı basit yapısal temel fonksiyondan türetilerek elde edilir. Bu ölçek analizi dizisi, sinyalin farklı ölçeğe sahip ortalama dalgalanmalarını ölçtüğünden gürültüye de en az duyarlıdır. Konuyla ilgili ilk bahis A. Haar (1909) tarafından sunulmuştur.

1930' larda fonksiyonların değişken ölçekli temel fonksiyonlar kullanılarak gösterilmesi ile ilgili bağımsız çalışmalar yapılmıştır. Temel fonksiyonlar ve değişken ölçekli temel fonksiyonlar kavramlarının anlaşılması dalgacıkların anlaşılmasına anahtar oluştururlar.

Aynı yıllarda Paul Levy, Haar temel fonksiyonu olarak adlandırılan deęişken ölçekli temel fonksiyonunu kullanarak rastgele bir sinyal tipi olan Brownian hareketi araştırmıştır.

1960-1980 yıllarında matematikçiler Guido Weiss ve Ronald R. Coifman “atoms” adı verilen bir fonksiyon uzayının en küçük elemanı üzerinde çalışmışlardır. Amaç sıradan bir fonksiyon için bu atomların bulunması ve bu atomlar kullanılarak fonksiyon uzayının tüm elemanlarını tekrar meydana getirecek birleştirme kuralını bulmaktır.

1980’ lerde fizikçiler Morlet ve Grossman dalgacıklara kuantum fiziğinde geniş yer vermişlerdir. Alex Grossman ve Jean Morlet bu fonksiyon yapı blokları için ilk defa “Wavelet” adını önermişlerdir ve o zamana kadar Littlewood-Paley teorisi olarak belirtilen teori “Wavelet” Dalgacık teorisi olarak adlandırıla gelmiştir [8].

1985’ de Stephane Mallat dalgacıkları bu alanda yeni bir sıçrama tahtası oluşturan sayısal sinyal işleme çalışmalarında kullanmış ve Quadrature Mirror Filtre, piramit algoritmaları ve normal-dikey (Orthonormal) dalgacık temeller ve daha birçokları arasındaki ilişkileri keşfetmiştir.

Y. Meyer ilk önemli dalgacıęı kurmuştur. Bu Haar dalgacıęının tersine sürekli türevlenebilir özellikte olmasına rağmen tam dayanaklı (Compact Support) olmadığı görülmüştü. Birkaç yıl sonra Ingrid Daubechies Mallat’ ın çalışmaları ışığında normal-dikey temel dalgacık fonksiyonlarını inşa etmiştir ki bunlar belki en seçkin ve günümüzdeki dalgacık uygulamalarına köşe taşı teşkil edecek olanlardır [9].

3.1 Sinyal Analizi

Bir sinyal frekans ve genlik olarak iki ayrı bileşene sahiptir. Frekans ve genlik bilgileri sabit bir düzlemde, zaman düzleminde tanımlanabilir. Bu bilgiler değerlendirilirken, zamana göre frekans veya zamana göre genlik şeklinde değerlendirilir. Sinyal analizinde, bir sinyali zamana göre düşünmek analiz işlemlerinin temelini oluşturur. Sinyallere matematiksel dönüşüm işlemleri uygulanarak, frekans ve genlik bilgileri elde edilebilir. Sinyal içerisinde frekans ve genlik bilgilerini almak için en yaygın kullanılan matematiksel dönüşüm teknięi Fourier Dönüşümü’ dür. Bir sinyalin

incelenmesi için belirli noktalardan alınan örneklerle sinyalin incelenmesi, sinyalin sayısallaştırılmasıdır. Bu şekilde bir sinyal sayısallaştırılarak, elektronik ortamlarda incelenebilir [10].

3.1.1 Fourier Teoremi

1807 yılında Fransız bir Matematikçi olan Joseph Fourier, kendi adıyla bilinen bir teorem geliştirmiştir. Bu teoremden periyodik fonksiyonların çoğunun, trigonometrik fonksiyonları kapsayarak, sonsuz seriler ve integraller içerisinde genişletilebileceğini ifade etmiştir [11]. Bir sinyal sinüs ve kosinüs toplamı ile ifade edilebilir ilkesi, Fourier teoreminin temelini oluşturur. Bu ilkeye göre sinyaller bir seri şeklinde ifade edilerek, daha kolay analiz edilebilir.

$$f(x) = a_0 + \sum_{k=1}^{\infty} (a_k \cos kx + b_k \sin kx) \quad (3.1)$$

Burada yazılan eşitlikte $f(x)$ fonksiyonu, sinüs ve kosinüs toplamlarının bir serisi olarak ifade edilmiştir. Eşitliğin sol tarafında yer alan a_0 , a_k ve b_k Fourier katsayılarıdır ve (3.2), (3.3) ve (3.4) eşitlikleri ile hesaplanabilir.

$$a_0 = \frac{1}{2\pi} \int_0^{2\pi} f(x) dx \quad (3.2)$$

$$a_k = \frac{1}{\pi} \int_0^{2\pi} f(x) \cos kx dx \quad (3.3)$$

$$b_k = \frac{1}{\pi} \int_0^{2\pi} f(x) \sin kx dx \quad (3.4)$$

Sinyallerin, Fourier serilerinde tanımlanmasında, karmaşık üstel biçimde gösterimleri ise

$$x(t) = \sum_{k=-\infty}^{\infty} c_k e^{jk\omega t} \quad (3.5)$$

şeklinde dir. Denklem 3.5 teki gösterimde bulunan katsayılar karmaşık Fourier katsayısıdır ve denklem (3.6) ile hesaplanır.

$$c_k = \frac{1}{T_0} \int_{T_0} x(t) e^{-j\omega t} dt \quad (3.6)$$

Karmaşık sayılarla Fourier serisinin gösterimi ile trigonometrik gösterimi arasında sadece sinyalin genlik değerlerini gösteren katsayılar farklı çıkar. Karmaşık gösterimdeki katsayılar, trigonometrik gösterimin yarısı değerinde çıkar.

3.1.2 Fourier Dönüşümü

Fourier serilerinin fonksiyonlar üzerine olan bu yaklaşımı, matematikte bir devrim niteliğindedir. Bundan sonraki süreçlerde, sinyallerin incelenmesi ve frekans analizlerinin yapılmasında etkin olarak yararlanılan Fourier Dönüşümleri, sinyallerin zaman ve frekans düzleminde incelenmesini mümkün hale getirmiştir.

$$F(\omega) = \int f(t) e^{-j\omega t} dt \quad (3.7)$$

$$e^{j\omega t} = \cos(\omega t) + j\sin(\omega t) \quad (3.8)$$


Karmaşık üstel gösterimde alınan bir sinyal bilgisinin Fourier dönüşümü (3.7) de $F(\omega)$ ile gösterilmektedir. Basit birkaç örnek ile Fourier dönüşümü daha kolay anlaşılabilir.

x_1 , x_2 ve x_3 periyodik sinyallerinin frekansları sırasıyla 5, 25 ve 50 Hz'dir. Sinyallerin Şekil 3.1 de genlik-zaman düzlemi gösterimi verilmiştir. Bu sinyallere Fourier dönüşümleri uygulandığı zaman Şekil 3.2 deki sinyal görünüşleri elde edilir.

$$x_1(t) = \cos(2\pi \cdot 5 \cdot t)$$

$$x_2(t) = \cos(2\pi \cdot 25 \cdot t)$$

$$x_3(t) = \cos(2\pi \cdot 50 \cdot t)$$




Şekil 3.1. Frekansları 5, 25 ve 50 Hz olan sinyaller

$$x_1(t) \xrightarrow{\text{Fourier}} x_1(w)$$

$$x_2(t) \xrightarrow{\text{Fourier}} x_2(w)$$

$$x_3(t) \xrightarrow{\text{Fourier}} x_3(w)$$




Şekil 3.2. x_1 , x_2 ve x_3 periyodik sinyallerinin Fourier dönüşümleri

Fourier Dönüşümleri bir sinyal içerisindeki frekans bilgilerini yakalamada bize oldukça kolaylık sağlar. Ancak Fourier Dönüşümü'nün yetersizliklerinden biri, sinyal frekans değerinin hangi zamanda alındığıdır. Bu eksikliği daha iyi anlayabilmemiz için sinyaller toplanıp Fourier Dönüşümü uygulanırsa Şekil 3.3' deki sinyal şekillerini elde ederiz.

