T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DALGACIK DÖNÜŞÜMÜ KULLANILARAK HİSSE SENEDİ FİYAT TAHMİNİ ÜZERİNE BİR UYGULAMA

HASAN AYKUT KARABOĞA

YÜKSEK LİSANS TEZİ
İSTATİSTİK ANABİLİM DALI
İSTATİSTİK PROGRAMI

DANIŞMAN
DOÇ. DR. İBRAHİM DEMİR

İSTANBUL, 2015

T.C.

YILDIZ TEKNİK ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

DALGACIK DÖNÜŞÜMÜ KULLANILARAK HİSSE SENEDİ FİYAT TAHMİNİ ÜZERİNE BİR UYGULAMA

Hasan Aykut KARABOĞA tarafından hazırlanan tez çalışması 17.02.2015 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü İstatistik Anabilim Dalı'nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Tez Danışmanı

Doç. Dr. İbrahim DEMİR

Yıldız Teknik Üniversitesi

Jüri Üyeleri

Doç. Dr. İbrahim DEMİR

Yıldız Teknik Üniversitesi _____

Prof. Dr. Ali Hakan BÜYÜKLÜ

Yıldız Teknik Üniversitesi _____

Doç. Dr. Reşat KÖŞKER

Yıldız Teknik Üniversitesi _____

ÖNSÖZ

Öncelikle çalışmalarımı tamamlamamı sağlayan, bana her koşulda güvenen anne babama, eşime ve kardeşlerime sonsuz teşekkür ediyorum.

Fikirleriyle çalışmalarımı başarıyla yürütmemi sağlayan ve çalışmalarımın her aşamasında tecrübesini yanımda hissettiğim tez danışmanım Doç. Dr. İbrahim Demir'e değerli katkılarından ve desteklerinden dolayı şükranlarımı sunuyorum.

Lisans eğitimimden itibaren beni özveriyle yetiştiren, aralarına katıldığım ve birlikte çalışmaktan mutluluk duyduğum Yıldız Teknik Üniversitesi İstatistik Bölümüne teşekkürlerimi sunuyorum.

Bunun yanında, akademisyenliği sevmemi ve bu mesleğe yönelmemi sağlayan Prof. Dr. Abbas Azimli' ye, her ihtiyaç duyduğumda bana kardeş yakınlığıyla can-ı gönülden destek veren Arş. Gör. Selahattin Aydoğdu ve Arş. Gör. Serkan Akoğul'a teşekkür ediyorum.

Son olarak, bu çalışmayı alın teri, emek ve çalışmanın meyvesinin ancak başarı olacağını öğreten babama ve ömrünü evlatlarına adayan anneme ithaf ediyorum.

Şubat, 2015

Hasan Aykut KARABOĞA

İÇİNDEKİLER

ÖNSÖZ iii

İÇİNDEKİLER v

SİMGE LİSTESİ viii

KISALTMA LİSTESİ ix

ŞEKİL LİSTESİ x

ÇİZELGE LİSTESİ xiv

ÖZET xv

ABSTRACT xvi

BÖLÜM 1

GİRİŞ 1

1.1 Literatür Özeti 1
1.2 Tezin Amacı 5
1.3 Hipotez 5

BÖLÜM 2

HİSSE SENETLERİ VE BORSALARIN GENEL ÖZELLİKLERİ 6

2.1 Borsanın Özellikleri 6
2.2 Hisse Senetleri Piyasası 7
2.2.1 Ulusal Pazar 8
2.2.2 İkinci Ulusal Pazar 9
2.2.3 Kurumsal Ürünler Pazarı 9
2.2.4 Gözaltı Pazarı 10
2.3 Hisse Senedi Piyasasının İşleyişi 10
2.4 Hisse Senetlerinin Ekonomik İşlevleri 12
2.5 Hisse Senetlerinde Fiyatlar ve Değerler 12
2.5.1 Nominal (İtibari) Fiyat 12
2.5.3 Piyasa Fiyatı 13

2.5.4 Borsa Fiyatı 13
2.5.5 Defter Değeri 13
2.5.6 Tasfiye Değeri 13
2.5.7 İşleyen Teşebbüs Değeri 13
2.5.8 Gerçek Değer 13
2.6 Hisse Senedi Sahibinin Başlıca Ortaklık Hakları 14
2.7 Hisse Senetlerinin Üzerinde Bulunan Haklar ile İlgili Yapılan İşlemler 14
2.7.1 Yönetime Katılma Hakkı 14
2.7.2 Kardan Pay Alma Hakkı 14
2.7.3 Oy Kullanma Hakkı 15
2.7.4 Rüçhan Hakkı 15
2.7.5 Tasfiyeden Pay Alma Hakkı 15
2.7.6 Şirket Faaliyetleri Hakkında Bilgi Edinme Hakkı 15
2.8 Hisse Senedi Piyasalarını Etkileyen Faktörler 15

BÖLÜM 3

YAPAY SİNİR AĞLARI 19

3.1 Tarihçe 20
3.2 Yapay Sinir Ağlarının Temel Özellikleri 21
3.2.1 Öğrenme 21
3.2.2 Genelleme 21
3.2.3 Hata toleransı 21
3.2.4 Doğrusal Olmama 21
3.2.5 Uyarlanabilir Ağ Yapısı 21
3.3 Sinir Hücresinin Yapısı 22
3.3.1 Biyolojik Sinir Hücresinin Yapısı 22
3.3.2 Yapay Sinir Hücresinin Yapısı 23
3.4 Öğrenme Yöntemlerine Göre Ağ Yapıları 24
3.4.1 Danışmanlı Öğrenme 25
3.4.2 Danışmansız Öğrenme 26
3.4.3 Destekleyici Öğrenme 26
3.5 Öğrenebilen Algoritmaların Kavranması 27
3.6 Yapay Sinir Ağlarında Ağ Mimarisi 28
3.6.1 Basit Algılayıcı (Perceptron) 28
3.6.2 ADALINE 29
3.6.3 MADALINE 30
3.6.4 Çok Katmanlı Algılayıcı 31
3.6.4.1 Birleştirme (Net) Fonksiyonu: 32
3.6.4.2 Aktivasyon Fonksiyonu 33
3.6.4.3 Hata Fonksiyonu 33
3.6.4.4 Öğrenme Algoritmaları 34

BÖLÜM 4

FOURİER DÖNÜŞÜMÜ VE DALGACIK DÖNÜŞÜMÜ 37

4.1 Frekans bilgisine neden ihtiyaç duyulur? 38

4.2 Verilere Neden Dönüşüm Yapılır? 40
4.3 Fourier Dönüşümü 41
4.4 Kısa Zamanlı Fourier Dönüşümü 43
4.5 Dalgacık Dönüşümü (DD) 47
4.6 Sürekli Dalgacık Dönüşümü (SDD) 51
4.7 Zaman-Frekans Çözümlemesi 54
4.8 Sürekli Dalgacık Dönüşümünü Kesikli Hale Getirme 55
4.9 Kesikli Dalgacık Dönüşümü (KDD) 58
4.10 Alt Bant Kodlaması ve Çoklu Çözüm Analizi 60
4.11 Ana Dalgacık Türü Örnekleri 63
4.11.1 Haar Dalgacığı 63
4.11.2 Morlet Dalgacığı 64
4.11.3 Meksika Şapkası Dalgacığı 64
4.11.4 SLOG Dalgacığı 65
4.11.5 POLYWOG Dalgacığı 66

BÖLÜM 5

UYGULAMA 67

5.1 Kullanılan Veriler 67
5.1.1 Verilerin Dönüştürülmesi 68
5.2 Analiz Sonuçları 71

BÖLÜM 6

KAYNAKLAR 80

EK-A

HİSSE SENETLERİNİN DALGACIK DÖNÜŞÜMÜ GRAFİKLERİ 86

EK-B

HİSSE SENETLERİNİN ANALİZ SONUÇLARI 93

ÖZGEÇMİŞ 113

SİMGE LİSTESİ

$x(t)$	Sinyalin Kendisi
$g(t)$	Pencere Fonksiyonu
τ	Pencere Genişliği (Dalgacığın Zaman Eksenindeki Ötelendiği Konum Değeri)
*	Fonksiyonun Karmaşık Eşleniği
T	Zaman
F	Frekans
X	Sinyalin Frekans Gösterimi
$\Delta\tau$	Zaman Ayrışımı Parametresi
Δf	Frekans Ayrışımı
G(t)	g(t) Pencere Fonksiyonunun Fourier Dönüşümü
S	$\psi\left(\frac{t-\tau}{s}\right)$ Fonksiyonunun Zaman–Frekans Çözümlemesinin Ölçeklendirme Parametresi
ψ^*	ψ Ana Dalgacığının Karmaşık Eşleniği
s_1	Ölçek
$\psi(t)$	Ana Dalgacık
N	Örnekleme Parametresi
D	Düşük Geçirgen Ayrıştırma Filtresi
Y	Yüksek Geçirgen Ayrıştırma Filtresi
Y'	Yüksek Geçirgen Yeniden Birleştirme Filtresi
D'	Düşük Geçirgen Yeniden Birleştirme Filtresi
$A_n(t)$	n Seviyedeki Ayrıntı Katsayıları
$D_n(t)$	n Seviyesindeki Yaklaşım Katsayıları
w_{ij}	i , j Nöronları Arasındaki Bağlantı Ağırlığı
x_i	i Nöronunun Çıktısı
Net_j	j Nöronunun Net Girdisi

KISALTMA LİSTESİ

BIST	Borsa Istanbul
IMKB	Istanbul Menkul Kıymetler Borsası
YSA	Yapay Sinir Ağları
ARIMA	Autoregressive Integrated Moving Average
ARMA	Autoregressive Moving Average
DD	Dalgacık Dönüşümü
GA	Genetik Algoritmalar
KDD	Kesikli Dalgacık Dönüşümü
EKK	En Küçük Kareler
GARCH	Generalized AutoRegressive Conditional Heteroskedasticity
DVM	Destekli Vektör Makineleri
BPNN	Geri Yayılımlı Yapay Sinir Ağları
GYA	Geriye Yayılımlı Ağlar
PLS	Kısmi En Küçük Kareler
ADELINE	Adaptive Linear Element
MADELINE	Many Adaptive Linear Element
ÇKA	Çok Katmanlı Algılayıcı
EKG	Elektromanyetik Kardiyografi
FD	Fourier Dönüşümü
KFD	Kesikli Fourier Dönüşümü
SFD	Sürekli Fourier Dönüşümü
KZFD	Kısa Zamanlı Fourier Dönüşümü
DD	Dalgacık Dönüşümü
SDD	Sürekli Dalgacık Dönüşümü
KDD	Kesikli Dalgacık Dönüşümü
QMF	Evreli Ayna Filtreleri

ŞEKİL LİSTESİ

Sayfa

Şekil 2. 1 Borsa İstanbul'da Yer Alan Hisse Senedi Piyasaları 7
Şekil 3. 1 Biyolojik Sinir Hücresi 22
Şekil 3. 2 Yapay sinir hücresi 23
Şekil 3. 3 Öğrenme Yöntemlerine göre Ağ Yapıları 27
Şekil 3. 4 Bir Algılayıcının Yapısı 28
Şekil 3. 5 ADALINE 30
Şekil 3. 6 İki Katmanlı Bir ÇKA Örneği 32
Şekil 3. 7 Aktivasyon Fonksiyonu Türleri 33
Şekil 4. 1 Durağan Fonksiyon Grafiği 39
Şekil 4. 2 Durağan Fonksiyonun Fourier Dönüşümü 39
Şekil 4. 3 Durağan Olmayan Bir Fonksiyonun Grafiği 39
Şekil 4. 4 Durağan Olmayan Bir Fonksiyonun Fourier Dönüşümü 40
Şekil 4. 5 x(t) Sürekli Sinyalinin Fourier Dönüşümünün Gösterimi 42
Şekil 4. 6 x(t) Sinyalinin Kısa Zamanlı Fourier Dönüşümünün Gösterimi 43
Şekil 4. 7 KZFD ile Zaman – Frekans Çözümlemesi (Pencere Genişliği: τ) 45
Şekil 4. 8 KZFD ile Zaman – Frekans Çözümlemesi 46
Şekil 4. 9 Üç Farklı Pencere Genişlikli Sinyalin KZFD nün Sonuçları 46
Şekil 4. 10 Haar Dalgacığının 3 Seviyede Açılımı 48
Şekil 4. 11 Dalgacık Dönüşümünün Gösterimi 48
Şekil 4. 12 Dalgacık Dönüşümünün Zaman – Frekans Çözümlemesi 50
Şekil 4. 13 Sinyalin Dalgacık Dönüşümü 50
Şekil 4. 14 2 Basamaklı Daubechies Dalgacığı 51
Şekil 4. 15 Farklı Yayılım Değerleriyle Üretilen Dalgacıklar 53
Şekil 4. 16 Dalgacık Dönüşümünün Frekans - Zaman Çözümlemesi 54
Şekil 4. 17 Fourier Dönüşümünün ve Dalgacık Dönüşümünün Frekans – Zaman Çözümlemesi 55
Şekil 4. 18 Örnekleme Yapılan Sürekli Bir Sinyal Örneği 56
Şekil 4. 19 KDD için Filtreleme Öbeği Şeması 59
Şekil 4. 20 Dalgacık Ayrıştırma Ağaç Diyagramı 59
Şekil 4. 21 Bir Sinyalin Ayrıştırma Basamakları 62
Şekil 4. 22 Haar Dalgacık Fonksiyonu 64
Şekil 4. 23 Morlet Dalgacığı Fonksiyonu 64
Şekil 4. 24 Meksika Şapkası Dalgacık Fonksiyonu 65
Şekil 5. 1 Matlab Programı Dalgacık Dönüşümü Arayüzü 68

Şekil 5. 2 Hisse 1 için DB5 ile Dalgacık Dönüşüm Katsayıları 69
Şekil 5. 3 Hisse 1 için DB5 ile Gürültüden Arındırılmış Sinyal ve Orijinal Sinyal..... 69
Şekil 5. 4 Hisse 1 için DB6 ile Dalgacık Dönüşüm Katsayıları 70
Şekil 5. 5 Hisse 1 için DB6 ile Gürültüden Arındırılmış Sinyal ve Orijinal Sinyal..... 70
Şekil 5. 6 Hisse 1 için DB6 ile Ayrıştırılan Serinin Gösterimi 71
Şekil 5. 7 Yapay Sinir Ağları - Zaman Serileri Ara Yüzü..... 72
Şekil 5. 8 Bir Gecikmeli Otoregresif Yapay Sinir Ağı Örneği..... 72
Şekil 5. 9 Hisse 1 için Çıktı ve Hedef Verilerinin Ham veriler için Gösterimi..... 74
Şekil 5. 10 Hisse 1 için Çıktı ve Hedef Verilerinin DB5 için Gösterimi..... 74
Şekil 5. 11 Hisse 1 için Çıktı ve Hedef Verilerinin DB6 için Gösterimi..... 75
Şekil 5. 12 Hisse 1 için Çıktı ve Hedef Verilerinin Regresyon Doğrularının Ham veriler için Gösterimi 75
Şekil 5. 13 Hisse 1 için Çıktı ve Hedef Verilerinin Regresyon Doğrularının DB5 verileri için Gösterimi 76
Şekil 5. 14 Hisse 1 için Çıktı ve Hedef Verilerinin Regresyon Doğrularının DB6 verileri için Gösterimi 76
Şekil 5. 15 Hisse 1 için Yeni Verilerde Çıktı ve Hedef Verilerinin Ham veriler için Gösterimi..... 77
Şekil 5. 16 Hisse 1 için Yeni Verilerde Çıktı ve Hedef Verilerinin DB5 verileri için Gösterimi..... 77
Şekil 5. 17 Hisse 1 için Yeni Verilerde Çıktı ve Hedef Verilerinin DB6 verileri için Gösterimi..... 78
Şekil A.1 Hisse 2 için Orijinal Sinyal ve DB5 ile Gürültüden Arındırılmış Sinyal 86
Şekil A.2 Hisse 2 için DB5 ile Ayrıştırılan Serinin Gösterimi 86
Şekil A.3 Hisse 2 için Orijinal Sinyal ve DB6 ile Gürültüden Arındırılmış Sinyal 87
Şekil A.4 Hisse 2 için DB6 ile Ayrıştırılan Serinin Gösterimi 87
Şekil A.5 Hisse 3 için Orijinal Sinyal ve DB5 ile Gürültüden Arındırılmış Sinyal 87
Şekil A.6 Hisse 3 için DB5 ile Ayrıştırılan Serinin Gösterimi 88
Şekil A.7 Hisse 3 için Orijinal Sinyal ve DB6 ile Gürültüden Arındırılmış Sinyal 88
Şekil A.8 Hisse 3 için DB6 ile Ayrıştırılan Serinin Gösterimi 88
Şekil A.9 Hisse 4 için Orijinal Sinyal ve DB5 ile Gürültüden Arındırılmış Sinyal 89
Şekil A.10 Hisse 4 için DB5 ile Ayrıştırılan Serinin Gösterimi 89
Şekil A.11 Hisse 4 için Orijinal Sinyal ve DB6 ile Gürültüden Arındırılmış Sinyal 89
Şekil A.12 Hisse 4 için DB6 ile Ayrıştırılan Serinin Gösterimi 90
Şekil A.13 Hisse 5 için Orijinal Sinyal ve DB5 ile Gürültüden Arındırılmış Sinyal 90
Şekil A.14 Hisse 5 için DB5 ile Ayrıştırılan Serinin Gösterimi 90
Şekil A.15 Hisse 5 için Orijinal Sinyal ve DB6 ile Gürültüden Arındırılmış Sinyal 91
Şekil A.16 Hisse 5 için DB6 ile Ayrıştırılan Serinin Gösterimi 91
Şekil A.17 Hisse 6 için Orijinal Sinyal ve DB5 ile Gürültüden Arındırılmış Sinyal 91
Şekil A.18 Hisse 6 için DB5 ile Ayrıştırılan Serinin Gösterimi 92
Şekil A.19 Hisse 6 için Orijinal Sinyal ve DB6 ile Gürültüden Arındırılmış Sinyal 92
Şekil A.20 Hisse 6 için DB6 ile Ayrıştırılan Serinin Gösterimi 92
Şekil B.1 Hisse 2 nin Çıktı ve Hedef Verilerinin Ham Veriler için Gösterimi..... 93
Şekil B.2 Hisse 2 nin Çıktı ve Hedef Verilerinin DB5 ve için Gösterimi..... 93
Şekil B.3 Hisse 2 nin Çıktı ve Hedef Verilerinin DB6 için Gösterimi 94

Şekil B.4 Hisse 2 nin Çıktı ve Hedef Verilerinin Regresyon Doğrularının Ham veriler için Gösterimi 94
Şekil B.5 Hisse 2 nin Çıktı ve Hedef Verilerinin Regresyon Doğrularının DB5 için Gösterimi 95
Şekil B.6 Hisse 2 nin Çıktı ve Hedef Verilerinin Regresyon Doğrularının DB6 için Gösterimi 95
Şekil B.7 Hisse 2 nin Yeni Verilerde Çıktı ve Hedef Verilerinin Ham veriler için Gösterimi 96
Şekil B.8 Hisse 2 nin Yeni Verilerde Çıktı ve Hedef Verilerinin DB5 için Gösterimi 96
Şekil B.9 Hisse 2 nin Yeni Verilerde Çıktı ve Hedef Verilerinin DB6 için Gösterimi 96
Şekil B.10 Hisse 3 nin Çıktı ve Hedef Verilerinin Ham Veriler için Gösterimi 97
Şekil B.11 Hisse 3 nin Çıktı ve Hedef Verilerinin DB5 ve için Gösterimi..... 97
Şekil B.12 Hisse 3 nin Çıktı ve Hedef Verilerinin DB6 için Gösterimi 97
Şekil B.13 Hisse 3 ün Çıktı ve Hedef Verilerinin Regresyon Doğrularının Ham veriler için Gösterimi 98
Şekil B.14 Hisse 3 ün Çıktı ve Hedef Verilerinin Regresyon Doğrularının DB5 için Gösterimi 98
Şekil B.15 Hisse 3 ün Çıktı ve Hedef Verilerinin Regresyon Doğrularının DB6 için Gösterimi 99
Şekil B.16 Hisse 3 ün Yeni Verilerde Çıktı ve Hedef Verilerinin Ham veriler için Gösterimi 99
Şekil B.17 Hisse 3 ün Yeni Verilerde Çıktı ve Hedef Verilerinin DB5 için Gösterimi 100
Şekil B.18 Hisse 3 ün Yeni Verilerde Çıktı ve Hedef Verilerinin DB6 için Gösterimi 100
Şekil B.19 Hisse 4 ün Çıktı ve Hedef Verilerinin Ham Veriler için Gösterimi 100
Şekil B.20 Hisse 4 ün Çıktı ve Hedef Verilerinin DB5 için Gösterimi 101
Şekil B.21 Hisse 4 ün Çıktı ve Hedef Verilerinin DB6 için Gösterimi 101
Şekil B.22 Hisse 4 ün Çıktı ve Hedef Verilerinin Regresyon Doğrularının Ham veriler için Gösterimi 102
Şekil B.23 Hisse 4 ün Çıktı ve Hedef Verilerinin Regresyon Doğrularının DB5 için Gösterimi 102
Şekil B.24 Hisse 4 ün Çıktı ve Hedef Verilerinin Regresyon Doğrularının DB6 için Gösterimi 103
Şekil B.25 Hisse 4 ün Yeni Verilerde Çıktı ve Hedef Verilerinin Ham veriler için Gösterimi 103
Şekil B.26 Hisse 4 ün Yeni Verilerde Çıktı ve Hedef Verilerinin DB5 için Gösterimi 104
Şekil B.27 Hisse 4 ün Yeni Verilerde Çıktı ve Hedef Verilerinin DB6 için Gösterimi 104
Şekil B.28 Hisse 5 in Çıktı ve Hedef Verilerinin Ham Veriler için Gösterimi..... 104
Şekil B.29 Hisse 5 in Çıktı ve Hedef Verilerinin DB5 için Gösterimi 105
Şekil B.30 Hisse 5 in Çıktı ve Hedef Verilerinin DB6 için Gösterimi 105
Şekil B.31 Hisse 5 in Çıktı ve Hedef Verilerinin Regresyon Doğrularının Ham veriler için Gösterimi 106
Şekil B.32 Hisse 5 in Çıktı ve Hedef Verilerinin Regresyon Doğrularının DB5 için Gösterimi 106
Şekil B.33 Hisse 5 için Çıktı ve Hedef Verilerinin Regresyon Doğrularının DB6 için Gösterimi 107

Şekil B.34 Hisse 5 in Yeni Verilerde Çıktı ve Hedef Verilerinin Ham veriler için Gösterimi 107
Şekil B.35 Hisse 5 in Yeni Verilerde Çıktı ve Hedef Verilerinin DB5 için Gösterimi..... 108
Şekil B.36 Hisse 5 in Yeni Verilerde Çıktı ve Hedef Verilerinin DB6 için Gösterimi..... 108
Şekil B.37 Hisse 6 nın Çıktı ve Hedef Verilerinin Ham Veriler için Gösterimi 108
Şekil B.38 Hisse 6 nın Çıktı ve Hedef Verilerinin DB5 için Gösterimi 109
Şekil B.39 Hisse 6 nın Çıktı ve Hedef Verilerinin DB6 için Gösterimi 109
Şekil B.40 Hisse 6 nın Çıktı ve Hedef Verilerinin Regresyon Doğrularının Ham veriler için Gösterimi 110
Şekil B.41 Hisse 6 nın Çıktı ve Hedef Verilerinin Regresyon Doğrularının DB5 için Gösterimi 110
Şekil B.41 Hisse 6 nın Çıktı ve Hedef Verilerinin Regresyon Doğrularının DB6 için Gösterimi 111
Şekil B.43 Hisse 6 nın Yeni Verilerde Çıktı ve Hedef Verilerinin Ham veriler için Gösterimi 111
Şekil B.44 Hisse 6 nın Yeni Verilerde Çıktı ve Hedef Verilerinin DB5 için Gösterimi 112
Şekil B.45 Hisse 6 nın Yeni Verilerde Çıktı ve Hedef Verilerinin DB6 için Gösterimi 112

ÇİZELGE LİSTESİ

Sayfa

Çizelge 2. 1 BİST Hisse Senetleri Piyasası'nda İşlem Gören Şirketler……10
Çizelge 3. 1 Biyolojik Sinir Ağını ve Yapay Sinir Ağını Oluşturan Yapılar ……..24
Çizelge 3. 2 Birleştirme (Net) Fonksiyonu Türleri……..32
Çizelge 3. 3 Ağ Performansı Ölçütleri……34
Çizelge 5. 1 Otoregresif YSA Sonuçlar……73
Çizelge 5. 2 Otoregresif YSA 60 Günlük Test Sonuçları……..73

ÖZET

DALGACIK DÖNÜŞÜMÜ KULLANILARAK HİSSE SENEDİ FİYAT TAHMİNİ ÜZERİNE BİR UYGULAMA

Hasan Aykut KARABOĞA

İstatistik Anabilim Dalı

Yüksek Lisans Tezi

Tez Danışmanı: Doç. Dr. İbrahim DEMİR

Dalgacık dönüşümü birçok alanda kullanılan, zaman ve frekans analizine dayanan bir yöntemdir. Gürültü ayıklama, görüntü işleme, frekans analizi, finansal tahmin yöntemlerinde oldukça faydalıdır. Bu özellikleri ile Dalgacık Dönüşümü literatürde oldukça yaygın olarak kullanılmaktadır.

Hisse senetleri finansal piyasalar açısından oldukça önemlidir. Hisse senetleri, risk iştahı yüksek kişiler tarafından tercih edilen bir yatırım aracıdır. Yatırımcılar, riskleri azaltmak için hisse senedinin yönünü doğru tahmin etmek için çeşitli yöntemler kullanmaktadırlar. Bunlardan bir tanesi de yapay sinir ağlarıdır. Ancak yapay sinir ağları tek başına yüksek volatilite değerlerinde öğrenme yerine ezberleme yapabilmektedir. Piyasa koşullarından doğan gürültülü hareketleri temizlemek amacıyla veriler dalgacık dönüşümünden yararlanılarak daha düzgün hale getirilmiştir.

Bu çalışmada dalgacık dönüşümlü yapay sinir ağlarının Borsa İstanbul'da bir uygulaması yapılmıştır. Uygulamada 2000-2012 yılları arasında günlük kapanış verilerine eksiksiz ulaşılabilen, BIST30 hisse senetlerinden 6 tanesi rastgele olarak seçilmiştir. Çalışmamızın amacı, hisse senetlerinin fiyat hareketlerinin dalgacık dönüşümü ve yapay sinir ağları kullanılarak tahmin edilebilir olup olmadığını tespit ederek bu konuyla ilgili literatüre katkı sağlamaktır.

Anahtar Kelimeler: Dalgacık Dönüşümü, Yapay Sinir Ağları, Hisse Senetleri, Tahmin Metotları, Finansal Tahmin, Borsa, BIST

ABSTRACT

AN APPLICATION ON STOCK PRICE PREDICTION WITH NEURAL NETWORK BY USING WAVELET TRANSFORM

Hasan Aykut KARABOGA

Department of Statistics

MSc. Thesis

Adviser: Assoc. Prof. Ibrahim DEMIR

Wavelet transform is a method based on time and frequency analysis used in many areas. It is very useful in noise extraction, image processing, frequency analysis, and financial forecasting methods. Therefore, this method is widely used in literature with its beneficial qualifications.

Stocks are an investment tool generally preferred by risk lovers. Investors use various methods to reduce risk and to predict the direction of the stocks right. Artificial neural networks are one of the widely used methods in stock market predictions. But, high volatile data sets may cause to memorize rather than learning. Therefore, in order to clear daily fluctuating movements wavelet transform is used to smooth the highly volatile data and afterwards neural network analysis is performed.

In this study, an application of wavelet based artificial neural networks on BIST is studied. In the application, 6 of the BIST30 stocks are selected randomly. The primary aim of this study is to determine whether stock price movements are predictable with wavelet transform and artificial neural networks and to contribute to the literature related to this area.

Keywords: Wavelet Transform, ANN, Financial Estimation, Stock Market, BIST

BÖLÜM 1

GİRİŞ

1.1 Literatür Özeti

Yapay Sinir Ağları 1980'li yılların sonlarından itibaren tahmin amaçlı kullanılan tekniklerden biridir. Bu teknik ile herhangi bir ön çalışma yapılmaksızın doğrusal olan ve doğrusal olmayan modeller kurulabilmektedir. Bu nedenle Yapay Sinir Ağları, tahmin aracı olarak esnektir [1]. Hisse senedi fiyatları davranışsal olarak lineer olmadığından borsa tahmin modeli olarak yapay sinir ağları gibi makine öğrenmesi yöntemlerinin kullanılması oldukça popülerdir [2][3][4]. Yapay sinir ağları veriler arasında bulunan gizli ilişkilerin ortaya çıkarılmasında veya bilinmese bile gerçekte mevcut olan fonksiyonel ilişkilerin tespitinde oldukça başarılı bir yöntemdir [36]. Hisse senedi fiyatları davranışsal olarak lineer olmadığından borsa tahmin modeli olarak yapay sinir ağları gibi makine öğrenmesi yöntemlerinin kullanılması oldukça popülerdir [33] [34] [35]. Egeli ve arkadaşları çalışmalarında yapay sinir ağlarının fiyat tahmininde kullanıldığı ilk çalışmalardan birinin Kimoto ve arkadaşlarının Tokyo Borsası endeksini yapay sinir ağları ile tahmin etmeleri olduğunu belirtmiştir. Mizuno ve arkadaşlarının %63 'ün üzerinde bir tahminle Tokyo Borsası'nda al ve sat faaliyetlerini tahmin ettiğini, Sexton ve arkadaşlarının da rasgele noktalarda momentum ve öğrenme oranı kullanarak problemleri çözebildiklerini ifade etmişlerdir. Phua ve arkadaşlarının ise genetik algoritma ile sinir ağlarını uygulayarak %81' lik bir kesinlikle Singapur Borsası'nı ve piyasa yönünü tahmin ettiklerini eklemişlerdir [1]. Ulusal literatürde finansal piyasalarda yapay sinir ağlarının tahmin problemlerinde kullanılması ile ilgili olarak hisse senedi fiyat tahmini ile ilgili çalışmalar [6] [7] [8] [9], hisse senedi getirilerinin tahmini ile ilgili çalışmalar [10], eski adıyla IMKB de yer alan çeşitli indeksler ve indeks

getirilerinin tahmini ile ilgili çalışmalar [11] [12] [15] [14], döviz kurları ile ilgili çeşitli çalışmalar yapılmıştır. Er ve arkadaşları ise yaptıkları yazın taraması ile YSA' nın finans alanındaki kullanım alanlarına örnekler vererek bu konu ile ilgilenen araştırmacılara yol göstermeye çalışmışlardır. Bu çalışmada Türkiye'de YSA' nın özellikle finans alanında yeterince kullanılmadığını belirtmektedirler [17]. Bununla birlikte birçok farklı piyasa için de çalışmalar yapılmıştır. Bu bilgiyi birkaç örnekle pekiştirmek uygun olacaktır.

Enke ve Thawornwong tahmin için model verileri ikiye ayırarak model ve girdi özelliklerini ortaya çıkarmaya çalışmışlardır. Elde ettikleri modelleri lineer regresyon ile karşılaştırmışlardır [18]. Ayodele vd. finansal tahminde YSA modelleri ile teknik analizi karşılaştırarak YSA nın finansal tahminlerdeki başarısını sorgulamıştır [19]. Tarsauliya ve arkadaşları da farklı öğrenme algoritmalarından hangisi ile daha iyi tahmin modeli elde edilebileceğini araştırmak amacıyla S&P 500 indeksini tahmin etmişlerdir [20]. Borsa indeksleri ile ilgili farklı çalışmalar da mevcuttur. Bu çalışmalar genellikle borsanın yönünü ve günlük getirilerini tahmin etmeye yöneliktir [21 - 29]. Çalışmalarda geriye yayılımlı ağların ve ileri beslemeleri ağların kullanıldığı görülmüştür. Yapay Arı Kolonisi veya İyileştirilmiş Bakteriyel Kemotaksi Optimizasyonu optimizasyon yöntemleri gibi yeni optimizasyon yöntemleri geliştirilmektedir [21] [54]. Geliştirilen modellerin başarısının tespiti için geleneksel yöntemlerle karşılaştırmalı olarak sunulmuştur [9 – 13] [18] [19] [27].

Finansal veriler kullanılırken verilerin durağan olması tercih edilir. Doğru tahminlerde bulunabilmek için de durağan veriler gereklidir ancak finansal veriler çoğunlukla gürültülü ve durağan olmayan verilerden oluşmaktadır [31][32]. Tahmin metotlarında kullanılan birçok yöntem vardır. Hareketli ortalamalar, lineer regresyon, Yapay sinir ağları, ARIMA modelleri ve ARMA modelleri bunlardan bazılarıdır. Tüm bu yöntemlerde geçmiş veriler kullanılarak geleceğe dönük tahmin yapılır. Zaman serileri deterministik seriler değildir. Buna mukabil tüm araştırmacılar durağan verilerle çalışmak isterler. Ekonomik seriler deterministik kısım ve beyaz gürültüden oluşur. Gürültü ise Fourier Dönüşümü, Dalgacık dönüşümü gibi kullanımı yeni olan gürültü ayıklama yöntemleri kullanılmaktadır[30].

Aggarwal vd. (2008), karma modellere dayalı dalgacık dönüşümlerini farklı 3 modelle karşılaştırmışlardır. Dalgacık dönüşümünde ikici derece Daubechies dalgacığının en iyi tahmin performansını sağladığını, dalgacık dönüşümüne dayalı modellerin diğer modellere göre daha iyi sonuç verdiğini belirtmişlerdir [37]. Wadia ve arkadaşları (2011), Amman Borsa İndeksini dalgacık dönüşümü ve ARIMA modellemesine dayanan bir model önerisinde bulunmuşlardır. Normalde Daubechies Dalgacıkları tahmin problemlerinde daha iyi sonuç veriyorken yaptıkları bu çalışmada tersi bir sonuç ortaya çıkmıştır. DD kullanılan ARIMA modellemesinde normal ARIMA modellemesine göre daha düşük tahmin hataları meydana gelmiştir [30]. Alrumaih ve Alfawzan (2002), Suudi hisse senedi endeksi verilerinin gürültüleri dalgacık dönüşümü ile ayıklandığında diğer tahmin metotlarından daha iyi sonuç verdiğini ortaya koymuşlardır [38]. Sanjeevkumar ve arkadaşları (2008), tahmin modelleri için tarihsel verileri dalgacık dönüşümü kullanarak dalgacıklara ayırıp bunları zaman düzeyindeki veriler ile bir araya getirerek modellerde kullanmıştır. Modellerde dalgacık dönüşümünün etkisi incelenmiştir[37].

Capobianco (2004), gizli periyodik bileşenleri ortaya çıkarmak için Nikkei Borsa Endeksinde yüksek frekanslı bileşenleri çoklu çözüm analizi ve takip algoritması ile birleştirerek analiz etmiştir [42]. Ravikumar ve Tamilselvan (2014), Bombay Borsa Endeksini kullanarak lineer olmayan zaman serilerinde trend tahmini yapmak amacıyla Dalgacık Paket Dönüşümünü kullanmışlardır [50]. M. Gallegati (2008), Dow Jones Endüstriyel Ortalamaları Indeksi ile ABD üretim endekslerini kullanarak ekonomik faaliyetler ile endeks getirileri arasındaki ilişkiyi incelemiştir. Çalışmasında kesikli dalgacık dönüşümünden faydalanmıştır [45]. Li ve arkadaşları (2006), Genetik Algoritmalar (GA) ve kesikli dalgacık dönüşümünü birlikte kullanarak Dow Jones Endüstriyel Ortalamalar Endeksinin istatistiksel özelliklerini ortaya çıkarmışlardır. Dalgacık dönüşümü ile kullanıldığında GA' ların performansı artmıştır [52]. Rua ve Nunes (2009), ayrık dalgacık dönüşümü ile ABD, Almanya, İngiltere ve Japonya'nın indekslerinin aylık veriler kullanılarak zaman içinde birlikte hareketlerinin incelemişlerdir [48]. Huang ve Wu (2010), NASDAQ, S&P 500, CAC40, FTSE100, DAX30, MIB40, TSX60, Nikkei225, TWSI ve KOSPI Endekslerini incelemek için KDD ile Tekrarlayan Öz-düzenlenme Haritası kullanmışlardır. Tahmin modeli olarak çoklu

Kernel EKK regresyonu modeli kullanılmıştır. Kullanılan model YSA, destekleyici vektör makineleri ve GARCH modellerine göre daha iyi sonuçlar vermiştir [53]. Hsieh vd. (2011), hisse senedi fiyat indekslerini analiz etmek için Dow Jones Endüstriyel Ortalamalar Endeksine (DJIA), FTSE, Nikkei-225 Endeksi, TAIEX verilerine dalgacık dönüşümü uygulamışlardır. Tahmin için tekrarlayan sinir ağı modellerini kullanmışlar ve optimizasyon algoritması olarak da Yapay Arı Kolonisi algoritmasını (Artificial Bee Colony) modele uyarlamışlardır. Çalışma sonucunda önerilen modelin ilerisi için son derece umut verici olduğunu belirtmişlerdir [54]. Lahmiri (2013), dalgacık dönüşümüyle ayrıştırılan verilerin düşük frekansları ile S&P 500 fiyat endeksinin yönünü tahmin etmiştir. Farklı parametre değerleri ile destekli vektör makineleri (DVM) temel tahmin modeli olarak kullanılmıştır. Simülasyon sonuçları dalgacık analizi yaklaşımı ile DVM' nin makroekonomik değişkenler veya teknik göstergeler değişken olarak kullanıldığında elde edilen DVM den daha kötü performansı olduğunu ortaya koymaktadır [57].

Wang ve diğ. (2011) Şangay Menkul Kıymetler Borsası (SCE) verilerini ayrıştırmak için kullanmışlardır. Ayrıca ayrıştırmadan sonra düşük frekanslar kullanılarak her seviyede geri yayılımlı yapay sinir ağları (BPNN) ile tahmin gerçekleştirmiştir. Çalışmada orijinal verileri kullanan BPNN ün dördüncü seviyede ayrıştırılan BPNN den daha iyi sonuç verdiğini belirtmişlerdir [4]. Kravets ve Sytienko (2013), kesikli ve sürekli dalgacık dönüşümünden faydalanarak Avrupa borsa endeksleri yardımıyla kriz tespiti yapılabileceğini önermişlerdir. Çalışmada ayrıca krizin bölgesel olarak yayılımının incelenmek için Ukrayna ve Polonya borsalarını analiz etmişlerdir [40]. Kim (2005), dalgacık varyansı, korelasyon ve çapraz-korelasyon kullanılarak ekonomik ve finansal zaman serilerinin karşılıklı bağımlılığını incelemiştir [46]. Abiyev (2012), dalgacık dönüşümü ile yapay sinir ağlarını zaman serileri tahmininde birlikte kullanmışlardır [41]. Gencay vd. (2001), döviz kurlarını dalgacık dönüşümü ve çoklu ölçeklendirme yaklaşımı ile incelemiştir [43]. Lee (2004), dalgacık dönüşümü kullanılarak ABD, Japonya, Almanya gelişmiş ülkeleri ile Türkiye ve Mısır gibi iki gelişmekte olan piyasaları arasında uluslararası aktarım etkilerini incelemiştir. Gelişmiş piyasaların gelişmekte olan pazarlar üzerinde güçlü etkileri olduğunu ancak gelişmekte olan piyasaların gelişmiş piyasalar üzerinde etkisinin olmadığını belirtmiştir [47]. Hisse senedi fiyatlarının tahmininde dalgacıklardan elde edilen yüksek frekanslı katsayıların

etkinliğini incelemek için, yapay sinir ağları (NN) ile birleştirme fikri Lahmiri (2014) tarafından yeni bir yaklaşımı olarak kullanılmıştır. KDD ile Geriye Yayılımlı YSA birleştirmiştir ancak yalnızca düşük frekansların girdi olarak kullanıldığı modelin ARMA ve Random Walk modellerinden daha iyi sonuç verdiğini tespit etmiştir[51]. Subbotin (2008), portföy analizinde dalgacık teknikleri kullanarak çok ölçekli hisse senedi volatilite katsayılarını incelemiştir [49]. Huang (2011), dalgacık analizi ile Kernel Kısmi En Küçük Kareler (PLS) regresyonunu birleştirerek indeks tahmini için kullanmıştır. KDD zaman serisini karakteristiklerini ortaya çıkarmak ve regresyon yöntemi de girdi ve çıktılar arasında maksimum korelasyonu sağlayan alt örneklemlerin oluşturmak için kullanılmıştır. Elde edilen sonuçlara göre KDD ile birleştirilen Kernel PLS, YSA, destekli vektör makineleri ve GARCH modellerine göre daha iyi sonuçlar verememiştir [55].

1.2 **Tezin Amacı**

Bu tez çalışması, İstanbul Borsası'nda hisse senedi fiyat tahmininde yapay sinir ağlarının dalgacık dönüşümü ile birlikte kullanımının model başarısındaki rolünü tespit etmeyi amaçlamaktadır.

1.3 **Hipotez**

Yapay sinir ağlarının son yıllarda yapılan çalışmalarda zaman serileri tahmininde oldukça başarılı olduğu görülmüştür. Yapay sinir ağlarının sınıflama ve eksik bilgi tamamlama problemlerine göre hisse senetleri gibi yüksek volatilite değerine sahip serilerde tahmin başarısı düşmektedir. Bu nedenle serilerin volatiliteden kaynaklanan hareketlerinin seriden uygun yöntemlerle ayıklanması tahmin başarısını arttıracaktır.

Serilerden gürültü adı verilen bu değerlerin ayıklanması için dalgacık dönüşümünün uygun olacağı öne sürülmüştür. Bu doğrultuda seriler sürekli dalgacıklardan Daubachies 5 ve 6 Dalgacığı kullanılarak gürültüden arındırılmış ve otoregresif yapay sinir ağları yardımıyla hisse senedi fiyat tahmini yapılmıştır. Elde edilen modeller karşılaştırılarak dalgacık dönüşümünün modellerin başarısına etkisi sorgulanmıştır.

BÖLÜM 2

HİSSE SENETLERİ VE BORSALARIN GENEL ÖZELLİKLERİ

Önceki kısımlarda belirtildiği gibi çalışma hisse senetlerinin fiyatlarını tahmin etmeye yöneliktir. Bu nedenle hisse senetlerinin yapısı, hisse senedi piyasalarının yapısı ve işleyişi anlaşılmalıdır. Ek olarak bu kısımda hisse senedi fiyatlarına etki eden unsurlara değinilecektir.

2.1 **Borsanın Özellikleri**

Genel olarak borsaların ekonomik işlevleri şöyle özetlenebilir [58]:

•Ekonomiye kaynak yaratır. Böylece yeni yatırımlar için sermaye birikimi sağlar.

•Sermayeyi tabana yayarak küçük birikimi olan insanların da yatırım yapabilmesine olanak sağlar.

•Likidite (hemen kullanılabilir para) sağlar. Bu birçok ticari girişimin kısa sürede yapılmasını sağlayarak ülkenin rekabet gücünü arttırır.