$$x_4(t) = \cos(2\pi \cdot 5 \cdot t) + \cos(2\pi \cdot 25 \cdot t) + \cos(2\pi \cdot 50 \cdot t)$$

$$x_4(t) \xrightarrow{\text{Fourier}} x_4(w)$$




Şekil 3.3. x_4 sinyali ve Fourier dönüşümü $x(t)$

x_4 sinyalinin içerisinde, Fourier Dönüşümü sonrası üç farklı frekans değeri olduğu görülmektedir. Frekanslardan biri 5 Hz., ikincisi 25 Hz. ve üçüncüsü de 50 Hz.' dir. Ancak bu frekansların x_4 sinyali içerisinde hangi anlarda olduğuna dair bir bilgi alınamaz. Çünkü Fourier Dönüşümü sonrası frekans düzleminde temsil edilen sinyalin zaman bilgisi kaybolur [12]. Sinyalin Fourier Dönüşümü' ne bakarak hangi frekansları ve ne ağırlıkta içerdiği hakkında yorum yapılabilinmektedir. Fakat ne zaman belirli bir frekans ile karşılaşırız diye bir yorum yapamayız. Eğer üzerinde çalıştığımız sinyal durağan olmayan bir sinyal ise o zaman belirli frekansın zaman bilgisine de ihtiyaç duyulacaktır. Sadece hangi frekans bileşenleri var bilgisi yetersiz kalacak ve ayrıca ne zaman belirli frekans gerçekleşiyor bilgisi gerekecektir. Fonksiyonun Fourier Dönüşümü frekans olarak çok verimli bir şekilde lokalize edilebilir, $x(t)$ fonksiyonun kendisi ise çok verimli bir zaman lokalizasyonuna sahiptir. $x(w)$ ve $x(t)$ aynı fonksiyonu göstermelerine rağmen zaman ve frekans lokalizasyonunda uç noktaları temsil ederler. Dolayısıyla durağan olmayan sinyallerde Fourier Dönüşümü sinyalin iyi zaman lokalizasyonu açısından yetersiz kalır. Bu sıkıntıyı aşmak için kullanabileceğimiz yöntem Kısa Zamanlı Fourier Dönüşümü' dür.

3.1.3 Kısa Zamanlı Fourier Dönüşümü

Fourier Dönüşümü, sinyal içerisinde yer alan tüm frekans bileşenlerini tanımlayabilir. Ayrıca daha önce de bahsettiğimiz gibi, zaman içerisindeki yerlerinin belirlenmesine dair hiçbir bilgi sağlamaz. Bunun sebebi, durağan sinyallerin zaman içerisinde değişmeyen frekans bileşenleri içermelerinden dolayıdır. Sinyalin zaman içerisindeki frekans bileşenleri tüm zamanlarda aynıdır. Bu nedenle zaman bilgisine durağan sinyallerde ihtiyaç yoktur [13]. Ancak tüm sinyaller durağan değildir. Sinyal içerisindeki frekans bileşenleri, zamana göre değişen bu sinyallere dinamik sinyaller denir. Dinamik sinyallerde frekans bileşenleri kadar, bu frekansların hangi zamanlarda olduğu bilgisi de çok önemlidir.

1946 yılında Dennis Gabor tarafından ortaya atılan, dinamik sinyallerin analizinde kullanılan, Kısa Zamanlı Fourier Dönüşümü (KZFD), klasik Fourier Dönüşümü' ne yeni bir boyut getirmiştir. Bu işlem, belirli zaman aralıklarında, pencereleme mantığını kullanarak yapılan analiz ile kaybolan zaman bilgisinin elde edilmesi yolunu açmıştır [14].



Şekil 3.4. KZFD ile bir sinyalin pencerelemesi ²⁴

Kısa Zamanlı Fourier Dönüşümü' nün bir sinyale uygulanabilmesi için toplam altı adım işleme konulmalıdır.

1. Sonlu bir pencere fonksiyonu seçilir.
2. Pencere $t=0$ anında, sinyalin başlangıcına yerleştirilir.
3. Pencere kullanılarak sinyal yuvalanır.
4. Pencere içerisindeki bu sinyale Fourier dönüşümü uygulanır.
5. Pencere sağa kaydırılır.
6. Sinyal sonuna kadar 3. adıma tekrar gidilir.

Her Fourier Dönüşümü uygulandığı 4. adımda bir frekans bilgisi elde edilir. Elde edilen bu değere Fourier katsayısı adı verilir ve uygulanan pencereye olan benzerliğini gösterir. Pencerenin uygulandığı zaman bilgisi de belirlendiği için, aynı anda hem frekans hem de zaman bilgisi analiz sonucunda elde edilir [12].

$$KZFD_x^w(t', w) = \int_t [x(t).W(t - t')].e^{-j\omega t} dt \quad (3.9)$$

$x(t)$ sinyalinin KZFD' nün verildiği 3.9 da ki fonksiyonda, W : pencere fonksiyonunu, w : frekans parametresini ve t : zaman parametresini temsil etmektedir.

KZFD, belirlenen zaman aralıklarında farklı dönüşüm değerlerinin hesaplanmasıyla, zaman bilgisinin de elde edilmesini sağlar. Böylelikle hem frekans bilgisinin, hem de zaman bilgisinin, sinyal içerisinde alınmasını sağlar. Seçilecek olan pencere fonksiyonun biçimi ve genişliği sonuç kesinliği için oldukça önemlidir. Dikdörtgen,

Üçgen veya Hamming gibi pencerelerden biri sinyalin özelliğine göre seçilmelidir. Örneğin giriş sinyali periyodikse, sinyal kısa bir pals biçimindeyse veya başlangıç ve bitiş genliği aynı ise dikdörtgen pencere seçilmelidir. Sinyal periyodik değilse üçgen pencere fonksiyonu seçilmelidir.

Pencere fonksiyon şeklinin seçimi kadar, darlığı veya genişliği de çok önemlidir. Pencere büyüklüğü Fourier analizinin kısa zamanda hesaplanacağı kadar olmalıdır. Geniş bir pencere, az zaman aralığı belirleyeceğinden dolayı, dönüşüm sonucunda zaman çözünürlüğü az olur. Buna karşın frekans çözünürlüğü yüksek olur. Analiz pencere fonksiyonu dar alınırsa bu seferde, zaman çözünürlüğü iyi, frekans çözünürlüğü kötü olur. Pencere geniş tutulduğunda düşük frekanslı bileşenler, dar tutulduğunda ise yüksek frekanslı bileşenler başka bir deyişle ayrıntılar görülebilir. Görüldüğü gibi her iki tür bileşen de aynı anda istenilen çözünürlükte görülemeyeceği için seçim yapılması gerekmektedir. Bu nedenle pencere büyüklüğünün sabit olması KZFD' nün bir dezavantajıdır.

3.1.3.1 Pencere Çeşitleri

Bu bölümde Dikdörtgen pencereleme, Hamming pencereleme, Hanning pencereleme ve Blackman pencereleme fonksiyonları kullanılmış ve her bir pencereleme fonksiyonu iki silindirden saçılan elektrik alanının zaman domenindeki cevabını analiz eden Kısa Zamanlı Fourier Dönüşümü' nde kullanılmıştır.

3.1.3.1.1 Dikdörtgen pencere

KZFD zayıf frekans çözünürlüğü doğurduğundan daha pürüzsüz pencereler tercih edilir.

Bu çalışmada da Hamming pencere kullanılmıştır.