•Ekonominin göstergesidir. Borsa güven yeridir. Ekonomisi güçlü ülkelerin borsaları da güçlüdür.

•Tasarrufların değerlendirilmesini sağlar. Birçok yatırım aracının alıcılarını ve satıcılarını bir araya getirir.

•Güven sağlar. Çünkü borsada işlem gören şirketler daha iyi denetlenir, daha dikkatli çalışırlar.

•Bilgilere kolay ulaşmayı sağlar. Borsada işlem gören işletmeler bilgilerini, alınan kurul kararlarını ve şirketle ilgili değişiklikleri Kamuyu Aydınlatma Platformunda paylaşmak zorundadırlar. Böylece daha şeffaf bir borsa oluşur.

2.2 **Hisse Senetleri Piyasası**

Tüm şirketler menkul kıymetler borsalarında işlem görmeye başladıklarında çeşitli avantajlara sahip olacaklardır. Bu avantajlar[59]:

•Alternatif finansal kaynağa uzun vadeli ve uygun maliyetlerle ulaşmak,

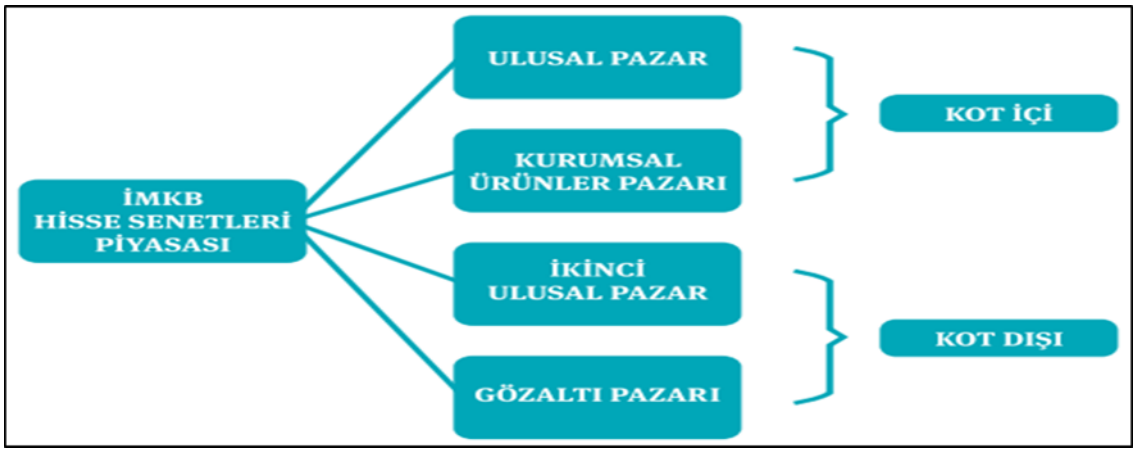
•Kurumsallaşma ilkelerini daha hızlı şekilde gerçekleştirmek,

•Ulusal ve uluslararası firma bilinirliğini sağlamak,

•Likidite imkânı ve güvenilirlik avantajlarını elde etmek

Şeklinde sıralanabilir.

Bunun için şirketlerin kendi şartlarına göre sermaye piyasalarında işlem görmesini sağlayan çeşitli menkul kıymet pazarları oluşturulmuştur. Şirketler kotasyon koşullarını sağlarlarsa kot içi pazarda işlem görürler, ancak kotasyon koşullarını sağlayamayan işletmeler de kot dışı pazarda işlem görebilirler. Kot dışı pazarda küçük ve orta büyüklükte işletmeler dediğimiz KOBİ'ler işlem görmektedir. Şirketlerin işlem görebilecekleri pazarlar aşağıdaki şemada gösterilmiştir [59].



Şekil 2. 1 Borsa İstanbul'da Yer Alan Hisse Senedi Piyasaları[1]

[1] **Kaynak:** BIST 2013 Faaliyet Raporu, 2013

2.2.1 Ulusal Pazar

Ulusal Pazar BİST' in en büyük pazarıdır ve kotasyon şartlarını sağlayan şirketlerin çıkardığı hisse senetleri işlem görmektedir.

BIST Kotasyon Yönetmeliği'nin 13'üncü maddesinde yer alan kotasyon kriterleri şöyledir [59]:

Ortaklık haklarını temsil eden menkul kıymetlerin kotasyon başvurusunun, başvuru tarihine kadar ihraç edilmiş bu tür menkul kıymetlerin tamamını kapsayacak şekilde yapılmış olması ve ortaklığın;

•İzahnamede yer alacak mali tablolar ile bağımsız denetim raporlarının Borsa'ya sunulmuş olması,

•Kuruluşundan itibaren en az 3 yıl geçmiş olması,

•Finansman yapısının sağlıklı olması,

•Ortaklığın aşağıda yer alan koşullardan aynı grup içerisinde yer alan koşulların tamamını sağlaması,

•Esas sözleşmede menkul kıymetlerin devir ve tedavülünü kısıtlayıcı veya senet sahibinin haklarını kullanmasına engel olacak kayıtlar bulunmaması,

•Ortaklığın üretim ve faaliyetlerini etkileyecek önemli hukuki uyuşmazlıkların bulunmaması,

•Son 1 yıl içinde ortaklığın faaliyetlerine 3 aydan fazla ara vermemiş olması, tasfiye veya konkordato istenmemiş olması,

•Menkul kıymetlerin, piyasadaki mevcut ve muhtemel tedavül hacmi bakımından Borsa yönetimince önceden belirlenecek kriterlere uygun olması,

•Kuruluş ve faaliyet bakımından hukuki durumu ile hisse senetlerinin hukuki durumunun tabi oldukları mevzuata uygun olduğunun belgelenmesi gerekmektedir.

İkinci Ulusal Pazar, kotasyon şartlarını sağlayamayan şirketler ve Küçük ve Orta Ölçekli İşletmeler 'e (KOBİ) yönelik faaliyet gösteren yapıdır. İkinci Ulusal Pazar' la ilgili bilgiler aşağıda verilmiştir.

2.2.2 İkinci Ulusal Pazar

Bu pazar, Ulusal Pazarda işlem görebilme şartlarını yerine getiremeyen ancak büyüme isteği olan işletmelerin büyüme ve gelişmesine olanak sağlamak amacıyla oluşturulmuştur. Bu işletmeler için finansal kaynakların oldukça önemli olduğu düşünüldüğünde, şeffaf piyasa koşullarında düzenli şekilde ve rekabetçi koşullarda işlem görmenin potansiyel büyüme imkânı olan işletmeleri yatırımcılarla buluşturmanın önemi anlaşılacaktır. Bu pazarda işlem görebilmek için [59];

•Başvurunun sermayeyi temsil eden menkul kıymetlerin tamamını kapsayacak şekilde yapılmış olması,

•Ortaklığın halka arz edilen hisse senetlerinin piyasa değeri ile bu hisse senetlerinin ödenmiş veya çıkarılmış sermayeye oranının sırasıyla en az, 5.500.000 TL ve %15 olması ya da 11.000.000 TL ve %5 olması,

•Hisse senetlerinin tedavülünü engelleyici bir husus bulunmaması kaydıyla, ortaklığın mali ve hukuki durumu, faaliyetleri, hisse senetlerinin tedavül hacmi göz önüne alınarak yapılan değerlendirme sonucunda ortaklık hisse senetlerinin İkinci Ulusal Pazar'da işlem görebilmesine ilişkin olarak Borsa Yönetim Kurulu'nun olumlu karar vermesi,

•Son 1 yıl içinde ortaklığın faaliyetlerine 3 aydan fazla ara vermemiş olması, tasfiye veya konkordato istenmemiş olması gerekmektedir.

2.2.3 Kurumsal Ürünler Pazarı

Kurumsal Ürünler Pazarı'nın amacı, Hisse Senetleri Piyasası bünyesindeki pazarların etkinliğini arttırmak için düzenli ve şeffaf bir pazarda uygun rekabet koşullarında varantların, menkul kıymet yatırım ortaklıklarının, gayrimenkul yatırım ortaklıklarının, yatırım fonu katılma belgelerinin ve girişim sermayesi hisse senetlerinin oluşturulmasını sağlamaktır.

Kurumsal Ürünler Pazarı'nda işlem gören Aracı Kuruluş Varantları, Borsa Yatırım Fonları ile her 3 ayda bir yapılan değerlendirme sonucunda halka açık piyasa değerinin art arda

iki kez 10 milyon TL'nin altında kaldığı belirlenen Menkul Kıymet Yatırım Ortaklıkları zorunlu olarak "Piyasa Yapıcılı Sürekli Müzayede Yöntemi" ile işlem görür [59].

2.2.4 Gözaltı Pazarı

Gözaltı Pazarı, olağan dışı fiyat ve miktar hareketlerinin, sermaye hareketlerinin ve diğer tüm olağan dışı koşulların meydana gelmesinden ötürü şirketlerin sürekli olarak gözetim ve denetim altında tutularak hisse senedinin işlem görmesinin devam etmesini sağlayacak koşulları oluşturmak ve yatırımcılara zamanında doğru bilgi verilmesi için önlemler alınmasını sağlamak amacıyla kurulmuştur [58] [59].

Gözaltı Pazarı'nda işlem gören menkul kıymetler, SPK'nın 23 Temmuz 2010 tarih ve 21/657 sayılı kararı gereğince C grubunda yer aldığından tek fiyat yöntemiyle işlem görmektedir [59].

Çizelge 2. 1 BİST Hisse Senetleri Piyasası'nda İşlem Gören Şirketler[1]

	2012		2013	
Yatırım Aracı	Şirket Sayısı	Toplam Piyasa Değeri (Milyon TL)	Şirket Sayısı	Toplam Piyasa Değeri (Milyon TL)
Pay	406	552.898	421	505.914
Ulusal Pazar	242	523.333	228	466.582
İkinci Ulusal Pazar	77	9.355	89	17.379
Gözaltı Pazarı	13	216	23	245
Kurumsal Ürünler Pazarı	47	17.148	48	19.462
Serbest İşlem Platformu	16	2.459	13	1.663
Gelişen İşletmeler Piyasası	11	387	20	583

2.3 Hisse Senedi Piyasasının İşleyişi

Çeşitli kuruluşlar Sermaye Piyasası Kurulundan üye ya da üye temsilcisi olarak yetki belgesi alırlar. Bu kuruluşlar bankalar, aracılık faaliyeti yapan kurumlardır. Hisse senetleri piyasalarında yapılan işlemler sırasıyla şöyledir [58]:

•Aracı kuruluşa alım satım emrinin verilmesi.

[1]**Kaynak:** BIST 2013 Faaliyet Raporu, 2013

•Verilen emrin temsilci tarafından borsaya iletmesi.

•Borsada alım veya satım emirlerinin seans saatleri içinde alıcı ve satıcıların karşılaştırılarak gerçekleştirilmesi.

•Alım emrinde alım fiyatı için verilen limit fiyat artırılıp azaltılabilir, iyileştirilip kötüleştirilebilir veya iptal edilebilir.

•Borsa ile ilgili sorgu ekranları kullanılarak bilgi toplanabilir.

•Eğer satılmak istenen menkul kıymet için belirli bir limit fiyatı belirlenmezse piyasada o andaki fiyatlardan işlem gerçekleştirilir. Elde hisse senedi bulunmuyorsa aracı kuruluştan ödünç alınan hisseler satılmış olacaktır. Bu işleme "açığa satış" işlemi denir. Bu işlemi yapan kişi senedin fiyatının düşeceğini düşünmektedir. Hisse fiyatı düşünce gün sonuna kadar düşük fiyattan aldığı hisseleri yerine koyar ve aradaki fark kar olarak kalır.

•Borsa verilerinin takip edilmesinde endeksler kullanılır.

•Hisse senedi piyasasında takas ve saklama hizmetleri de verilmektedir.

Verilen bilgiler şimdiye kadar hisse senedi piyasaları ile ilgiliydi. Ancak hisse senetleri ile ilgili temel önemli tanımlar aşağıda verilmiştir.

Tanım 2.1 Hisse senetleri; anonim şirketler, sermayesi paylara bölünmüş komandit şirketler, özel kanunla kurulmuş kamu kuruluşları tarafından çıkarılan, sermayenin belirli bir bölümünü temsil eden, sahibine ortaklık haklarından yararlanma imkânı veren menkul kıymetlerdir.

Tanım 2.2 Borsada işlemlerin gün içinde başlaması ve bitmesi arasında geçen süreye "seans" denir.

Tanım 2.3 Hisse senedi piyasasında işlem birimi "lot" tur. Bir lot bin adet hisse senedini ifade eder.

Tanım 2.4 Hisse senetlerinin fiyat ve getirilerini, oransal değişimleri yansıtan göstergeye "endeks" denir.

2.4 Hisse Senetlerinin Ekonomik İşlevleri

Hisse senetlerinin ekonomik işlevlerini şu şekilde özetleyebiliriz [60]:

•Hisse senetleri, küçük tasarrufların büyük işletmelerde değerlendirilmesine olanak sağlar.

•Hisse senetleri, iktisadi şirketlere küçük birikimlerle de ortak olunabilmesini sağlayarak toplumun refah seviyesinin arttırılması işlevini yerine getirir.

•Hisse senetleri, halkın ekonomide de söz sahibi olmasının önünü açar. Böylece ekonomi dünyasında da demokrasinin işlemesini sağlar.

•Hisse senetleri, halkın yatırımlarını enflasyona karşı korur. Bunu üretimden uzak olan faiz geliri ile değil tasarrufların ekonomiye üretim kaynağı olarak girmesini sağlayarak yapar. Böylece tasarrufların enflasyon karşısında değeri düşmez ve ek bir gelir elde edilmiş olur.

•Hisse senedi, aracı kuruluşların aracılık maliyetlerini ortadan kaldırmış olur. Yüksek miktarda fona ihtiyaç duyulduğunda sermaye artırımı gibi yollarla düşük maliyetlerle hissedarlardan yeni yatırımlar için fon sağlanmış olur. Böylece yüksek aracılık maliyetlerinden işletme kurtulmuş olur.

2.5 Hisse Senetlerinde Fiyatlar ve Değerler

Hisse senedi yatırımcılarının daha bilinçli yatırım yapmalarını sağlamak için hisse senetlerinde fiyatları ve değeri bilmelidir. Bu tanımlar kısaca şöyledir [58]:

2.5.1 Nominal (İtibari) Fiyat

Hisse senedinin çıkarılması sırasında belirlenen ve senedin üzerinde yazılı olan değere nominal değer denir. Bu değer genellikle 1 TL olarak belirlenmektedir.

2.5.2 İhraç Fiyatı

Hisse senedinin ilk ihraç edildiği fiyattır. Hisse senedi ihraççı kuruluşa bağlı olarak hissenin nominal fiyatı üzerinden çıkarılabileceği gibi farklı bir fiyat ile de çıkarılabilir.

2.5.3 Piyasa Fiyatı

Hisse senedinin arz - talep piyasasında işlem gördüğü fiyattır. Piyasa fiyatı işletmenin içinde bulunduğu duruma göre yüksek ya da düşük olabilir, artabilir veya azalabilir.

2.5.4 Borsa Fiyatı

Hisse senetlerinin borsada işlem gördüğü piyasada oluşan arz ve talebe göre ortaya çıkan fiyatıdır. Şirketin yeni yatırımları, kredi sözleşmeleri, varlık satışı, yeni anlaşmaları, ortaklıklar gibi durumlarda hisse senedine talep artar ve hissenin değeri de talebe göre artış gösterir. İflas durumu, piyasadaki oynaklıklar, belirsizlikler, şirkete açılan davalar gibi olumsuz haberler ile de talep azalacağından hissenin değeri düşer. Bu durum her şartta belirtildiği gibi gerçekleşmeyebilir. Bunu etkileyen yatırımcı davranışları ve manipülatif hareketler olabilir.

2.5.5 Defter Değeri

Şirketin öz sermaye değerinin toplam hisse sayısına bölünmesi sonucu elde edilen değerdir.

2.5.6 Tasfiye Değeri

Şirketin dağılması yani tasfiyesi halinde şirketin tüm varlıklarından borçlar düşüldükten sonra kalan tutarın toplam hisse senedi sayısına bölünmesi ile elde edilen tutardır.

2.5.7 İşleyen Teşebbüs Değeri

İşletmenin çalışır halde devri durumunda sağlayacağı gelir hesaplanarak bulunan değerdir.

2.5.8 Gerçek Değer

Yatırımcıların tüm koşulları dikkate alarak hisse senedi için belirlediği değere denir.

2.6 **Hisse Senedi Sahibinin Başlıca Ortaklık Hakları**

Hisse senetleri sahibi olan kişiyeler çeşitli haklara sahip olmaktadır. Hisse senedi sahibinin hakları aşağıdaki gibi özetlenebilir:

•Rüçhan hakkı (bedelli sermaye artırımına katılım hakkı),

•Kârdan pay alma hakkı (temettü),

•Oy kullanma hakkı,

•Yönetime katılma hakkı,

•Tasfiyeden hissesi oranında pay alma hakkı,

•Bilgi edinme hakkı.

2.7 **Hisse Senetlerinin Üzerinde Bulunan Haklar ile İlgili Yapılan İşlemler**

2.7.1 Yönetime Katılma Hakkı

Hisse senetlerini ihraç eden kuruluşlar, genel kurul toplantısının tarihini ve yerini toplantı tarihinden 15 gün önce Merkezi Kayıt Kuruluşu (MKK)' na bildirir. Eğer hak sahibi yatırımcı genel kurula katılmak isterse, sahip olduğu paylara blokaj konur. Blokaj konulan hisse senetleri ihraççıya bildirilir. Toplantı tarihinde Blokajlı hisseler üzerinde BIST' te yapılan işlemlerin ardından blokaj MKK tarafından re'sen kaldırılacaktır. İhraççının talep etmesi halinde blokaj koyma ve kaldırma süresi MKK tarafından kısaltılabilmektedir[61].

Hisse senedi sahibi şirketin yönetim kuruluna katılmakla kalmayıp şirkette yönetim kurulu üyesi olabilir, şirkette yönetim kurulu kademelerinde de çalışabilir [61].

2.7.2 Kardan Pay Alma Hakkı

Kar payı, yönetim kurulu kararına bağlı olarak yılda bir veya birkaç defa dağıtılan ödemelere denir. Genel kurul veya yönetim kurulu kar payı dağıtımına karar verirse, hisse senedi sahipleri, sahip oldukları hisse senedi sayısı ile pay başına dağıtılan kar payı miktarının çarpımı şeklinde hesaplanan miktarda kar payı alma hakkı elde ederler[61] [62].

2.7.3 Oy Kullanma Hakkı

Hisse senedi sahibinin bir başka hakkı da şirket genel kurulunda oy kullanma hakkıdır. Hisse sahibi elinde bulunan lot miktarı kadar oy hakkına sahip olmaktadır. Mesela elinde 1000 lot hissesi bulunan bir hissedarın genel kurulda 1000 oy hakkı bulunmaktadır [62].

2.7.4 Rüçhan Hakkı

Rüçhan hakkı, yeni ihraç edilen hisse senetlerinden mevcut ortaklara ellerinde bulunan pay miktarınca öncelikli satın alma hakkının verilmesidir. Ancak bu hak kullanılmak zorunda değildir, isteyen ortaklar bu hakkı satabilirler. Rüçhan hakkının kurul kararıyla kullanımı kaldırılabileceğinden veya kısıtlanabileceğinden bu hak kazanılmış bir hak değildir [62].

2.7.5 Tasfiyeden Pay Alma Hakkı

Tasfiyeden pay alma hakkı, iflas eden şirketin tasfiye edilmesi durumunda, imtiyazlı hisse senedi sahiplerinin ve alacaklıların alacakları ödendikten sonra geriye kalan tutar, hisse senedi sahiplerine payları miktarınca paylaştırılmasıdır [62].

2.7.6 Şirket Faaliyetleri Hakkında Bilgi Edinme Hakkı

Hissedarlar, hisse senetlerini elinde bulundurdukları firmanın faaliyetleri hakkında bilgi edinme hakkına sahiptirler. Eğer bir konuda şüphelenirlerse şüphe ettikleri konularda inceleme yapmasını talep edebilirler. Ancak bu talepleri karşılanırken belgeler haricinde şirketin işle ilgili başka sırlarını öğrenemezler. Bilgi alma hakkı, engellenemez veya sınırlandırılamaz. Bunun yanında hisse sahipleri öğrendikleri şirket sırlarını saklamakla yükümlüdürler [61] [62].

2.8 Hisse Senedi Piyasalarını Etkileyen Faktörler

Hisse senetleri birçok yatırım aracıyla yakın ilişki içerisindedir. Bu gerek hisselerin kendi özelliklerinden gerekse de finans piyasalarının yapısından kaynaklanmaktadır. Uzun yıllardır birçok araştırmacı hisse senetlerinin ilişkili olduğu menkul kıymetleri ortaya

çıkarmak amacıyla çalışmalar yapmaktadırlar. İstanbul Menkul Kıymetler Borsası, yeni adıyla Borsa İstanbul, gelişen bir borsa olması nedeniyle araştırmalara konu olmuştur.

Bu bölümde BIST' te işlem gören hisse senetleri ile ilgili yapılmış, çalışmalardan bazıları incelenecek ve hisse senedi yatırımlarına etki eden faktörler incelenecektir.

Usul ve arkadaşları hisse senetleri yatırımına etki eden sosyo-ekonomik faktörleri şu şekilde sıralamışlardır:

- **Kişisel Etkenler**
  - Tasarruf Sahibinin Bilgisi ve Zamanı
  - Tasarruf Sahibinin Yaşı ve Sağlık Durumu
  - Tasarruf Sahibinin Beklentisi
  - Tasarruf Sahibinin Geliri ve Yaşam Biçimi
  - Tasarruf Sahibinin Psikolojik Yapısı
- **Finansal Etkenler**
  - Sermayeyi Koruma İsteği
  - Değer Artışı Sağlama İsteği
  - Devamlı Gelir İsteği
- **Çevresel Etkenler**
  - Sosyal ve Kültürel Durum
  - Referans Grup

Bu etkenlerin çeşitli birleşimleri farklı yatırımcı profillerinin ortaya çıkmasına neden olmaktadır. Buna göre yatırımlarının hisse senetlerinde değerlendirme isteğini, yatırımın süresini, risk iştahlarını etkilemektedir. Hisse senetlerine genç yatırımcılar daha fazla ilgi göstermektedir. Yaşlı yatırımcıların yaşam süresi beklentisinin az olması daha kısa süreli elde tutma eğilimine neden olmaktadır. Ayrıca daha az spekülatif ve sabit getirili yatırım araçlarını tercih ettikleri ortaya çıkarılmıştır. Bununla birlikte erkek yatırımcıların risk düzeyi yüksek hisseleri daha fazla tercih ettikleri tespit edilmiştir. Gelir düzeyi arttıkça elde tutma süresi, risk alma isteği artmaktadır [63]. Döviz

kurundaki değişimler, dünya ekonomilerindeki gelişmeler, diğer yatırım araçlarının getirilerindeki değişimler, şirketlere ilişkin piyasa defter değeri, fiyat kazanç oranı gibi bilgiler, manipülasyon gibi değişkenlerin ve değişikliklerin İMKB 100 indeksini etkilediğini ortaya koyulmuştur. Yabancı yatırımcılar tarafından yapılan yatırım artışının, faiz oranlarındaki değişimin hisse senedi fiyatını etkilediğini belirtilmiştir [64].

Demir (2001), mali sektör hisse senedi fiyatını etkileyen en önemli faktörün piyasa değeri / defter değeri oranı olduğunu, etkileyen ikinci önemli faktörün ise hisse başına kar olduğunu belirtmiştir. Ayrıca yatırımcıların işletmelerin öz sermaye karlılığına da aynı önemi verdiklerini eklemiştir. Hisse senetlerinin yüksek kaldıraç oranına sahip olmalarının risk unsuru olarak değerlendirildiğini, net kar büyüme hızı, işlem görme oranının ve temettü ödeme oranının çalışmada belirtilen diğer oranlara göre mali sektör hisse senedi fiyatlarını daha az etkilediğini vurgulamıştır [65]. Albeni Ve Demir (2005), mali sektörde yer alan işletmelerin fiyatlarını etkileyen faktörlerin mevduat faiz oranları, Cumhuriyet altını, uluslararası portföy yatırımları ve Alman Markı olduğunu bulmuşlardır. Döviz fiyatlarında yaşanan hareketliliğin mali endekste yer alan hisse senetlerini negatif yönde etkilediğini, bunun siyasi ve ekonomik istikrar, psikolojik etkenler gibi genel ekonomiyi ilgilendiren nedenlerden ötürü olduğu öngörmüşlerdir [66]. Gaygusuz (2008), İMKB' de hisse senedi getirilerinden işlem hacmine doğru nedensellik olduğunu tespit etmiştir. Buna göre işlem hacmindeki bir hareket getirilerde de bir harekete neden olmaktadır. Çalışmanın sonunda İMKB' de yer alan yatırımcıların büyük bir kısmının bilgiye dayalı yatırım yapmadıklarını, bu nedenle de noise yatırımcı olduklarını savunmuştur [67].

Aklan Ve Nargeleçekenler (2012), U100, Mali ve Sınai endeksleri ile para politikaları arasındaki ilişkileri birlikte ele alarak incelemişlerdir. Söz konusu çalışmada Türkiye'de 1996M06-2012M05 döneminde hisse senedi piyasası para politikası şoklarına tepki gösterdiği vurgulanmıştır. İlgili dönemde politika faiz değişikliklerinden en çok etkilenen sektörün mali sektör olduğu belirlenmiştir. Tepkilerin 2002 yılından sonraki dönemde daha düşük olduğu görülmüştür. Çalışmanın bulgularına göre, Merkez Bankasının 2002 yılı sonrasında fiyat istikrarının sağlanması için para politikalarını kullandığı, bu politikalardan da en fazla mali endeksinin etkilendiği görülmüştür [68].

Aydemir vd. (2012), İMKB'de işlem gören 73 imalat sanayi işletmesi ile ilgili yaptıkları çalışmada kârlılık oranlarının hisse senedi getirisi üzerinde pozitif bir etkiye sahip olduğu ortaya konmuştur. Likidite oranlarının hisse senedi getirisi üzerinde pozitif bir etkiye sahip olduğunu, kaldıraç oranının da hisse senedi getirisini belirlemede pozitif bir etkiye sahip olduğunu fakat bu etkinin kârlılık ve likidite oranlarına göre daha düşük olduğunu belirtmişlerdir. Ancak modele dâhil edilen değişkenlerin modeli açıklama gücünün yeterli olmadığını, başka faktörlerin de incelenmesi gerektiğini vurgulamaktadırlar [69]. Akkum ve Vuran (2005), çalışmalarında İMKB 30 endeksi, mali endeks, sinai endeks, hizmet endeksi, büyüme, sanayi üretim endeksi, para arzı, reel bütçe dengesi, ihracat ve ithalat, cari işlemler dengesi, hisse senedi getirileri pozitif etkili değişkenler olurken; döviz kuru, vade riski, ihracat/ithalat oranları, faiz oranları, altın fiyatları, enflasyon negatif etkili değişkenler çıkmıştır [70]. Demir Ve Yağcılar (2009), 2000-2006 dönemine İMKB'de işlem gören bankaların hisse senetlerine etki eden faktörleri incelemişlerdir. Çalışmaya göre hisse senetlerinin getirileri üzerinde ağırlıklı olarak İMKB- 100 endeksinin etkili olduğu, Hazine Bonosu Faiz Oranları, Sanayi Üretim Endeksi ve Cari İşlemler Dengesi değişkenlerinin getirileri etkileyen diğer faktörler olarak yer aldıkları belirlenmiştir. Kapasite Kullanım Oranı, Sanayi Üretim Endeksi, Gayri Safı Yurtiçi Hâsıla ve Cari İşlemler Dengesi değişkenlerinin beklenen yönde hisse senedi getirileri ile ilişkili olmadığı sonucuna ulaşılmıştır. Banka hisse senetlerinin getirileri ile altın fiyatlarının ters yönlü hareket ettiği çalışmada görülmüştür. Bu sonuca bakarak altının hala geleneksel yatırım aracı olma özelliğini koruduğunu söylemişlerdir [71]. Çalışmalardan da anlaşılacağı gibi hisse senetlerinin, hisse senedi indekslerinin birçok faktör ile ilişkili olduğu anlaşılmaktadır. Literatürde genel olarak indeksler, döviz kuru, altın ve faiz oranlarının hisse senetleri ile yakın ilişkili olduğu anlaşılmaktadır.

BÖLÜM 3

YAPAY SİNİR AĞLARI

Son zamanlarda Neuro – Computing (sinirsel bilgi işleme) terimi yoğun olarak kullanılmaktadır. Bu terim, insan beynini örnek alarak işlem yapan, daha gelişmiş hesaplamalar ve çıkarımlar yapabilen bilgisayarları ve bilgisayar programlarını ifade etmektedir. Tüm bunların temelinde ise şüphesiz yapay sinir ağları vardır.

İnsan sinir sistemini örnek alan Yapay Sinir Ağları (YSA), eş zamanlı olarak çalışan birçok sinir hücresinden meydana gelen bir bilgi işleme sistemi olarak tanımlanabilir. Sistemi oluşturan hücreler, beyin hücrelerini örnek alan, onun işleyişini matematiksel olarak modellemeyi amaçlayan birimlerdir. Bu özelliği sayesinde son yıllarda işletme, ekonomi, inşaat mühendisliği, bilgisayar mühendisliği, harita mühendisliği, veri madenciliği gibi alanlarda yapay sinir ağları yoğun olarak kullanılmaktadır.

Yapay sinir ağlarını bu kadar popüler kılan şey insan beynini taklit edebilen bilgisayar programları olmalarıdır. Yapılarında kendiliğinden öğrenebilen, ezberleyebilen, örüntüleri keşfedebilen ve ilişki kurabilen, verilen bilgileri kullanılarak çıkarımda bulunabilen, tahmin yapabilen veya yorum yapabilen işlem birimleri vardır. Belirsiz, gürültülü ve eksik verileri YSA ile işlemek oldukça kolaydır. Bu verilerle YSA tahminde bulunabilir ve model oluşturabilir.

YSA' nın farklı birçok ağ modelleri mevcuttur. Ancak Geriye Yayılımlı Ağlar (GYA) en çok kullanılan YSA modeli olarak bilinmektedir. Bu tip modeller özellikle tahmin ve sınıflama problemlerinde oldukça iyi sonuçlar vermektedirler.

3.1 **Tarihçe**

İnsan beynine benzer olarak çalışan sistem fikri çok eskilere dayanmasına rağmen bu alandaki en geçerli çalışmalar Walter Pitts ve Warren MacCulloch tarafından 1943 yılında yapılan elektrik devreleriyle basit hesap makinesine dayanır. 1948 yılında Wiener, 1949' da ise Hebb çalışmalarıyla bu alana katkı sağlamışlardır. Hebb kitabında "Hebb Kuralı" adı verilen kuralı ortaya atmıştır. Bu kurala göre eğer sinirlerin sahip olduğu bağlantı sayılarında değişiklik yapılabilirse sinirlerin öğrenmesi mümkün olabilecektir.

Hebb Kuralı ortaya atıldıktan sonra bilim insanları bunun nasıl yapılabileceği üzerine çalışmışlardır. Bu çalışmalar devam ederken 1957 yılında Frank Rosentblatt "Perceptron" adı verilen tek katmanlı, eğitilebilen ve tek çıktı değerine sahip olan bir yapay sinir ağı modelini geliştirmiştir. Bu çalışmadan iki yıl sonra Bernard Widrow ve Marcian Hoff ADELINE ve MADELINE adını verdikleri yapay sinir ağı modellerini geliştirerek gerçek yaşam problemlerine uygulamışlardır. Ayrıca Hu 1964 yılında hazırlanmış olan doktora tezinde ADELINE' i hava durumu tahmininde kullanmıştır. Bu çalışma YSA' nın tahmin amaçlı kullanıldığı ilk uygulamalardan biri olarak görülmektedir.

Bunula birlikte 1969 yılında Misky ve Papert XOR problemleri gibi iki aşamalı problemlerin Perceptron gibi tek katmanlı yapay sinir ağları tarafından çözülemeyeceğini ortaya çıkarmışlardır. Bu problem bir hayal kırıklığına neden olmuş ve bu alandaki gelişmeleri durma noktasına getirmiştir. Ancak Rumelhart ekibiyle 1986 yılında geriye yayılımlı ağlar yardımıyla problemi çözmeyi başarmıştır. YSA' nın yeniden popüler hale gelmesiyle birçok çalışma yapılmıştır.

Ardından Kohonen, Hopfield gibi araştırmacılar buluşlarıyla YSA' nın daha da popüler hale gelmesini ve birçok alanda YSA kullanılmasını sağlamışlardır.

Kullanımı arttıkça YSA yeni ihtiyaçlara cevap verebilen, dinamik ve değişen problemlere çözüm getirmek amacıyla kendini güncelleyebilen daha verimli yapılar haline getirmek amacıyla çalışmalar yapılmaktadır. Kısaca daha akıllı, daha zeki sistemler oluşturabilen bir ağ yapısı kurmak istenmektedir ve bu alanda çalışmalar oldukça hızlı şekilde devam etmektedir.

3.2 Yapay Sinir Ağlarının Temel Özellikleri

YSA' nın birçok özelliği bulunmaktadır. Bu özelliklerinden en temel olanları şöyledir:

3.2.1 Öğrenme

YSA' ların en önemli özelliği öğrenebilmesidir. Ağın girdi ve çıktı değişkenleri arasındaki ilişkileri ortaya çıkarmak amacıyla bağlantı ağırlıklarının belirlenmesi işlemine öğrenme denilmektedir.

3.2.2 Genelleme

YSA ağın öğrenmesi sağlandıktan sonra ağa daha önce görmediği veriler gösterildiğinde ürettiği çıktı değerlerinin bu değerlere yakın olması ağın genelleme yeteneği olarak bilinmektedir. Başarılı bir ağın genelleme yeteneği yüksek olmaktadır.

3.2.3 Hata toleransı

Yapay sinir ağlarının diğer istatistiksel yöntemlere göre daha başarılı olmasını sağlayan en önemli özelliği hata toleransıdır. Yapay sinir ağları, paralel dağıtılmış bir yapıya sahip olduğundan diğer modellerden farklı olarak toplam hata tüm ağa yayılacaktır. Böylece hatanın sonuç üzerindeki etkisi en aza indirilmiş olacaktır.

3.2.4 Doğrusal Olmama

Yapay sinir ağlarının diğer bir özelliği doğrusal olmayan problemler karşısında çözüm üretebilmesidir. Günlük yaşamda problemlerinin büyük bir yüzdesi doğrusal değildir. Ancak bu tip problemlere YSA aktivasyon fonksiyonları ile önemli ölçüde çözüm getirmiştir.

3.2.5 Uyarlanabilir Ağ Yapısı

Uyarlanabilir ağ yapısı, belirlenen bir probleme çözüm olarak oluşturulan bir yapay sinir ağının yeni bir veriye veya yeni bir probleme göre uyarlanabilir olmasını ifade etmektedir.

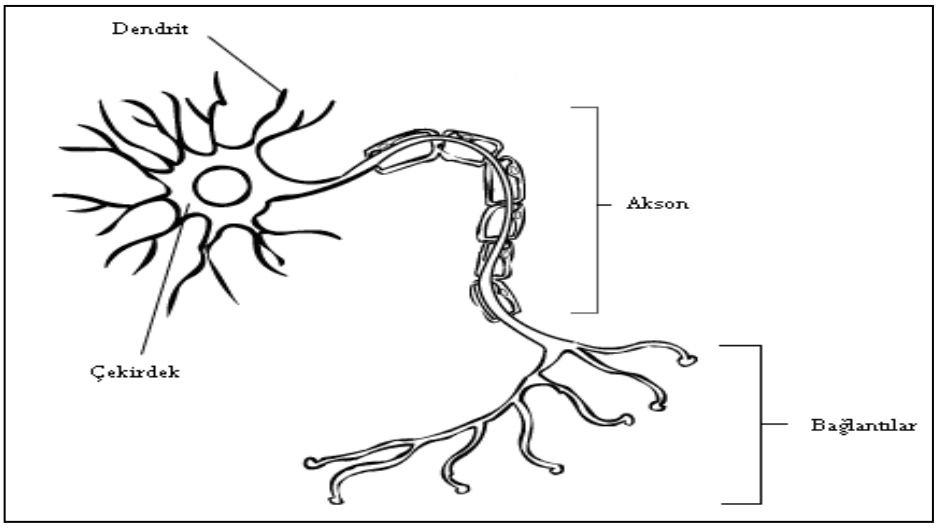
Özet olarak verilen özelliklerden en önemlisi YSA' nın öğrenebilmesidir. Girdilerin değiştirilmesi yoluyla sistemin öğrenmesi sağlanabilmektedir. Ancak sistem doğru şekilde eğitilemezse, elde edilecek çıktılar da başarılı olmayacaktır.

Tüm bunlara ek olarak YSA, matematiksel modele ihtiyaç duymaz. Çok farklı öğrenme algoritmalarını öğrenme uyum sağlama yeteneği vardır. Bunula birlikte sistem tam bir kara kutudur. Ağın içerisinde ne olduğu bilinemez. Her sisteme uyarlamak da mümkün olmamaktadır. Uyarlaması oldukça zor ve maliyetli sistemler mevcuttur. Ağın eğitimi sonucunda elde edilen ağırlıkları yorumlamak mümkün değildir. Elde edilen değerler regresyon analizindeki β katsayıları gibi yorumlanabilir değerler değildir. Ayrıca bazı ağlar haricinde ağlara kararlılık analizi yapılamaz [72] [73].

3.3 **Sinir Hücresinin Yapısı**

3.3.1 Biyolojik Sinir Hücresinin Yapısı

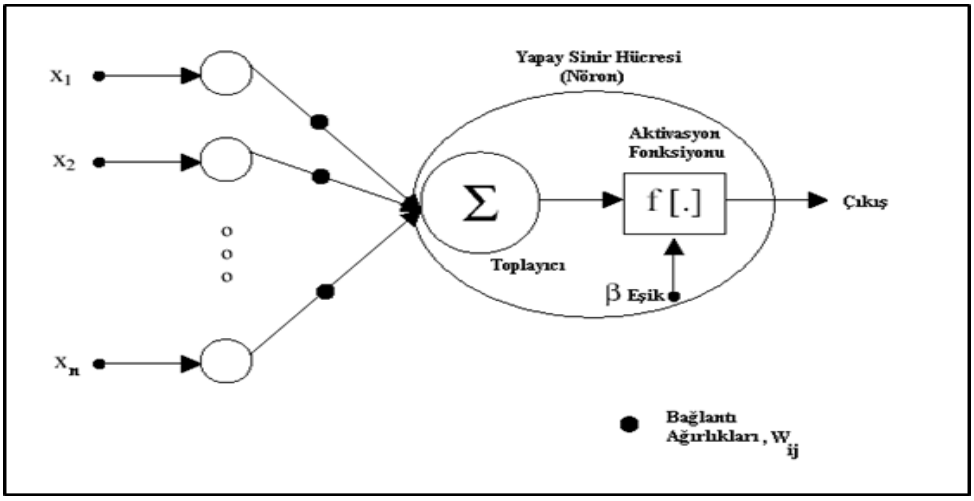
Sinir hücreleri nöron olarak da ifade edilen ve insan sinir sisteminin temelini oluşturan yapılardır. Temel olarak bir sinir hücresi 3 bölümden oluşur. Bu bölümler Şekil 3.1' de de görüldüğü gibi dendrit, akson ve hücrenin ana yapılarını barındıran hücre gövdesidir. Dendritler ve aksonlar hücrenin elektriksel sinyallerinin giriş ve çıkışını sağlarlar. Dendritler aksonlara göre daha kısadır. Bilginin hücre gövdesine iletilmesini sağlamaktır. Hücreye gelen uyarılar dendritlerle hücre gövdesine iletilir. Burada işlenen uyarılar aksonlar vasıtasıyla diğer hücrelere taşınır.



Şekil 3. 1 Biyolojik Sinir Hücresi

3.3.2 Yapay Sinir Hücresinin Yapısı

YSA, düğümlerden meydana gelen, çoğunlukla paralel işleyen elemanlardan oluşan ve biyolojik sinir hücresinde olduğu gibi öğrenme, genelleme, hatırlama gibi yeteneklere sahip olan yapılardır. Ancak yapay sinir hücreleri gerçek sinir hücreleri kadar karmaşık değildirler. Biyolojik sinir hücrelerinin ancak 4 temel işlevini taklit edebilmektedirler[73].



Şekil 3. 2 Yapay sinir hücresi

Şekilde bir yapay sinir hücresi görülmektedir. Burada ham halde alınan bilgiler (x değerleri) modele alınır. Her biri ağırlık (w değerleri) değerleriyle çarpılarak bir kurala göre bir araya getirilir(toplama işlevi gibi). Toplam değeri aktivasyon fonksiyonu ile etkinlik işlevinden geçirilerek çıktı üretilir.

YSA paralel bilgisayar ağlarına benzeyen, eğitilebilen, ilişkileri öğrenebilen özel yapılardır. Yapılarında bulunan düğüm denilen işlem elemanlarından meydana gelmektedirler. Şekil 3.2' deki yapay sinir hücresinde görüldüğü gibi $x = (x_1, x_2, ..., x_n)$ değerleri girdi değerleridir. $w_i = (w_1, w_2, ..., w_n) \in R^n$ değerleri ağırlıklar vektörüdür. $f\left[w^T x\right]$ ise etkinlik işlevidir. Etkinlik değeri eşitlik 3.1 ile tanımlanabilir.

$$\upsilon_i = \sum_{i=1}^{n} w_{ij} * x_i + \beta_j \tag{3.1}$$

$$A\breve{g} = w^T x = w_1 x_1 + w_2 x_2 + ... + w_n x_n \tag{3.2}$$

Ağın değerleri eşitlik 3.2 ile hesaplanır. Burada ilk durumdaki ağın çıktı değerleri ise eşitlik 3.3 te verilen fonksiyon ile hesaplanacaktır.

$$y_i = f(A\breve{g}) = \begin{cases} 1 & \text{eğer, } \mathrm{w}^T x \\ 0 & \text{eğer,} farklı \end{cases} \quad (3.3)$$

β eşik düzeyi olarak düğümün 0 veya 1 değerini üretmesini sağlar. Burada üretilen değer 0 olursa hücre aktif olmayacak, 1 olursa hücre aktif olacaktır[73].

Çizelge 3. 1 Biyolojik Sinir Ağını ve Yapay Sinir Ağını Oluşturan Yapılar [73]

Biyolojik Sinir Ağı	**Yapay Sinir Ağı**
• Sinir sistemi	• Sinirsel hesaplama sistemi
• Sinir	• Düğüm (sinir, işlem elemanı)
• Sinaps	• Sinirler arası bağlantı ağırlıkları
• Dentrit	• Toplama işlevi
• Hücre gövdesi	• Etkinlik işlevi
• Akson	• Sinir çıkışı

3.4 **Öğrenme Yöntemlerine Göre Ağ Yapıları**

YSA da öğrenme olarak bildiğimiz durum esasen girdi olarak verilen değerlere göre ağırlıkların doğru olarak ayarlanmasıdır. Öğrenme, sistemde tanımlanan algoritmaya göre ağa tanıtılan değerlerden yararlanılarak ağırlıkların değiştirilmesi ile uygun ağırlıkların belirlenmesi olarak tanımlanabilir. Öğrenme gerçekleştirildiğinde ağ problemlerimize istenen çözümü sunacaktır.

Yıllarca tartışılan bir konu olan YSA da öğrenmenin nasıl gerçekleşeceğidir. Hebb bu probleme 1949 yılında kendi adıyla anılan Hebb Kuralı ile çözüm getirmiştir. Çözümün geliştirilmesinden sonra çalışmalar devam etmiş ve öğrenme yöntemleri temel olarak danışmanlı ve danışmansız olmak üzere iki şekilde gruplanmışlardır[73].

Öğrenme konusunda birçok yöntem geliştirilmiştir. Hebb Kuralı, Hopfield Kuralı, Delta Öğrenme Kuralı, Konohen Öğrenme Kuralı bunlara örnek olarak verilebilir. Ağ mimarileri, yapılarına göre bunlardan herhangi birini kullanabilirler.

Ağ mimarileri olarak da iki temel yapı vardır. Bu yapılar ileri beslemeli ve geri beslemeli ağ yapılarıdır. Katmanlar arasında bağlantı varsa, yani ağ bir önceki katmana hataları

yayıyorsa bu tip ağlar geri beslemeli ağlardır. Eğer oluşturulan katmanlarda her bir katmandaki düğümler yalnızca bir önceki katmandaki düğümlerden veri alıyorsa ve veriler yalnızca girdilerden çıktılara doğru ilerliyorsa bu tip ağlar da ileri beslemeli ağlardır. Düğümler kendi katmanındaki diğer düğümlerle ve kendisiyle bağlantı yapamaz.

Eğitim yöntemlerine göre ağlar danışmanlı (supervised), danışmansız (unsupervised) ve destekleyici öğrenme (reinforcement learning) olmak üzere üçe ayrılmaktadır.

3.4.1 Danışmanlı Öğrenme

Gerçek değer ile çıktı değeri arasında meydana gelen toplam hataların kabul edilebilir düzeye indirilene kadar ağırlıkların değiştirilmesi yöntemidir. Öğrenme sonunda ağın üretmesi istenen çıktıların da girdiler ile ağa tanıtıldığından bu öğrenme yöntemi danışmanlı öğrenme olarak ifade edilir. Yani ulaşmak istediğimiz değerler elimizde mevcuttur. Ağdan sadece bu değerlere en yakın değerleri vermesi için gerekli ağırlık değerlerini bulması istenmektedir.

Ağın eğitimi verilen girdi ve çıktı değerleriyle tamamlandıktan sonra oluşturulan model kullanılmaya başlanmalıdır. Çünkü elde edilen ağırlıklar eğitim tamamlandıktan sonra tekrar değiştirilmemek üzere sabitlenmektedir. Bu YSA nın bir eksikliği olarak görülebilir. Çünkü bazı veri setleri dinamiktir ve ağın verilere hemen uyum sağlaması zor olabilir.

Ağın eğitiminde dikkat edilecek husus her bir örneğin diğer örneklerle uyumsuz olmamasıdır. En azından belirli noktalarda örnekler birbirine benzerlik göstermelidir. Eğer benzerlik olmazsa öğrenilen her bilgi diğer örneği öğrenirken unutulacaktır. Bunun dışında ağda birçok noktaya dikkat edilmesi gereklidir. Ağa verilen bilgiler ham verilerden oluşmamalı, işlenmiş (ölçeklendirilmiş) olmalıdır.

Eğitim aşamasında her bir eğitim çiftine göre hatalar şekillendiriliyorsa bu yönteme ”örüntü kipi öğrenme”, ağırlıkların tüm çiftlere göre toplam hata üzerinden güncellenmesine de “küme kipi öğrenme” denir [73]. Perceptron (Algılayıcı), Çok Katmanlı Algılayıcı, Geriye Yayılımlı Ağlar, Boltzman Makinesi, Delta Öğrenme Kuralı,

ADELİNE danışmanlı öğrenme yöntemlerini kullanan ağlara örnek olarak verilebilir [72] [73].

3.4.2 Danışmansız Öğrenme

Geçmiş bilgilerin ağa tanıtılarak veriler arasındaki bağlantıların kendi kendine öğrenmesini sağlama işlemine danışmansız (öğretmensiz) öğrenme denir. Her çıktı aynı zamanda bir girdi olarak kullanılmaktadır. Girdi ve çıktı değerlerinin arasındaki en uygun ilişkinin tespiti ağın öğrenme sürecini tanımlamaktadır.

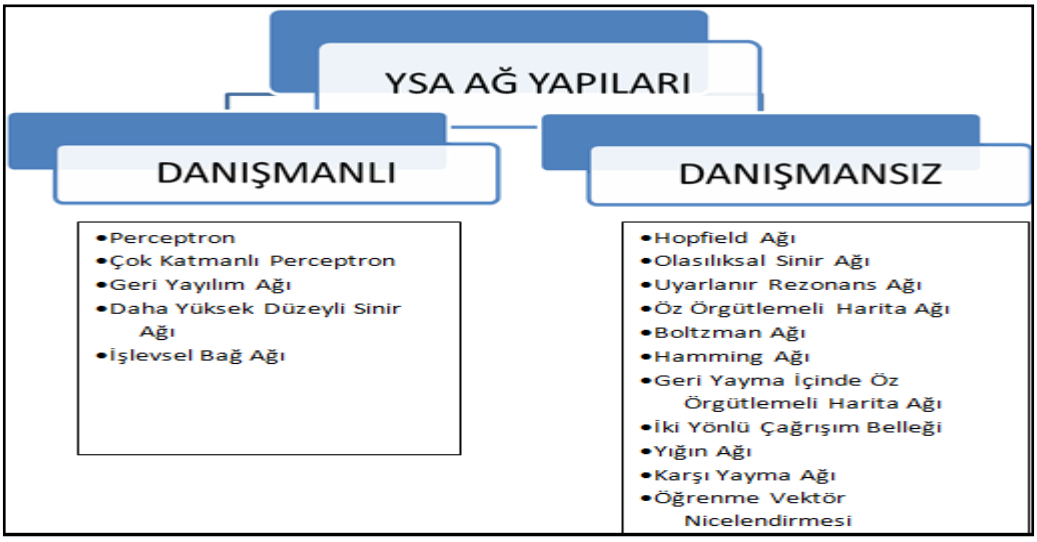
Daha çok sınıflama ve gruplama problemlerinin çözümünde kullanılan danışmansız öğrenme, danışmanlı öğrenme yöntemlerine göre oldukça hızlı işlem yapar [73].

Yarışmacı Öğrenme (Competitive Learning), Grossberg Öğrenme, Hebbian Öğrenme, Kohonen Öğrenme, Öz Örgütlemeli Harita Ağları (Self-Organising Map), Adaptif Rezonans Teorisi, Hopfield Ağı danışmansız öğrenme yöntemlerine örnek olarak verilebilir [72] [73].

3.4.3 Destekleyici Öğrenme

Destekleyici öğrenmede ağa veriler girilir ve üretilen çıktıların doğru ya da yanlış olduğunu belirtilir. Bu sistemde yakın-uzak oyunu benzeri bir sistem söz konusudur. Girdiler ağa verilir ve oyunda olduğu gibi olumlu ya da olumsuz bir sinyal yardımıyla ağın öğrenmesine destek verilir[1].

[1] Oyun gözü kapalı birinin belirli bir hedefi bulmak için adım atmasına dayanır. Kişiye hedefe yaklaşıyorsa yakın, hedeften uzaklaşıyorsa uzak diyerek yol gösterilmesidir.



Şekil 3. 3 Öğrenme Yöntemlerine göre Ağ Yapıları [73]

3.5 **Öğrenebilen Algoritmaların Kavranması**

Bir ağı eğitirken izlenecek adımlar şu şekildedir [73]:

K eğitim parçası alınmış bir verinin $(x^1, y^1),...,(x^K, y^K)$ parçaları için $X^K = x_1^K,\ldots, x_n^K$, $y^K = y_1^K,\ldots, y_n^K$, $k = 1,2,...,K$ 'dir.

Adım 1: n>0 seçilir.

Adım 2: w_i ağırlık vektörü küçük rastgele değerler alınır. Çalışma hatası k=1 iken E'ye ayarlanır ve işlem başlar.

Adım 3: Eğitimin başlama noktası burasıdır. X^K değeri $x = x^K$, $y = y^K$ olacaktır.

$$y_i(x) = sign(w_i, x) \quad i = 1,...m \tag{3.4}$$

Adım 4: Ağırlıklar güncellenir.

$$w_i = w_i + \eta(y_i - sign(w_i, x))x \quad , \quad i = 1,...m \tag{3.5}$$

Adım 5: Her dönüşte hata E ile sunulan hataya eklenerek hesaplanacaktır.

$$E = E + \frac{1}{2}.\|\upsilon_i - z_i\|^2 \tag{3.6}$$

Adım 6: Eğer k=k+1 den k<K ise üçüncü adıma geri gidilir. Aksi durumda adım 7' ye gidilir.

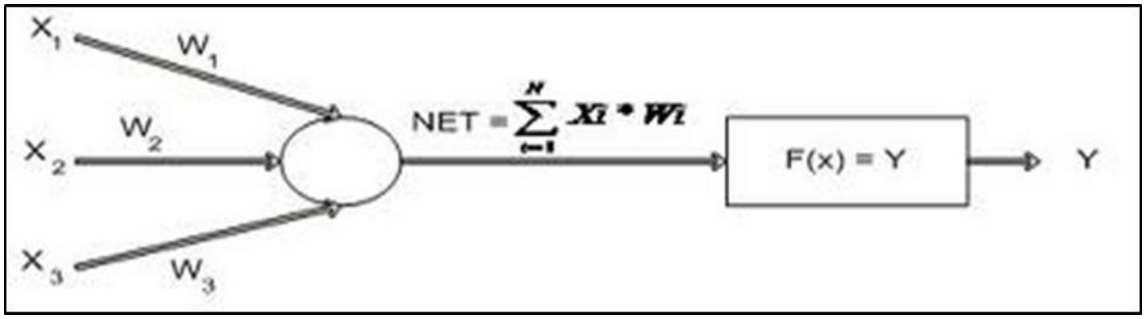
Adım 7: Eğitim bitirilir. E=0 için eğitim durdurulur. Ancak E>0 olmuşsa E çıkış değerinde k=1 gibi bir dizi olur ve yeniden adım üçe geri dönülür.

3.6 Yapay Sinir Ağlarında Ağ Mimarisi

Waren McCulloc ve Walter Pits 1943 yılında bir mantık problemini çözmek için sinir hücresine benzeyen yapıda bir yapay sinir hücresi geliştirmişlerdir. Öğrenme yeteneği olmayan bu yapılar için ağırlık değerleri kullanıcı tarafından belirtilmektedir. 1950' lerde F. Rosenblatt ilgilenilen problemin çözümü için ağın öğrenebilmesini sağlamak amacıyla bir öğrenme kuralı geliştirilmiştir. Rosenblatt ilgilenilen problemin çözümü için uygun ağırlıklar mevcutsa eğer bunların algılayıcılarla bulunabileceğini göstermiştir. Basit algılayıcı, doğrusal problemlere çözüm getirebilmektedir. Bu sebeple sınırlı performans göstermektedir. Bunu Marvin Minsky ve Seymour Papert 1969' da yayınladıkları kitapta göstermişlerdir.

3.6.1 Basit Algılayıcı (Perceptron)

Basit bir algılayıcı girdilere karşılık en uygun çıktıyı üretme işlemidir. ADELİNE(ADaptive LINear Element) ile yalnızca doğrusal problemlere çözüm üretilebilmektedir. Uygulamada en fazla kullanılan ağlardan olsa da doğrusal olmayan problemlere çözüm üretme kapasitesi yoktur. Şekilde bir algılayıcının yapısı gösterilmektedir.



Şekil 3. 4 Bir Algılayıcının Yapısı

$$Net = w_1 x_1 + w_2 x_2 + w_3 x_3 + b \tag{3.7}$$

Y= f (Net) olacak şekilde,

$$f\left(Net\right) = \begin{cases} 1, \text{Net} \geq 0 \text{ ise} \\ 0, \text{Diğer durumlarda} \end{cases} \tag{3.8}$$

Verilenleri basitçe matris formatında ifade edersek eşitlik 3.9' u elde ederiz.

$$Y = f(W^T X + b) \tag{3.9}$$

Bu denklemde $W = \begin{bmatrix} w_1 \\ w_2 \\ w_3 \end{bmatrix}$ ağırlık vektörüdür. $X = \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix}$ ise girdi vektörüdür.

Basit algılayıcı için öğrenme algoritması:

1. W bağlantı değerleri için rastgele değerler ata.
2. Girdi kümesinden x_i girdi vektörünü seç.
3. $O_\Sigma = f(wx_i + b)$ fonksiyonuyla ağ çıktısını hesapla.
4. İstenen çıktı ile üretilen çıktı arasındaki farkı(hata miktarını = $t_i - o_i$) hesapla.
5. Ağırlıkları eşitlik 3.10 da verilen denklemlere göre güncelle. (η öğrenme oranıdır.)

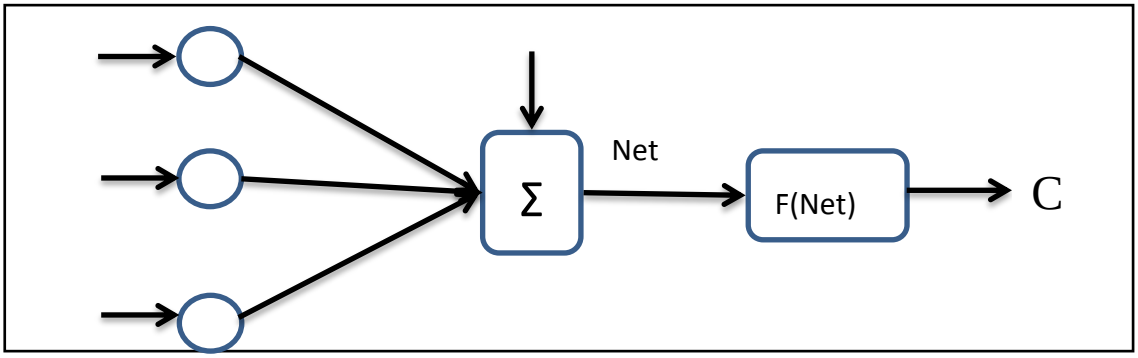
$$\begin{aligned} w_{yeni} &= w_{eski} + \eta(t_i - o_i)x_i \\ b_{yeni} &= b_{eski} + \eta(t_i - o_i) \end{aligned} \tag{3.10}$$

6. Hata toleransına ulaşılmışsa ağırlıkları sabitle. Ulaşılamamışsa 2. Adıma geri dön.

Şeklinde olacaktır.

3.6.2 ADALINE

ADALINE(ADAptive LInear NEuron) 1960 yılında Widrow ve Hoff tarafından geliştirilmiştir. Delta öğrenme kuralını kullanmaktadır. Bu kural aktivasyon fonksiyonu çıktısı ile istenen çıktı arasındaki farkların kareleri ortalamasını minimum yapmaya çalışmaktadır.



Şekil 3. 5 ADALINE

ADALINE sınıflandırma fonksiyonu eşitlik 3.11 de ifade edilmiştir.

$$C_j = \begin{cases} 1, \text{Net} \geq 0 \\ 0, \text{ Diğer Durumlarda} \end{cases} \tag{3.11}$$

ADALINE' nin ağ eğitim algoritması aşağıda verilmiştir.

1. Bağlantılar için rastgele w değerleri, η öğrenme oranı için 1 değeri atanır.
2. Girdi kümesinden x_i girdi vektörünü seçilir.
3. Net girdi $Net = wx_i + b$ şeklinde verilen denkleme göre hesaplanır.
4. $(t_i - Net_i)$ eşitliği ile istenen çıktı ile net girdi arasındaki fark hesaplanır.
5. Eşitlik 3.12 den yararlanarak ağırlıklar güncellenir.

$$\begin{aligned} w_{yeni} &= w_{eski} + \eta(t_i - Net_i)x_i \\ b_{yeni} &= b_{eski} + \eta(t_i - Net_i) \end{aligned} \tag{3.12}$$

6. 2-6 adımları arası tüm girdi - çıktı eşleşmeleri için hataların En Küçük Kareler değerini hesaplanır. Hatalar için bu değer belirlenen seviyenin altında ise eğitim durdurulur.

3.6.3 MADALINE

MADALINE (Many ADALINE) adından da anlaşılacağı gibi bir çok ADALINE den oluşmuş bir YSA' dır. MADALINE 1990 yılında Windrow ve Lehr tarafından geliştirilmiştir. MADALINE kullanımının en önemli avantajı lineer olmayan ayrıştırılabilirlik sorununun

çözümünde yardımcı olmasıdır. Her katmanda değişik sayıda ADALINE olabilir. Ancak genellikle iki katmandan oluşmaktadır.

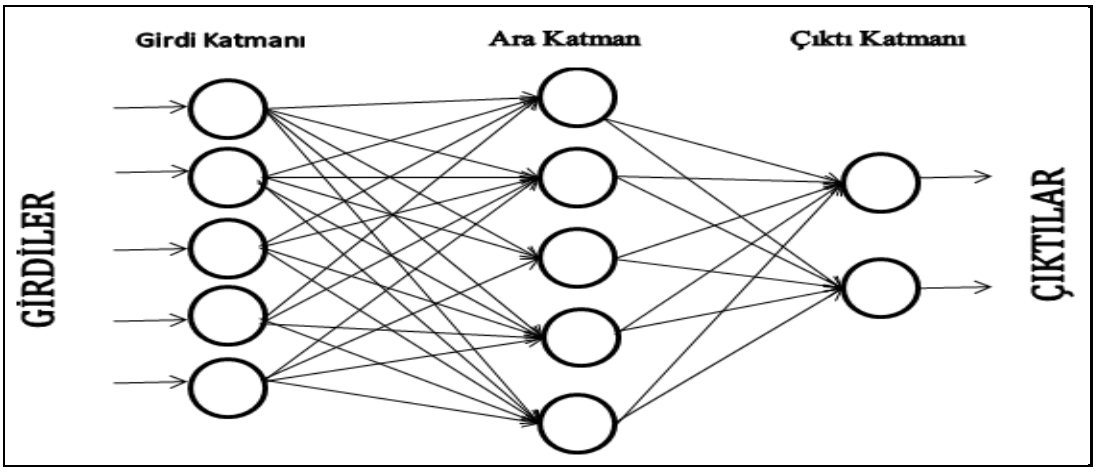
3.6.4 Çok Katmanlı Algılayıcı

Öğrenme algoritması olarak geriye yayılım algoritması kullanan ve geri yayılım ağları olarak da adlandırılan Çok Katmanlı Algılayıcı (ÇKA) genel olarak tahmin problemlerinin çözümünde kullanılmaktadır. Girdi ve çıktı katmanı ile birlikte en az bir gizli katmandan oluşmaktadır.

ÇKA da bulunan tüm nöronlar doğrusal olmama özelliği göstermektedir. En az bir gizli katmana sahip bu ağlar oldukça karmaşık yapıları dahi öğrenebilme özelliği göstermektedir. Bunun için hiçbir önbilgiye ihtiyaç duyulmaz. Esnek yapısı oldukça dinamik bir model elde edilmesini sağlar. Bu esneklik ağa yeterince veri girilmesini zorunlu kılacaktır. Model varsayımlarına ihtiyaç duyulmaması ÇKA için önemli bir avantajdır. Fakat ağın kurulması işleminin oldukça uzun sürmesi ve ağın kara kutu şeklindeki yapısı eleştiri konusudur. Ağdaki ağırlıklar yorumlanabilir değildir[72].

Bir yapay sinir ağının lineer olmayan ilişkilerde de problemi çözebilmesi için Çok Katmanlı Algılayıcılar gibi daha gelişmiş modellere ihtiyaç vardır. Tek katmanlı modellerden farklı olarak en az bir tane gizli katman içermektedir. Bu gizli katmanlar karmaşık problemleri rahatlıkla çözebilmesine olanak sağlamaktadır. Bu yönteme eğitimde kullanılan öğrenme algoritmasından esinlenilerek Geriye Yayılımlı Ağlar da denmektedir. Bir ÇKA modeli genel olarak aşağıdaki öğelerden oluşmaktadır[72] [73] [74]:

1. Yapay sinir hücresi (YSH) ve katmanlar
2. Birleştirme fonksiyonu
3. Aktivasyon fonksiyonu
4. Hata fonksiyonu
5. Öğrenme algoritması



Şekil 3. 6 İki Katmanlı Bir ÇKA Örneği

3.6.4.1 **Birleştirme (Net) Fonksiyonu:**

Bir nöronda yer alacak olan girdi değerlerinin etkinliği derecesinde ağırlık miktarıyla çarparak birleştiren fonksiyona birleştirme fonksiyonu denir. Bu fonksiyon net girdi değerini üretmek amacıyla kullanılmaktadır. Üretilen ağın yapısına ve varsayımlarına bağlı olarak değişmekle birlikte birleştirme fonksiyonu olarak genellikle toplam fonksiyonu kullanılmaktadır. Net girdi değeri toplam fonksiyonu için:

$$Net_j = \sum_i w_{ij} x_i + w_{0j} \qquad (3.13)$$

şeklinde olacaktır. Bunun dışında kullanılan birleştirme fonksiyonlarından bazıları çizelgede gösterilmiştir [72].

Çizelge 3. 2 Birleştirme (Net) Fonksiyonu Türleri

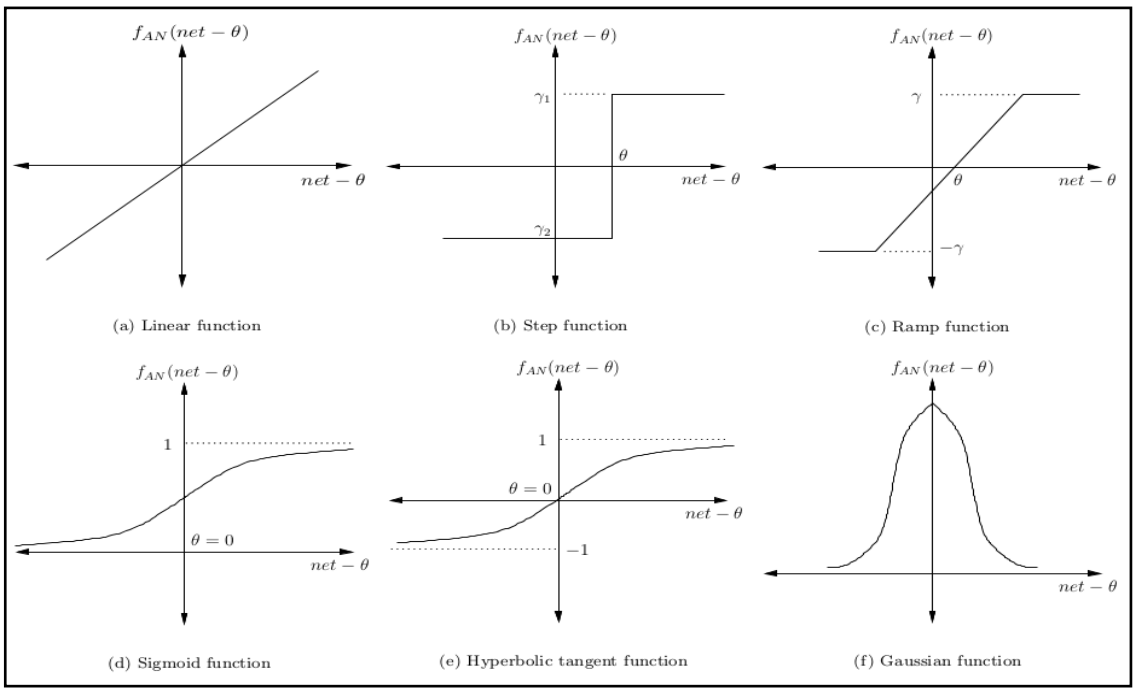
Toplam Fonksiyonu	**Çarpım Fonksiyonu**	**Signum Fonksiyonu**
$Net_j = \sum_i w_{ij} x_i$	$Net_j = \prod_i w_{ij} x_i$	$Net_j = \sum_i \mathrm{sgn}(w_{ij} x_i)$
Maksimum Fonksiyonu	**Minimum Fonksiyonu**	
$Net_j = Maks(w_{ij} x_i)$	$Net_j = Min(w_{ij} x_i)$	

Burada w_{ij} : i , j nöronları arasındaki bağlantı ağırlığı, x_i : i nöroni,unun çıktısı,

Net_j : j nöronunun net girdisidir.

3.6.4.2 **Aktivasyon Fonksiyonu**

Aktivasyon fonksiyonu ağırlıklandırılmış değerleri alarak 0 ile 1 ya da -1 ile 1 arasında çıktı değerlerine dönüştüren fonksiyondur. Literatürde çok kullanılan aktivasyon fonksiyonları şekilde verilmiştir. Verilen fonksiyonlardan en yoğun kullanılanları sigmoid, hiperbolik tanjant ve özdeşlik fonksiyonlarıdır.



Şekil 3. 7 Aktivasyon Fonksiyonu Türleri[1]

3.6.4.3 **Hata Fonksiyonu**

Daha önce de belirtildiği gibi yapay sinir ağları en doğru ağırlıklara ulaşmak için hataları minimum yapmaya çalışmaktadır. Bu nedenle hatanın optimize edilmesini sağlayan fonksiyonlar önemli olmaktadır. Y ağın çıktısını ifade etmek üzere hata aşağıda verilen eşitlik 3.14 yardımı ile hesaplanmaktadır.

$$e = Y_{gerçek} - Y_{tah\min} \tag{3.14}$$

Ağ performansını ölçmek için birçok ölçüt bulunmaktadır. Hata Kareleri Ortalaması, Hata Kareleri Toplamı, Ortalama Hata Kareleri ağ performansını ölçmek için kullanılan

[1] **Kaynak:** http://www.stuartreid.co.za/misconceptions-about-neural-networks/

ölçütlerden bazılarıdır. Genel olarak kullanılan ağ performansı ölçütlerinden bazıları tabloda gösterilmiştir [72].

Çizelge 3. 3 Ağ Performansı Ölçütleri

Ortalama Hata $OH = \frac{1}{n}.\sum_{i=1}^{n} e_i$	**Ortalama Mutlak Hata** $OMH = \frac{1}{n}.\sum_{i=1}^{n} \lvert e_i \rvert$	**Ortalama Mutlak Yüzde Hata** $OMYH = \frac{1}{n}.\sum_{t=1}^{n} \left\lvert \frac{e_t}{Y_t} \right\rvert .100$	**Ortalama Yüzde Hata** $OYH = \frac{1}{n}.\sum_{t=1}^{n} \frac{e_t}{Y_t}.100$
Yüzdelik Hata $YH = \frac{e_t}{Y_t}.100$	**Hata Kareleri Toplamı** $HKT = \sum_{i=1}^{n} e_i^{\,2}$	**Hata Kareleri Ortalaması** $HKO = \frac{1}{n}.\sum_{i=1}^{n} e_i^{\,2}$	

3.6.4.4 **Öğrenme Algoritmaları**

ÇKA, birçok problemin çözümüne yardımcı olmaktadır. Bunu sağlayan GYA adı verilen öğrenme algoritmasıdır. Bu yöntem ÇKA' ların yaygınlaşmasında önemli rol oynamıştır.

ÇKA ların öğrenme algoritması olan GYA da sistem eğitilirken önce veriler ağdan geçirilir. Oluşan hataya göre ağırlıklar hatalar geriye yayılarak güncellenir.

Gerçek değerler ile hesaplanan değerler arasındaki fark bulunur. Bulunan hatalar geri besleme bağlantıları ile ağda girdi olarak yeniden kullanılır. Bu algoritmanın işleyebilmesi için aktivasyon fonksiyonu türevlenebilir bir fonksiyon olmalıdır. GYA ların da çeşitli zayıf yönleri mevcuttur. Bu zayıflıkları ortadan kaldırmak amacıyla genetik algoritmalar, rassal arama, quickprop gibi birçok optimizasyon yöntemi geliştirilmiştir. GYA tasarımı için önemli olan bazı dikkat edilmesi gereken maddeler mevcuttur. Bu maddeler[72] [73]:

- ÇKA' da en önemli konuların başında verilere karar verilmesi gelmektedir. Verilerin nasıl kullanılacağı, girdi değerlerinin ve çıktı değerlerinin neler olacağı iyi belirlenmelidir.

- Verilere karar verildikten sonra model içindeki bazı zararlı durumlar temizlendikten sonra modelleme yapılabilir. Modelleme için önce ağın nasıl olacağına karar verilmelidir. Katman sayısı, gizli nöron sayısı, eğitim algoritması, aktivasyon fonksiyonu gibi unsurlar ağa ve veri yapısına uygun olarak seçilmelidir.
- Öğrenme oranı bağlantı ağırlıklarını güncellerken kullanılacak olan 0 ile 1 aralığında yer alan bir değerdir. Dik iniş kuralı adı verilen yöntemde önemli olan öğrenme oranı istenen ağın yapısına bağlı olarak belirlenmelidir. Oran büyük olursa kısa sürede öğrenme gerçekleşecektir. Ancak küçük öğrenme oranına göre ağın daha az öğrenmesine neden olacaktır. Ancak oran azaldıkça eğitim süresi artmaktadır.
- Hatalı terimlerden ötürü öğrenmenin yanlış olmasının önüne geçmek amacıyla dik iniş kuralında inişin daha hızlı olmasını sağlamak için kullanılan sabit teri momentum parametresidir. Momentum terimi 0 ile 1 arasında bir değerdir. Bu değerin 0 olması ağırlıkların geçmiş değişimlerden etkilenmeyeceğini, 1 olması da değişimin tamamen geçmiş değişimlere bağlı olacağını ifade etmektedir. Yani yüksek momentum terimi hata toplamına daha yüksek bir eğimle yaklaşılacağını ifade etmektedir.
- Gizli katmanlarda yer alması gereken düğüm sayısının kesin bir kuralı yoktur. Temel amaç optimizasyon olduğundan en az sayıda düğüm ile en iyi performansı elde etmek için deneme yanılma yoluyla en ideal düğüm sayısı tespit edilmelidir. Ancak literatürde çeşitli yaklaşımlar mevcuttur. Bu yaklaşımların dikkate alınması sonuca ulaşmayı kolaylaştıracaktır.
- Eğitime başlarken aktivasyon fonksiyonunun türevini 0 yapacak değerlerden ve aşırı büyük/küçük değerlerden uzak durulmalıdır.
- Ağın ezberlememesine dikkat edilmelidir.
- Ağın düzgün eğitilmesi için ağda yer alacak verileri eğitim – doğrulama – test şeklinde ayırmak gerekmektedir. Böylece ağın eğitiminde ezberlemeye başladığı nokta tespit edilebilir. Ağda yer alan ağırlıklar genelleştirilerek sabitlenebilir.

Literatürde verileri %80 %10 %10 , %70 %15 %15 veya %60 %20 %20 şeklinde ayırmak yaygın olarak kullanılmaktadır.

- Veriler modele ham veri olarak değil işlenmiş olarak dahil edilmelidir. Bunun için basit normalizasyon, istatistiksel normalizasyon, doğrusal normalizasyon gibi yöntemler kullanılmaktadır.

BÖLÜM 4

FOURİER DÖNÜŞÜMÜ VE DALGACIK DÖNÜŞÜMÜ

Dalgacık Analizi veya Dalgacık Dönüşümü terimleri son otuz yılda adını sinyal işleme, görüntü işleme, gürültü ayıklama gibi mühendisliğin temel problemlerine ürettiği pratik çözümler ile duyurmuştur. Bu kadar yaygınlaşmasını 1980 - 1990 yılları arasında yaptıkları çalışmaları ile Coifman, Grossmann, Morlet, Yves Meyer , Daubechies, Mallat gibi bilim insanlarının sağladığı söylenebilir. Son yıllarda elde edilen bu başarıların temeli Joseph Baptiste Fourier tarafından 1805 yılında ısının katılardaki iletimini hesaplamak için ortaya atılan Fourier Dönüşümü olarak bilinen yöntemdir.

Fourier, herhangi bir periyodik fonksiyonun sinüs ve kosinüs fonksiyonlarının toplamıyla ifade edilebileceğini söylemiştir. Genel bir görüş sağlaması açısından önemli olan Fourier Dönüşümü her türlü sinyale çözüm sağlamamaktadır. Çünkü günlük yaşamımızda sinyallerin birçoğu sonludur. Üstelik elde edilen frekans çözümlemesinde ortaya çıkarılan frekansların hangi zamanda gerçekleştiği bilinememektedir. Ancak sinyallerin ve zaman serilerinin analizinde frekans bilgisi kadar zaman bilgisi de önemlidir. Ölçekler sinyalin dalgalanmalara karşı oluşan gürültülerin azaltılması amacıyla kullanılan değişkenlerdir. Dalgacık Dönüşümü ise Fourier Dönüşümünün tersine aynı anda hem ölçek hem de frekans düzeyinde bölgesel olarak gösterilebilirler.

Matematiksel olarak dalgacıklar farklı ölçek katmanlarına göre bir fonksiyonu parçalara ayıran küçük dalgalardan oluşan yerel ortonormal bir tabandır [78]. Dalgacık dönüşümü bir sinyali dalgacıklar yardımıyla farklı ölçeklerdeki bileşenlere ayıran, ayrılan bu yapıları matematiksel bileşenler olarak ifade eden bir matematiksel analiz türüdür. Sinyallerin kesildiği bölgelerde, pik yaptığı noktalarda, sinyalin kırılma noktalarında da analiz gerçekleştirebilmektedir. Buna ek olarak süreksiz, sonlu,

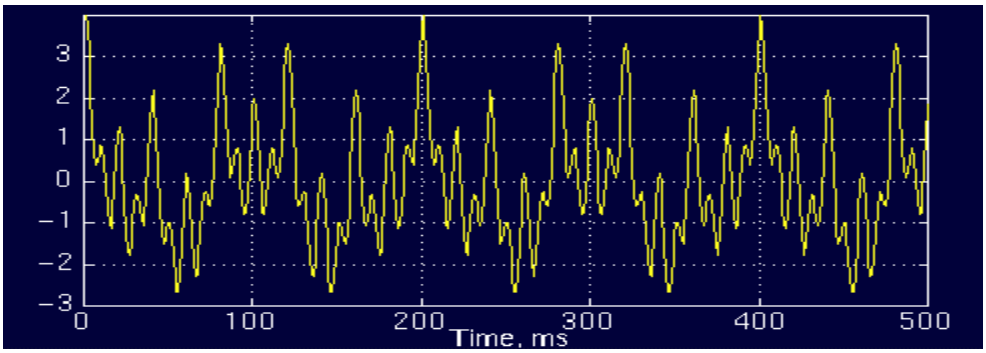
değişken ve periyodik olmayan sinyallerin analizinde de oldukça başarılı sonuçlar vermektedir [75] [77]. Özet olarak dalgacıklar hem bir ağacı hem de tüm ormanı görebilmeyi sağlar [77] [78].

Dalgacık dönüşümünün ekonomi alanında kullanılmasıyla ilgili oldukça az sayıda çalışma yapılmıştır. Yapılan çalışmalar da son birkaç yıl içerisinde gerçekleştirilmiştir. Dalgacıklar özellikle mühendislik alanında çok yaygın olarak kullanılmaktadır. Teoride ekonomik faaliyetler ve karar alma konusu çok farklı başlıklardır. Tahminlerin farklı ölçek seviyelerinde geliştirildiği görülmektedir. Çünkü ARMA (autoregressive moving average) ve YSA gibi tahmin yöntemlerinde tahminler verinin tamamından farklı ölçeklerde ortaya çıkarılmaktadır. Bu bilgiler bize ekonomi alanında da uygulamaların yoğun şekilde yapılacağını ve hızla artacağını göstermektedir [78].

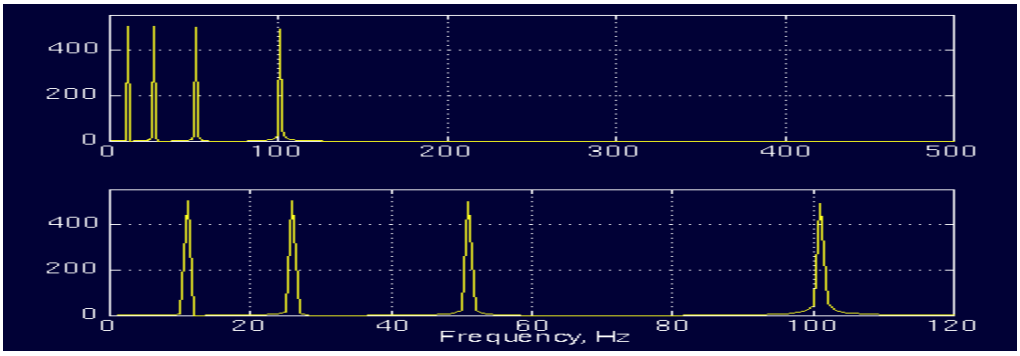
4.1 **Frekans bilgisine neden ihtiyaç duyulur?**

EKG(Elektromanyetik Kardiyografi) gibi biyolojik sinyallerde frekans gösterimi analiz bakımından daha faydalı olabilir. DD' nün temelinde FD yer almaktadır. FD yapılan veriler istendiğinde eski hallerine dönüştürülebilirler. Yani FD dönüştürülebilir bir yöntemdir. Zaman grafiğinde verinin frekans bilgisi yer almadığı gibi frekans grafiğinde de verinin zaman bilgisi yer almaz. Yani gerçekleşen frekansların genliği, gerçekleştiği zaman aralığı FD ile dönüştürülen verilerde yer almaz. Bu bilgi durağan verilerde gerekli değildir. Ancak ekonometrik veriler gibi durağan olmayan verilerde bu bilgi önemli çıktılar verebilir. Burada durağan veriler frekansların zaman içinde değişmediği verilerdir. Yani tüm frekanslar tüm zamanlarda gerçekleşiyorsa bu seriler durağandır.

Sinyallerde frekans ölçüsü periyottur. Buna "Hertz" de denir. Örneğin: 10 Hertz dediğimizde bir sinüs dalgasının belirlenen bir noktadan saniyede 10 defa geçtiğini belirtmiş oluruz. Bir sinyalin frekans içeriklerini bulmak için genlik-frekans grafiğinin çizilerek sinyalde yer alan frekansları gözlemlemek gerekir. Frekans ekseni sıfırdan başlayıp sonsuza gider. Her frekans değeri bir genlik değerine karşılık gelir. $x(t) = cos(2.\pi.10.t) + cos(2.\pi.25.t) + cos(2.\pi.50.t) + cos(2.\pi.100.t)$ Fonksiyonu durağan bir fonksiyondur. Çünkü 10, 25, 50, 100 Hzlik frekanslar mevcuttur. Bu seri ve serinin FD şekil 4.1 ve 4.2 de gösterilmiştir.

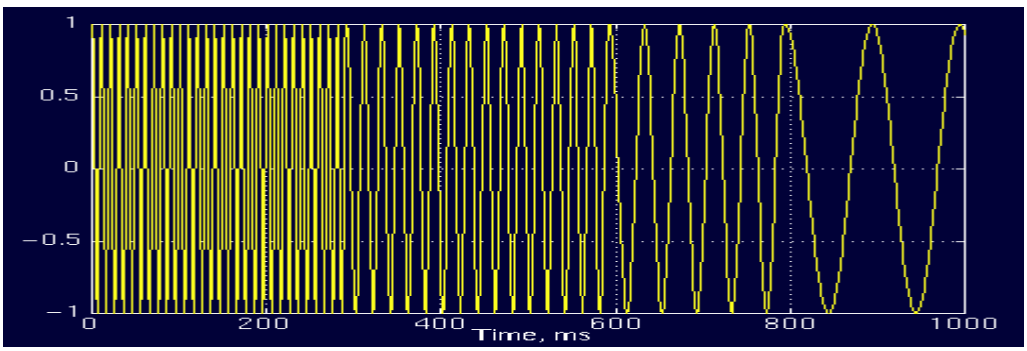


Şekil 4. 1 Durağan Fonksiyon Grafiği [77]

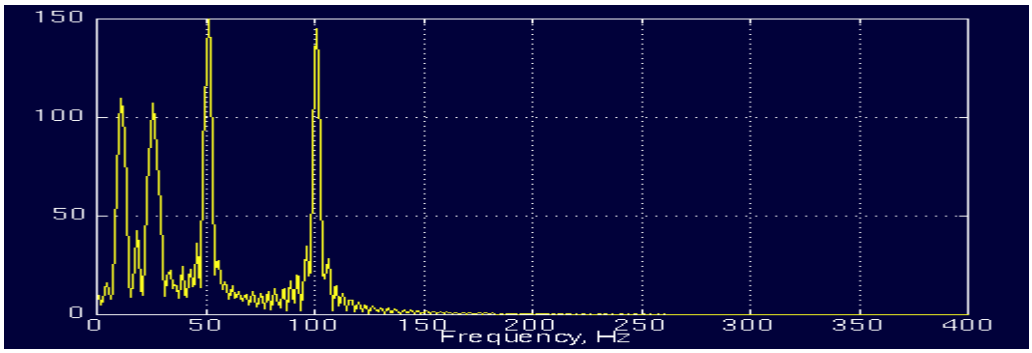


Şekil 4. 2 Durağan Fonksiyonun Fourier Dönüşümü [77]

Şekil 4.2 de görüleceği gibi 4 tane frekans bileşeni mevcuttur. 120 Ms ya da 500 Mslik iki grafikte de 4 tane frekans bileşeni mevcuttur. Şekil 4.3 de durağan olmayan bir sinyal ve şekil 4.4 de sinyalin FD mü örnek olarak verilmiştir.



Şekil 4. 3 Durağan Olmayan Bir Fonksiyonun Grafiği [77]



Şekil 4. 4 Durağan Olmayan Bir Fonksiyonun Fourier Dönüşümü [77]

Şekil 4.3 den de anlaşılacağı gibi bu seri durağan değildir. 0-300 saniye aralığında 100 Hz, 300-600 saniye arasında 50 Hz, 600-800 saniye arasında 25 Hz ve 800-1000 saniye 10 Hzlik sinüsoidlerden oluşmaktadır. Serinin FD şekil 4.4 de verilmiştir. Yüksek frekans değerlerinin genliği düşük frekans değerlerinin genliğinden yüksektir. Yani yüksek frekanslar düşük frekanslardan daha uzun sürmektedir. Şekle göre 4 tepe noktası vardır. Yani dikkate değer 4 frekans mevcuttur. Durağan olmayan serilerde tüm frekans değerleri tüm zamanlarda gerçekleşmemektedir. Durağan ve durağan olmayan sinyallerin frekans grafikleri benzerlikler göstermektedir. Grafiklerden de anlaşılacağı gibi spektral bileşenlerin ne zaman ortaya çıktığını bildirmemektedir. Bu sebeple durağan olmayan verilerde sadece spektral bileşenleri bilinmek isteniyorsa ve frekansları hangi aralıkta gerçekleştiği önemli değilse FD kullanılmalıdır.