Dikdörtgen pencereleme fonksiyonunun formülü


$$w(n) = \begin{cases} 1 & ; \quad 0 \leq n \leq N - 1 \\ 0 & ; \quad otherwise \end{cases} \quad (3.10)$$

3.1.3.1.2 Hamming Pencere

Hamming pencereleme fonksiyonunun formülü

$$w[n] = \begin{cases} 0.54 - 0.46 \cos \frac{2\pi n}{N}, & 0 \leq n \leq N-1 \\ 0, & \text{otherwise} \end{cases} \quad (3.11)$$

Geliştirilen uygulamada kullanılan Hamming penceresi uygulandığı sinyalin orta noktalarını iyileştirirken uç noktalarında bilgi kaybına neden olmaktadır. Pencereleme yönteminin bu etkisi pencerelerin üst üste bindirilmesi ile çözülür.




Şekil 3.5 Hamming penceresi

3.1.3.1.3 Hanning Pencere

Hanning pencereleme fonksiyonunun formülü

$$w[n] = 0.5 (1 - \cos (2 \pi n / (N - 1))) \quad (3.12)$$




Şekil 3.6 Hanning penceresi

3.1.3.1.4 Blackman Pencere


Blackman pencereleme fonksiyonunun formülü

$$w(n) = 0.42 - 0.5\cos(2\pi n/N - 1) + 0.08\cos(4\pi n/N - 1) \quad (3.13)$$


Aşağıda iki silindirden saçılan elektrik alanının zaman domenindeki ifadesine farklı pencereler kullanılarak Kısa Zamanlı Fourier Dönüşümü uygulanmış hali gösterilmiştir.




Şekil 3.7 Elektrik alana Dikdörtgen pencere kullanarak Kısa Zamanlı Fourier Dönüşüm analizi



Şekil 3.8 Elektrik alana Hamming pencere kullanarak Kısa Zamanlı Fourier Dönüşüm analizi




Şekil 3.9 Elektrik alana Hanning pencere kullanarak Kısa Zamanlı Fourier Dönüşüm analizi



Şekil 3.10 Elektrik alana Blackman pencere kullanarak Kısa Zamanlı Fourier Dönüşüm analizi


Birinci yöntem olarak, Kısa Zamanlı Fourier Dönüşümü uygulanan saçılan elektrik alan yapay sinir ağının girişleri olacak şekilde özellik çıkarılmıştır.

İkinci yöntem olarak, Kısa Zamanlı Fourier Dönüşümü'nden geçirilen saçılan elektrik alan yapay sinir ağının girişleri olacak şekilde Matlab' da Dalgacık araç kutusu yardımıyla özellik çıkarılmıştır. Önce saçılan elektrik alanın şekli iki boyutlu Wavelet için yüklenip db10 3. seviye Dalgacık Dönüşümü seçilerek Şekil 3.11' te görüldüğü gibi analizi yapılmıştır.



Şekil 3.11 Wavelet toolbox ile analizi yapılan imaj

Daha sonra bu sinyalin 3. seviye yaklaşıklık katsayıları araç kutusunda hesaplatılmış ve Şekil 3.12 'de kırmızı ile çerçevelendirilmiş 9 görüntüye ait özellik kullanacağımız yapay sinir ağının girişleri olarak kullanılmıştır.



Şekil 3.12 İmajın Yaklaşıklık katsayılarının hesaplanması

Görüldüğü gibi KZFD' nde pencere büyüklüğünün analiz boyunca sabit olması istenilen zaman-frekans çözünürlüğünün elde edilememesine sebep olmaktadır. KZFD' nün sabit uzunluktaki pencerelerle analiz yapmasından kaynaklanan bu sıkıntı, araştırmacıları kısa süreli ani değişimleri kısa pencerelerle, uzun süreli değişimleri daha geniş pencerelerle analiz edebilen (başka bir deyişle düşük frekans bileşenleri için geniş zaman aralığı, alçak frekans bileşenleri için dar zaman aralığı sağlayan) yöntemler araştırmaya yöneltmiştir. Bir sonraki bölümde bu özelliği sağlayan ve yaygın olarak kullanılan yöntemlerden birisi olan Dalgacık Dönüşümü incelenecektir.

3.1.4 Dalgacıklar

Dalgacıklar, bir sinyalin içerdiği bilgiyi, farklı frekans bileşenlerine ayıran ve sonra kendi ölçekleriyle eşleştirilmiş bir çözünürlüğe sahip bileşenler üzerinde çalışan, matematiksel fonksiyonlardır. Dalgacıkların arkasındaki temel fikir, belirlenen bir ölçeğe göre analizdir [9].


Son yıllarda, dalgacıkları kullanarak sinyalleri analiz etmek ve uygulamalarda kullanmak oldukça yaygınlaşmıştır. Özellikle sinyal işlemede daha önce kullanılan geleneksel yöntemlere göre daha avantajlı olan dalgacık analizleri, matematik, kuantum fiziği, elektrik, elektronik ve bilgisayar gibi mühendislik alanlarında yeni bir devir açma niteliğindedir. Uygulama alanları da gün geçtikçe artmaktadır. Özellikle tıp biliminde ve resim analiz işlemlerinde çok büyük kolaylık ve kalite getirmektedir [10].

Dalgacıklar kullanılmadan önce, şu an hala bazılarının kullanılmaya devam ettiği, birçok teknikler sinyal analizlerinde kullanılmaktadır. Bunlar arasında en kullanışlı ve en yaygın olanı Fourier Dönüşümleridir. Daha önceki bölümde anlatıldığı üzere Fourier teoreminde bir sinyal sonsuz sinüs ve kosinüslerin toplamı şeklinde ifade edilebilir. Bu teoremden yola çıkarak, bir sinyal içerisindeki frekans bileşenleri, sinyale Fourier Dönüşümü uygulanarak elde edilebilir. Ancak Fourier Dönüşümü, durağan sinyaller olarak adlandırılan, tüm zamanlarda frekans değeri aynı olan sinyallerde güzel sonuçlar vermektedir [15]. Durağan sinyallerin tüm zamanlarda frekans değerleri aynı olmasından dolayı, bu sinyallerde zaman bilgisi önemli değildir. Fourier Dönüşümü yapılan bir sinyalden zaman bilgisi kaldırılır, sadece frekans bilgisi elde edilir. Bunun anlamı; sinyalin içerisindeki tüm frekanslar bulunabilir ancak bu frekansların hangi zaman


diliminde meydana geldikleri bilinemez [9]. Fourier Dönüşümündeki bu yetersizlikler, özellikle durağan olmayan sinyallerin analizinde oldukça büyük problemler ortaya çıkarır. Doğadaki sinyallerin büyük bir çoğunluğu, her an değişimin olduğu, durağan olmayan sinyaller olması sebebiyle, Fourier yaklaşımlarıyla analiz, frekans bileşenlerinin hepsini yakalayamaz. Bu sorunun üstesinden gelmek için Ayrık Zamanlı Fourier Dönüşümü gibi çeşitli yöntemler kullanılsa da çözüme ulaşılammıştır. Durağan olmayan sinyallerin incelenmesinde dalgacık analizinden önce KZFD yaygın olarak kullanılmaktaydı. Ancak KZFD' nün de analiz sonuçlarında eksiklikleri vardır. Zaman bilgisi bu yöntemle sinyal içerisinde alınabilmektedir. Ancak, zaman çözünürlüğünün tüm sinyal boyunca aynı olması, sinyal içerisindeki ani frekans değişimlerinin yakalanmasında KZFD yetersiz kalmasına neden olmaktadır. Ayrıca sinyali kesmek için kullanılan pencere sinyali ile orijinal sinyalin arasında bir konvolüsyon oluşacak ve bu da frekans düzleminde kalıntı sinyallere sebep olacaktır [12]. Dalgacık Dönüşümü veya Dalgacık Analizi, şu ana kadar uygulanan analiz yöntemlerindeki noksanlıkları ortadan kaldırmak için kullanılan en son çözümdür [14]. Fourier Dönüşümündeki zaman bilgisinin kaybolması ve konvolüsyon gibi problemleri ortadan kaldıran Dalgacık Analizi, bir sinyalin içerisindeki tüm frekans bileşenlerinin hangi zamanlarda ve hangi genliklerde olduğunu tespit edebilir.