Sosyal ve biyolojik birçok dalga, birçok seri durağan değildir. Bu sebeple FD kullanmak uygun değildir. Çünkü FD sadece frekans bileşenlerini vermektedir. Eğer seride frekans bileşenlerinin ne zaman gerçekleştiği önemliyse zaman-frekans gösterimine ihtiyaç vardır.

4.2 **Verilere Neden Dönüşüm Yapılır?**

Mühendislik uygulamalarında sinyal, ekonomi ve beşeri bilimlerde zaman serileri şeklinde toplanan verilerin analizinde elde edilmek istenen bilgiler veri işlenmeden her zaman mümkün olmamaktadır. Bu nedenle sinyali farklı platformlara taşımak daha faydalı olacaktır. Bu işlem x(t) sinyalinin $\{\psi_n(t)\}_{n\in Z}$ fonksiyonu ile benzerliklerinin katsayılar serisi şeklinde ifade edilmesiyle sağlanır [79].

$$c_n = \int_{-\infty}^{\infty} x(t)\psi_n^*(t)dt \tag{4.1}$$

Serisinde $x(t)$ ile $\psi_n(t)$ fonksiyonlarının iç çarpımı 4.2 eşitliğinde gösterilmiştir.

$$< x,\psi_n >= \int x(t)\psi_n^*(t)dt \tag{4.2}$$

4.1 eşitliği 4.2 eşitliğinin genel formu şeklinde 4.3 eşitliği şeklinde ifade edilebilir.

$$c_n =< x,\psi_n > \tag{4.3}$$

c_n ifadesi ψ_n fonksiyonu ile x sinyalinin benzerliğini ve yakınlığını ortaya çıkarmaktadır. Bu ifadeye göre yüksek benzerlikler yüksek iç çarpım değerine karşılık gelecektir.

4.3 **Fourier Dönüşümü**

1807 yılında Fransız matematikçi Joseph Fourier, herhangi bir periyodik fonksiyonun sinüs ve kosinüs fonksiyonlarının ağırlıklı toplamı şeklinde ifade edilebileceğini keşfetmiştir [80]. Bu keşiften yıllar sonra onun periyodik fonksiyonlar için ortaya attığı bu fikirleri periyodik olan ve olmayan tüm fonksiyonlar için de genelleştirilmiştir. Bu integral Fourier Dönüşümü olarak bilinir ve eşitlik 4.4' te gösterilmiştir. Buna göre x(t) sinyalinin Fourier Dönüşümü:

$$X(f) =< x,e^{i2\pi ft} >= \int_{-\infty}^{\infty} x(t)e^{-i2\pi ft}dt \tag{4.4}$$

Sinyalin enerjisinin sonlu olduğu varsayılırsa 4.5 eşitliğinin sağlanması gerekir. Dönüştürülen sinyalin geriye dönmesi de mümkündür. Buna Ters Fourier Dönüşümü denir. X(t) sinyalinin Ters Fourier Dönüşümü eşitlik 4.6 da verilmiştir.

$$\int_{-\infty}^{\infty} |x(t)|^2 dt < \infty \tag{4.5}$$

$$x(t) = \int_{-\infty}^{\infty} X(f)e^{i2\pi ft}dt \tag{4.6}$$

Fonksiyonlarda yer alan ifadelerden;

t: zaman

x: sinyal

f: frekans

X: sinyalin frekans gösterimini ifade etmektedir.

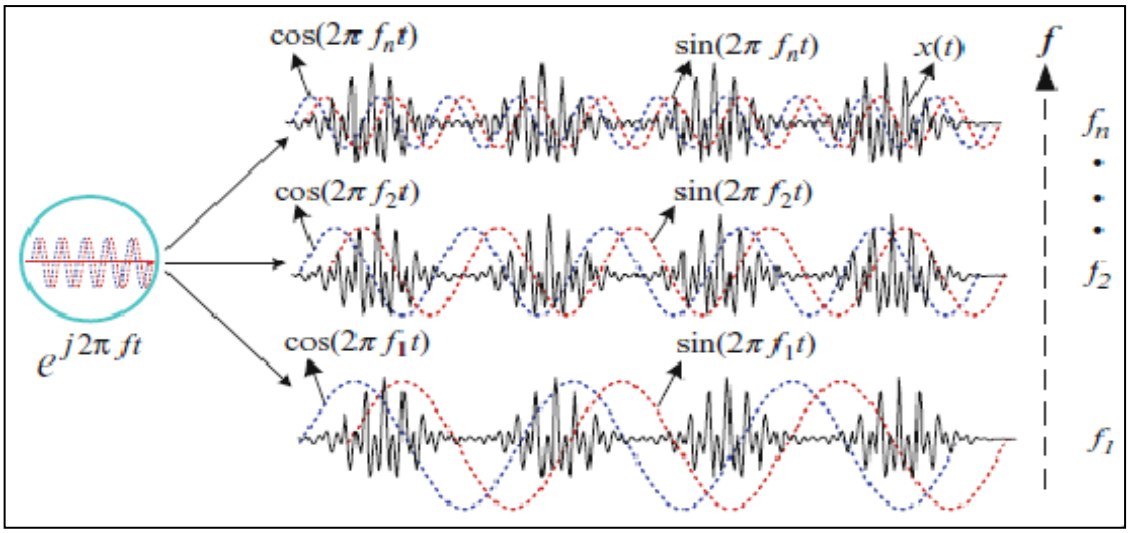
x_k sürekli bir sinyali toplam T zamanda ΔT zaman aralıklarıyla kesikli olarak gösterilecek olursa:

$$KFD(f_n) = \frac{1}{N}\sum_{k=0}^{N-1} x_k e^{-i2\pi f_n k\Delta T} \qquad (4.7)$$

Burada örnek sayısı, yani bölünen sinyal sayısı $N = \frac{T}{\Delta T}$, $f_n = \frac{n}{T}$ (n=0,1,2,3,…N-1) de kesikli frekans bileşenleridir. Ters Kesikli Fourier Dönüşümü de:

$$x_k = \frac{1}{\Delta T}\sum_{f_n=0}^{(N-1)/T} KFD(f_n) e^{i2\pi f_n k\Delta T} \qquad (4.8)$$

Eşitlik 4.4 ve 4.7 den anlaşılacağı üzere x(t) veya x_k serisi ile sinüs – kosinüs fonksiyonları yakından ilişkilidir. Verilen fonksiyon ile serinin benzerliğini ortaya çıkararak ortalama frekans bilgilerini hesaplar. Şekil 4.5 te bu işlemler gösterilmiştir.



Şekil 4. 5 x(t) Sürekli Sinyalinin Fourier Dönüşümünün Gösterimi [79]

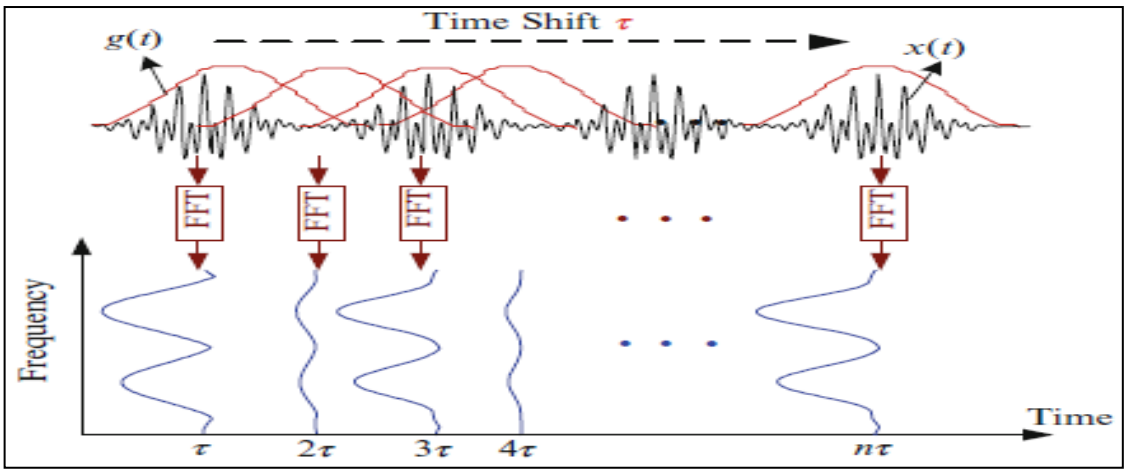
Kesikli Fourier Dönüşümü oldukça zahmetli ve uzun hesaplamalar içermektedir. Bunun yerine 1965 yılında Cooley – Tukey algoritması olarak bilinen Hızlı Fourier Dönüşümü

ortaya atılarak bu tür problemler kolaylıkla çözüme ulaştırılmıştır. Bilgisayar programlarının da yaygınlaşması sonucunda FD oldukça yaygın hale gelmiştir. İntegralden elde edilen bilgi $-\infty$ dan ∞ a kadar olan tüm zamanlara yayılır. Bu dönüşümde "f" frekansının ne zaman gerçekleştiği önemli değildir. Herhangi bir t_1 zamanında gerçekleşse de t_2 zamanında gerçekleşse de integraldeki etkisi aynı olacaktır. Bu nedenle Fourier Dönüşümü zamana bağlı olarak değişen sinyaller için uygun değildir.

4.4 **Kısa Zamanlı Fourier Dönüşümü**

Kısa Zamanlı Fourier Dönüşümü (KZFD) durağan olmayan bir sinyalin durağan durağan olacak kadar küçük parçalara ayrılarak incelenmesi esasına dayanır. Temelde FD ile KZFD arasında fark yoktur. Tek fark durağan olmasa da sinyalin küçük parçalara ayrılarak durağanmış gibi incelenmesidir. Bunun için bir pencere fonksiyonu (window function) seçilir. Bu pencerenin genişliği her pencerede sinyalin durağan kabul edilebileceği kadar küçük olmalıdır.

Fourier Dönüşümündeki zaman problemini çözmek için 1946 yılında Dennis Gabor tarafından KZFD ortaya atılmıştır. Bu yönteme göre sabit genişlikli bir pencere fonksiyonu zaman ekseninde kayarak analizi gerçekleştirir. Gabor' un ortaya attığı dalgacık ile 3 önemli bilgiye sahiptir. Bu dalgacıkların başlangıcı, bitişi ve başlangıç ile bitiş arasında bir frekans değerine sahiptir [81].



Şekil 4. 6 x(t) Sinyalinin Kısa Zamanlı Fourier Dönüşümünün Gösterimi [79]

Şekil 4.6 da gösterildiği gibi KZFD g(t) pencere fonksiyonu ile sinyalin zaman ekseninde τ kadar kaydırılır. Sinyal pencere fonksiyonu boyunca durağan gibi kabul edilir. Böylece sinyal sadece zaman gösteriminden, zaman – frekans gösterimi şeklinde 2 boyutlu hale getirilir. Anlatımın grafiksel olarak gösterimi şekil 4.6 da gösterildiği gibi olacaktır.

KZFD 4.9 ve 4.10 eşitlikleri yardımıyla hesaplanacaktır.

$$KZFD(\tau, f) = < x, g_{\tau,f} > \tag{4.9}$$

$$< x, g_{\tau,f} > = \int x(t) g^*_{\tau,f}(t) dt = \int x(t) g(t-\tau) e^{-j2\pi ft} dt \tag{4.10}$$

Formülü ile hesaplanır. Verilen denklemlerde;

$x(t)$: sinyalin kendisidir.

$g(t)$: pencere fonksiyonudur.

τ : pencere genişliğidir.

* ise fonksiyonun karmaşık eşleniğini ifade eder. Burada FD ile arasındaki temel fark sinyalin FD nün pencere fonksiyonu ile çarpılmış olmasıdır.

Eşitlik 4.10 sinyalin zamanda kayan ve frekans modüllü g(t) pencere fonksiyonu ile benzerliklerini ortaya çıkaran fonksiyondur. Son yıllarda her biri farklı bir uygulama için geliştirilen birçok fonksiyon vardır. Gauss Pencere Fonksiyonu süreksiz sinyalleri analiz etmek için geliştirilmiştir.

KZFD ile sinyalin iyi bir zaman-frekans gösterimini ortaya çıkardığı söylenebilir. Ancak burada da temel problem Heisenberg belirsizlik prensibidir. Bu prensibe göre daha önce de belirtildiği gibi bir frekansın tam olarak gerçekleşme zamanı bilinemez. Bunun yerine bir frekans bandının bir zaman aralığında gerçekleştiği söylenebilir. Buna göre KZFD için asıl problem seçilen pencerelerin genişliğidir. Pencereyi sonsuz genişlikte seçersek FD nü elde ederiz ve zaman bilgisine sahip olamayız. Sinyali durağan olarak inceleyebilmek için ise yeterince dar bir pencere seçilmelidir. Ancak bu durumda da zaman çözümlemesi çok iyi olmasına rağmen frekans çözümlemesi zayıf olacaktır. Yani küçük bir pencerede iyi zaman çözümlemesi, kötü frekans çözümlemesi elde edilirken büyük bir pencerede iyi frekans çözümlemesi, kötü zaman çözümlemesi elde edilir [77]

[79] [81]. Zaman – frekans ayrışımının çıktıları eşitlik 4.11 de verilen eşitlik ile alttan sınırlandırılır.

$$\Delta\tau.\Delta f \geq \frac{1}{4\pi} \tag{4.11}$$

Burada $\Delta\tau$ ve Δf sırasıyla zaman ve frekans ayrışımını (resolution) gösterir. $\Delta\tau$ ise pencere fonksiyonunun zaman genişliğinin kare ortalamalarının karekökü şeklinde tanımlanır ve eşitlik 4.12 ile hesaplanır.

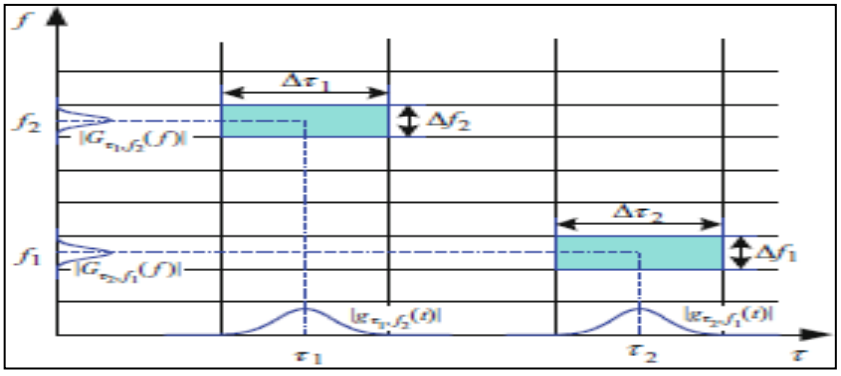
$$\Delta\tau^2 = \frac{\int \tau^2 |g(\tau)|^2 \, d\tau}{\int |g(\tau)|^2 \, d\tau} \tag{4.12}$$

Benzer şekilde Δf, pencere fonksiyonunun bant genişliğinin kare ortalamalarının karekökü olarak tanımlanır ve matematiksel olarak eşitlik 4.13 ile hesaplanır.

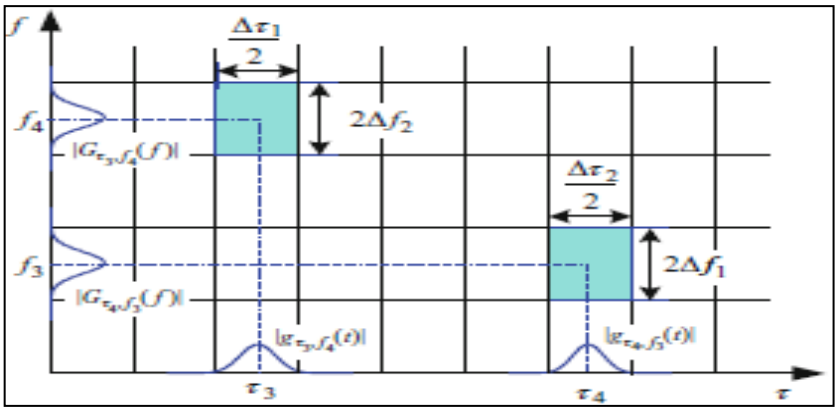
$$\Delta f^2 = \frac{\int f^2 |G(f)|^2 \, df}{\int |G(f)|^2 \, df} \tag{4.13}$$

G(t) fonksiyonu, g(t) pencere fonksiyonunun Fourier dönüşümüdür.

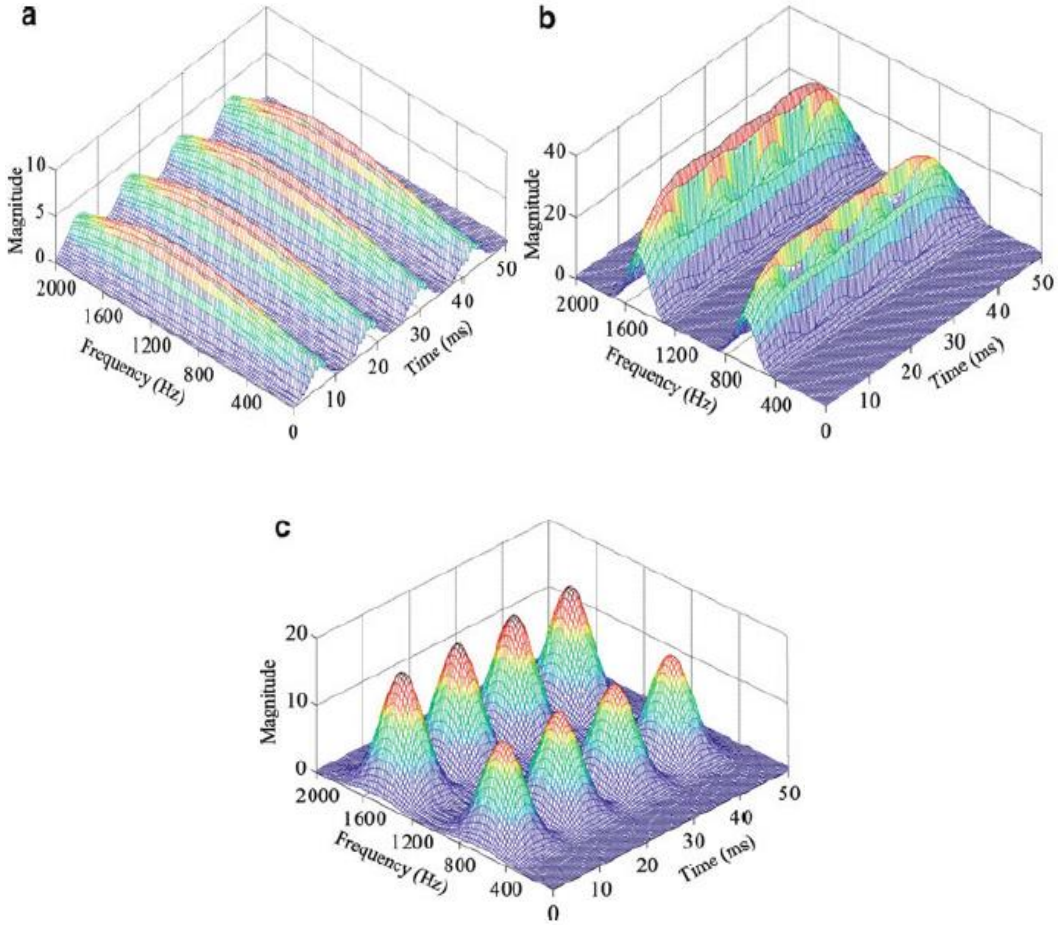
Bir sinyalin frekans ayrışımı sadece τ parametresine bağlıdır. İlk olarak pencere fonksiyonu seçildiğinden tüm sinyal boyunca zaman – frekans çözümlemesinde pencere genişliği sabittir. Şekil 4.7 ve 4.8 de görüldüğü gibi pencere genişliği τ veya $\tau/2$ olsa da pencerenin alanı sabittir.



Şekil 4. 7 KZFD ile Zaman – Frekans Çözümlemesi (Pencere Genişliği: τ)[79]



Şekil 4. 8 KZFD ile Zaman – Frekans Çözümlemesi
(Pencere Genişliği: $\tau / 2$)[79]



Şekil 4. 9 Üç Farklı Pencere Genişlikli Sinyalin KZFD nün Sonuçları
(a) Pencere Genişliği 1.6 ms, **(b)** Pencere Genişliği 25.6 ms, ve **(c)** Pencere Genişliği 6.4 ms [79]

Şekil 4.9 da Gauss Pencere Fonksiyonu kullanılarak bir sinyalin KZFD yapılmıştır. En küçük pencere genişliği olan 1.6 ms de en iyi zaman çözümlemesi sağladığı, ancak kötü

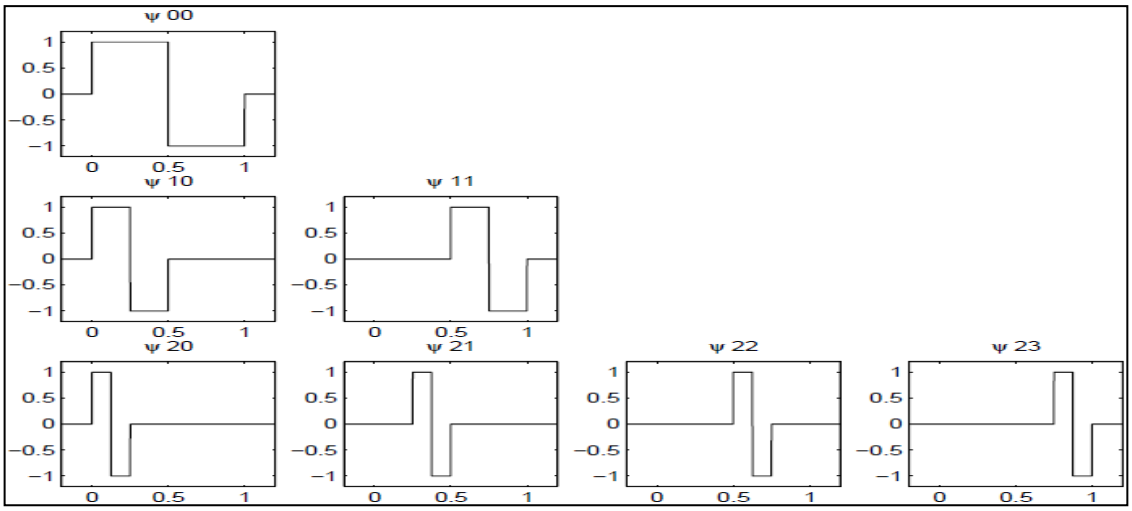
bir frekans çözümlemesi elde edildiği görülmektedir. En büyük pencere genişliği olan 25.6 ms de ise en iyi frekans çözümlemesi sağladığı, kötü bir zaman çözümlemesi elde edildiği görülmektedir. En iyi performans da 6.4 ms de elde edilmektedir. Ancak en iyi çözümleme için uygun pencere genişliğini bulmak KZFD da garanti değildir. DD, durağan olmayan sinyallerde daha iyi çözümleme için KZFD nün bu problemine çözüm getiren alternatif bir yöntemdir.

4.5 **Dalgacık Dönüşümü (DD)**

Heisenberg tarafından ortaya atılan belirsizlik prensibine göre hareketli bir parçanın momentumu ve tam pozisyonu anlık olarak bilinemez. Bu kurala göre sinyalin spektral bileşenlerinin zaman ekseninde tam olarak hangi anda olduğunu bilemeyiz. Onun yerine spektral bileşenlerin verilen bir zaman aralığında olduğunu bilebiliriz. Bu problem araştırmacıların KZFD yerine DD kullanmasının nedenini kanıtlamaktadır. KZFD sabit bir ayrıştırma verir. DD ise bir değişken çözümlemesi verir. Yüksek frekanslar zaman gösteriminde daha iyi ayrışırken düşük frekanslar frekans gösteriminde daha iyi ayrışır. Yani yüksek frekanslı bileşenler düşük frekanslı bileşenlere göre zaman gösteriminde daha az hatayla konumlandırılırken düşük frekans bileşenleri frekans gösteriminde yüksek frekans bileşenlerine göre daha iyi konumlandırılır.

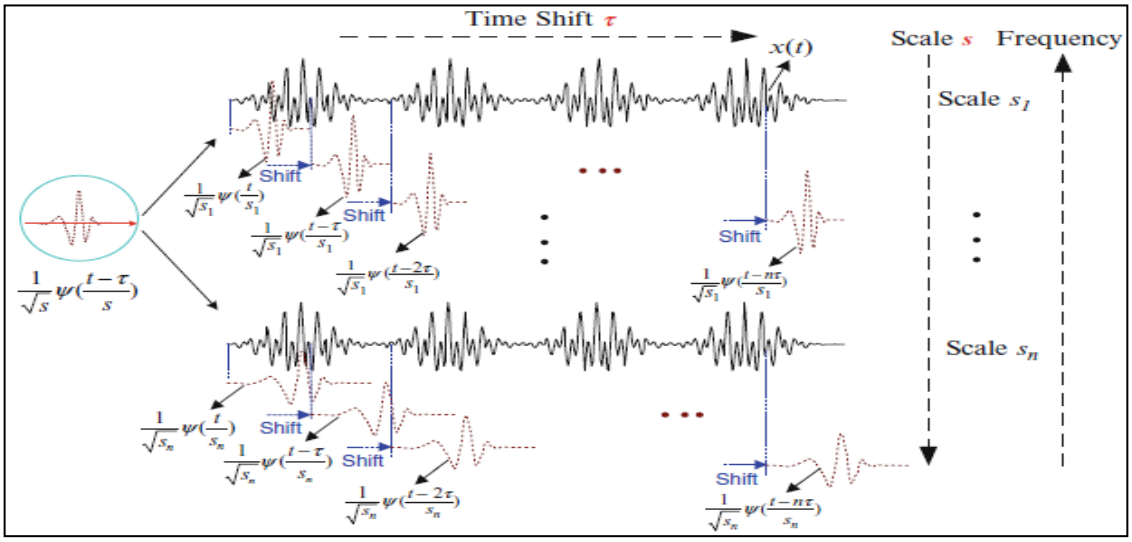
Dalgacıklardan ilk olarak Alfred Haar doktora tezinde bahsetmiştir. Haar dalgacığı ailesi, dikdörtgen baz fonksiyonundan elde edilmektedir. “Haaar Dalgacığı elde edilen en basit dalgacık ailesidir.” Bu dalgacığın fonksiyon denklemi ve 4.14 de grafiği şekil 4.10 da aşağıda gösterilmektedir.

$$\psi(x)=\begin{cases}1 & 0\le x<\frac{1}{2}\\ -1 & \frac{1}{2}\le x<1\\ 0 & x\notin[0,1]\end{cases} \qquad (4.14)$$



Şekil 4. 10 Haar Dalgacığının 3 Seviyede Açılımı

Dalgacık Dönüşümü, Jean Morlet tarafından yer altına gönderilen ses dalgaları yardımıyla yer altında petrolün olup olmadığını araştırmak amacıyla kullanılmıştır. KZFD de pencerelerin sabit olması probleme çözüm getirmemiştir. Bu sebeple Morlet frekans sabit kalırken pencerelerin genişleyip daralabilmesinin problemi çözebileceğini belirtmiştir. Morlet, genişliği değişen bu yapılara ilk kez "Wavelet" yani dalgacık adını vermiştir. ψ gerçek değerli olduğunda dalgacık tabanının ortanormal olduğunu ispatlamıştır [82]. Morlet, dalgacık dönüşümünde Haar' ın yönteminden farklı bir şey önermemiştir. Ancak ondan farklı olarak Grossmann ile birlikte dönüştürülen sinyalin orijinal haline dönüştürülürken hiçbir bilgi kaybına neden olmayacağını ispatlamışlardır [79] [82].



Şekil 4. 11 Dalgacık Dönüşümünün Gösterimi [79]

KZFD de pencereler sabit büyüklükte olmasına rağmen DD de frekans bileşenlerini analiz etmek için farklı genişlikte çeşitli pencereler kullanılır. Şekil 4.11 de de gösterildiği gibi DD sinyal ile $\psi(t)$ ana dalgacığı arasındaki benzerlikleri ölçek ve kaydırma parametrelerine bağlı olarak ortaya çıkarır.

İç çarpım notasyonu kullanılarak x(t) sinyalinin dalgacık dönüşümü:

$$wt(s,\tau) = < x, \psi_{s,\tau} > = \frac{1}{\sqrt{s}} \int_{-\infty}^{\infty} x(t) \psi^* \left(\frac{t-\tau}{s} \right) dt, \quad s > 0 \tag{4.15}$$

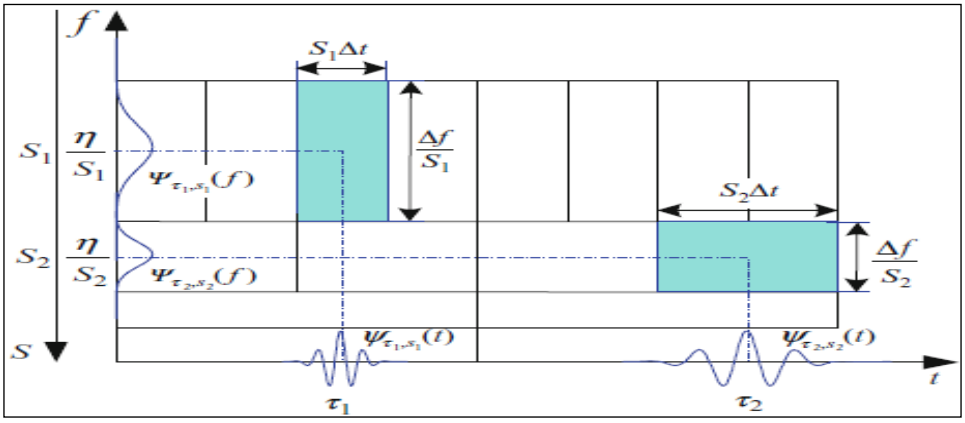
Burada verilen s, $\psi\left(\frac{t-\tau}{s}\right)$ fonksiyonunun zaman – frekans çözümlemesinin ölçeklendirme parametresidir ve sıfırdan büyük olmalıdır.

S, frekansın çarpma işlemine göre tersidir. τ sinyali zaman ekseninde ana dalgacığın kaydırma parametresidir. ψ^* ise ψ ana dalgacığının karmaşık eşleniğidir. Örneğin Morlet Dalgacığı ana dalgacık olarak seçilsin. Morlet Dalgacığı eşitlik 4.16 da verilmiştir. Bu dalgacığın ölçeklendirilmiş versiyonu eşitlik 4.17 de gösterilmiştir.

$$\psi(t) = e^{i2\pi f_0 t} e^{\frac{-(\alpha t^2/\beta^2)}{s^2\beta^2}} \tag{4.16}$$

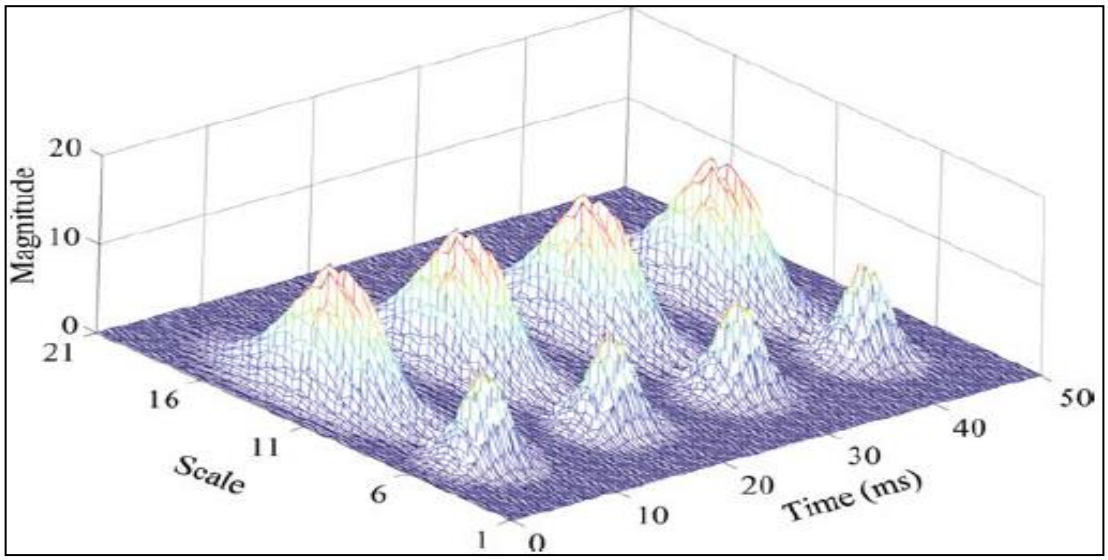
$$\psi\left(\frac{t-\tau}{s}\right) = e^{i2\pi f_0 \frac{t-\tau}{s}} e^{\frac{-\alpha(t-\tau)^2}{s^2\beta^2}} \tag{4.17}$$

Denklemde f_0, α ve β parametreleri sabittir. Morlet Dalgacığının zaman – frekans çözümlemesi $\Delta t = \frac{s\beta}{2\sqrt{\alpha}}$ ve $\Delta f = \frac{\sqrt{\alpha}}{s.2\pi\beta}$ yardımıyla hesaplanacaktır. Açıklamalar da göstermektedir ki zaman – frekans çözümlemesi direkt ve ters orantılı olarak ölçeklendirme parametresi ile ilişkilidir.



Şekil 4. 12 Dalgacık Dönüşümünün Zaman – Frekans Çözümlemesi [79]

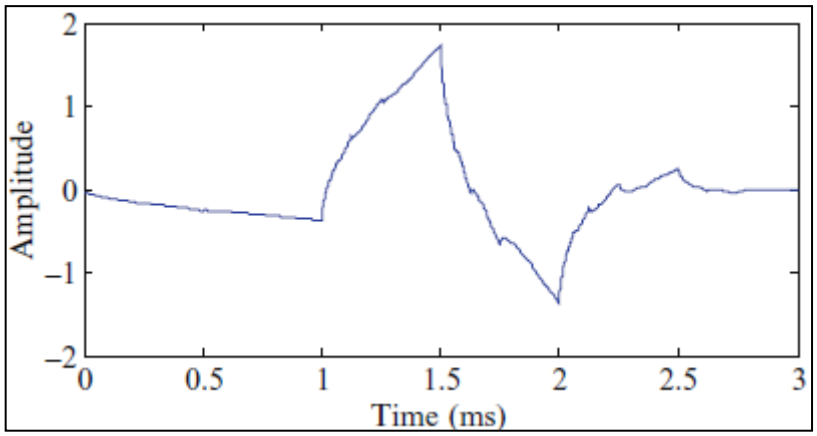
Şekil 4.12 de Morlet Dalgacığının $(\tau_1,\eta_1/s_1)$ ve $(\tau_2,\eta_2/s_2)$ frekans – zaman denklemlerindeki dalgacık çözümlemesi görülmektedir. Şekilden anlaşılacağı gibi ölçek s_1 den $2s_1$ e çıkarılırsa zaman çözümlemesi de yarıya düşmektedir.



Şekil 4. 13 Sinyalin Dalgacık Dönüşümü [79]

Grossmann, Morlet, Newman gibi araştırmacıların çalışmaları DD nün gelişmesinde önemli olsa da bu alanda en önemli adımı Çoklu Çözüm Analizi (Multiresolution Analysis) ile Stephen Mallat (1989, 1999) ve Yves Meyer (1989, 1993) atmıştır.

Çoklu Çözüm Analizi ile araştırmacıların kendi dalgacık ailelerini matematiksel olarak oluşturabileceklerini ortaya koymuştur. Daubechies de şekil 4.14 de verilen dalgacık ailesini ortaya çıkarmıştır(1988, 1992).



Şekil 4. 14 2 Basamaklı Daubechies Dalgacığı

DD görüntü işleme, ses işleme, sinyal analizi gibi birçok alanda kullanılmaktadır.

4.6 **Sürekli Dalgacık Dönüşümü (SDD)**

KZFD ne alternatif bir yaklaşım olarak sunulan SDD, çözümleme problemlerinin üstesinden gelmek amacıyla kullanılmaktadır. SDD, dalgacıklar ile sinyaller arasındaki benzerliklerini ölçmektedir. Verilen katsayılar ile sinyal arasındaki yakınlık o anki ölçeğe göre hesaplanır.

SDD, KZFD de olduğu gibi pencere fonksiyonuna benzer bir fonksiyonla sinyal çarpılır ve dönüşüm farklı zaman parçalarına göre hesaplanır. SDD ile KZFD arasında temel iki fark vardır [77]:

Pencere fonksiyonundan geçirilen sinyallerin Fourier dönüşümü yapılmaz. Sinüsoide benzer bir pik meydana gelir ve negatif frekanslar hesaplanmaz.

Her bir spektral bileşen hesaplanırken pencere genişliği değişecektir. Bu dalgacık dönüşümünün en önemli özelliklerinden biridir.

SDD aşağıda verilen 4.17 ve 4.18 eşitlikleriyle hesaplanacaktır:

$$SDD(s,\tau) = \int_{-\infty}^{\infty} x(t)\Psi_{s,\tau}^{*}\,dt \tag{4.18}$$

$$SDD(\tau,s) = \Psi_x^{\psi}(\tau,s) = \frac{1}{\sqrt{|s|}}\int_t x(t)\psi^{*}\left(\frac{t-\tau}{s}\right)dt \tag{4.19}$$

Görüldüğü gibi dalgacık dönüşümü iki değişken cinsinden bir fonksiyondur ve $x(t)$, $\psi(\mathrm{t})$ fonksiyonları da $L^2(R)$ kümesine dâhildir. Bu küme karesel integrallenebilir fonksiyonlar kümesini ifade etmektedir. İfadelerde yer alan * işareti verilen fonksiyonun karmaşık eşleniğidir. S ve τ değişkenlerin dönüşümden sonraki ölçek (scale) ve öteleme (translation) değerleri gibi yeni ölçüleridir. Eşitlik 4.18 $x(t)$ fonksiyonunun nasıl $\Psi_{s,\tau}(t)$ ana dalgacığından elde edilen dalgacıkların toplamı şeklinde ifade edileceğini göstermektedir. $\psi(t)$ ana dalgacık olarak adlandırılan dönüşüm fonksiyonudur. Ana denmesinin sebebi çeşitli bölgelerdeki pencere fonksiyonlarının üretildiği fonksiyon olduğundan verilmiştir. Diğer bir ifadeyle; ana dalgacık pencere fonksiyonlarının üretildiği bir prototiptir. Buna ek olarak wavelet terimi küçük bir dalgacığı ifade etmektedir. Dalga, fonksiyonun titreşimli olduğunu varsayar. Seçilen dalgacığın küçüklüğü de şartlara bağlı olarak pencere fonksiyonunun sonluluğuyla ilgilidir [77] [79] [81]. Ana dalgacık formülü eşitlik 4.20' de gösterilmiştir.

$$\Psi_{s,\tau}(t) = \frac{1}{\sqrt{|s|}}\psi\left(\frac{t-\tau}{s}\right) \tag{4.20}$$

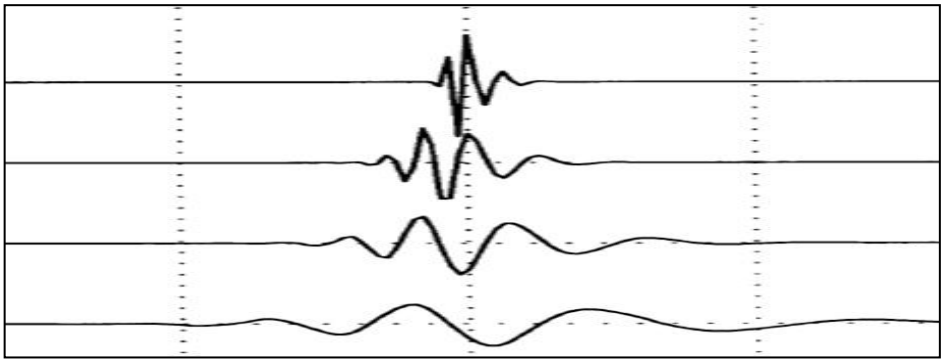
Eşitlikte *s* dalgacığın genişliğini gösteren ölçek değeri, τ dalgacığın zaman eksenindeki ötelendiği konum değerini, $\frac{1}{\sqrt{|s|}}$ değeri ise farklı ölçekler boyunca yapılan enerji normalleştirme katsayısını temsil etmektedir. Fourier dönüşümünde sinyalin farklı frekanslarda sinüs ve kosinüs fonksiyonlarına ayrıştırıldığı gibi sürekli dalgacık dönüşümünde de sinyal *s* ölçekli ve τ ötelemeli dalgacıklara ayrıştırılır. Bu terim, tam olarak dönüşüm yapılırken dönüşümdeki zaman bilgisine karşılık gelir. KZFD de frekans parametresi kullanılıyorken Sürekli Dalgacık Dönüşümünde frekans parametresi yerine $\frac{1}{frekans}$ olarak ifade edilen ölçek parametresi kullanılır.

Özetlemek gerekirse DD de belirtilen hesaplamalar öteleme ve ölçeklendirme terimlerine göre yapılır. Frekans ve zamana göre yapılmaz. Öteleme zamanla yakından ilgilidir. Çünkü ana dalgacığın konumunu gösterir. Ana dalgacığın ötelemesi $t=0$ da zamanın geçmesi olarak düşünülebilir. Ölçekte frekansın tam tersidir. Dalgacık

analizinde frekanslar ilgili söylenen her şeyin şekillerde zaman bölgesinde tam tersi görülecektir.

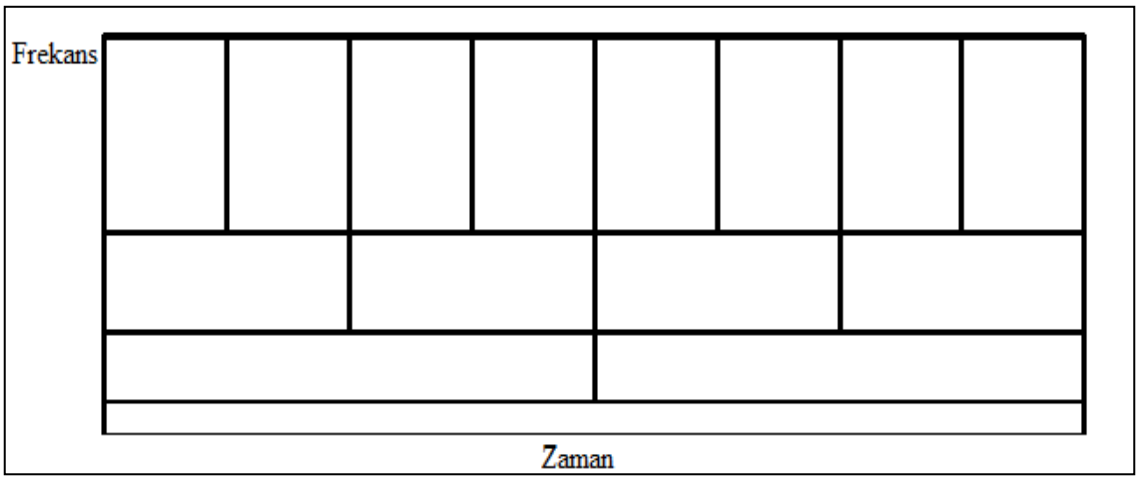
Sonuç olarak; KZFD tüm zaman ve frekanslarda sabit bir çözümlemeye sahiptir. DD ise yüksek frekanslarda iyi zaman çözümlemesine, zayıf frekans çözümlemesine sahiptir ve düşük frekanslarda iyi frekans çözümlemesine, zayıf zaman çözümlemesine sahiptir. Yüksek frekanslar daha iyi bir ölçek çözümlemesi sağlar. Dar ölçekte olma ölçeğin değerinin daha az belirsiz olması anlamına gelmektedir. Ancak bu zayıf bir frekans çözümlemesi sağlar. Benzer şekilde yüksek frekanslar düşük ölçek çözümlemesine sahiptir ki o daha geniş ölçek desteği ve daha belirsiz ölçek değeri olmasıdır. Fakat düşük frekanslarda daha iyi bir frekans çözümlemesine sahip olacaktır.

Şekilde $s = 1/2$, $s = 1$, $s = 3/2$, $s = 2$ değerleri için oluşturulan dalgacıklar gösterilmiştir. Ölçek ve öteleme değerlerinden yararlanılarak ana dalgacıktan birçok dalgacık üretebiliriz.



Şekil 4. 15 Farklı Yayılım Değerleriyle Üretilen Dalgacıklar

4.7 **Zaman-Frekans Çözümlemesi**



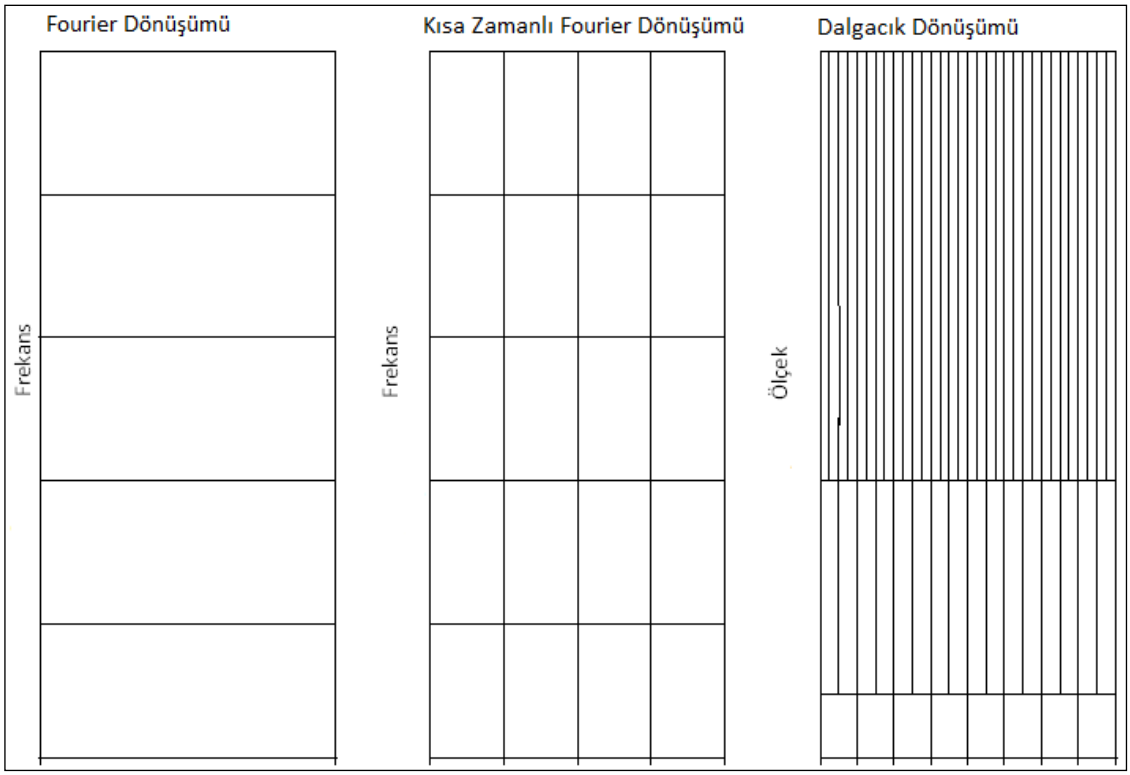
Şekil 4. 16 Dalgacık Dönüşümünün Frekans - Zaman Çözümlemesi

Şekilde gösterilen her bir kutucuk zaman-frekans düzeyinde bir dalgacık dönüşümü değerine karşılık gelir. Kutucuklar kesin bir sıfır olmayan alana sahiptir. Bu ise zaman frekansı yüzeyinde belirli bir frekansın yerinin bilinemeyeceğini gösterir. Belli bir alana düşen tüm değerler bir DD değeri tarafından temsil edilir.

Şekilde kutucukların genişlik ve yükseklikleri değişse de alanlarının sabit olduğu görülecektir. Her bir parça frekans zaman düzleminde eşit miktarda parçayı temsil etmesine rağmen farklı oranlarda etkisi vardır. Düşük frekanslarda kutuların yükseklikleri daha kısadır. Bu daha iyi frekans çözümlemesi yapıldığını gösterir. Çünkü tam frekansın ne olduğunu göstermek için az belirsizlik vardır. Yüksek frekanslarda kutuların genişliği azalır, zaman çözümlemesi daha iyi olur ve de kutuların yükseklikleri artar, frekans çözümü daha kötü olur.

Burada KZFD den farklı olarak kutuların eni ve boyu sabit değildir. Oysa KZFD de zaman ve frekans sabittir. Bu kısımda kareler meydana gelir. Çözümler de dalgacık dönüşümünden farklı olarak pencere fonksiyonunun genişliğine göre yapılmaktadır. Kutuların boyutlarından bağımsız olarak kutuların alanları her iki analizde de Heisenberg belirsizlik prensibine göre belirlenmektedir. KZFD de her pencere fonksiyonu için ve DD de her ana dalgacık alanları için de kutucukların alanları sabittir. Bu, farklı fonksiyonlar kullanılınca fonksiyona göre değişebilir. (Alan sabit kalmak şartıyla) Ancak tüm alanlar $\frac{1}{4\pi}$ değeri ile alt bantlandırılır. Bu bilgi doğrultusunda

Heisenberg belirsizlik prensibine göre kutuların alanları istenildiği kadar küçültülemez. Diğer taraftan verilen fonksiyona göre kutunun boyutları alan aynı kalmak koşulu ile değiştirilebilir. DD nün temel işlevi de budur.



Şekil 4. 17 Fourier Dönüşümünün ve Dalgacık Dönüşümünün Frekans - Zaman Çözümlemesi

4.8 **Sürekli Dalgacık Dönüşümünü Kesikli Hale Getirme**

DD de artıkların fazlalığı ve hesaplamaların oldukça uzun olması nedeniyle verilen problemleri integrasyon yoluyla veya analitik denklemlerle hesaplamak oldukça çok zor olmaktadır. Ayrıca sinyalin belli kısımlarda kesilmesi, bazı bölgeleri analiz etmenin zaman ve işlem yoğunluğu bakımından yük getirmesi sürekli yapıyı kesikli hale getirmeyi zorunlu kılmaktadır. Bunun için DD de küçük örneklemler alınarak işlem yapılacaktır. Ayrıca ölçek değişimi yapılarak örnekleme oranı azaltılmaktadır.

Nyquist Kuralı, orijinal sürekli sinyalin kesikli örneklemlerden yeniden oluşturulmasına izin veren en küçük orandır. Bu nedenle de temel dalgacık fonksiyonları açısından oldukça önemlidir. Yüksek ölçeklerde Nyquist Kuralına göre örneklem sayısı azaltılabilir. Düşük frekanslarda örneklem sayısı azaltılırsa oldukça fazla zaman tasarrufu sağlanmış

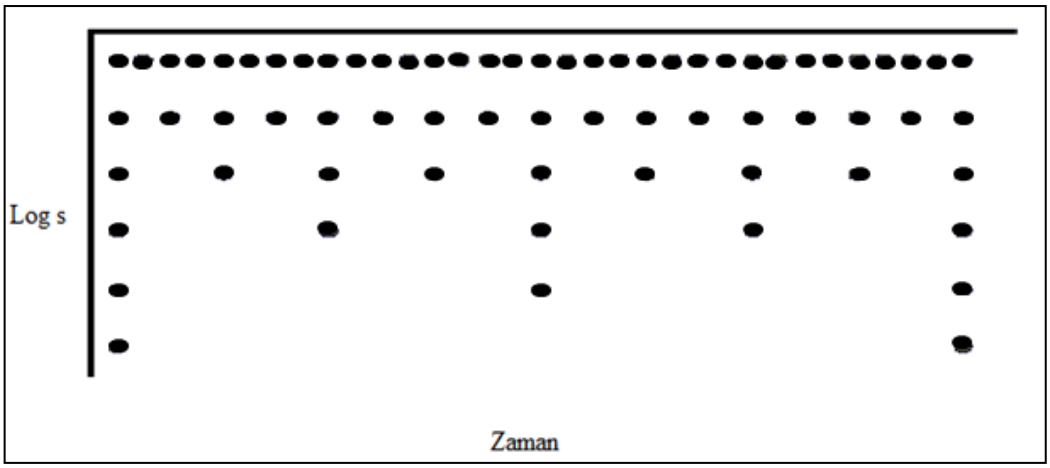
olur. Diğer bir ifadeyle zaman-ölçek yüzeyinde s_1 ölçeğinde N_1 tane örneklem ile örnekleme yapılabiliyorken, s_2 ölçeğiyle $s_1 < s_2$ olacak şekilde ($f_1 > f_2$) ve $\mathrm{N}_2 < \mathrm{N}_1$ şeklinde örnekleme yapılabilir. N_1 ve N_2 arasındaki ilişki 4.21 veya 4.22 eşitlikleriyle gösterilebilir.

$$\mathrm{N}_2 = \frac{s_1}{s_2}\mathrm{N}_1 \tag{4.21}$$

$$\mathrm{N}_2 = \frac{f_2}{f_1}\mathrm{N}_1 \tag{4.22}$$

Bu konudaki önemli sorunlardan biri de sürekli dalgacık dönüşümünün kesikli hale getirilmesi durumunda ölçek parametreleri ile yeniden oluşturulmasıdır. Oluşturmak kesinlikle mümkündür.

İlk olarak "s" ölçek parametresi logaritmik tabanda kesikli hale getirilir. Her ölçekte farklı örnekleme parametresi kullanılır. Diğer bir ifadeyle örnekleme ikincil bir örnekleme tabanında yapılır. Şekil 4.18 de 2 tabanında yapılan örnekleme ile kesikli hale getirilen sinyal görülmektedir. Toplamda 32 adet örnek ortaya çıkmıştır.



Şekil 4. 18 Örnekleme Yapılan Sürekli Bir Sinyal Örneği

Matematiksel olarak ölçeğin kesikli hale getirilmesi $s = s_0^j$ ve dönüşümün kesikli hale getirilmesi $\tau = k.s_0^j.\tau_0$; $s_0 > 1$ ve $\tau_0 > 0$ eşitlikleri ile olacaktır. Dönüşümün kesikli hale getirilmesi s_0 da ölçeği kesikli hale getirmeye bağlıdır. Şöyle ki;

Eşitlik 4.20 de verilen dalgacık fonksiyonunda s ve τ yerine $s = s_0^j$ ve $\tau = k.s_0^j.\tau_0$ yazılırsa $\psi(t)$ dönüşüm fonksiyonu eşitlik 4.23 te belirtilen şekle dönüşecektir. Eğer $\{\psi_{j,k}\}$ ortanormal bir taban oluşturuyorsa dönüşüm eşitlik 4.24 veya eşitlik 4.25 teki gibi olacaktır.

$$\psi_{j,k}(t) = s_0^{-j/2}\psi(s_0^{-j}t - k\tau_0) \tag{4.23}$$

$$\Psi_x^{\psi_{j,k}} = \int x(t)\psi_{j,k}^*(t)dt \tag{4.24}$$

$$x(t) = c_\psi \sum_j \sum_k \Psi_x^{\psi_{j,k}} \psi_{j,k}(t) \tag{4.25}$$

$$\Psi_x^{\psi_{j,k}} = \int_t x(t)\psi_{j,k}^*(t)dt \tag{4.26}$$

Bir wavelet serisinde $\psi_{j,k}$' nin ortanormal, biortagonal ve çerçeve (frame) olması gerekir. Eğer $\psi_{j,k}$ ortanormal değilse 4.24 eşitliği eşitlik 4.26 daki gibi yazılacaktır. Burada üst $\psi_{j,k}^*(t)$ dual biortanormal veya dual frame olacaktır. Eğer $\psi_{j,k}$ ortanormal veya biortagonal ise dönüşüm kalıntısız olacaktır. Eğer dönüşüm çerçeve oluşturuyorsa kalıntı dönüşümde olacaktır. Diğer taraftan çerçeveyi bulmak ortagonal veya biortagonal bulmaktan daha kolaydır. Bu durumu açıklamak amacıyla bir örnek verelim [77]:

İnsan gözüne nesnelerin uzaklığına bağlı olarak genel bir bakışa karar verir. Buna s_0^{-j} ölçek parametresi uygun düşer. Cisme oldukça yakından ve detaylı olarak bakılacak olursa j negatif veya büyük olur (yüksek frekans, düşük ölçek sinyalde detayları analiz eder). Kafayı küçük adımlarla hareket ettirmek $\tau = k.s_0^j.\tau_0$ nun küçük değerlerine karşılık gelir. Burada j eğer negatif ve büyükse bu, zaman ekseninde az bir değişime karşılık gelir(τ yüksek örneklem oranı ve büyük değişiklikler) s_0^{-j}(yüksek frekans düşük ölçektir ve örneklem oranı yüksektir). Ölçek parametresi aynı zamanda büyüme parametresi olarak da gösterilebilir. Cevaplanacak asıl soru örnekleme parametresinin yeniden oluşturma için ne kadar düşük olabileceğidir. Değerleri optimize etmek için

genel olarak $s_0 = 2$ ve $\tau = 1$ alınmaktadır. Örnekleme oranını olabildiğince küçük olması için zorlarsak uygun ortanormal dalgacık sayısı azalacaktır.

4.9 **Kesikli Dalgacık Dönüşümü (KDD)**

Sürekli Dalgacık Dönüşümünde verilerin analizinde yapılan hesaplamalar karmaşıklık meydana getirirken bunun yanında bir de artık problemi ortaya çıkar. Ayrık Dalgacık Dönüşümü (ADD) de bu problemin çözümü için tüm parçalara gerek duyulmadan ve veri kaybına neden olmadan çözülmesini sağlar. SDD ile mantıksal olarak bir fark yoktur. SDD den farklı olarak KDD verileri birbirine dik dalgacıklara ayrıştırır. Kesikli dalgacık denklem 4.27' deki gibi tanımlanmıştır.

$$\psi_{i,k}(t) = \frac{1}{\sqrt{s_0^j}} \psi \left(\frac{t - k\tau_0 s_0^j}{s_0^j} \right) \tag{4.27}$$

Denklemde j ve k değerleri tamsayıdır. Ayrıca $s_0 > 1$ olmak üzere bu değer sabitlenmiş genişleme adımı, τ_0 da genişleme değerine bağlı öteleme faktörüdür. Kesikli dalgacık dönüşümünün öteleme fonksiyonu ve dalgacık fonksiyonu eşitlik 4.28 ve 4.29' daki gibi tanımlanmıştır.

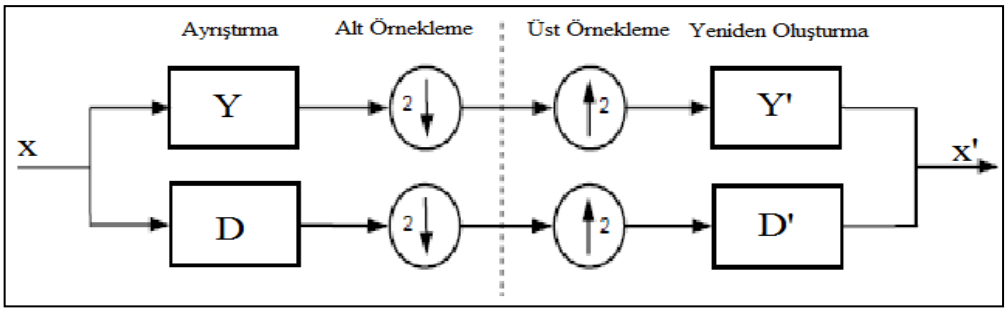
$$\varphi(2^j t) = \sum_{i=1}^{k} h_{j+1}(k) \varphi(2^{j+1} t - k) \tag{4.28}$$

$$\psi(2^j t) = \sum_{i=1}^{k} g_{j+1}(k) \varphi(2^{j+1} t - k) \tag{4.29}$$

Bu bilgiler kullanılarak x*(t)* fonksiyonu eşitlik 4.30' daki gibi yazılabilir:

$$x(t) = \sum_{i=1}^{k} \lambda_{j-1}(k) \varphi(2^{j-1} t - k) + \sum_{i=1}^{k} \gamma_{j-1}(k) \psi(2^{j-1} t - k) \tag{4.30}$$

Ayrık dalgacık dönüşümü, Mallat' ın geliştirdiği Filtreleme Öbeği Şeması kullanılarak yapılabilir. Şekil 4.19 KDD için iki kanallı filtreleme öbeği şemasını göstermektedir.

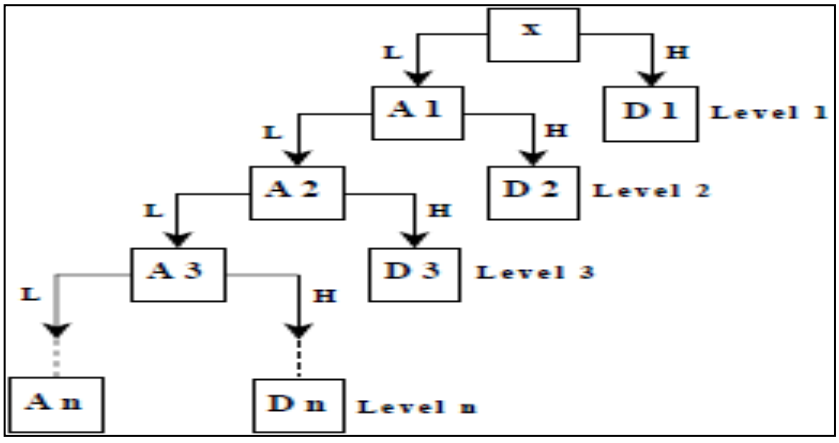


Şekil 4. 19 KDD için Filtreleme Öbeği Şeması

Şekilde görülen Y, D, Y',D' ifadeleri dalgacık dönüşümünde ayrıştırma ve yeniden birleştirme için düşük (low-pass) ve yüksek geçirgen (high-pass) filtreleri ifade etmektedir. Ayrıştırma aşamasında, low-pass filtre yüksek frekans bileşenlerini sinyalden çıkarır ve high-pass filtre bu parçaları alır. Sonra, ayrıştırılan sinyaller iki alt örnekleme ayrılır. Elde edilen sonuçlar yaklaşım katsayıları ve detay katsayıları olarak adlandırılır. Yeniden birleştirme kusursuz yeniden yapılandırma için sadece filtreleme öbeklerinin geriye yapılandırma işlemdir. Burada $x = x'$ dir. Eşitlik 4.31 de gösterildiği gibi bir sinyal ayrıca kademeli algoritma ile ayrıştırılabilir.

$$\begin{aligned} x(t) &= A_1(t) + D_1(t) \\ &= A_2(t) + D_2(t) + D_1(t) \\ &= A_3(t) + D_3(t) + D_2(t) + D_1(t) \\ &= A_n(t) + D_n(t) + D_{n-1}(t) + \ldots + D_1(t) \end{aligned} \qquad (4.31)$$

Denklemde $A_n(t)$ ve $D_n(t)$ katsayıları n seviyesindeki ayrıntı ve yaklaşım katsayılarıdır. Şekil 4.20 de bu sinyalin ayrıştırma değerlerinin ağaç diyagramı gösterilmiştir.



Şekil 4. 20 Dalgacık Ayrıştırma Ağaç Diyagramı

KDD nün önemli bir potansiyel sorunu değişen varyans durumunun ortaya çıkmasıdır. Böyle durumlarda KDD yerine Durağan Dalgacık Dönüşümü (DDD) yapılır. KDD ile DDD şekil olarak aynıdır ancak sinyale KDD de olduğu gibi alt örnekleme yapılmaz. Bunun yerine sadece üst örnekleme yapılır. Daha esnek bir analiz kullanılması istenirse KDD yerine Paket Dalgacık Dönüşümü (PDD) kullanılır. PDD kesikli dalgacık dönüşümüne oldukça benzerdir. Aralarındaki fark KDD de yalnızca yaklaşım katsayıları (approximation coefficients) ayrıştırılıyorken paket dalgacık dönüşümünde hem detay hem yaklaşım katsayıları ayrıştırılmaktadır. Bu nedenle PDD daha karmaşık ve daha esnek bir analiz ortaya koyar. Kesikli Dalgacık Dönüşümünü daha iyi anlamak için Alt Bant kodlaması ve Çoklu Çözüm Analizi konusuna değinilecektir.

4.10 **Alt Bant Kodlaması ve Çoklu Çözüm Analizi**

Kesikli dalgacık Dönüşümünün kökleri 1976'ya dayanmaktadır. Croiser, Esteban ve Galand kesikli sinyalleri ayrıştırmak için KDD nü ortaya atmışlardır. Crochiere, Weber ve Flanagan alt bant kodlama adı verilen ses sinyali işleme çalışmasını aynı yıllarda yapmışlardır. Burt de 1983' te alt bant kodlamasına benzer olan piramit kodlama (Çoklu Çözüm Analizi) adı verilen çalışmayı yayınlamışlardır. Daha sonra 1989 da Vetterli ve Le Gall piramit kodlamayı geliştirerek çoklu çözüm analizine katkı sağlamışlardır [77].

Sürekli DD analiz penceresinin ölçeğini değiştirerek pencereyi zaman ekseninde kaydırıp sinyal ile çarparak ve tüm zamanlarda integral alarak hesaplanır. Kesikli DD de farklı kesme frekanslar, filtreleri farklı ölçeklerde analiz etmek için kullanılır. Yüksek frekansları analiz için yüksek çözünürlük filtresinden, düşük filtreleri analiz için düşük çözünürlük filtresinden geçirilerek analiz gerçekleştirilir.

Sinyalin ayrıştırılması filtreleme operasyonlarına göre değişmekte ve ölçekleme parametreleri üst örnekleme ve alt örnekleme yöntemlerine göre değişmektedir. Alt örnekleme sinyalin örnekleme oranını düşürmektir veya sinyaldeki bazı örnekleri çıkarmak demektir. N faktörlü bir alt örnekleme sinyaldeki örneklem sayısını n kez düşürür. Üst örnekleme ise sinyalin örnekleme oranını yeni örneklemler ekleyerek arttır. N faktörlü bir üst örnekleme sinyalin örneklem sayısını n faktör kadar

arttıracaktır. $x[n]$ serisi bir kesikli zaman serisi olarak kullanılır. Süreç, seriyi $h[n]$ şeklinde itici bir güç ile düşük geçirgen filtreden geçirmeyle başlar.

Bir sinyali filtreleme, bükülme sinyal ile filtrenin karşılığının matematiksel ifadesidir. Kesikli zamanda bükülme aşağıdaki gibi ifade edilir.

$$x[n].h[n] = \sum_{k=-\infty}^{\infty} x[k].h[n-k] \tag{4.32}$$

Yarı bant düşük geçirgen filtre ortanca frekanstan düşük olan tüm sinyalleri çıkarır. Örneğin 1000 Hz lik bileşenleri olan bir sinyalde yarı bant düşük geçirgen filtre maksimum 500 üstünde olan tüm frekansları çıkarır. Sürekli sinyallerde Hz kullanılmaktadır. Kesikli sinyallerde ise frekans birimi radyandır. Düşük geçirgen filtreden geçirilen sinyalde p radyan olan en yüksek frekans filtrelemeden sonra $\frac{p}{2}$ radyan olacaktır. Sinyaldeki diğer örneklemleri çıkarılınca sinyal eldeki noktaların yarısına sahip olacaktır. Alt filtreleme yüksek frekansları temizler ancak ölçeği değiştirmeden bırakır. Bu sebeple alt örnekleme yapılarak ölçek değiştirilir. Çözümleme, filtreleme operasyonlarından etkilenen, sinyaldeki bilgi miktarıyla yakından ilişkili bir işlemdir. Özetle düşük geçirgen filtreleme çözümlemeyi ikiye ayırır ancak ölçek aynı kalır. Ardından sinyal, örneklemlerin yarısı kalıntı olduğundan 2 alt örneklemlendirilir. Bu işlem ölçeği ikiye katlar. İşlemlerin matematiksel ifadeleri aşağıda verilmiştir;

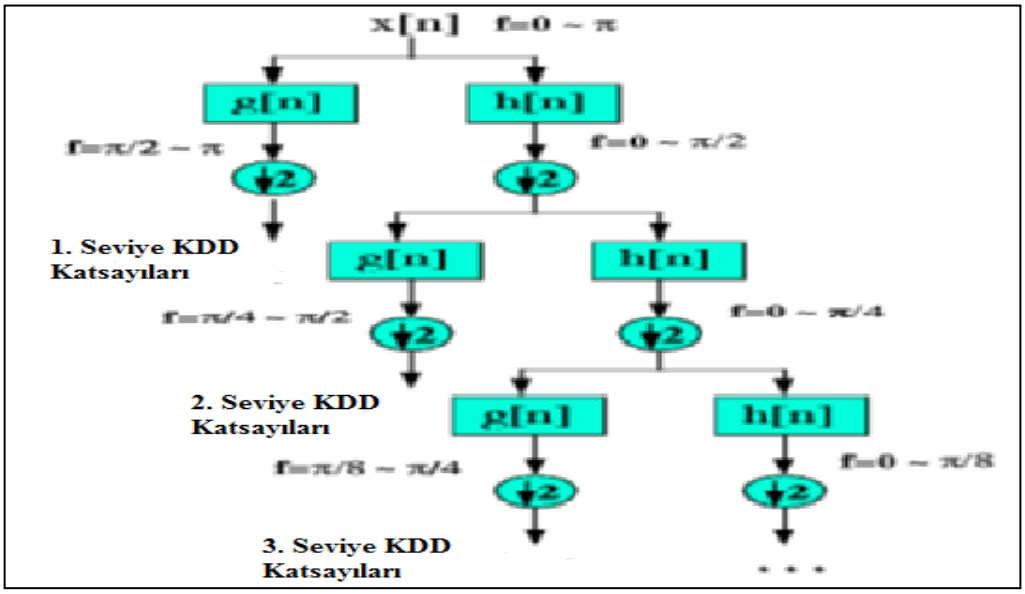
$$y[n] = \sum_{k=-\infty}^{\infty} h[k].x[2n-k] \tag{4.33}$$

KDD, sinyali farklı frekans bantlarında farklı çözümlemelerle kaba ve ayrıntılı bilgilere ayrıştırarak inceler. KDD de ölçeklendirme ve dalgacık fonksiyonu olmak üzere iki çeşit fonksiyon işlem görür. Bunlar yüksek ve düşük geçirgen filtreleri birbirine bağlarlar.

$$y_{yüksek} = [k] = \sum_{n} x[n]\, g[2k-n] \tag{4.34}$$

$$y_{düşük} = [k] = \sum_{n} x[n] h[2k-n] \tag{4.35}$$

Yukarıda görüldüğü gibi $x[n]$ orijinal sinyali, $g[n]$ yüksek çözünürlüklü filtreden ve $h[n]$ şeklindeki düşük çözünürlüklü filtreden geçirilir. Nyquist kuralına göre filtrelemeden sonra verilerin yarısı çıkarılabilir. Sinyal bundan sonra p yerine $\frac{p}{2}$ yüksek frekansa sahip olur. Sinyal bundan sonra iki alt örnekleme düşürülür, diğer örneklemler elenir. Burada $y_{yüksek}$ ve $y_{düşük}$ sırasıyla yüksek ve düşük çözünürlüklü filtrelerin iki alt örnekleminden elde edilen çıktılardır. Ayrıştırma, zaman çözümlemesini ikiye böler, frekansı ikiye katlar. Yani daha net şekilde frekans incelenirken frekanstaki belirsizlik de azalmış olur. Bu işleme alt bant kodlaması denir. Şekil 4.21 de bu işlemin görsel olarak anlatımı bulunmaktadır.



Şekil 4. 21 Bir Sinyalin Ayrıştırma Basamakları

Düşük geçirgen ve yüksek geçirgen filtreler birbirinden bağımsız değildir.

$$g[L-1-n]=(-1)^n h[n] \tag{4.36}$$

Denkleminden bu ilişki görülebilir. Burada $g[n]$ yüksek çözünürlüklü, $h[n]$ de düşük çözünürlüklü filtredir. Düşükten yükseğe $(-1)^n$ terimi ile geçiş yapılabilmektedir. Dört Evreli Ayna Filtreleri (QMF-Quadrature Mirror Filters) olarak da bilinen bu özellik sinyal işlemede yoğun olarak kullanılmaktadır. Bu iki filtreleme ve alt örnekleme şu şekilde özetlenebilir;

$$y_{yüksek}[k] = \sum_n x[n].g[-n+2k] \tag{4.37}$$

$$y_{düşük}[k] = \sum_n x[n].h[-n+2k] \tag{4.38}$$

Yarı bant filtreleri ortanormal taban oluşturunca sinyali yeniden oluşturmak oldukça kolay olmaktadır. Buradaki ilginç özellik analiz ve sentez fonksiyonlarının aynı olmasıdır. Zaman dönüşümü bunun dışındadır.

Her tabaka için yeniden oluşturma formülü;

$$x[n] = \sum_{k=-\infty}^{\infty} \left(y_{yüksek}[k].g[-n+2k]\right) + \left(y_{düşük}[k].h[-n+2k]\right) \tag{4.39}$$

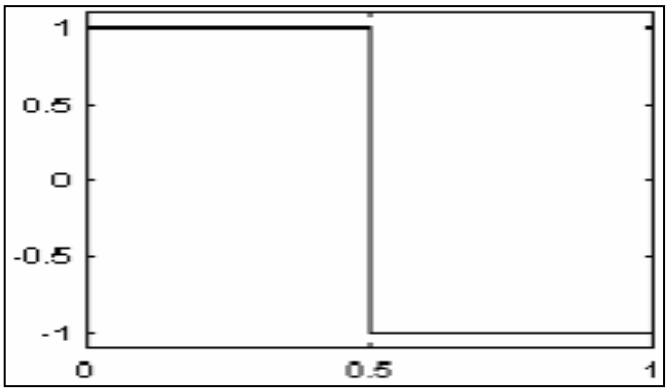
Eğer filtreler ideal yarı bant değillerse yeniden oluşturma mümkün olmaz. İdeal filtreleri bulmak mümkün olmasa da kesin koşullar altında mükemmel yeniden oluşumu sağlayacak filtreleri bulmak mümkündür. Bunlardan biri Ingrid Daubechies tarafından geliştirilen Daubechies Dalgacıklarıdır.

2 ile alt örnekleme yapmak için sinyal ikinin katı veya kuvvetleri şeklinde olmalıdır. Sinyal uzunluğu çözümlemenin (decompozition) seviyesine karar verirken kullanılır. Örneğin: 2048 uzunluğunda bir sinyal çözümlendiğinde 11 seviye ortaya çıkacaktır. KDD katsayılarını yazmak daha zordur. Çünkü her seviyeye ait katsayılar sıralanmıştır. Ancak bu sıra en son seviyeden başlar [77].

4.11 **Ana Dalgacık Türü Örnekleri**

4.11.1 Haar Dalgacığı

Dalgacıklardan ilk olarak Alfred Haar doktora tezinde bahsetmiştir. Haar dalgacık ailesi, dikdörtgen baz fonksiyonundan elde edilmektedir. Literatürde Haar Dalgacığının elde edilen en basit dalgacık ailesi olduğu belirtilmektedir. Bu dalgacığın fonksiyon denklemi eşitlik 4.14 de grafiği şekil 4.22 de gösterilmektedir.

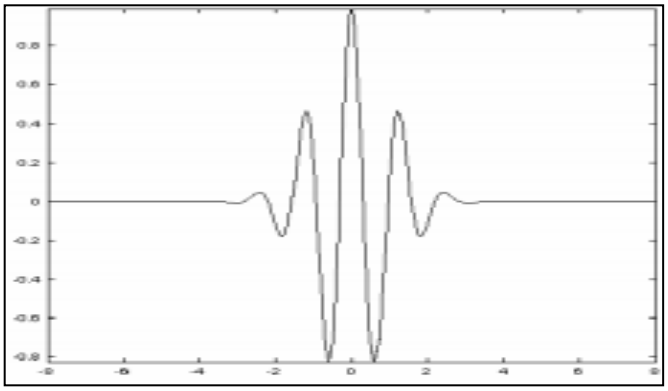


Şekil 4. 22 Haar Dalgacık Fonksiyonu

4.11.2 Morlet Dalgacığı

Morlet' in temel dalgacık fonksiyonu Gauss pencere fonksiyonu ile Fourier baz fonksiyonunun çarpımına eşittir. Burada a değişim (geçiş) parametresi, σ da ölçeklendirme parametresi(bu parametre pencere genişliğini etkilemektedir.) olarak belirlenmiştir. Fonksiyon eşitlik 4.40' da ifade edilmiştir. Bu fonksiyonun grafiği de şekil 4.23 te gösterilmiştir.

$$w(t) = e^{iat}.e^{\frac{-t^2}{2\sigma}} \tag{4.40}$$



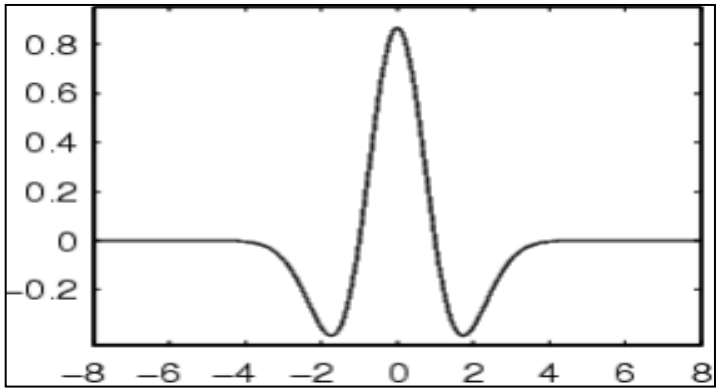
Şekil 4. 23 Morlet Dalgacığı Fonksiyonu

4.11.3 Meksika Şapkası Dalgacığı

Meksika şapkası dalgacığı, Gauss fonksiyonunun negatif normalizasyonunun ikinci türevi olan ve Hermit fonksiyonu olarak bilinen halidir. Hermit dalgacıkları sürekli dalgacık ailesinden gelen özel bir dalgacık fonksiyonudur ve literatürde bu dalgacık

ailesi genellikle Meksika Şapkası Dalgacığı olarak bilinir. Bu dalgacık fonksiyonu eşitlik 4.41 de gösterilmiştir.

$$\psi(\mathrm{t}) = \frac{2}{\sqrt{3\sigma}\pi^{\frac{1}{4}}}(1-\frac{t^2}{\sigma^2})e^{\frac{-t^2}{2\sigma^2}} \tag{4.41}$$



Şekil 4. 24 Meksika Şapkası Dalgacık Fonksiyonu

*Meksika Şapkası, Gauss Fonksiyonunun 2. türevinin alınmasıyla ortaya çıkan fonksiyon olarak verilmiştir.

$$w(t) = \frac{1}{\sqrt{2\pi}\sigma}e^{\frac{-t^2}{2\sigma^2}} \tag{4.42}$$

Öyle ki

$$\psi(t) = \frac{1}{\sqrt{2\pi}\sigma^3}\left(e^{\frac{-t^2}{2\sigma^2}}.\left(\frac{t^2}{\sigma^2}-1\right)\right) \tag{4.43}$$

Olacaktır.

4.11.4 SLOG Dalgacığı

SLOG Dalgacığı (Superposed LOGistic) yani çakışık lojistik fonksiyonları ağırlıklandırılmış ve gecikmeli lojistik fonksiyonlarının sonlu süreli toplamlarından meydana gelmektedir. Lojistik fonksiyonu genellikle yapay sinir ağı modellerinde aktivasyon fonksiyonu olarak kullanılan monoton artan, pürüzsüz, asimptotik bir işlev türüdür. Asimetrik tek kutuplu bir biçime sahip olan lojistik fonksiyonu eşitlik 4.44' te gösterilmiştir [75].

$$f(t) = \frac{1}{1+e^{-t}} \tag{4.44}$$

4.11.5 POLYWOG Dalgacığı

POLYWOG (POLYnomials WindOwed with Gaus) tipi fonksiyonlardan birçok kullanışlı ana dalgacık elde edilir. Örneğin Gauss fonksiyonunun tüm türevleri ana dalgacık olarak kabul edilebilecek POLYWOG fonksiyonlarıdır [75].

POLYWOG1: $\mathrm{h}_{\mathrm{POLYWOG1}} = \mathrm{k}_1 \mathrm{t}\, \mathrm{e}^{\frac{-t^2}{2}}$, $k_1 = \sqrt{e}$ (4.45)

POLYWOG2: $\mathrm{h}_{\mathrm{POLYWOG2}} = \mathrm{k}_2(\mathrm{t}^3\text{-}3\mathrm{t})\mathrm{e}^{\frac{-t^2}{2}}$, $\mathrm{k}_2 = 0{,}7246$ (4.46)

Dalgacıklar verilen örneklerle sınırlı değildir. Bu dalgacık aileleri haricinde Daubechies, Meyer, Biortoaonal, Ters Biortogonal, Spline, Coiflet, Symlet, Shannon Dalgacık aileleri de örnek olarak verilebilir. Konu ile ilgilenen kişiler bir probleme çözüm getirecek dalgacık fonksiyonu yazarak kendi dalgacık ailesini oluşturabilir.

BÖLÜM 5

UYGULAMA

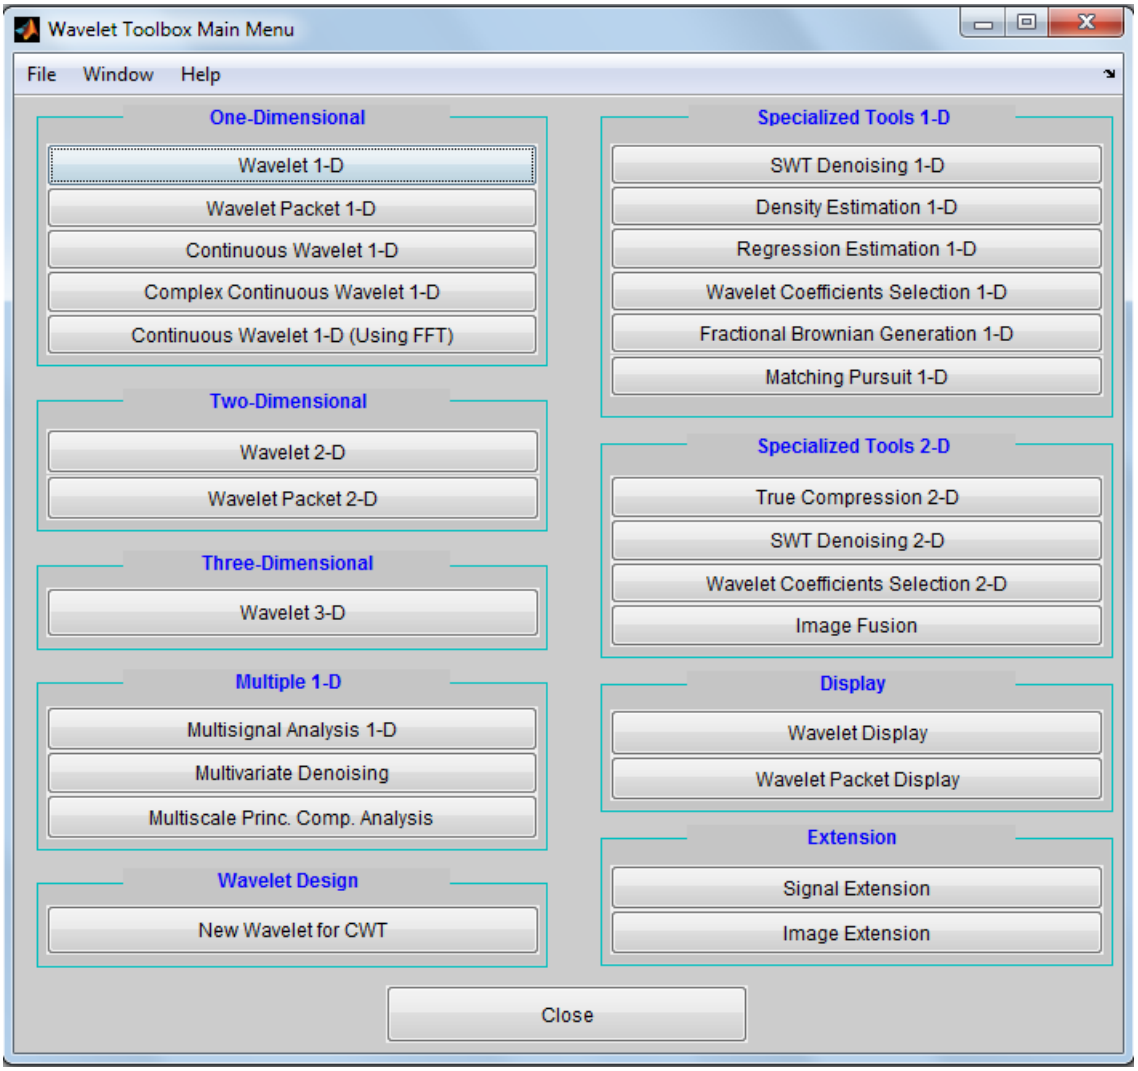
5.1 **Kullanılan Veriler**

Çalışmada birinci bölümde belirtilen hisse senedi ile ilgili çalışmalardan faydalanılarak hisse senetlerini etkilediği düşünülen temel değişkenler girdi olarak kullanılmıştır. Bu girdi değerleri ulusal 100 indeksi kapanış değeri (XU100), ulusal 30 indeksi günlük kapanış değeri (XU030), bankacılık indeksi günlük kapanış değeri (XBANK), ulusal mali indeksi günlük kapanış değeri (XUMAL), ulusal tüm indeksi günlük kapanış değeri (XUTUM), dolar günlük kapanış fiyatı, avro günlük kapanış fiyatı, sterlin günlük kapanış fiyatı, altın ons günlük kapanış fiyatı, devlet iç borçlanma senetleri günlük kapanış indeksi (DIBS_GFI) dir. Hedef değeri olarak ulusal 30 indeksinde yer alan hisse senetlerinden 6 tanesi rastgele olarak seçilerek analiz edilmiştir. Hisse senetleri kullanılan işletmelerin bilgileri ve isimleri çalışmada belirtilmemiştir. Ulusal tüm indeksi ve ulusal bankacılık indeksi mali sektör hisse senetlerinde kullanılmıştır. Diğer değişkenler tüm hisse senetlerinde kullanılmıştır.

Hisse senetleri ve girdiler en çok kullanılan dalgacık ailelerinden Daubechies Dalgacıklarından DB5 ve DB6 dalgacıkları ile süzülerek gürültülerinden temizlenmiştir. Analizlerde 05.01.2000 ile 01.01.2013 tarihleri arasındaki 3232 iş gününe ait veriler kullanılmıştır. Eğitimde kullanılan veriler %75 eğitim, %15 geçerlilik ve %10 test amacıyla ayrılarak kullanılmıştır. Modeller işlenmemiş veriler ve işlenmiş verilerle kurularak tahmin başarıları irdelenmiştir.