3.1.5 Dalgacık Analizi

Dalgacık Dönüşümü bir ana fonksiyonun (dalgacık) ötelenme ve yayılması ile oluşturulan baz fonksiyonlarına, işaretin izdüşümünün alınması ile bulunur. Böylelikle, sinyalin yüksek ve düşük frekanslı bileşenleri, zaman bilgisi ile birlikte elde edilebilir. Şekil 3.13' de görüldüğü gibi, yüksek frekanslar kısa süreli, düşük frekanslar ise uzun süreli dalgacık ile bulunabilir. Dalgacık Dönüşüm işleminin daha iyi anlaşılabilmesi için Şekil 3.14' da verilen KZFD ile Dalgacık Dönüşümü zaman-frekans düzlemi gösterimleri verilmiştir. Bu şekilden de anlaşılacağı gibi Dalgacık Dönüşümü daha iyi zaman çözünürlüğüne sahiptir.



Şekil 3.13. Dalgacık Dönüşümünün gösterimi ⁷




Şekil 3.14. Zaman-frekans düzleminde sinyal dönüşümlerinin gösterimi ⁷

(a)KZFD (b)Dalgacık Dönüşümü

3.1.6 Dalgacık Dönüşümleri

Dalgacık Dönüşümü değişken zaman-frekans çözünürlüğüne sahiptir. Bu nedenle çok çözünürlüklü işaret işleme aracı olarak nitelendirilir ve durağan sinyallerin analizinden çok ayrık zamanlı sinyalleri incelemeye kullanılır. Dalgacık Dönüşümleri sonsuz bir kümeden oluşur. Farklı dalgacık aileleri, dalgacık temel fonksiyonlarının, uzayda kompakt dağılımlarına göre farklılıklar gösterirler. Uygulamada çok kuvvetli işlem gücüne sahip dalgacıklar olduğu gibi sadece teorikte kullanılan dalgacıklar da vardır. Şekil 3.15' de bu dalgacık tiplerinden birkaçı verilmiştir. Dalgacık Dönüşümlerinin farklı tipleri vardır:

- 1) Sürekli Dalgacık Dönüşümü
- 2) Ayrık Dalgacık Dönüşümü



Şekil 3.15. Dalgacık örnekleri


3.1.6.1 Sürekli Dalgacık Dönüşümü

Sürekli Dalgacık Dönüşümü (SDD), sinyalin toplam zamanı ile, dalgacık fonksiyonunun değiştirilmiş ve ölçeklenmiş versiyonlarının çarpılması olarak tanımlanır. 3.14’ da verilen fonksiyonda SDD görülmektedir. Bu fonksiyonda, $x(t)$ sinyalinin, zamanda kaydırılan ve ölçeklendirilen y dalgacığı ile çarpılması görülmektedir. Her ölçeği değiştirme işlemi tespit edilecek frekans değerini belirlemek için, her zamanda kaydırma işlemi de sinyalin farklı bir bölgesini incelemek için kullanılır [11], [14].

$$SDD_x^w(\tau, s) = \frac{1}{\sqrt{|s|}} \int_t x(t) \varphi\left(\frac{t-\tau}{s}\right) dt \quad (3.14)$$


$$\varphi_{a,b}(t) = \frac{1}{\sqrt{a}} \varphi\left(\frac{t-b}{a}\right) \quad (3.15)$$

Ölçeği belirleyen her s değerinde dalgacık, zamanı belirleyen t değeri ile zamanda kaydırılır. Bu işlem diğer ölçeklerde de devam edilerek dalgacık katsayıları elde edilir. 3.15’ de ki eşitlikte de dalgacık fonksiyonu verilmiştir. Analiz sonucunda oluşan değerlere dalgacık katsayıları denir ve seçilen dalgacık tipi ile orijinal sinyalin, 3.14 denklemi sonucunda ki üretilen değerleridir. Şekil 3.16 bir sinyale SDD uygulamak için, sinyalin üzerinde dalgacığın kaydırılması, Şekil 3.17’ da dalgacığın ölçeklendirilmesi verilmiştir.




Şekil 3.16. Dalgacığın sinyal üzerinde kaydırılması ⁷

(a) Başlangıç durumu (b) Sağa kaydırılmış durum




Şekil 3.17. Ölçeğin değiştirilmesi ⁷

SDD' nün genliği scolagram olarak adlandırılır. Scolagram sayesinde SDD' nün iki boyutlu veya üç boyutlu grafikleri çizilebilir [22]. 1000 Hz ve 3000 Hz frekans değerlerine sahip iki ayrı sinyalin toplamı sonucunda oluşan sinyalin iki boyutlu spectogramı Şekil 3.18' de verilmiştir. Yatay eksen zaman, dikey eksen de frekans bilgisini vermektedir. Sinyalin genliği ise renklerle belirlenmektedir. Şekil 3.19 aynı sinyalin üç boyutlu grafiğini göstermektedir. Şekillerden de anlaşılacağı üzere, sinyal içerisindeki frekans bileşenleri, zaman ve genlik bilgileri ile birlikte alınabilmektedir.



Şekil 3.18. Sinyal spektrogramı




Şekil 3.19. Üç boyutlu gösterim

3.1.6.2 Ayrık Dalgacık Dönüşümü

Mümkün olan her ölçek için dalgacık katsayılarının hesaplanması, gereksiz olan bilgileri de sinyal içerisinden alır. Dönüşüm işleminin ve dolayısıyla da analiz işleminin uzamasına sebep olur [16]. Eğer seçilecek olan ölçek ve pozisyonları, ikinin üstleri biçiminde seçilirse, yapılan analiz daha etkili ve hızlı olur. İstenmeyen verilerin analiz işleminden ayıklanmasını sağlar ve Ayrık Dalgacık Dönüşümü (ADD) olarak adlandırılır. ADD, filtreleri kullanarak gerçekleştirilir. 1988 yılında Mallat tarafından

gerçekleştirilen bir algoritmadır. Bu çok pratik filtreleme algoritması, Dalgacık dönüşümünü, SDD' ne nazaran daha hızlı yapılmasını sağlar [9]. Şekil 3.20' de bir sinyale filtre uygulanışı ve elde edilen değerler verilmiştir. En temel filtre devresinde S sinyale uygulanan bir filtre ile sinyal içerisindeki alçak ve yüksek frekanslar ayrılmıştır. Düşük frekansları geçiren filtre Alçak Geçiren Filtre (AGF) ve yüksek frekansları geçiren filtre de Yüksek Geçiren Filtre (YGF) olarak adlandırılır.




Şekil 3.20. Temel filtreleme uygulanması


Filtre sonucunda oluşan iki ayrı sinyalden A ile gösterilene yaklaşım (Approximation) ve D ile gösterilene de detay (Detail) ismi verilir. Yaklaşım sinyalleri, orijinal sinyali temsil eder ve sinyalin tanımını verir. Detaylar ise sinyalin karakteristiğini yada ayrıntısını içerir [17]. Örnek olarak insan sesini ele alırsak; insan sesinden yüksek frekanslar kaldırılırsa konuşmanın içeriği anlaşılabilir. Ancak düşük frekanslar kaldırılırsa içeriği anlaşılmayan, anlam verilemeyen sesler duyulur. Dalgacık Dönüşümü' nde de yaklaşımlar sinyalin orijinalini temsil eder ve yüksek ölçek ile elde edilir. Detaylar ise düşük ölçekteki bilgilerdir ve sinyalin yüksek frekanslı bileşenleridir.

Sinyallere alçak geçiren ve yüksek geçiren filtreler uygulayarak ve ortaya çıkan verileri iki ile azaltarak bu sinyalin ADD yapılabilir. Bu işlem çıkan sonuçlara da uygulanırsa çoklu çözünürlük analizi sinyale uygulanmış olur. Şekil 3.21' de $x(n)$ sinyaline uygulanan bu prosedür görülmekte ve burada YGF ve AGF sırasıyla yüksek geçiren ve alçak geçiren filtreleri belirtmektedir. Aşağı doğru ok ile gösterim ise iki üssü azaltılma (Downsampling) işlemidir. Her bir ayrıştırma seviyesinde ortaya çıkan detaylar ve yaklaşımlar gösterilmektedir. $x(n)$ sinyalinin içerisindeki bilgi A3 yaklaşımıdır. D1,D2

ve D3 bu sinyalin farklı frekans değerlerindeki yüksek frekans kısımları olup, $x(n)$ sinyali tüm detaylarla A3 yaklaşımının toplamına eşittir. Ayırıştırma işlemi sonrasında, istenen frekans aralığı seviyesindeki detay veya yaklaşım bilgisi seçilerek analiz edilebilir. Şekil 3.22, bu ayırıştırma işleminde oluşan yaklaşım ve detayları daha net göstermektedir. Ayrıca her ayırıştırma seviyesindeki frekans bantları da belirtilmiştir.




Şekil 3.21. Sinyal ayırıştırma işlemi ⁷



Şekil 3.22. Frekans bantları ile yaklaşımlar ve detaylar arasındaki ilişki ⁷

Şekil 3.22' de görüldüğü gibi her ayırıştırma aşamasında, orijinal sinyalden aldığımız örnek sayısı yarı yarıya azalmaktadır. Ayırıştırılan bu sinyallere ters ayırıştırma işlemi

uygulanarak, orijinal sinyali tekrar elde etmek mümkündür. Dalgacık Dönüşümlerinin bu yönü de oldukça kuvvetlidir ve görüntü işlemede resim bilgisinden daha iyi bilgiler alınmasını sağladığı için mükemmel sonuçlar vermektedir [18]. Şekil 3.23, ADD' nün frekans-zaman düzlemini göstermektedir. Burada ki j ölçeği, k ise filtreleme sonucunda oluşan alçak ve yüksek frekansları temsil etmek için kullanılmıştır. k değerinin düşük değerle temsil ettiği bölgeler, düşük frekanslı bileşenleri göstermektedir. Başka bir deyişle, düşük k değerleri bir frekans bandı içerisindeki yaklaşımları, yüksek k değerleri detayları nitelemektedir.



Şekil 3.23. ADD zaman-frekans düzlemi

$m = \log_2$ örnekleme frekansı (3.12)

Şekil 3.23' den de anlaşılabileceği gibi ADD, yüksek frekanslarda yüksek zaman çözünürlüğü ve düşük frekans çözünürlük özelliğine sahipken alçak frekanslarda ise yüksek frekans çözünürlüğü ve düşük zaman çözünürlüğünü sağlar. Yapılan çalışmada sinyaller, Daubechies, 'db10' dalgacığının üçüncü seviyesi kullanılarak ayrılmıştır. Elde edilen katsayılar GRNN' nin 31 girişini oluşturacaktır. Ana sinyal, üç detay (D1-3) ve son yaklaşım sinyali (A3) kullanılarak katsayı matrisinden yeniden elde edilebilir.

4. YAPAY SİNİR AĞLARI

Yapay sinir ağı ya da kısaca YSA, beyindeki sinirlerin çalışmasını taklit ederek sistemlere öğrenme, genelleme yapma, hatırlama gibi yetenekler kazandırmayı amaçlayan bilgi işleme sistemidir. Yapay sinir ağı insan vücudundaki sinir sisteminin bazı fonksiyonlarını modelleyen ve bazı yeteneklerini yakalamak isteyen basit hesapsal birimlerin (nöronlar) yoğun bir paralel dizisidir; başka bir deyişle, teorik hale getirilmiş zekâ ve beyin faaliyetlerinin matematiksel modelleridir. Ancak biyolojik sistemler o kadar karmaşıktır ki yapay sinir ağı için kullanılan biyolojik modellerin fazlaca basite indirgenmiş biçimleri şeklindedir. Yapay sinir ağı, kesin kurallarla gösterimi zor olan, daha çok algılamaya yönelik bilgileri işlemekte kullanılırlar. Olayları genelleme yetenekleri ve eksik, belirsiz, bozulmuş bilgileri işleyebilme ve esnek olarak çalıştırabilmeleri önemli özelliklerindendir. Bu ağlarda kullanılan basit işleme elemanları insan beyninin işleme elemanı olan nöronların modelidir. İnsan sinir sisteminin problemleri çözebilmek için öğrenme özelliği olduğu gibi yapay sinir ağlarının da bu özelliği mevcut bulunmaktadır.

4.1 Yapay Sinir Ağlarının Özellikleri

Genelleme, eğitim ya da öğrenme sürecinde karşılaşılmayan girişler için de YSA' nın uygun tepkileri üretmesi olarak tanımlanır. Bu üstün özellikleri, YSA' nın karmaşık problemleri çözebilme yeteneğini gösterir. Günümüzde birçok bilim alanında YSA, bundan sonraki bölümlerde anlatılacak özellikleri nedeniyle etkin olmuş ve uygulama yeri bulmuştur.

4.1.1 Doğrusal Olmama

YSA' nın temel işlem elemanı olan hücre doğrusal değildir. Dolayısıyla hücrelerin birleşmesinden meydana gelen YSA da doğrusal değildir ve bu özellik bütün ağa yayılmış durumdadır. Bu özelliği ile YSA, doğrusal olmayan karmaşık problemlerin çözümünde en önemli araç olmuştur.

4.1.2 Öğrenme

YSA' nın arzu edilen davranışı gösterebilmesi için amaca uygun olarak ayarlanması gerekir. Bu, hücreler arasında doğru bağlantıların yapılması ve bağlantıların uygun ağırlıklara sahip olması gerektiğini ifade eder. Yapay sinir ağı programlama yerine

örneklerle eğitilir. Ağ, ağırlık matrisindeki değerleri değiştirerek bunları öğrenir ve ağa bir giriş uygulandığı zaman o girişe uygun çıkış cevabı üretir.

Yapay sinir ağları eğiticili ve eğiticişiz olmak üzere iki şekilde eğitilmektedirler. Eğiticili öğrenmede, ağa hem giriş hem de istenen çıkış bilgisi (hedef vektörü) girilir. Her denemeden sonra ağ kendi çıkışını doğru cevaplarla karşılaştırır ve çıkış hatası kabul edilebilecek seviyeye ininceye kadar ağırlıklarını değiştirerek tekrarlama yapar. Eğiticişiz öğrenmede hiçbir hedef vektörü yoktur. Giriş vektörü sisteme uygulanır ve sistem, girişin benzer veya ayrılan özelliklerinden yararlanarak uyumlu bir çıkış (muhtemelen eğitimden önce tahmin edilemeyen) üretecek şekilde kendisini organize eder [19], [20].

4.1.3 Genelleme

Bir yapay sinir ağının geliştirilmesindeki en kritik parametrelerden biri genelleme, yani ağın gelecekteki performansdır. Diğer bir deyişle ağın, eğitim kümesinde mevcut olmayan durumlar için ne kadar iyi tahminlerde bulunabildiğinin belirlenmesidir. Öğrenme süresince, eğiticili bir sinir ağının çıkışları eğitime kümesindeki girişleri verilen hedef değerlere yaklaştırır. Bu yetenek tek başına yararlı olabilir; fakat bir sinir ağının kullanmanın amaçlarından biri genelleme yapmaktır. Yani, ağın çıkışlarının eğitime kümesinde verilmeyen girişler için de hedef değerlere yaklaştırmaktır. Genelleme her zaman mümkün olmayabilir.

4.1.4 Uyarlanabilirlik

YSA, ilgilendiğı problemdeki değişikliklere göre ağırlıklarını ayarlar. Yani, belirli bir problemi çözmek amacıyla eğitilen YSA, problemdeki değişimlere göre tekrar eğitilebilir, değişimler devamlı ise gerçek zamanda da eğitime devam edilebilir. Bu özelliğı ile YSA, uyarlamalı örnek tanıma, sinyal işleme, sistem tanımlama ve denetim gibi alanlarda etkin olarak kullanılır.