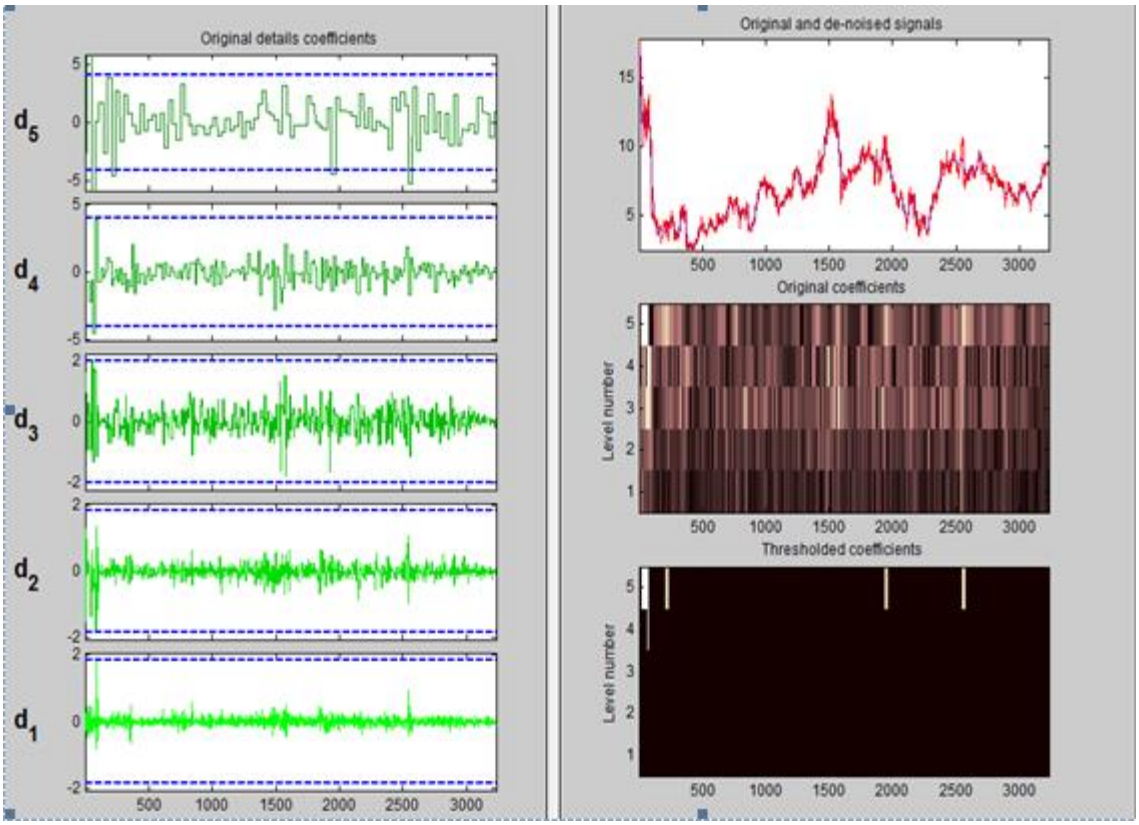
5.1.1 Verilerin Dönüştürülmesi

Dalgacık dönüşümü ile verilerimizin gürültülerden temizlendiği belirtilmiştir. Bu amaçla Matlab programının şekil 5.1 de gösterilen Wavelet Toolbox aracından yararlanılmıştır.

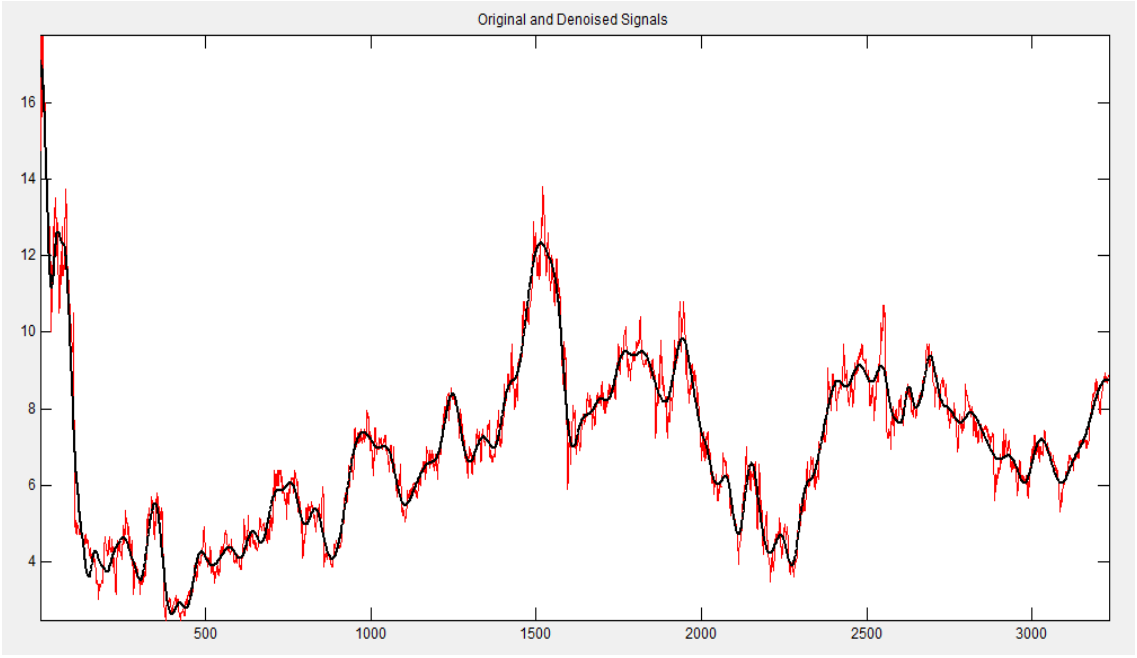


Şekil 5. 1 Matlab Programı Dalgacık Dönüşümü Arayüzü

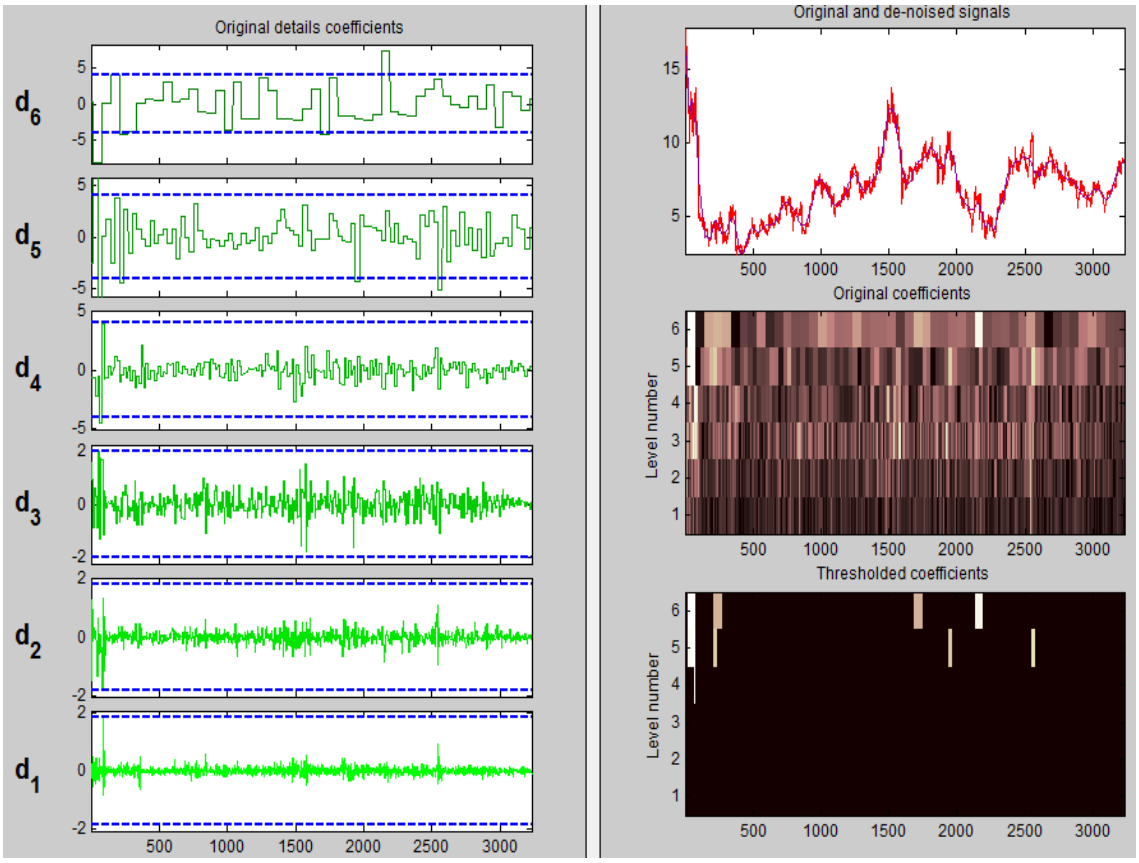
Aşağıda hisse senedi 1 için DB5 ve DB6 dalgacıkları kullanılarak gürültüden arındırılan sinyaller gösterilmiştir. Diğer hisse senetleri için ekler bölümüne bakılabilir.



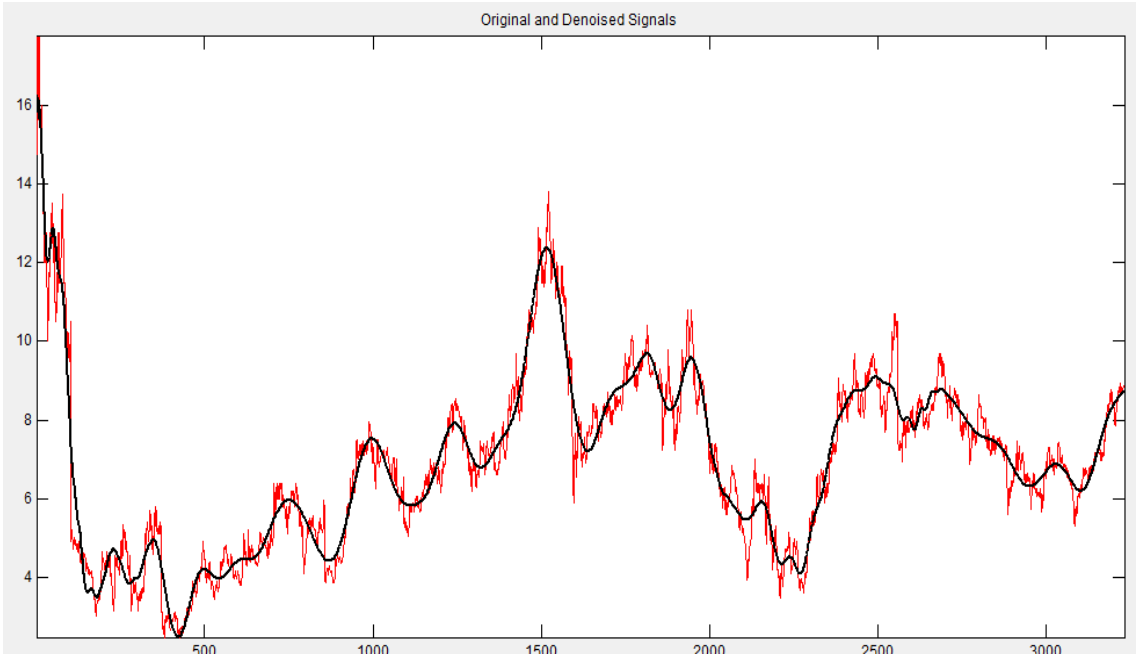
Şekil 5. 2 Hisse 1 için DB5 ile Dalgacık Dönüşüm Katsayıları



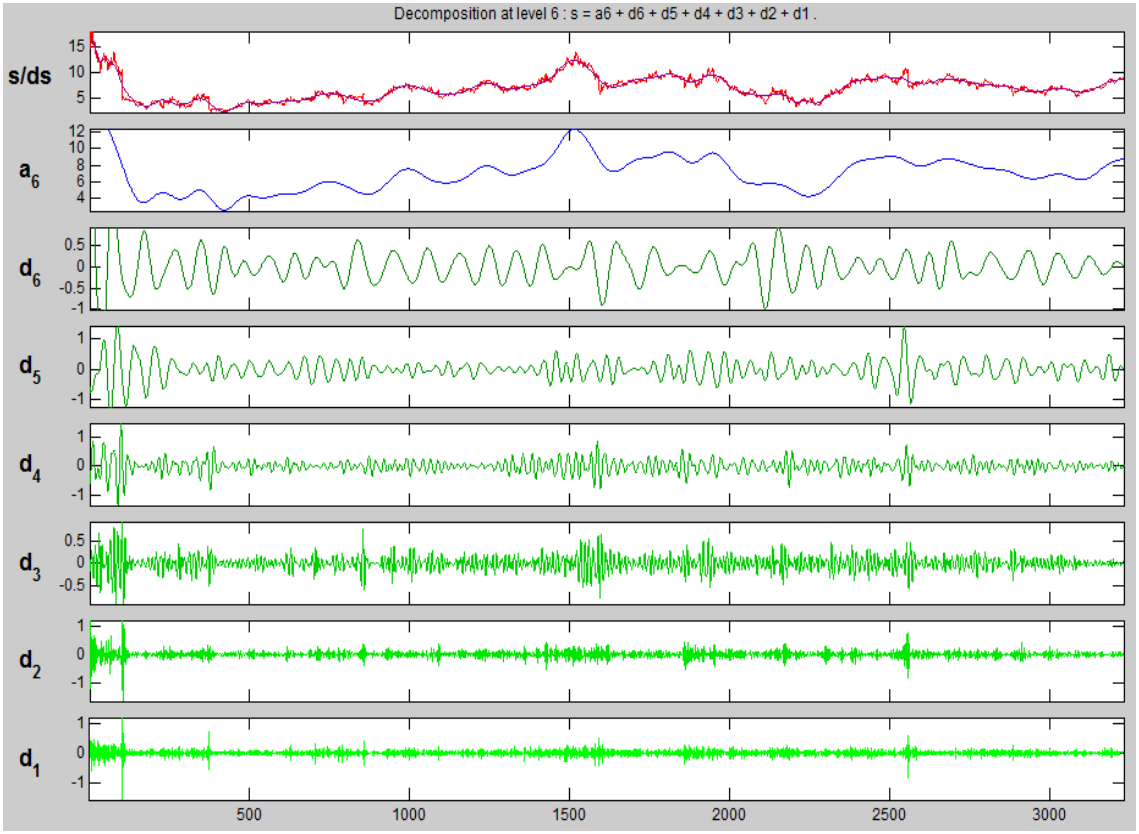
Şekil 5. 3 Hisse 1 için DB5 ile Gürültüden Arındırılmış Sinyal ve Orijinal Sinyal



Şekil 5. 4 Hisse 1 için DB6 ile Dalgacık Dönüşüm Katsayıları



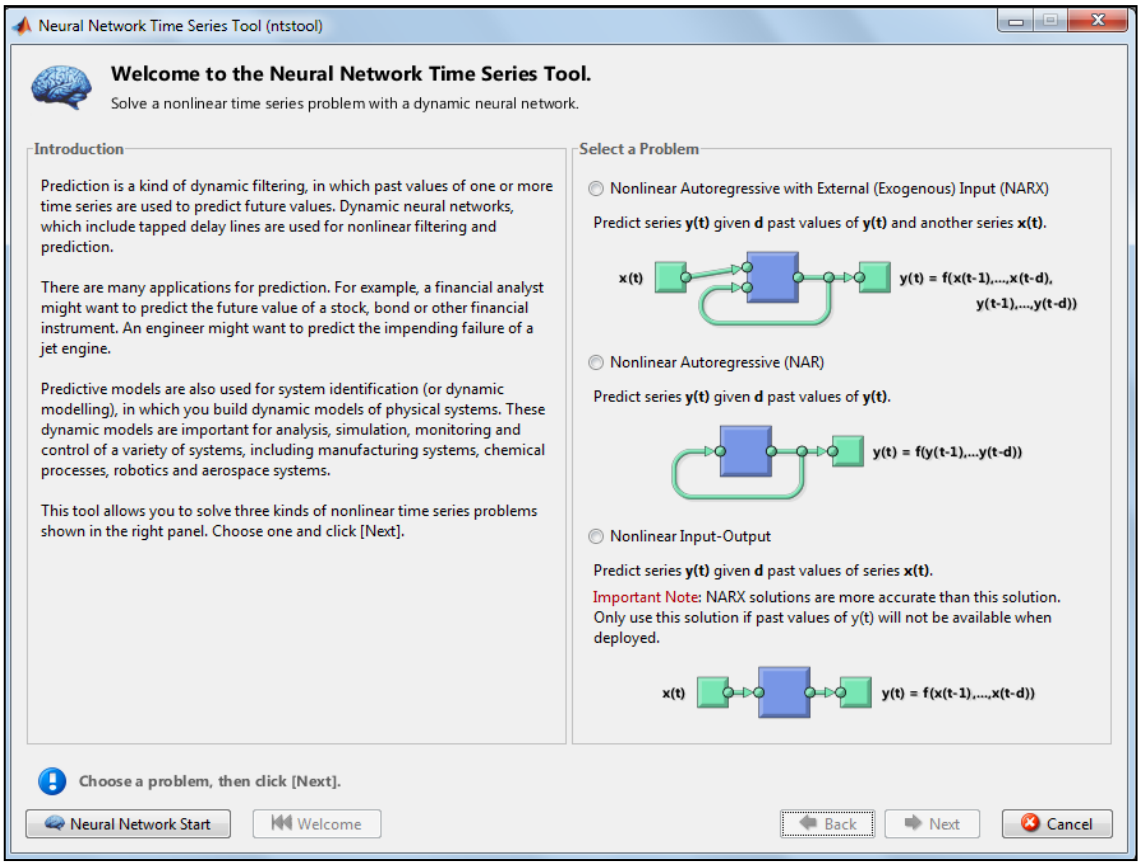
Şekil 5. 5 Hisse 1 için DB6 ile Gürültüden Arındırılmış Sinyal ve Orijinal Sinyal



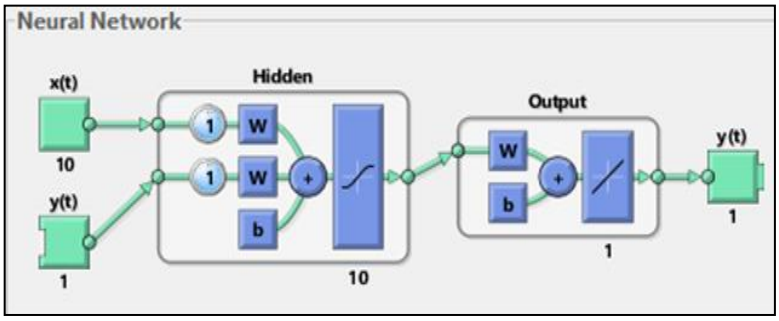
Şekil 5. 6 Hisse 1 için DB6 ile Ayrıştırılan Serinin Gösterimi

5.2 **Analiz Sonuçları**

Analiz otoregresif yapay sinir ağları modelleri ile gerçekleştirilmiştir. Bunun için şekil 5.7 de gösterilen yapay sinir ağları - zaman serileri ara yüzü kullanılmıştır. Analizlerde zaman serileri tahmini için kullanılan tek gizli katmanlı ağların uygun olduğu görülmüştür. Çalışmada hisse senetlerinin girdi sayılarına göre gizli katmanda 8 ila 12 arasında nöron kullanılmıştır. Hisse senetlerinde 1 veya 2 gecikmeli modellerin tahmin için uygun olduğu kanaatine varılmıştır. Her bir hisse senedi için farklı denemeler yapılarak hissenin karakterine uygun olan gecikme tespit edilmiştir. Kullanılan ağlardan bir gecikmeli otoregresif YSA modeli şekil 5.8 de verilmiştir.



Şekil 5. 7 Yapay Sinir Ağları - Zaman Serileri Ara Yüzü



Şekil 5. 8 Bir Gecikmeli Otoregresif Yapay Sinir Ağı Örneği

Çizelge 5.1 de hisse senetleri için kullanılan verilere göre en iyi modellerin test çıktılarının hataları ve R değerleri gösterilmiştir. Modellerin dönüşüm yapılmadan önceki ve sonraki performansları farklıdır. Çizelge 5.1 de görüldüğü gibi DB5 ve DB6 dalgacıkları ile dönüştürülen veriler daha az hatalı sonuçlar vermiştir. Yani verilerin dalgacık dönüşümü ile gürültüden arındırılması işlemi ağın tahmin performansını arttırmıştır. Ağı test etmek amacıyla 04.10.2012 ile 01.01.2013 tarihleri arasında kalan 60 iş günü analiz edilmiş ve model başarıları irdelenmiştir. Modellerin tahmin başarıları

Çizelge 5.2 de yer almaktadır. Çizelgedeki sonuçlara bakılarak sırasıyla DB6 ve DB5 ile dönüştürülen verilerle kurulan modellerin genel olarak en az hata kareleri ortalamasına sahip olduğu tespit edilmiştir.

Çizelge 5. 1 Otoregresif YSA Sonuçları

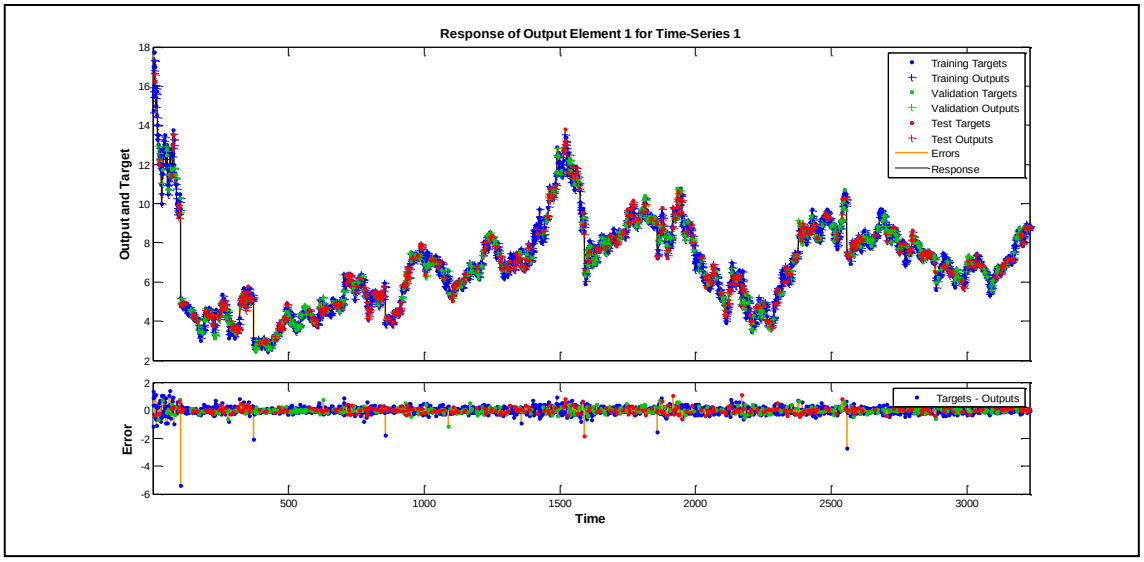
	YSA		DB5 + YSA		DB6 + YSA	
	MSE	**R**	**MSE**	**R**	**MSE**	**R**
H1	5.86229e-2	9.93859e-1	2.19395e-4	9.99977e-1	1.58848e-1	9.84321e-1
H2	3.38241 e-1	9.96997e-1	1.07444e-2	9.99854e-1	2.65159e-2	9.99772e-1
H3	2.97981e-2	9.96854e-1	8.39138e-5	9.99990e-1	7.39270e-5	9.99992e-1
H4	9.03164e-1	9.99221e-1	2.35220e-1	9.99736e-1	6.87455e-1	9.99458e-1
H5	2.58616e-2	9.95895e-1	4.46429e-3	9.99396e-1	1.60784e-3	9.99774e-1
H6	6.93134e-1	9.97455e-1	1.45564e-2	9.99943e-1	2.56133e-2	9.99908e-1

Çizelge 5. 2 Otoregresif YSA 60 Günlük Test Sonuçları

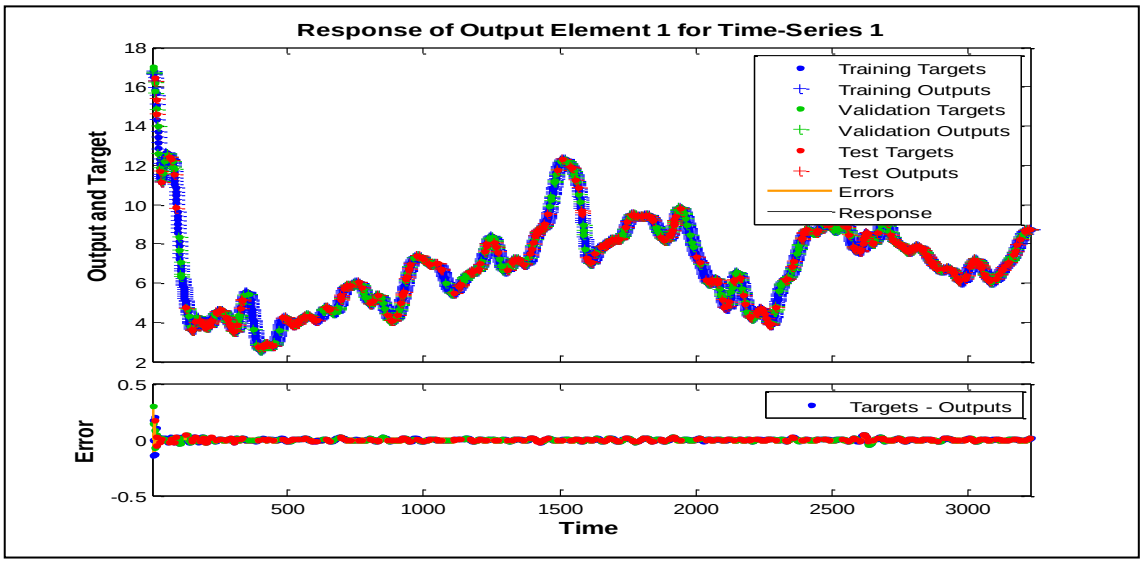
	YSA		DB5 + YSA		DB6 + YSA	
	MSE	**R**	**MSE**	**R**	**MSE**	**R**
H1	1.51538e-2	9.42884e-1	4.56658e-5	9.99821 e-1	1.97024e-5	9.99864e-1
H2	1.20162e-1	9.58926e-1	4.82698e-3	9.99786e-1	1.20070e-4	9.99923e-1
H3	1.79195e-2	9.56002e-1	2.30587e-5	9.99934e-1	7.41137e-6	9.99962e-1
H4	3.95692e-2	9.74281 e-1	2.91194e-3	9.96114e-1	3.15262e-4	9.99675e-1
H5	9.51414e-3	9.32800e-1	6.53885e-5	9.99405e-1	9.66483e-4	9.85786e-1
H6	5.5746 e-1	9.82760e-1	1.63902e-4	9.99994e-1	2.74947e-4	9.99983e-1

Modellerin genel başarısını görmek için Şekil 5.9, Şekil 5.10 ve Şekil 5.11 de verilen hedef değerler ile çıktı değerlerinin grafiğine bakılabilir. Şekil 5.9 da hataların yüksek olduğu, Şekil 5.10 ve Şekil 5.11 de ise daha az tahmin hatalarının olduğu anlaşılmaktadır. Ek olarak Şekil 5.12, Şekil 5.13 ve Şekil 5.14 te verilen regresyon

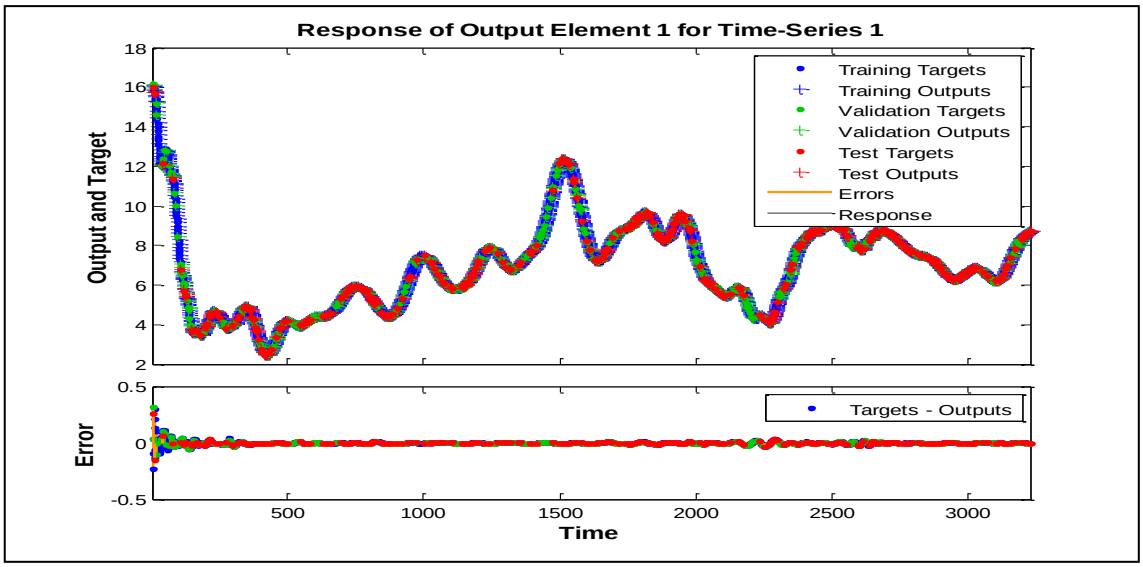
grafikleri incelenebilir. Yeni veri setinin testi ile modellerin başarısı daha anlaşılır olmaktadır. Şekil 5.15, Şekil 5.16 ve Şekil 5.17 den de anlaşılacağı gibi modeller dalgacık dönüşümü ile daha başarılı tahminler yapmıştır.



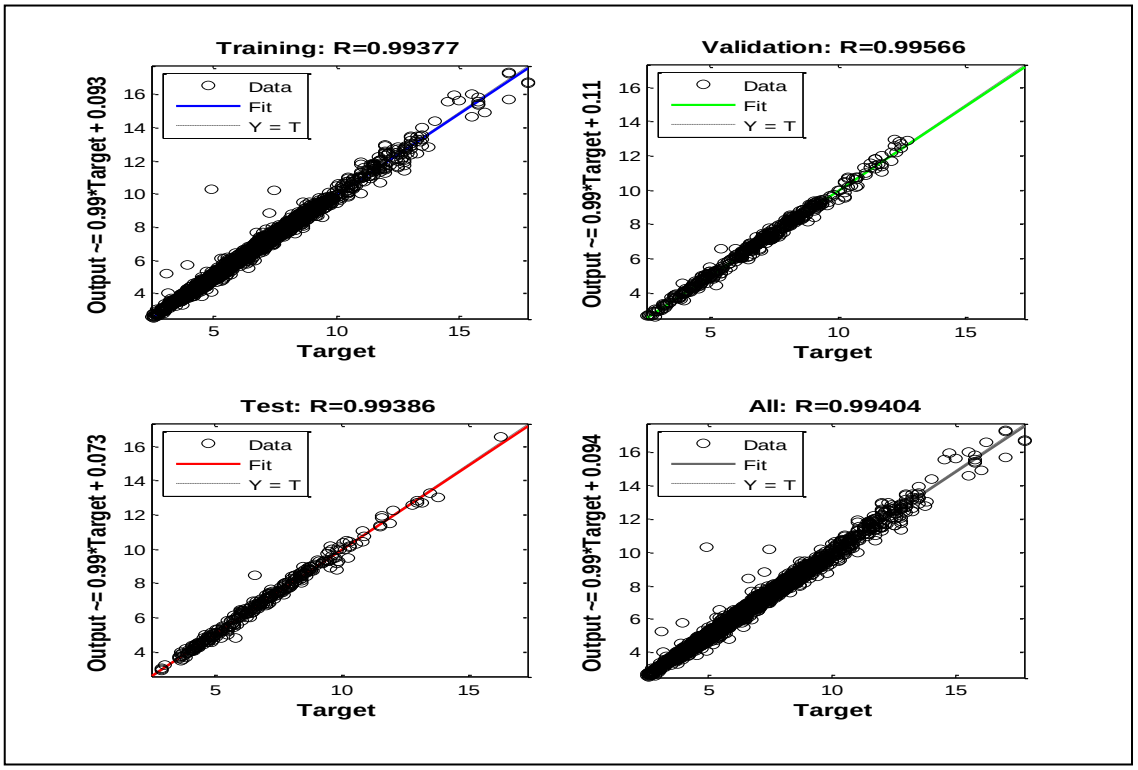
Şekil 5. 9 Hisse 1 için Çıktı ve Hedef Verilerinin Ham veriler için Gösterimi



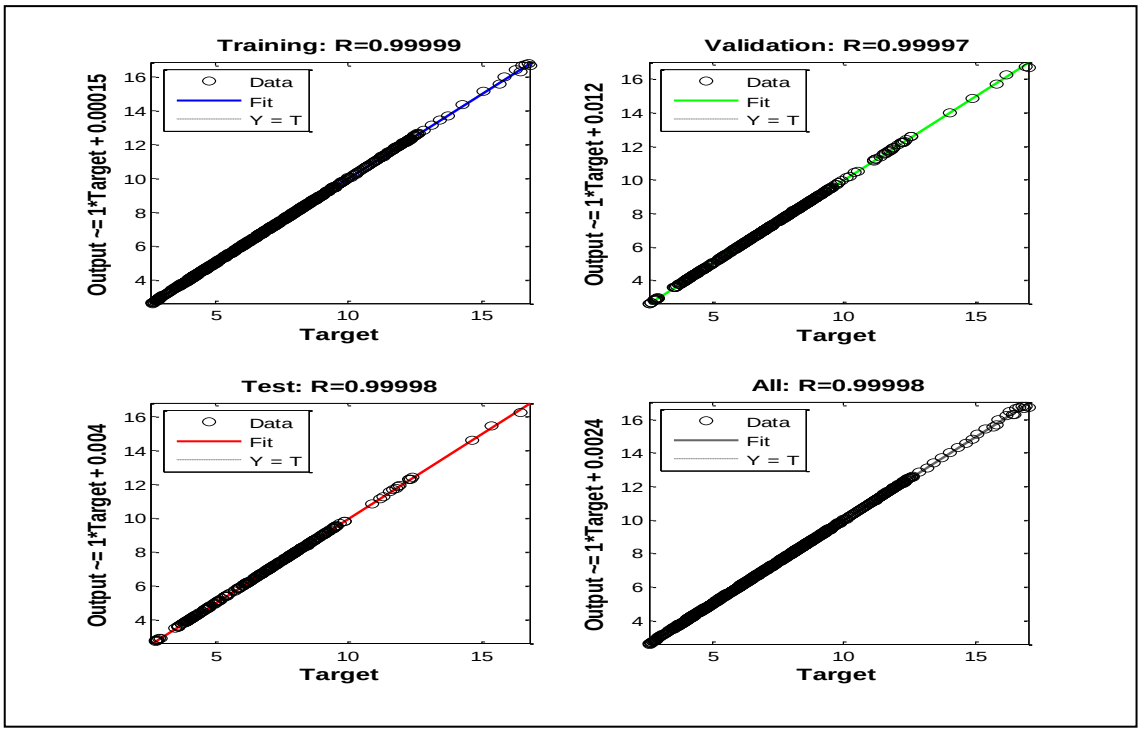
Şekil 5. 10 Hisse 1 için Çıktı ve Hedef Verilerinin DB5 için Gösterimi



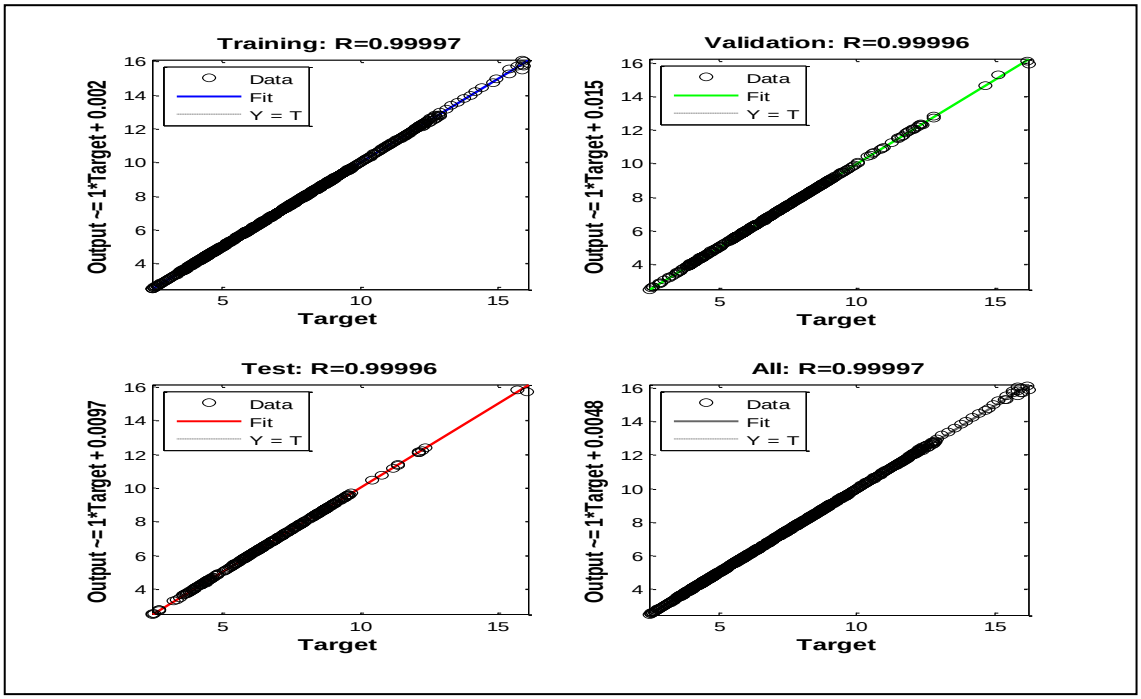
Şekil 5. 11 Hisse 1 için Çıktı ve Hedef Verilerinin DB6 için Gösterimi



Şekil 5. 12 Hisse 1 için Çıktı ve Hedef Verilerinin Regresyon Doğrularının Ham veriler için Gösterimi

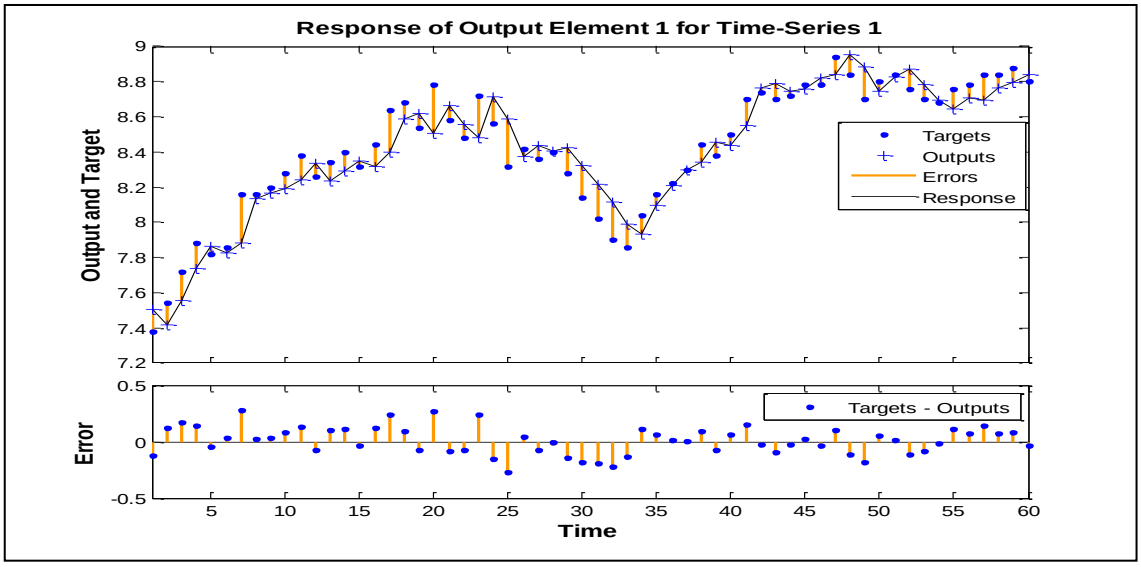


Şekil 5. 13 Hisse 1 için Çıktı ve Hedef Verilerinin Regresyon Doğrularının DB5 verileri için Gösterimi

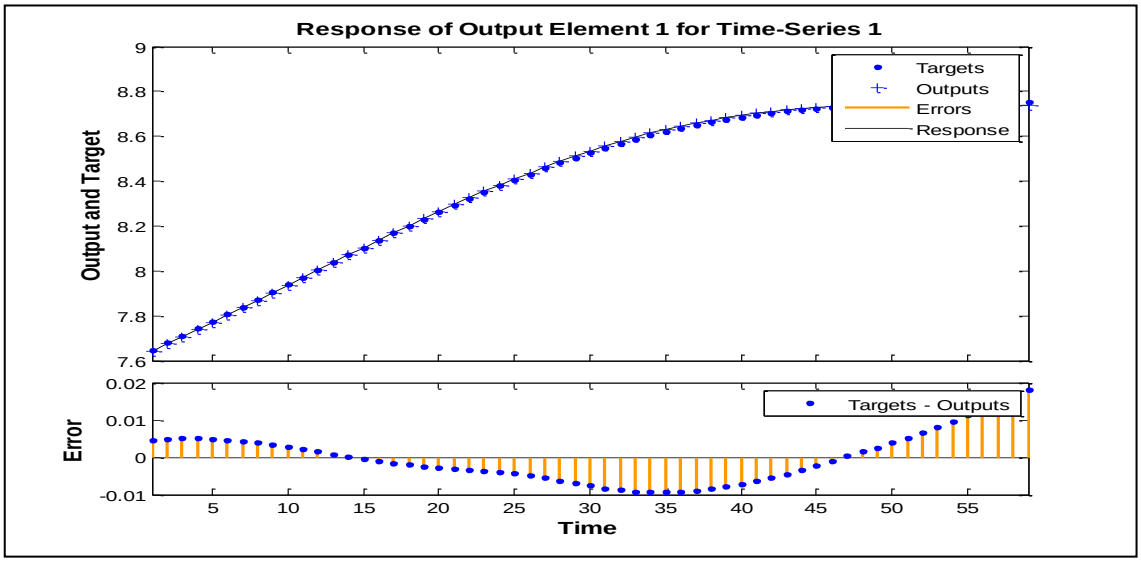


Şekil 5. 14 Hisse 1 için Çıktı ve Hedef Verilerinin Regresyon Doğrularının DB6 verileri için Gösterimi

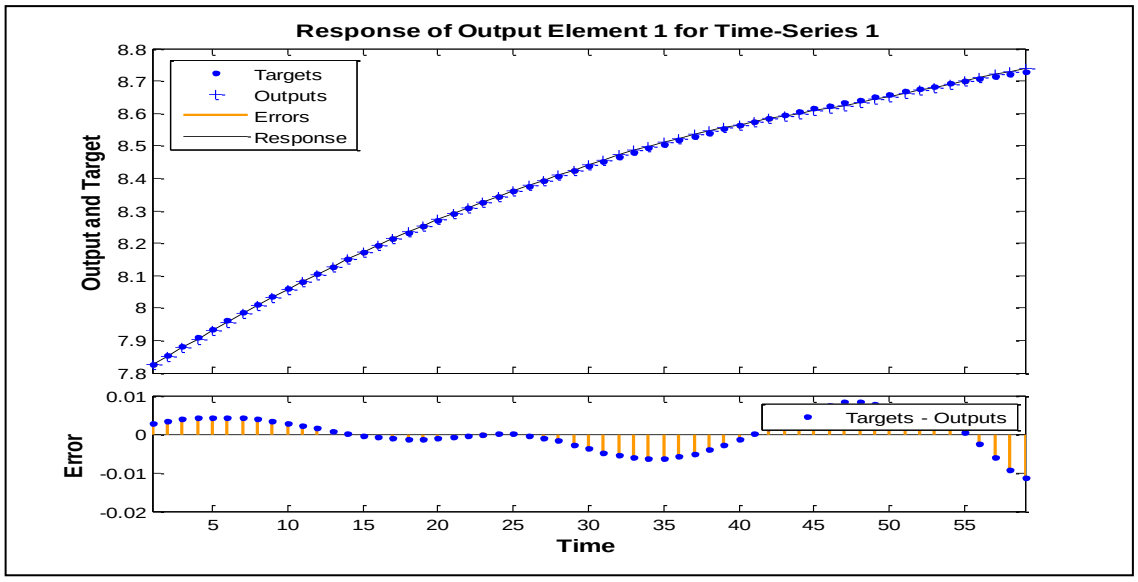
Yukarıda regresyon grafiklerinde verilen R değeri çıktı ve hedef değerleri arasındaki korelasyonun bir ölçüsüdür. Bu değerin 1 e yakın olması yakın ilişkiyi, 0 a yakın olması rastgele bir ilişkiyi göstermektedir.