4.1.5 Hata Toleransı

YSA, çok sayıda hücrenin çeşitli şekillerde bağlanması ile oluştuğundan paralel dağılmış bir yapıya sahiptir ve ağın sahip olduğı bilgi, ağdaki bütün bağlantılar üzerine dağılmış durumdadır. Bu nedenle, eğitilmiş bir YSA'nın bazı bağlantılarının hatta bazı hücrelerinin etkisiz hale gelmesi, ağın doğru bilgi üretmesini önemli ölçüde etkilemez.

Bu nedenle, geleneksel yöntemlere göre hatayı tolere etme yetenekleri son derece yüksektir.

4.1.6 Donanım ve Hız

YSA, paralel yapısı nedeniyle büyük ölçekli tümdevre (VLSI) teknolojisi ile gerçekleştirilebilir. Bu özellik, YSA'nın hızlı bilgi işleme yeteneğini artırır ve gerçek zamanlı uygulamalarda arzu edilir.

4.1.7 Analiz ve Tasarım Kolaylığı

YSA'nın temel işlem elemanı olan hücrenin yapısı ve modeli, daha önce açıklandığı gibi bütün YSA yapılarında yaklaşık aynıdır. Dolayısıyla, YSA'nın farklı uygulama alanlarındaki yapıları da standart yapıdaki bu hücrelerden oluşacaktır. Bu nedenle, farklı uygulama alanlarında kullanılan YSA benzer öğrenme algoritmalarını ve teorilerini paylaşabilirler. Bu özellik, problemlerin YSA ile çözümünde önemli bir kolaylık getirecektir.


4.2 Çalışmada Kullanılan Yapay Sinir Ağı Yapısı

Bu çalışmada temel yapay sinir ağı olarak Genelleştirilmiş Regresyon Ağları kullanılmıştır.

4.2.1 Genelleştirilmiş Regresyon Ağları (GRNN)

Genelleştirilmiş Regresyon Ağları, radyal temelli ağların genellikle fonksiyon yaklaştırma problemleri için kullanılmakta olan özel bir halidir. Bu ağlar önemli ölçüde iyi başarı ile sürekli fonksiyonlara yaklaşımı sağlarlar. Bazı ağlar gibi tekrarlı eğitim işlemine ihtiyaç duymamaktadır. Giriş ve çıkış arasında, eğitim kümesinden elde ettiği bulgularla herhangi sıradan bir fonksiyona yaklaşabilir. Eğitim kümesinin boyutları büyüdükçe yaklaşımdaki hata oranı sıfıra yakınsar. GRNN, standart teknikler gibi sürekli değişkenler üzerinde yargıya varılabilmesi içinde kullanılır. Temelinde standart bir istatistiksel yöntem olan Kernel yaklaşımını kullanmaktadır. Bu tanıma göre, bağımlı bir y değişkeninin bağımsız bir x değişkenine göre regresyonu, verilen x girişleri ve eğitim kümesine göre y için en çok olasılığa sahip değere yaklaşır. Yaklaşım yöntemi ortalama karesel hatayı en düşük değere yaklaştıracak şekilde belirlenir. GRNN, belirli bir eğitim kümesinde x ve y giriş ve çıkışları için bileşik olasılık

yoğunluk fonksiyonunun da tahmini için kullanılmaktadır. Ağırlık matrisi w_{ij} , eğitim kümesinden belirlenen hedef değer ağırlık matrisi olarak atanır [21].




Şekil 4.1 GRNN ağ yapısı ⁴

4.3 KZFD İle Oluşturulan Veri Kümesi

Birinci model, 64 durum için KZFD ile yapay sinir ağına 9 giriş, 3 çıkış olarak da 1. silindirin yarıçapı, 2. silindirin yarıçapı ve silindirler arası mesafeler girilmiştir. İkinci model olarak, KZFD uygulanan elektrik alana dalgacık araç kutusu kullanılarak elde edilen özelliklerin oluşturduğu 9 giriş, 3 çıkışlı aynı GRNN modeli kullanılmıştır. Birinci ve ikinci model olarak aynı giriş ve çıkışlı GRNN ağ yapısı kullanıldığı için ayrı şekillerle gösterilmemiştir.

4.4 KZFD Analizinin GRNN Ağı Sonuçları

Yapay sinir ağı için kullanılan veri kümesinde toplam 64 adet veri bulunmaktadır. Ağın test başarısı için bu verilerin 52 adeti test için kullanılmıştır. Şekil 3.13' de de görüldüğü gibi çıkışlar, birinci ve ikinci hedeflerin yarıçapları ile aralarındaki mesafedir. Dolayısıyla GRNN ağının girişinde 9 nöron, çıkışında ise 3 nöron bulunmaktadır. Yayılım değeri olarak 1 kullanılmıştır.



Şekil 4.2 GRNN Ağının giriş ve çıkışlarını gösteren blok diyagram

KZFD kullanılarak elde edilen 9 giriş 3 çıkışlı GRNN ağının bu uygulama için eğitime başarısı %75.64, test başarısı ise %55.97 olarak bulunmuştur. KZFD ile elde edilen şekle uygulanan dalgacık araç kutusu ile oluşturulan 9 giriş 3 çıkışlı GRNN ağının bu uygulama için eğitime başarısı %80.37, test başarısı ise %57.06 olarak bulunmuştur.


4.5 Dalgacık Dönüşüm ile Oluşturulan Veri Kümesi

64 durum için ayrı ayrı Dalgacık dönüşümü yapılmış yapay sinir ağına giriş olarak 31 dalgacık katsayısı, 3 çıkış olarak da 1. silindirin yarıçapı, 2. silindirin yarıçapı ve silindirler arası mesafeler girilmiştir. Bu çalışmada da yapay sinir ağı olarak Genelleştirilmiş Regresyon Sinir Ağı kullanılmıştır.

GRNN ağının test başarısı için 2 farklı yol izlenmiştir. Çıkışlar birinci silindirin yarıçapı, ikinci silindirin yarıçapı ve aralarındaki mesafe olarak aynıdır. Birinci durumda girişler dalgacık dönüşümü katsayılarıdır.

4.6 Dalgacık Dönüşümünün GRNN Ağı Sonuçları

Yapay sinir ağı için kullanılan veri kümesinde toplam 64 adet veri bulunmaktadır. Ağı eğitilmesi için 52 adet veri, test başarısı için ise bu verilerin 12 adeti kullanılmıştır. Şekil 3.25' de de görüldüğü gibi çıkışlar, birinci ve ikinci silindirlerin yarıçapları ile aralarındaki mesafedir. Dolayısıyla GRNN ağının girişinde 31 nöron, çıkışında ise 3 nöron bulunmaktadır. Yayılım değeri olarak 0.5 kullanılmıştır.




Şekil 4.3 GRNN Ağının giriş ve çıkışlarını gösteren blok diyagram

GRNN ağının bu uygulama için eğitime başarısı %99.98, test başarısı ise %68.86 olarak bulunmuştur.

İkinci durumda girişler görüntü matrisinin en yüksek katsayıları olan (1, 3, 5... 27, 29, 31) Dalgacık dönüşümü katsayıları olarak alınmıştır.

Yapay sinir ağı için kullanılan veri kümesinde toplam 64 adet veri bulunmaktadır. Ağın eğitilmesi için 52 adet veri, test başarısı için ise bu verilerin 12 adeti kullanılmıştır. Şekil 3.26' de de görüldüğü gibi çıkışlar, birinci ve ikinci silindirlerin yarıçapları ile aralarındaki mesafedir. Dolayısıyla GRNN ağının girişinde 16 nöron, çıkışında ise 3 nöron bulunmaktadır. Yayılmı değeri olarak 0.6 kullanılmıştır.



Şekil 4.4 GRNN Ağının giriş ve çıkışlarını gösteren blok diyagram

GRNN ağının bu uygulama için eğitme başarısı %99.87, test başarısı ise %79.35 olarak bulunmuştur. Alınan girişler test başarısını bir hayli yükseltmiştir.

5. SONUÇLAR

KZFD ile eğitime başarısı %75.64, test başarısı ise %55.97 de kalırken Dalgacık Dönüşümü ile eğitime başarısı %99.87, test başarısı da %79.35' e kadar çıkmıştır. KZFD' nde pencere büyüklüğünün analiz boyunca sabit olması istenilen zaman-frekans çözünürlüğünün elde edilememesine sebep olmuştur. Yapay sinir ağından aldığımız başarı yüzdelerinin düşük olması bu sebebin sonucudur. Dalgacık Dönüşümü' nün eğitime ve test başarısının sırrı kısa süreli ani değişimleri kısa pencerelerle, uzun süreli değişimleri daha geniş pencerelerle analiz edebilmesidir.

KAYNAKLAR

- [1] Turhan, G., Leblebicioğlu, K., İnce, T., (1999), “Electromagnetic Target Classification Using Time-Frequency Analysis and Neural Networks”, Microwave and Optical Technology Letters, Vol.21, No.1, April 5 1999.
- [2] Turhan, G., (2005), “Real Time Electromagnetic Target Classification Using a Novel Feature Extraction Technique With PCA-Based Fusion”, IEEE Transaction On Antennas and Propagation, Vol.53, No.2, February 2005.
- [3] Zhihe, S., Feng, L., (2006), “Applying Improved BP Neural Network in Underwater Target Recognition”, International Joint Conference on Neural Networks, Canada, July 2006.
- [4] Makal, S., (2007), “Sonsuz Uzun Mükemmel İletken Düz Yüzeyler Üzerindeki Silindirik Hedeflerin Yapay Sinir Ağları Kullanılarak Tanımlanması ve Sınıflandırılması”, Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, Türkiye
- [5] Chen, S., (1990), “Radar Target Identification with Relative Amplitudes and Unknown Target Aspect Angles”, IEEE Aerospace and Electronics Conference, Vol.1, 1990.
- [6] Huaitie, X., Zhaowen, Z., Guirong, G., (1993), “An Artificial Neural Network Approach to Radar Target Identification in Polarization Domain”, TENCON '93. Proceedings. Computer, Communication, Control and Power Engineering., Vol.1, 1993.
- [7] Fidan, H., (2006), “Dalgacık Dönüşümü Tekniği ile Motor Arıza Tespiti”, Yüksek Lisans Tezi, Süleyman Demirel Üniversitesi, Türkiye.
- [8] Jawert, B., Sweldens, W., 1992. An Overview Of Wavelet Based Multiresolution Analysis. <http://Cm.Bell-Labs.Com/Who/Wim/Papers/Overview.Pdf>
- [9] Graps, A., 1995. An Introduction to Wavelets. IEEE Computational Sciences and Engineering, Volume 2, Number 2, 50-61.
- [10] Uçan, O.N., 2003. İşaret ve Görüntü İşlemede Yeni Yaklaşımlar. İ.Ü. Mühendislik Fakültesi Yayınları No:4408, 213s. İstanbul.
- [11] Altmann, J., 1996. <http://www.wavelet.org/tutorial/index.html>
- [12] Polikar, R., 2001. <http://users.rowan.edu/~polikar/WAVELETS/WTtutorial.html>
- [13] Pillis L.G., Radunskaya A.E., 2003. An Introduction to Fourier Transforms, Fourier Series and the FFT. oldsite.capital.edu/acad/as/csac/Keck/modules/Depillis/Fourier/Intro.pdf

- [14] Valens, C., 1999. A Really Friendly Guide to Wavelets.
<http://perso.wanadoo.fr/polyvalens/clemens/wavelets/wavelets.html>
- [15] Marcianesi, A., Scaletti S., Speciale, N., 2001. A New Wavelet-Based Algorithm for Filtering Low SRN Signals. Neural Networks for Signal Processing XI, Proceedings of the IEEE Signal Processing Society Workshop, 549-558.
- [16] Rioul, O., Vetterli, M., 1991. Wavelets and Signal Processing. Signal Processing Magazine IEEE, Volume: 8, Issue: 4, 14–38.
- [17] Misiti M., Misiti, Y., Oppenheim, G., Poggi, J., 2004. User Guide Wavelet Toolbox For Use with MATLAB.
www.mathworks.com/access/helpdesk/help/pdf_doc/wavelet/wavelet_ug.pdf
- [18] Chhokra, K., 2002. Applications of Wavelets Data Compression.
www.vuse.vanderbilt.edu/~chhokrkg/math297/wavelet_compression.ppt
- [19] Hinton, G.E., (1989), “Connectionist Learning Procedures”, Artificial Intelligence, 40:185-234
- [20] Lippman, R.P., (1987), “An Introduction to Computing with Neural Nets”, IEEE ASSP Magazine, 4-22.
- [21] Avci, M., Yıldırım, T., (2002), “Classification of Escherichia Coli Bacteria by Artificial Neural Networks”, IEEE International Symposium on Intelligent Systems, Vol.3, Varna, Bulgaristan, sf.16.20.
- [22] Phillips W.J., 2003. <http://www.engmath.dal.ca/courses/engm6610/notes/>
- [23] Mallat S.G., 1989. A Theory for Multiresolution Signal Decomposition: The Wavelet Representation. IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. II, NO. 7, 674-693
- [24] Batar, H., (2005), “EEG işaretlerinin Dalgacık Analiz Yöntemleri Kullanılarak Yapay Sinir Ağları ile Sınıflandırılması”, Kahramanmaraş Sütçü İmam Üniversitesi, Türkiye.
- [25] Graps, A., 2004. <http://www.amara.com/current/wavelet.html>

EKLER

Ek 1 Kullanılan Kısa Zamanlı Fourier Dönüşüm İçin Simülasyon Programı

Ek 2 Kullanılan Dalgacık Dönüşümü İçin Simülasyon Programı

Ek 3 Kısa Zamanlı Fourier Dönüşümünde Kullanılan Genelleştirilmiş Regresyon Sinir Ağının Simülasyon Programı

Ek 4 Dalgacık Dönüşümü Katsayılarının Girişi Oluşturduğu Birinci Durum İçin Kullanılan Genelleştirilmiş Regresyon Sinir Ağı İçin Simülasyon Programı

Ek 5 Dalgacık Dönüşümü Katsayılarının Girişi Oluşturduğu İkinci Durum İçin Kullanılan Genelleştirilmiş Regresyon Sinir Ağı İçin Simülasyon Programı

Ek 1 Kullanılan Kısa Zamanlı Fourier Dönüşümü İçin Simülasyon Programı

Silindirlerden saçılan elektrik alan sinyallerine Kısa Zamanlı Fourier Dönüşümü uygulamak için yazılan MATLAB kodu bulunmaktadır.

```
function y = STFT(x, sampling_rate, window, window_length, step_dist, padding)
%
% y = STFT(x, sampling_rate, window, window_length, step_dist, padding)
%
% STFT produces a TF image of "x".
% The output is also stored in "y".
%
% For "window", use one of the following inputs:
% rectangular    = 1
% Hamming       = 2
% Hanning       = 3
% Blackman-Tukey = 4
%
% The time scale is associated with the center of the window,
% if the window is of odd length. Otherwise, the window_length/2
% is used. "Step_dist" determines the stepping distance between the number
% of samples, and is arranged to maintain the proper time index
% provided by "sampling_rate" in seconds. "Padding" is the
% total length of the windowed signal before the fft, which is
% accomplished by zero padding.
%
% Developed by Timothy D. Dorney
%      Rice University
%      April, 1999
%      tdorney@ieee.org
%
% Coded using MATLAB 5.X.X.
%
```

```

%    REVISION HISTORY
%
%    VERSION 1.0.0          APR. 21, 1999          TIM DORNEY
%
clc;clear all;close all;
load altmis.txt;
x=altmis;
zaman=altmis(1:103);
genlik=altmis(104:end);
figure(1), clf
plot(zaman,genlik,'k')
grid on
xlabel('Zaman (ns)');
ylabel('Normalize Edilmis Elektrik Alanin Genligi');
x=genlik;
sampling_rate=82; % örnekleme frekansı
window=3;
window_length=20;
step_dist=1;
padding=100;

if ((window < 1) | (window > 4))
    window = 1;
    disp('The argument "window" must be between 1-4, inclusively. Window set to
1!');
end
if ((step_dist < 1) | (round(step_dist) ~= step_dist))
    step_dist = 1;
    disp('The argument "step_dist" must be an integer greater than 0. Step_dist set
to 1!');
end