Şekil 5. 15 Hisse 1 için Yeni Verilerde Çıktı ve Hedef Verilerinin Ham veriler için Gösterimi



Şekil 5. 16 Hisse 1 için Yeni Verilerde Çıktı ve Hedef Verilerinin DB5 verileri için Gösterimi



Şekil 5. 17 Hisse 1 için Yeni Verilerde Çıktı ve Hedef Verilerinin DB6 verileri için Gösterimi

BÖLÜM 6

SONUÇ VE ÖNERİLER

Çalışmada hisse senetlerinin tahmininde verilerin volatilite etkisi giderilerek daha doğru tahminler elde edilebileceği önerilmiştir. Bu doğrultuda veriler dalgacık dönüşümü ile gürültülerden arındırılarak otoregresif yapay sinir ağları modeli ile ağın veriler arasındaki ilişkiyi öğrenmesi sağlanmış ve yeni veriler ağa gösterildiğinde ağın başarısı irdelenmiştir.

Elde edilen bulgulara bakılacak olursa verilerin dalgacık dönüşümünden sonra yapay sinir ağları ile modellenmesinin ham veriler ile modellenmesinden daha başarılı sonuçlar verdiği görülmüştür. Yani dalgacık dönüşümü modellerin tahmin başarısını arttıran bir yöntemdir.

Hisse senetleri gibi zaman serilerinin tahmininde dalgacık dönüşümlü yapay sinir ağlarının başarılı sonuçlar verdiği ortaya çıkarılmıştır. Modellerin sürekli güncellenebilmesini sağlamak amacıyla çeşitli programlardan faydalanılarak günlük tahminlerde modelin kendini yenilemesi ve ağ ağırlıklarının hisse senetlerinin gerçekleşen fiyatlarına uygun olarak yeniden hesaplanması sağlanabilir. Bundan sonraki çalışmalarda değişik dinamiklere sahip ülke piyasalarında belirtilen modelin kullanımı irdelenecektir.

KAYNAKLAR

[1] Egeli, B., Ozturan, M., Badur, B., (2003). "Stock Market Prediction Using Artificial Neural Networks", Proceedings of the 3rd Hawaii International Conference on Business, Hawai, USA.

[2] Atsalakis, G.S., Valavanis, K.P., (2009). "Surveying stock market forecasting techniques – Part II: soft computing methods", Expert System Application, 36: 5932–5941.

[3] Bahrammirzaee, A., (2010). "A comparative survey of artificial intelligence applications in finance: artificial neural networks, expert system and hybrid intelligent systems", Neural Computing and Applications, 19: 1165–1195.

[4] Wang, J.-Z., Wang, J.-J., Zhang, Z.-G., Guo, S.-P., (2011). Forecasting stock indices with back propagation neural network, Expert System Application, 38: 14346–14355.

[5] Zhang, G. (2003). "Time series forecasting using a hybrid ARIMA and neural network model", Neurocomputing, 50: 159–175.

[6] Akcan, A., Kartal, C., (2011). "The Forecasting of Stock Prices in ISE Insurance Index with Artificial Neural Networks", The Journal of Accounting and Finance.

[7] Toraman , C., (2008). "Stock Price Forecasting by Using Artificial Neural Networks in Iron-Steel Sector: A Forecasting Application on Erdemir Co. and Kardemir Co.", The Journal of Accounting and Finance (AAFA).

[8] Erdoğan, E., Özyürek, H., (2012). "Estimating Stock Prices By Neural Networks", Sosyal ve Beşeri İlimler Dergisi, 4: 1309-8012 (Online).

[9] Tektaş, A., Karataş, A., (2004). "Yapay Sinir Ağları Ve Finans Alanına Uygulanması: Hisse Senedi Fiyat Tahminlemesi", Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi, Sayı: 3-4.

[10] Ünlü, U., Yıldız, B., Yalama, A., (2009). "İlk Halka Arzlarda Uzun Dönem Getirilerinin Tahmini: Yapay Sinir Ağları İle İmkb İçin Ampirik Bir Çalışma", İstanbul Üniversitesi İktisat Fakültesi Ekonometri ve İstatistik Dergisi,10: 29-47

[11] Karaatlı M., Güngör İ., Demir Y., Kalaycı Ş., (2005). " Estimating stock market movements with neural network approach ", Akademik Fener, Vol. 2 - 1.

[12] Aygören, H., Sarıtaş, H., Moralı, T., (2012). “Forecasting ISE 100 Indice Using Artificial Neural Networks And Newton Numerical Search Models”, International Journal of Alanya Faculty of Business, 4;1: 73-88.

[13] Kaynar, O., Taştan, S., (2009). “Comparasion of MLP Artificial Neural Network And ARIMA Method in Time Series Analysis”, Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, ss.161-172

[14] Diler, A., İ., (2003). “Imkb Ulusal-100 Endeksinin Yönünün Yapay Sinir Ağları Hata Geriye Yayma Yöntemi İle Tahmin Edilmesi”, Imkb Dergisi, Cilt: 7, Sayı: 25-26.

[15] Avci, E., (2007). “Forecasting Daily And Sessional Returns Of The Ise-100 Index With Neural Network Models”, Doğuş Üniversitesi Dergisi, 128-142.

[16] Şeker, M., E. Yıldırım, S., Berkay, A., (2004). “ Using Neural Network For Financial Applications Estimations”, Pamukkale University Journal of Engineering Sciences (Special Issue) 79-83.

[17] Er, H., Çetin, M., K., Çetin, E., İ., (2005). “Evolutionary Algorithmic Approaches In Finance: Applications Of Genetic Algorithms”, Akdeniz İ.İ.B.F. Dergisi, 10: 73-94.

[18] Enke, D., Thawornwong, S., (2005). “The use of data mining and neural networks for forecasting stock market returns”, Expert Systems with Applications 29: 927–940.

[19] Ayodele, A., Charles, A., K., Marion, A., O., Sunday, O., O., (2012). “Stock Price Prediction using Neural Network with Hybridized Market Indicators”, Journal of Emerging Trends in Computing and Information Sciences, Vol. 3 – 1.

[20] Tarsauliya, A., Kant, A., Kala, R., Tiwari, R., Shukla, A., (2010). “Analysis of Artificial Neural Network for Financial Time Series Forecasting”, International Journal of Computer Applications, Vol. 9 – 5.

[21] Zhang, Y. D., Wu, L. N. (2009). “Stock market prediction of S&P 500 via combination of improved BCO approach and BP neural network”, Expert Systems with Applications, 36: 8849–8854.

[22] Vahedi, A., (2012). “The Predicting Stock Price using Artificial Neural Network”, Journal of Basic and Applied Scientific Research, Vol. 2 – 3: 2325-2328.

[23] Zhang, D., Jiang, Q., Li, X., (2007). “Application of Neural Networks in Financial Data Mining”, World Academy of Science, Engineering and Technology 1

[24] Pan, H., Tilakaratne, C., Yearwood, J., (2005). “Predicting Australian Stock Market Index Using Neural Networks Exploiting Dynamical Swings and Intermarket Influences”, Journal of Research and Practice in Information Technology, Vol. 37 – 1.

[25] Arisa, Z., Mohamad, D., (2008). “Application Of Artificial Neural Networks Using Hijri Lunar Transaction As Extracted Variables To Predict Stock Trend Direction”, Labuan e-Journal of Muamalat and Society, 2: 9-16.

[26] Patel, P. B., Marwala, T., (2006)., "Forecasting closing price indices using neural networks", 2006 IEEE Conference on Systems, Man, and Cybernetics October 8-11, 2006, Taipei-Taiwan.

[27] Thenmozhi, M., (2006). "Forecasting Stock Index Returns Using Neural Networks", Delhi Business Review X, Vol. 7 – 2.

[28] Isfan, M., Menezes, R., Mendes, D. A., (2010). "Forecasting the Portuguese Stock Market Time Series by Using Artificial Neural Networks", 7th International Conference on Applications of Physics in Financial Analysis, Journal of Physics: Conference Series221, 1-5 March, 2009, Tokyo, Japan.

[29] Tabrizi, H. A., Panahian, H., (2001). "Stock Price Prediction by Artificial Neural Networks: A Study of Tehran's Stock Exchange (T.S.E)", Management Studies Quarterly Journal of Management & Accounting School, No. 31 – 32.

[30] Wadia, S. A., Ismail, M., T., Alkhahazalehc, M., H., Abdul Karim, S., A., (2011). "Selecting Wavelet Transforms Model in Forecasting Financial Time Series Data Based on ARIMA Model", Applied Mathematical Sciences, 5: 315 – 326.

[31] Deboeck, G.J., (1994). "Trading on the Edge: Neural, Genetic and Fuzzy Systems for Chaotic Financial Markets", Willey & Sons, New York.

[32] Yaser S.A.M., Atiya, A.F., (1996). "Introduction to financial forecasting, Applied Intelligence", 6 :205–213.

[33] Atsalakis, G.S., Valavanis, K.P., (2009). "Surveying stock market forecasting techniques – Part II: soft computing methods", Expert System Application, 36: 5932–5941.

[34] Bahrammirzaee, A., (2010). "A comparative survey of artificial intelligence applications in finance: artificial neural networks, expert system and hybrid intelligent systems", Neural Computing Application, 19: 1165–1195.

[35] Goswami, J. C., Chan, A. K., (1999), "Fundamentals of Wavelets: Theory, Algorithms, and Applications", Wiley Publishers.

[36] Zhang, G., Patuwo, B.E., Hu, M.Y., (1998). "Forecasting with artificial neural networks: the state of the art",International Journal of Forecasting 14: 35–62.

[37] Aggarwal, S. K., Saini L. M., Kumar, A., (2008). "Electricity Price Forecasting in Ontario Electricity Market Using Wavelet Transform in Artificial Neural Network Based Model", International Journal of Control, Automation, and Systems.

[38] Alrumaih M., Al- Fawzan, A., (2002). Time series forecasting using wavelet denoising an application to Saudi stocks index, Journal of King Saudi University,14: 221-234.

[39] Contreras, J., Espinola, R., Nogales, F.J., Conejo, A.J., (2005). ARIMA models to predict next-day electricity prices, IEEE Transactions on Power Systems, 18: 1014-20.

[40] Kravets, T., Sytienko, A., Shevchenko, T., (2013). "Wavelet Analysis Of The Crisis Effects In Stock Index Returns", Ekonomika, Vol. 92 - 1

[41] Abiyev, R.H., Abiyev, V.H. (2012). Differential evaluation learning of fuzzy wavelet neural networks for stock price prediction. Journal of Information and Computing Science, 7: 121–130.

[42] Capobianco, E. (2004). “Multiscale analysis of stock index return volatility”, Computational Economics, 23: 219–237.

[43] Gencay, R., Selcuk, F., Whitcher, B. (2001). “Scaling properties of foreign exchange volatility”, Physica A: Statistical Mechanics and Its Applications, 289: 249–266.

[44] Nekhilia, R., Altay-Salih, A., Gencay, R., (2002). “Exploring exchange rate returns at different time horizons”, Physica A 313: 671 – 682.

[45] Gallegati, M., (2008). “Wavelet analysis of stock returns and aggregate economic activity”, Computational Statistics and Data Analysis, 52: 3061–3074.

[46] Kim, S., In, F., (2005). “The relationship between stock returns and inflation: new evidence from wavelet analysis”, Journal of Empirical Finance, 12: 435–444.

[47] Lee, H.S., (2004). “International transmission of stock market movements: a wavelet analysis”, Applied Economics Letters, 11: 197–201.

[48] Rua, A., Nunes L.C., (2009). “International comovement of stock market returns: a wavelet analysis”, Journal of Empirical Finance, 16: 632–639.

[49] Subbotin, A. A., (2008). “Mutli-horizon scale for volatility”, CES Working Papers Series, University of Paris-1 (Pantheon-Sorbonne), 20: 1–44.

[50] Ravikumar, K., Tamilselvan, S., (2014). “On the Use of Wavelets Packet Decomposition for Time Series Prediction”, Applied Mathematical Sciences, 8 (58): 2847 - 2858

[51] Lahmiri, S., (2014). “Wavelet low- and high-frequency components as features for predicting stock prices with backpropagation neural networks”, Journal of King Saud University – Computer and Information Sciences

[52] Li, J., Shi, Z., Li, X., (2006). “Genetic programming with wavelet-based indicators for financial forecasting”, Transactions of the Institute of Measurement and Control, 28: 285–297.

[53] Huang, S. C., Wu, T. K., (2010). “Integrating recurrent SOM with wavelet-based kernel partial least square regressions for financial forecasting”, Expert System Application 37: 5698–5705.

[54] Hsieh, T. J., Hsiao, H. F., Yeh, W. C., (2011). “Forecasting stock markets using wavelet transforms and recurrent neural networks: an integrated system based on artificial bee colony algorithm”, Applied Soft Computing, 11: 2510–2525.

[55] Huang, S. C., (2011). “Forecasting stock indices with wavelet domain kernel partial least square regressions”, Applied Soft Computing 11: 5433–5443.

[56] Huang, S. C., Wu, T. K., (2008). “Combining wavelet-based feature extractions with relevance vector machines for stock index forecasting”, Expert Systems, 25: 133–149.

[57] Lahmiri, S., (2013), “Forecasting direction of the S&P500 movement using wavelet transform and support vector machines”, International Journal of Strategic Decision Sciences, 4: 78–88.

[58] MEGEP Projesi, (2007). “Muhasebe Ve Finansman Menkul Kıymetler”, Ankara.

[59] İstanbul Menkul Kıymetler Borsası, (2011). “Hisse Senetleri Piyasası”, İstanbul.

[60] Sayılır, Ö., Ertuğrul, M., Ulutekin, M., (2012), “Menkul Kıymet Yatırımları”, T.C. Anadolu Üniversitesi Yayını No:2539, Eskişehir.

[61] İstanbul Menkul Kıymetler Borsası, (2011), “Alım Satım Kılavuzu”, İstanbul.

[62] Bayraktaroğlu, A., Menkul Kıymet Değerlemesi, Bölüm 4, http://mukweb.mu.edu.tr/Icerik/abayrakdaroglu/Dokuman/B%C3%B6l%C3%BCm-4%20(K%C4%B1s%C4%B1m%201)%20Ders%20Notu.pdf, 11 Haziran 2014.

[63] Usul, H. ,Bekçi, İ., Eroğlu, A. H., (2002). “Bireysel Yatırımcıların Hisse Senedi Edinimine Etki Eden Sosyo-Ekonomik Etkenler”, Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 19: 135-150.

[64] Dizdarlar, H. I., Derindere, S., (2008). “Hisse Senedi Endeksini Etkileyen Faktörler: İMKB 100 Endeksini Etkileyen Makroekonomik Göstergeler Üzerine Bir Araştırma”, Yönetim, 19(61).

[65] Demir, Y., (2001). “Hisse Senedi Fiyatını Etkileyen İşletme Düzeyindeki Faktörler Ve Mali Sektör Üzerine İMKB’ de Bir Uygulama”, Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi, 6(2): 109-130.

[66] Albeni, M., Yusuf Demir, Y., (2005). “Makroekonomik Göstergelerin Mali Sektör Hisse Senedi Fiyatlarına Etkisi (İMKB Uygulamalı)”, Muğla Üniversitesi SBE Dergisi, 14.

[67] Gaygusuz, F., (2008). “Hisse Senedi Piyasalarında İşlem Hacmi- Volatilite İlişkisi ve İMKB’ye Ait Bir Uygulama”, Çukurova Üniversitesi İİBF Dergisi, 12(1): 34-55.

[68] Aklan, N., A., Nargeleçekenler, M., (2012). “Hisse Senedi Piyasasında Para Politikalarının Rolü: Türkiye Örneği”, Marmara Üniversitesi İ.İ.B. Dergisi, 33(2): 103-128.

[69] Aydemir, O., Ögel, S., Demirtaş, G., (2012). “Hisse Senetleri Fiyatlarının Belirlenmesinde Finansal Oranların Rolü”, Yönetim Ve Ekonomi, 19(2).

[70] Akkum, T., Vuran, B., (2005). “Türk Sermaye Piyasasındaki Hisse Senedi Getirilerini Etkileyen Makroekonomik Faktörlerin Arbitraj Fiyatlama Modeli ile Analizi”, İktisat İşletme ve Finans Dergisi, 20: 28-45.

[71] Demir, Y., Yağcılar, G., G., (2009). “İMKB’ de İşlem Gören Banka Hisse Senetlerinin Getirilerini Etkileyen Faktörlerin Arbitraj Fiyatlama Modeli İle Belirlenmesi”, Alanya İşletme Fakültesi Dergisi, 1(2): 36-51.

[72] Hamzaçebi, C., (2011). “Yapay Sinir Ağlarının Tahmin Amaçlı Kullanımı: Matlab Ve Neurosolutions Uygulamalı”, Ekin Yayınevi.

[73] Elmas, Ç., (2010). “Yapay Zekâ Uygulamaları”, 2. Baskı, Seçkin Yayıncılık.

[74] Fyfe, C., (1996). “Artificial Neural Networks”, University of Paisley.

[75] Bansal, S., (2010), “Forecasting the Stock Index of SBI Using Wave-Nets”, Yüksek Lisans Tezi, Thapar University School of Mathematics and Computer Applications, Hindistan.

[76] Tan, C., (2009), “Financial Time Series Forecasting Using Improved Wavelet Neural Network”, Yüksek Lisans Tezi, Aarhus University Department of Computer Sciences, Danimarka.

[77] Polikar, R, (1996). “The Wavelet Tutorial”, Second Edition, College of Engineering, Rowan University, ABD.

[78] Schleicher, C., (2002). “An Introduction to Wavelets for Economists”, Bank of Canada Working Paper, Canada.

[79] Gao, R. X., Yan, R., (2011). “Wavelets: Theory and Applications for Manufacturing”, Springer Science LLC, London.

[80] Bracevvell, R. N., (1989), “Fourier Dönüşümü” ,Scientific American, syf 62 – 69, ABD; Çeviren: Bultan, A., (1991), Elektrik Mühendisleri Odası Dergisi, Sayı: 380, Ankara.

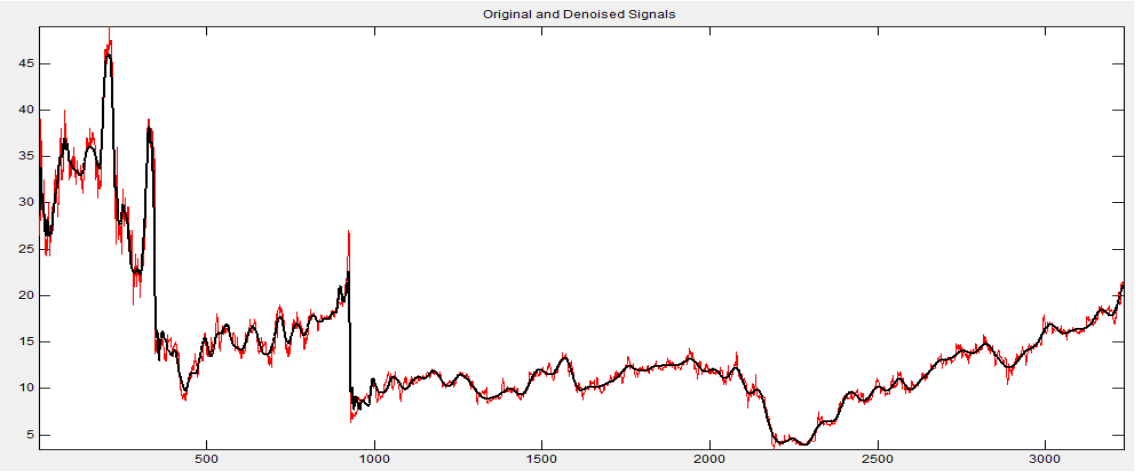
[81] Meyer, Y., Ryan, R. D., (1993). “Wavelets Algorithms & Applications”, Socicty for Industrial and Applied Mathematics(SIAM), Philadelphia

[82] Jaffard, S., Meyer, Y., Ryan, R. D., (2001). “Wavelets Tools for Science & Technology”, Socicty for Industrial and Applied Mathematics(SIAM), Philadelphia

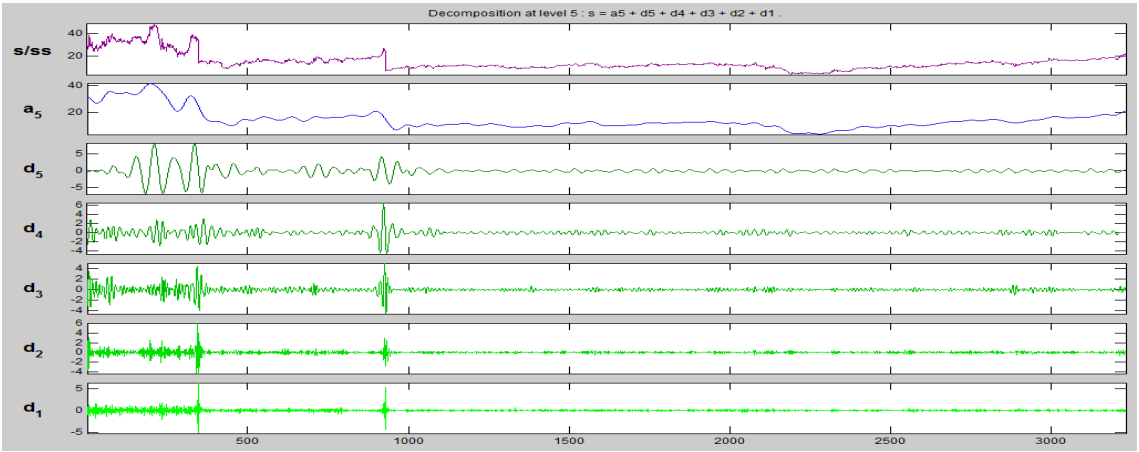
EK-A

HİSSE SENETLERİNİN DALGACIK DÖNÜŞÜMÜ GRAFİKLERİ

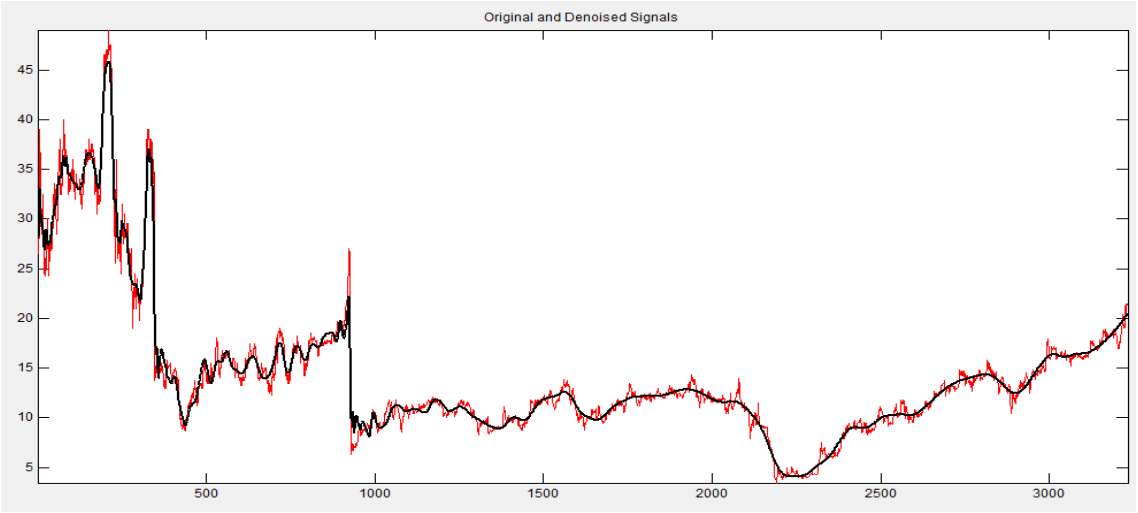
Hisse 1 için analiz sonuçlarında gürültüden arındırılmaları ve bununla ilgili grafikleri verilmişti. Diğer hisse senetlerinin gürültüden arındırılmış verilerinin ham veriler ile birlikte grafikleri aşağıda verilmiştir.



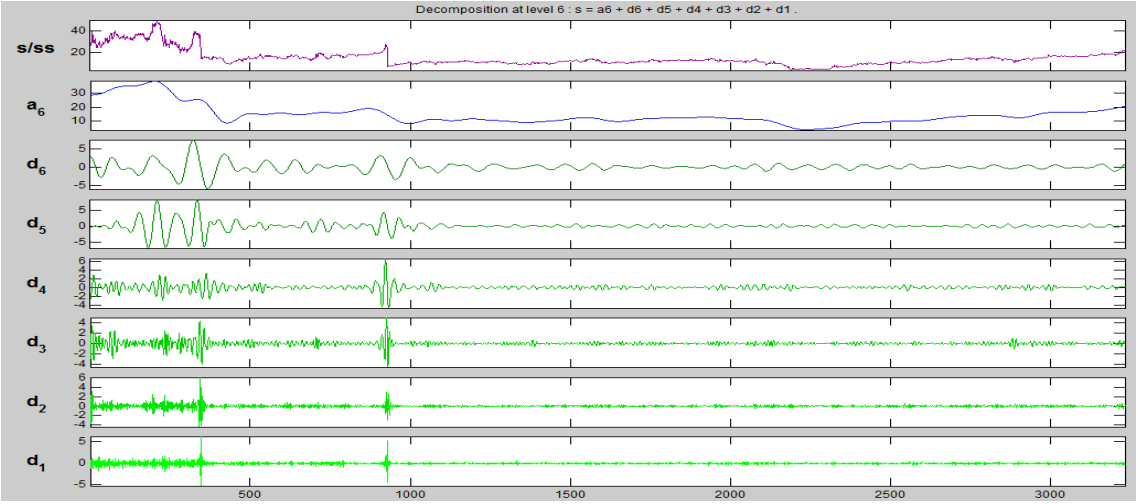
Şekil A.1 Hisse 2 için Orijinal Sinyal ve DB5 ile Gürültüden Arındırılmış Sinyal



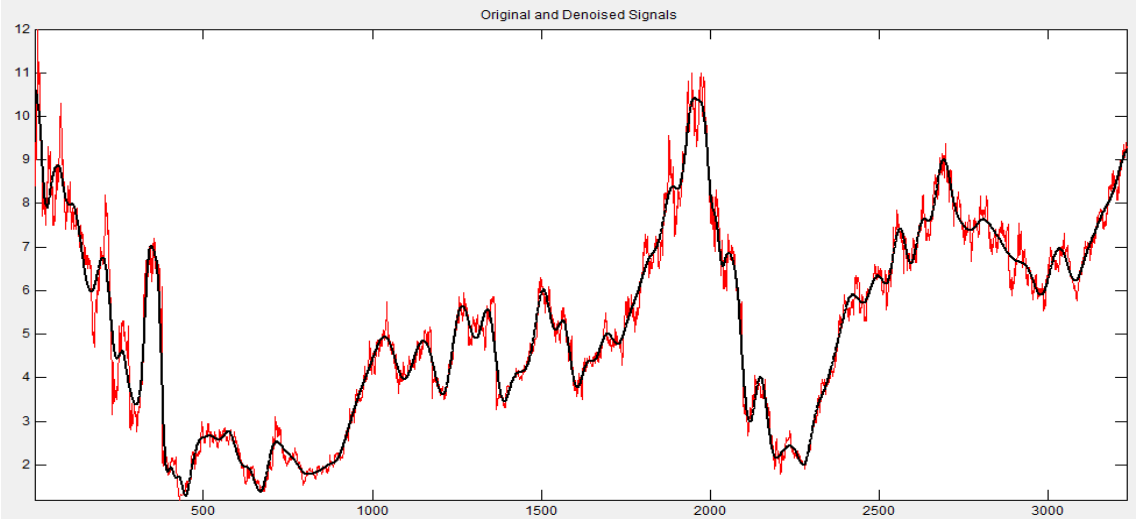
Şekil A.2 Hisse 2 için DB5 ile Ayrıştırılan Serinin Gösterimi



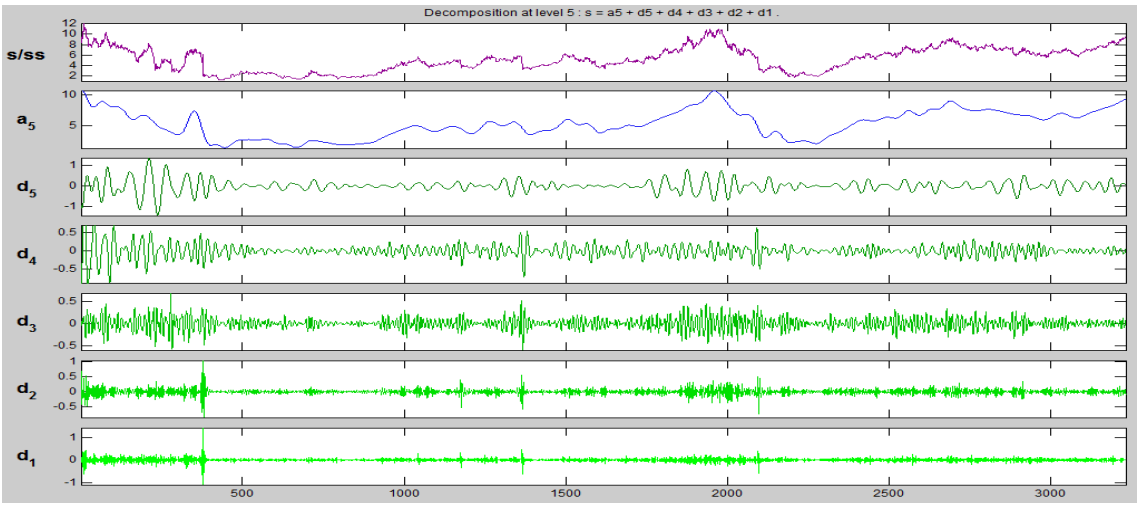
Şekil A.3 Hisse 2 için Orijinal Sinyal ve DB6 ile Gürültüden Arındırılmış Sinyal



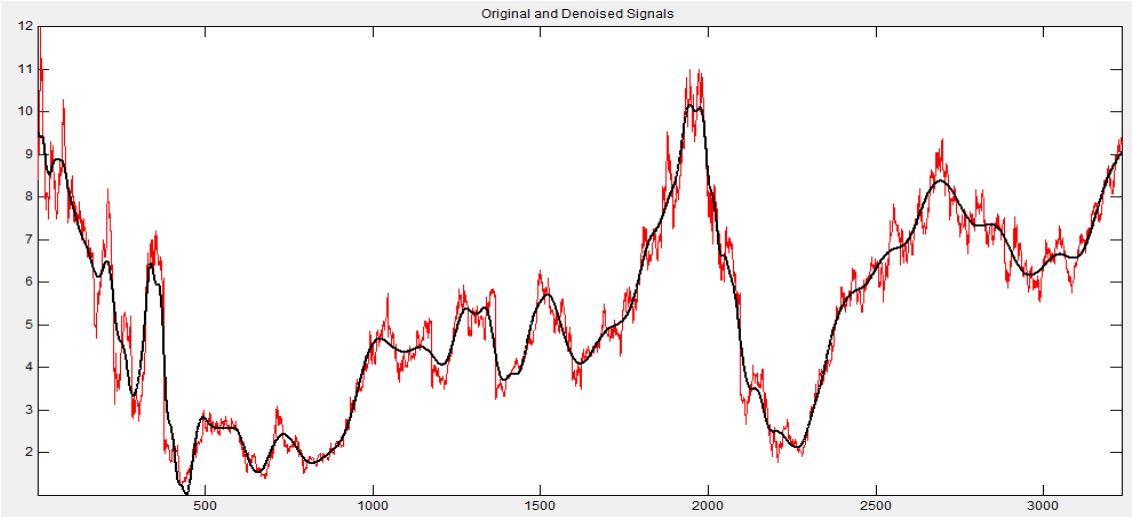
Şekil A.4 Hisse 2 için DB6 ile Ayrıştırılan Serinin Gösterimi



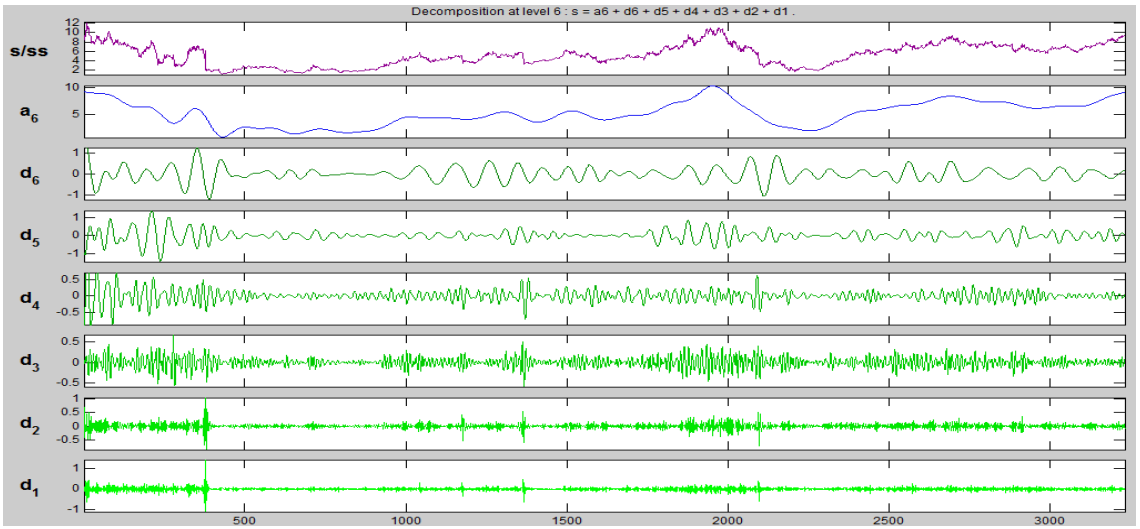
Şekil A.5 Hisse 3 için Orijinal Sinyal ve DB5 ile Gürültüden Arındırılmış Sinyal



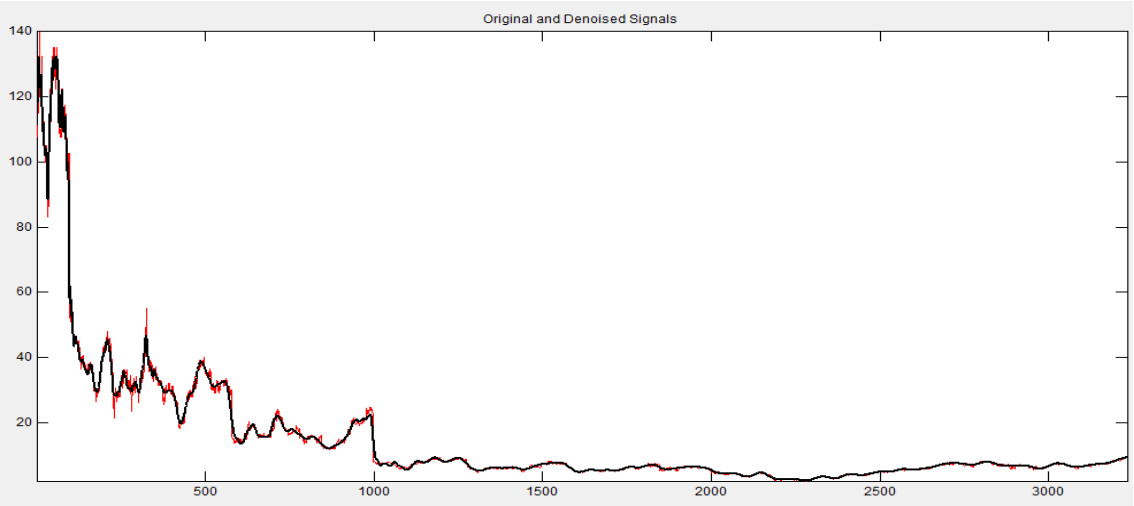
Şekil A.6 Hisse 3 için DB5 ile Ayrıştırılan Serinin Gösterimi



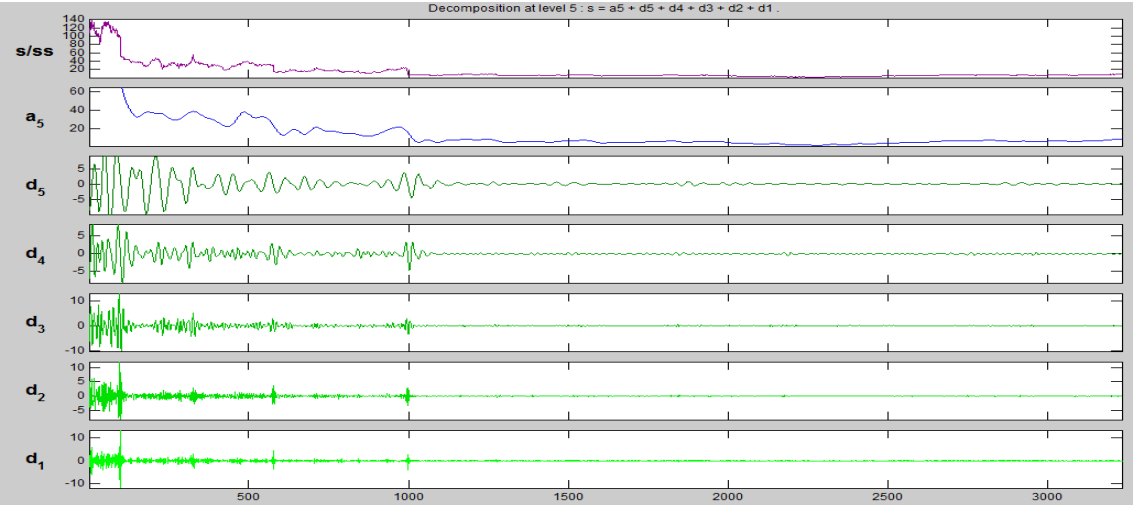
Şekil A.7 Hisse 3 için Orijinal Sinyal ve DB6 ile Gürültüden Arındırılmış Sinyal



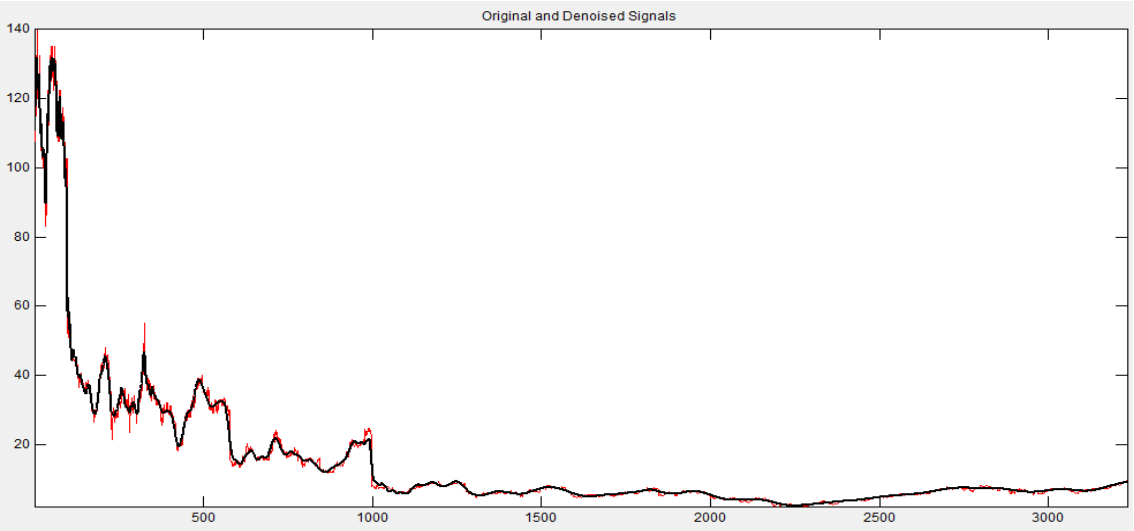
Şekil A.8 Hisse 3 için DB6 ile Ayrıştırılan Serinin Gösterimi



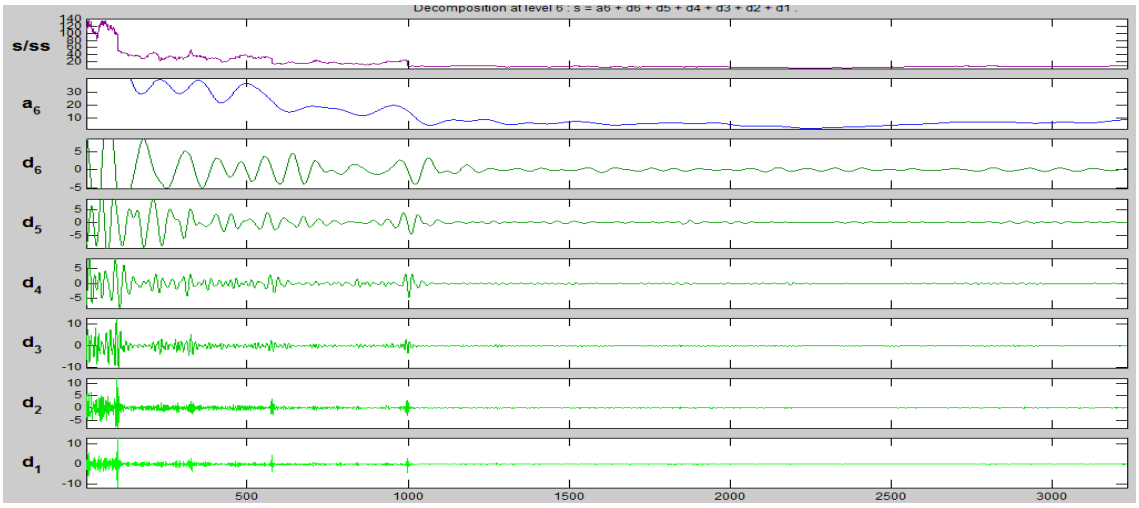
Şekil A.9 Hisse 4 için Orijinal Sinyal ve DB5 ile Gürültüden Arındırılmış Sinyal