```

```

if (sampling_rate <= 0)
    disp('The argument "sampling_rate" must be greater than 0. ');
    return;
end
if (padding < window_length)
    padding = window_length;
    disp('The argument "padding" must be non-negative. Padding set to
"window_length"!');
end

if (window == 1)
    WIN = ones(1,window_length);
elseif (window == 2)
    WIN = hamming(window_length)';
elseif (window == 3)
    WIN = hanning(window_length)';
elseif (window == 4)
    WIN = blackman(window_length)';
end

[m,n] = size(x);
if (m ~= 1)
    X = x';
else
    X = x;
end
[m,n] = size(X);
if (m ~= 1)
    disp('X must be a vector, not a matrix!');
    return;
end

```

```

LENX = length(X);
IMGX = ceil(LENX/step_dist);
if (padding/2 == round(padding/2))
    IMGY = (padding/2) + 1;
else
    IMGY = ceil(padding/2);
end

y = zeros(IMGX,IMGY);

if (window_length/2 == round(window_length/2))
    CENTER = window_length/2;
    x_pad_st = window_length - CENTER - 1;
    x_pad_fi = window_length - CENTER;
else
    CENTER = (window_length+1)/2;
    x_pad_st = window_length - CENTER;
    x_pad_fi = window_length - CENTER;
end

X = [zeros(1,x_pad_st) X zeros(1,x_pad_fi)];

iter = 0;
for kk = 1:step_dist:LENX
    iter = iter + 1;
    XX = X(kk:(kk + window_length - 1));
    YY = XX .* WIN;
    ZZ = abs(fft(YY, padding));
    y(iter,:) = ZZ(1:IMGY);
end

freq = (1/sampling_rate)/2;

```

```
imagesc([0:(step_dist*sampling_rate):(sampling_rate*(LENX-1))], ...  
        [0:(freq/(IMGY-1)):freq],y');  
xlabel('Time (seconds)');  
ylabel('Frequency (Hz)');  
axis('xy')
```

Ek 2 Kullanılan Dalgacık Dönüşümü İçin Simülasyon Programı

Silindirlerden saçılan elektrik alan sinyallerine Dalgacık dönüşümü uygulamak için yazılan MATLAB kodu bulunmaktadır.

```

clc;
clear all;
load time60.txt;

save time60.mat
% [XD1,CXD,LXD] = wden(tra10,'minimaxi','s','mln',8,'sym8');

w = 'db10';
L = 3;
[c,l] = wavedec(time60,L,w);
[cd11,cd21,cd31] = detcoef(c,l,[1 2 3]);
ca11 = appcoef(c,l,'db10',1);
ca21 = appcoef(c,l,'db10',2);
ca31 = appcoef(c,l,'db10',3);
% ca41 = appcoef(c,l,'haar',4);
% ca51 = appcoef(c,l,'haar',5);
% ca61 = appcoef(c,l,'haar',6);
% ca71 = appcoef(c,l,'haar',7);
% ca81 = appcoef(c,l,'haar',8);
ca31'

subplot(4,1,1), plot(time60);
subplot(4,1,2), plot(ca11);
subplot(4,1,3), plot(ca21);
subplot(4,1,4), plot(ca31);

```

Ek 3 Kısa Zamanlı Fourier Dönüşümde Kullanılan Genelleştirilmiş Regresyon Sinir Ağının Simülasyon Programı

Saçılan elektrik alana Kısa Zamanlı Fourier Dönüşümü uygulanarak yapay sinir ağı için giriş vektörlerinin oluşturulması için yazılan MATLAB kodu bulunmaktadır.

```

clc
clear all
close all

load traint2.txt
load testt2.txt

data = abs(traint2(:,1:4)');
target = traint2(:,10:12)';
target1=testt2(:,10:12)';
spread=1;
eg=.1;
net=newgrnn(data,target,spread);

Y = sim(net,data);

test=(testt2(:,1:4)');

Y_test = sim(net,test)

fark=abs(Y_test(:,:)-target1(:,:));
hata=abs(fark./target1)*100;
toplam=0;
for k=1:3
    for m=1:10

```

```
        toplam=toplam+hata(k,m);  
    end  
end
```

```
ort_hata=toplam/(14*3);
```

```
basari=100-ort_hata
```

```
fark=abs(Y(:,:)-target(:,:));  
hata=abs(fark./target)*100;  
toplam=0;  
for k=1:3  
    for m=1:50  
        toplam=toplam+hata(k,m);  
    end  
end
```

```
ort_hata=toplam/(50*3);
```

```
basari2=100-ort_hata
```

Ek 4 Dalgacık Dönüşümü Katsayılarının Girişi Oluşturduğu Birinci Durum İçin Kullanılan Genelleştirilmiş Regresyon Sinir Ağı İçin Simülasyon Programı

Saçılan elektrik alana Dalgacık dönüşümü uygulanarak yapay sinir ağı için giriş vektörlerinin oluşturulması için yazılan MATLAB kodu bulunmaktadır.

```

clc
clear all
close all
load datasetson.txt
load train10son.txt
load test10son.txt

data =abs(train10son(:,1:31)).*10;
target = train10son(:,32:34)';
target1=test10son(:,32:34)';
spread=0.5;
eg=.05;
net=newgrnn(data,target,spread);

Y = sim(net,data);

test=abs(test10son(:,1:31)).*10;

Y_test = sim(net,test)

fark=abs(Y_test(:,:)-target1(:,:));
hata=abs(fark./target1)*100;
toplaml=0;
for k=1:3

```

```
    for m=1:12
        toplam1=toplam1+hata(k,m);
    end
end
```

```
ort_hata1=toplam1/(12*3);
```

```
basari1=100-ort_hata1
```

```
fark=abs(Y(:,:)-target(:,:));
hata=abs(fark./target)*100;
toplam2=0;
for k=1:3
    for m=1:51
        toplam2=toplam2+hata(k,m);
    end
end
```

```
ort_hata2=toplam2/(51*3);
```

```
basari2=100-ort_hata2
```

Ek 5 Dalgacık Dönüşümü Katsayılarının Girişi Oluşturduğu İkinci Durum İçin Kullanılan Genelleştirilmiş Regresyon Sinir Ağı İçin Simülasyon Programı

Saçılan elektrik alana Dalgacık dönüşümü uygulanarak yapay sinir ağı için giriş vektörlerinin oluşturulması için yazılan MATLAB kodu bulunmaktadır.

```

clc
clear all
close all
load datasetson.txt
load train10son.txt
load test10son.txt

data =abs(train10son(:,1:2:31))'.*10;
target = train10son(:,32:34)';
target1=test10son(:,32:34)';
spread=0.6;
eg=.05;
net=newgrnn(data,target,spread);

Y = sim(net,data);

test=abs(test10son(:,1:2:31))'.*10;

Y_test = sim(net,test)

fark=abs(Y_test(:,:)-target1(:,:));
hata=abs(fark./target1)*100;
toplam=0;
for k=1:3
    for m=1:12

```

```
        toplam=toplam+hata(k,m);  
    end  
end
```

```
ort_hata=toplam/(12*3);
```

```
basari=100-ort_hata
```

```
fark=abs(Y(:,:)-target(:,:));  
hata=abs(fark./target)*100;  
toplam=0;  
for k=1:3  
    for m=1:51  
        toplam=toplam+hata(k,m);  
    end  
end
```

```
ort_hata=toplam/(51*3);
```

```
basari=100-ort_hata
```

ÖZGEÇMİŞ

Doğum tarihi	07.03.1983	
Doğum yeri	Ankara	
Lise	1997-2000	Ankara Gazi Lisesi
Lisans	2002-2006	Uludağ Üniversitesi Mühendislik - Mimarlık Fakültesi Elektronik Mühendisliği Bölümü

Çalıştığı kurumlar

2007 – Türk Telekomünikasyon A.Ş.