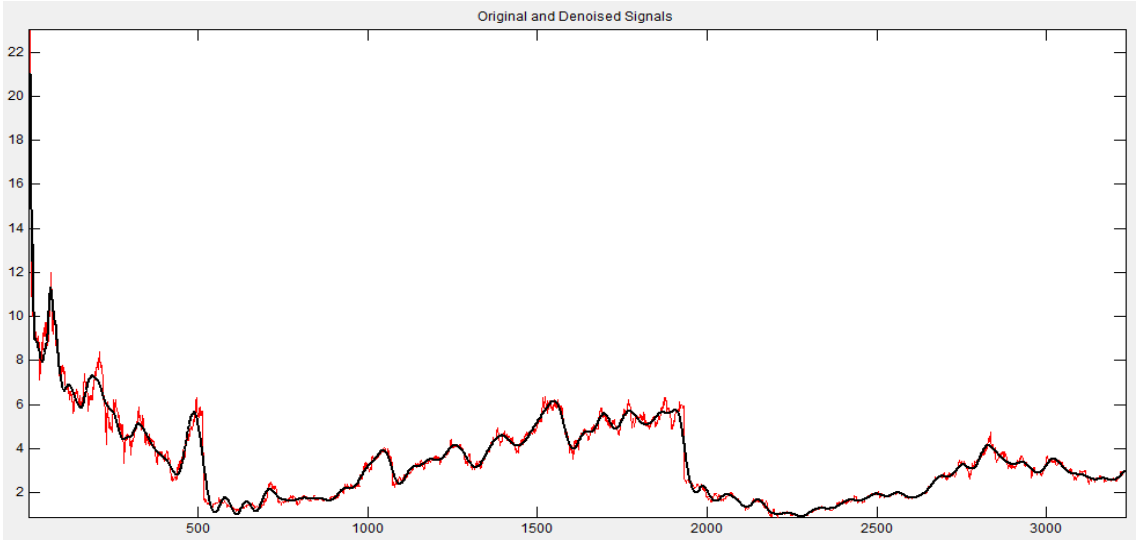
Şekil A.10 Hisse 4 için DB5 ile Ayrıştırılan Serinin Gösterimi



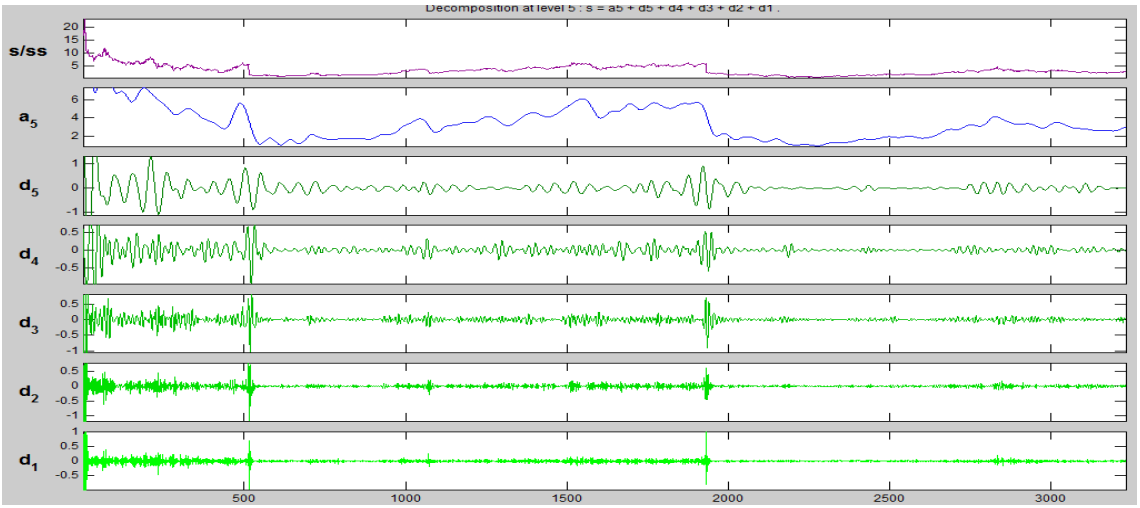
Şekil A.11 Hisse 4 için Orijinal Sinyal ve DB6 ile Gürültüden Arındırılmış Sinyal



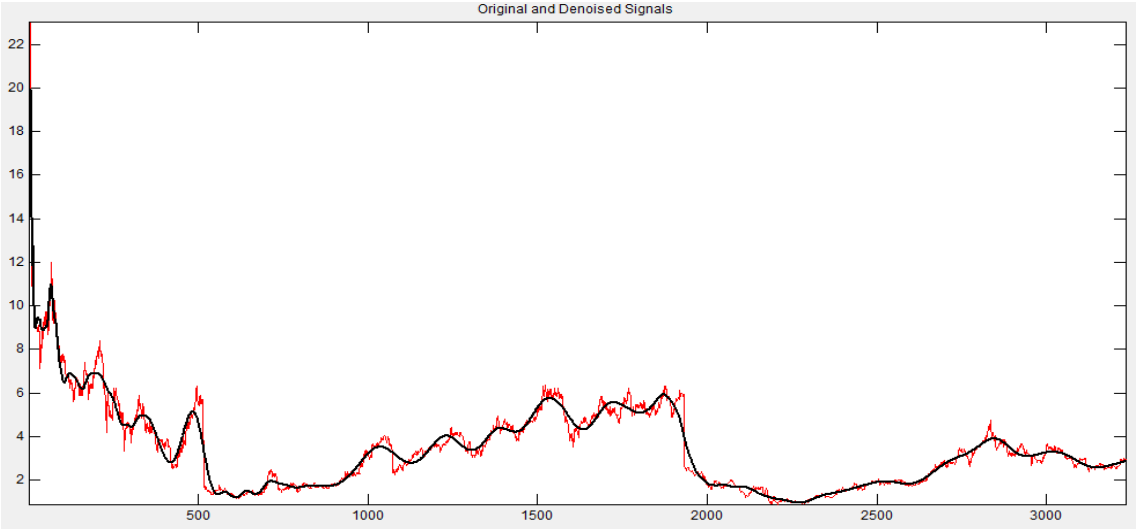
Şekil A.12 Hisse 4 için DB6 ile Ayrıştırılan Serinin Gösterimi



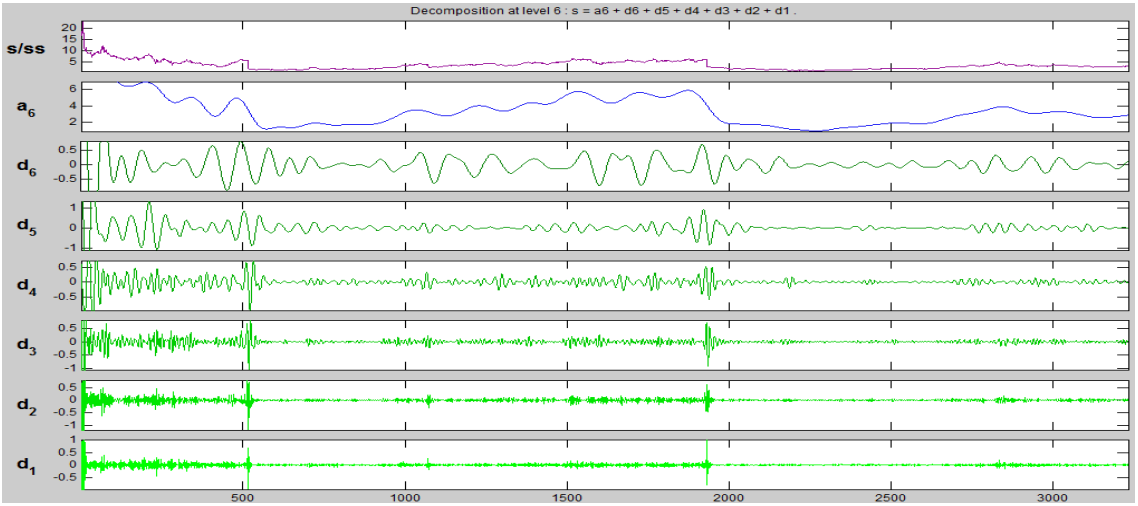
Şekil A.13 Hisse 5 için Orijinal Sinyal ve DB5 ile Gürültüden Arındırılmış Sinyal



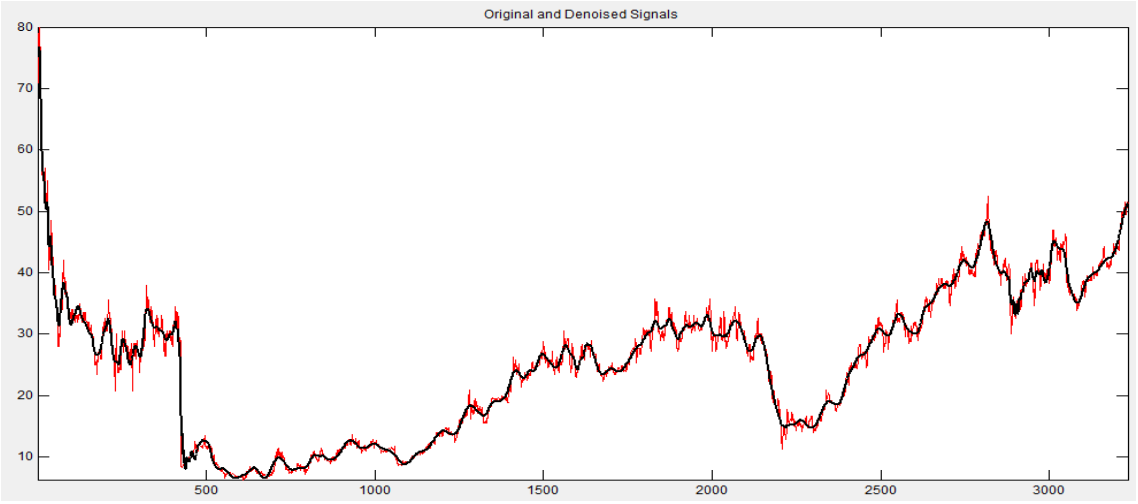
Şekil A.14 Hisse 5 için DB5 ile Ayrıştırılan Serinin Gösterimi



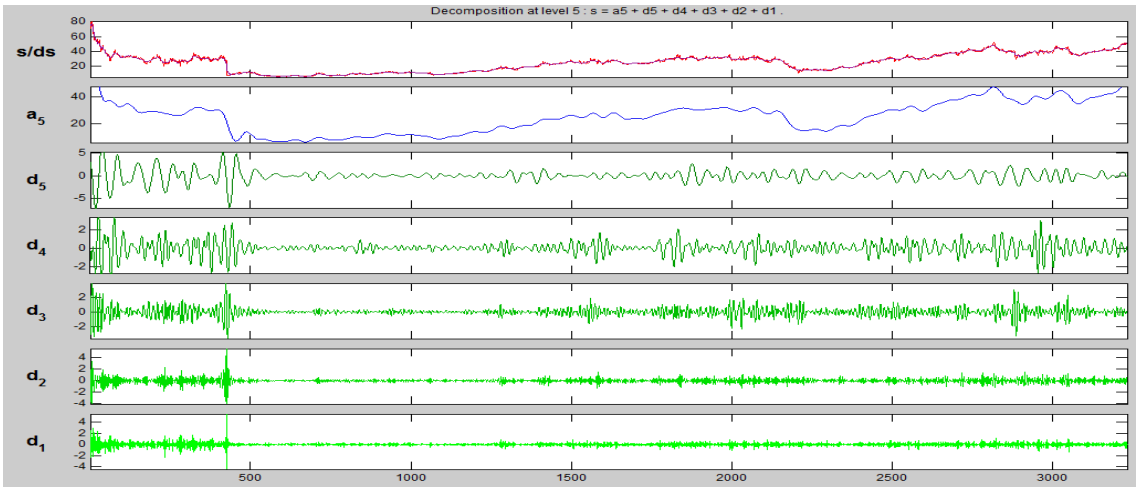
Şekil A.15 Hisse 5 için Orijinal Sinyal ve DB6 ile Gürültüden Arındırılmış Sinyal



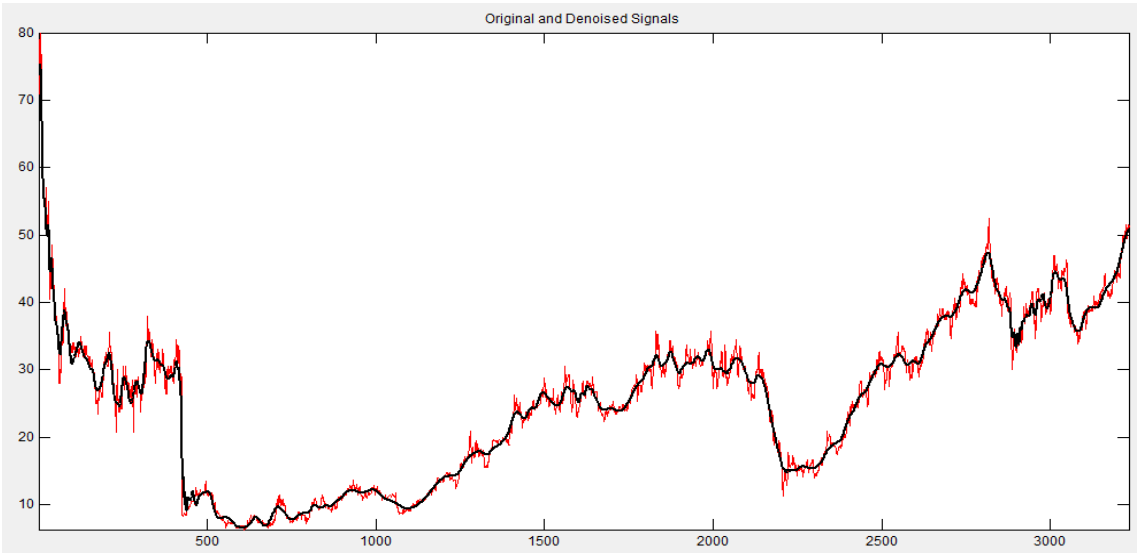
Şekil A.16 Hisse 5 için DB6 ile Ayrıştırılan Serinin Gösterimi



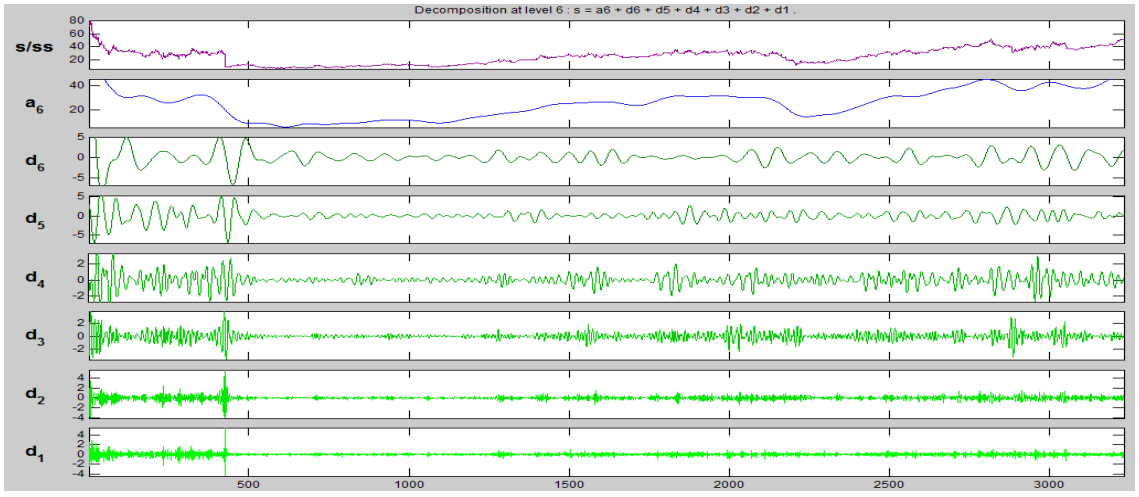
Şekil A.17 Hisse 6 için Orijinal Sinyal ve DB5 ile Gürültüden Arındırılmış Sinyal



Şekil A.18 Hisse 6 için DB5 ile Ayrıştırılan Serinin Gösterimi



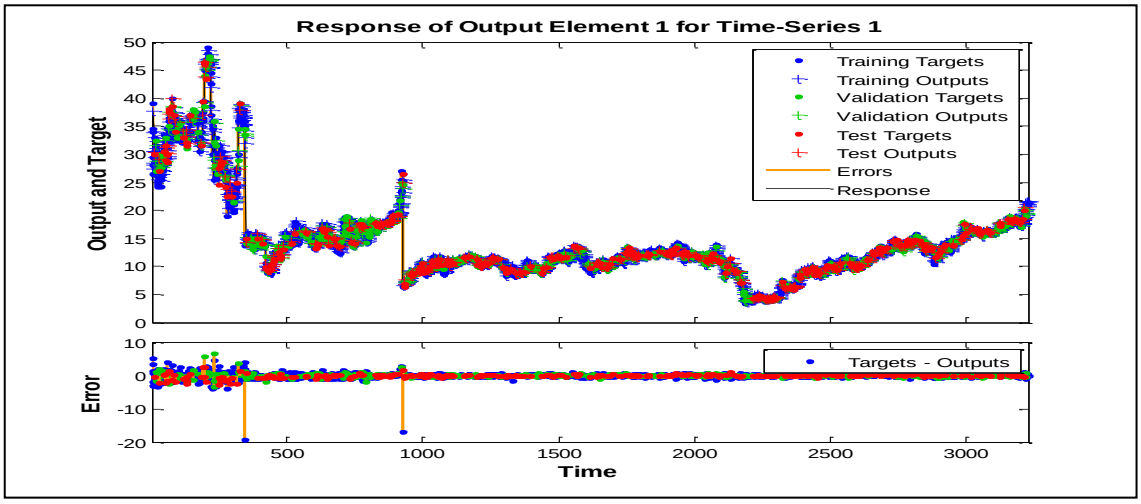
Şekil A.19 Hisse 6 için Orijinal Sinyal ve DB6 ile Gürültüden Arındırılmış Sinyal



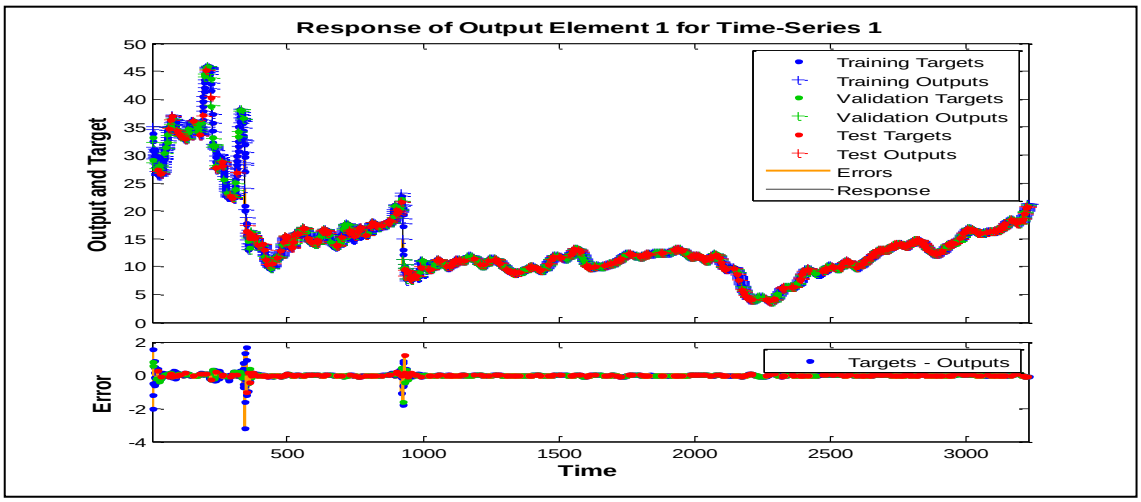
Şekil A.20 Hisse 6 için DB6 ile Ayrıştırılan Serinin Gösterimi

HİSSE SENETLERİNİN ANALİZ SONUÇLARI

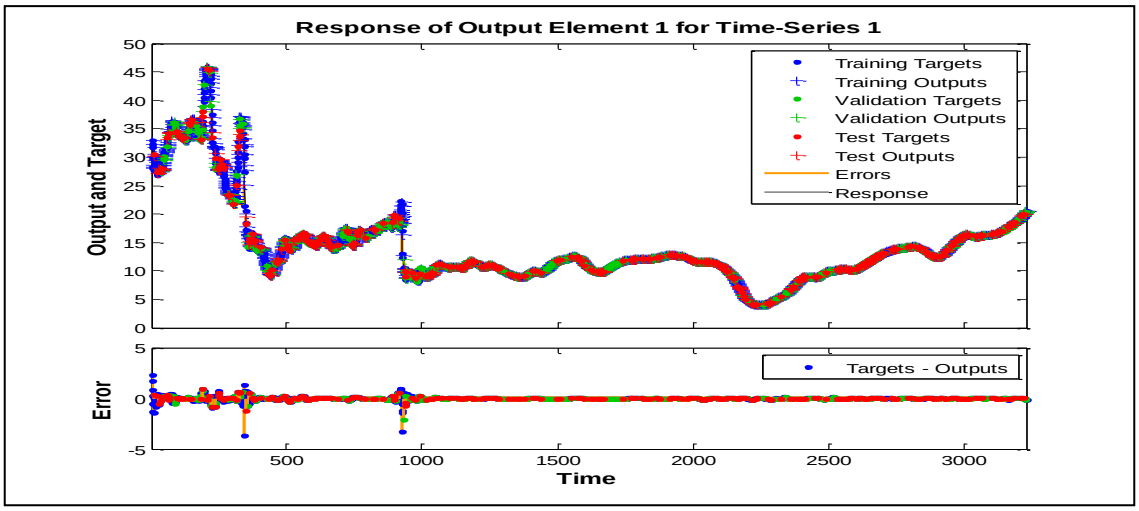
Hisse 1 için analiz sonuçları daha önce gösterilmiş ve yorumlanmıştır. Diğer hisse senetleri için analiz sonuçlarının grafiksel bu bölümde gösterimi verilmiştir.



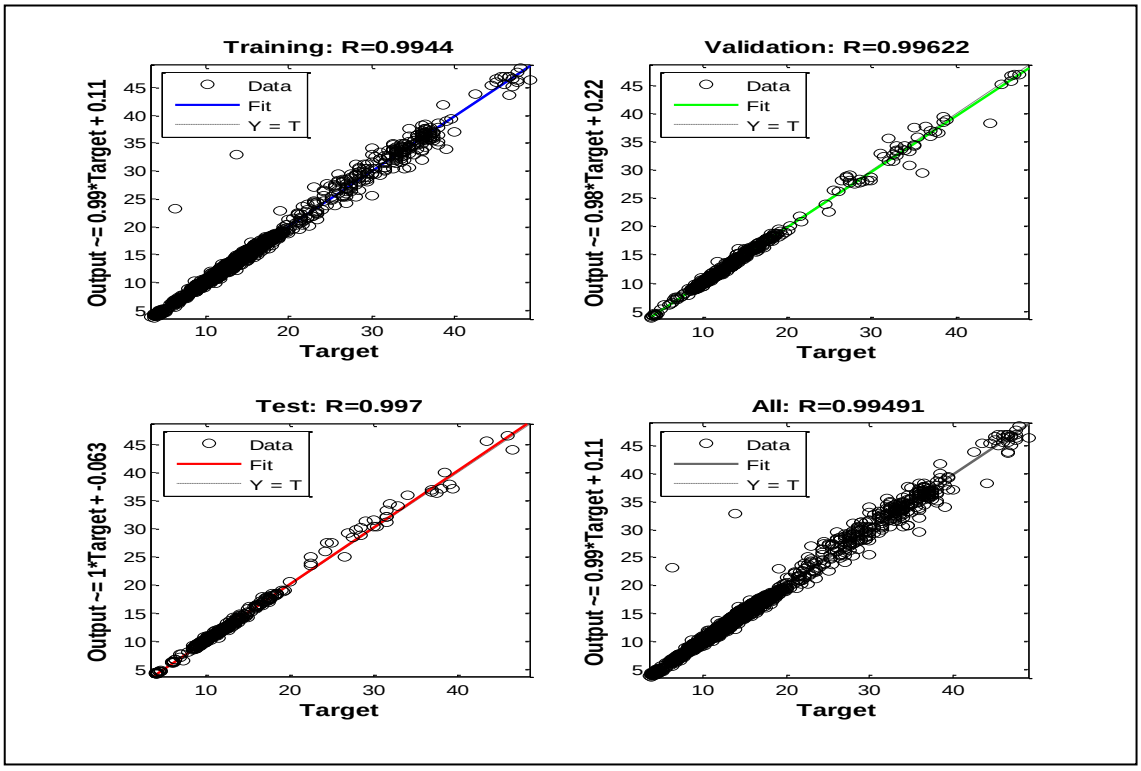
Şekil B.1 Hisse 2 nin Çıktı ve Hedef Verilerinin Ham Veriler için Gösterimi



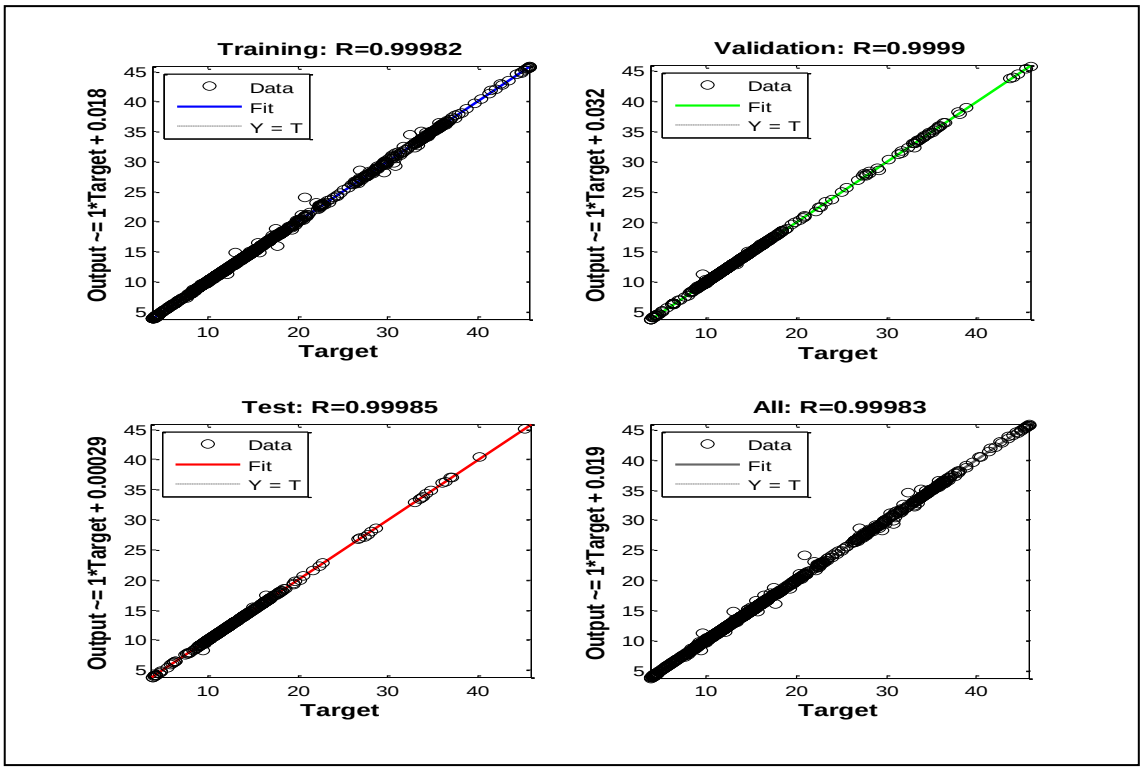
Şekil B.2 Hisse 2 nin Çıktı ve Hedef Verilerinin DB5 ve için Gösterimi



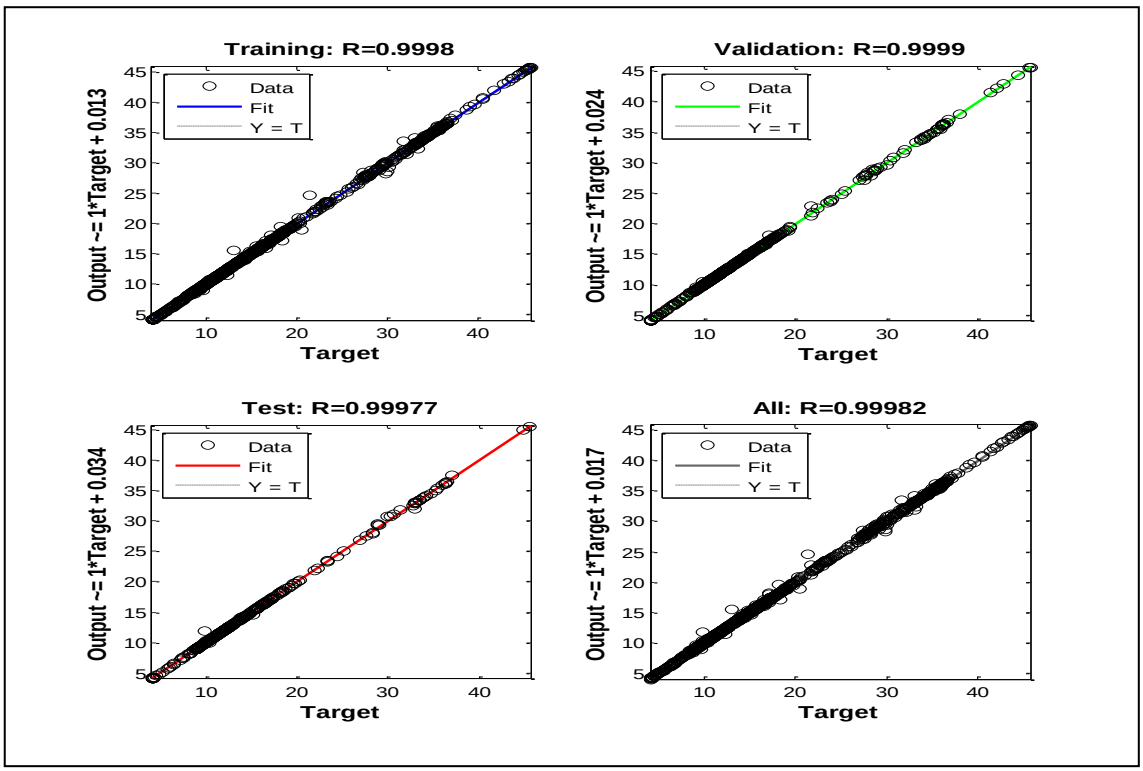
Şekil B.3 Hisse 2 nin Çıktı ve Hedef Verilerinin DB6 için Gösterimi



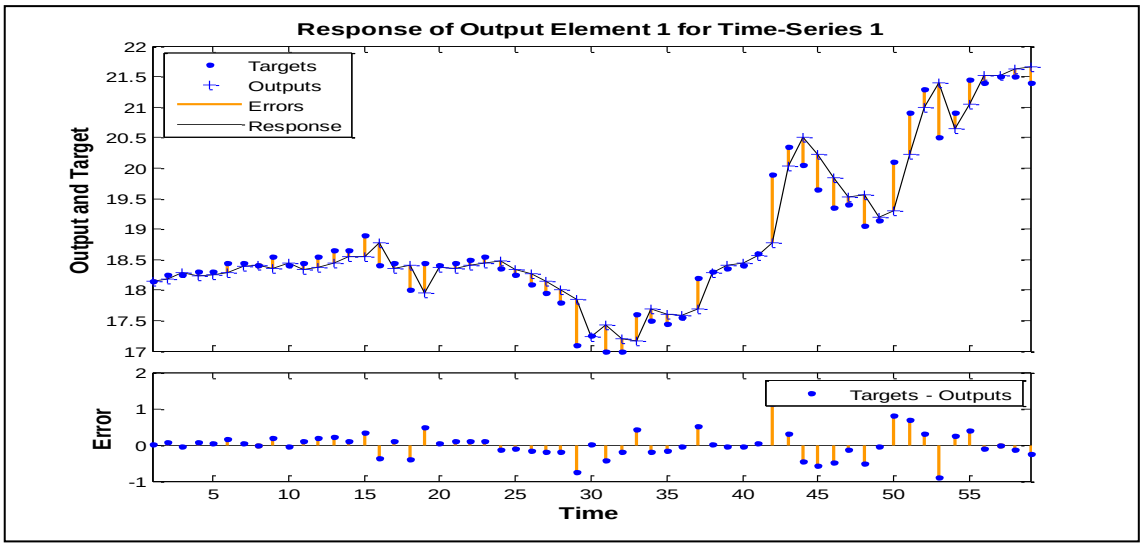
Şekil B.4 Hisse 2 nin Çıktı ve Hedef Verilerinin Regresyon Doğrularının Ham veriler için Gösterimi



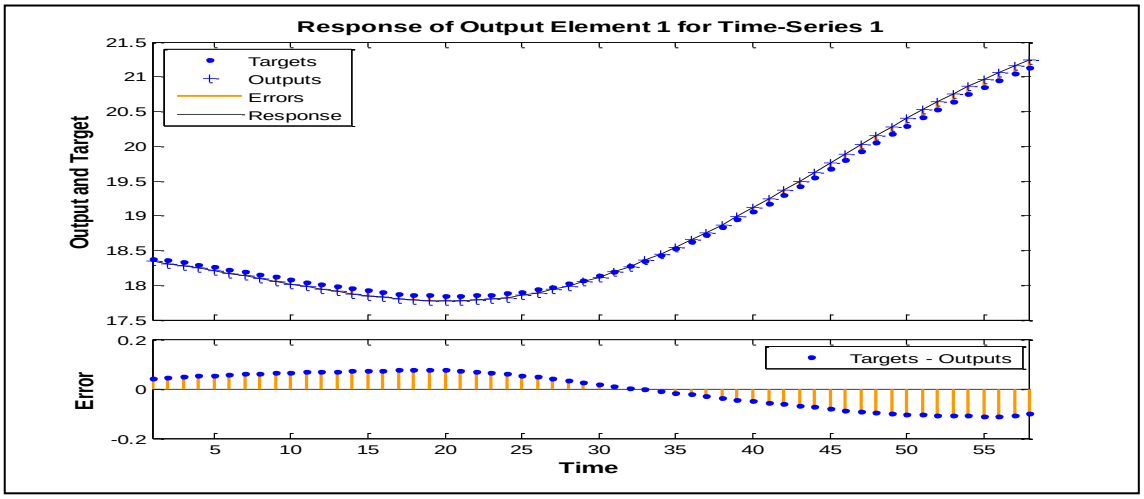
Şekil B.5 Hisse 2 nin Çıktı ve Hedef Verilerinin Regresyon Doğrularının DB5 için Gösterimi



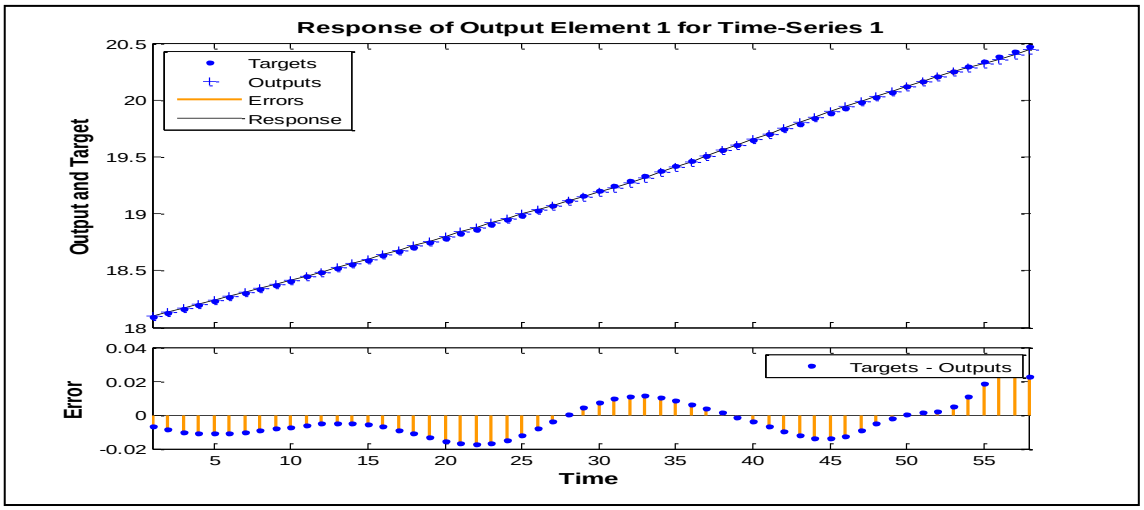
Şekil B.6 Hisse 2 nin Çıktı ve Hedef Verilerinin Regresyon Doğrularının DB6 için Gösterimi



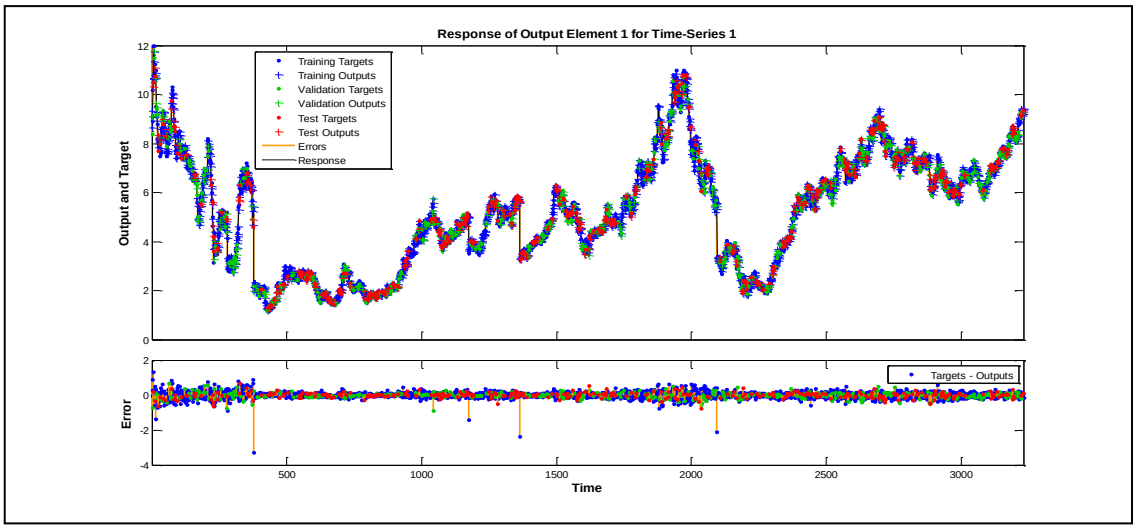
Şekil B.7 Hisse 2 nin Yeni Verilerde Çıktı ve Hedef Verilerinin Ham veriler için Gösterimi



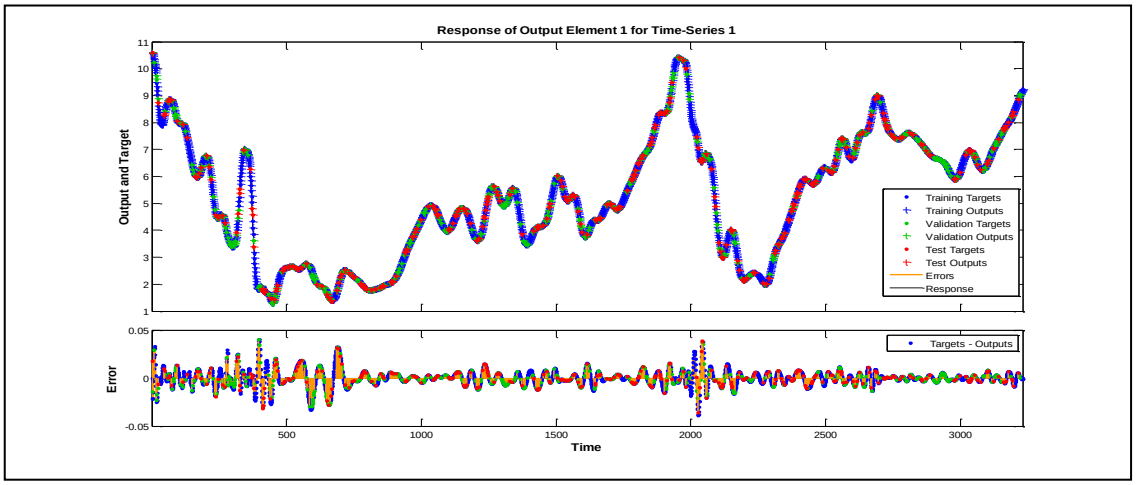
Şekil B.8 Hisse 2 nin Yeni Verilerde Çıktı ve Hedef Verilerinin DB5 için Gösterimi



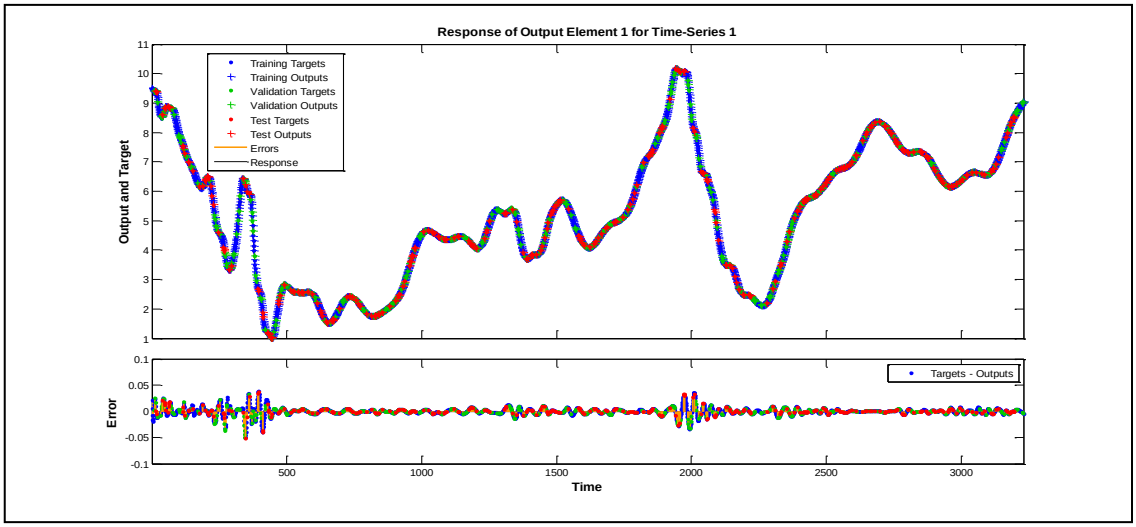
Şekil B.9 Hisse 2 nin Yeni Verilerde Çıktı ve Hedef Verilerinin DB6 için Gösterimi



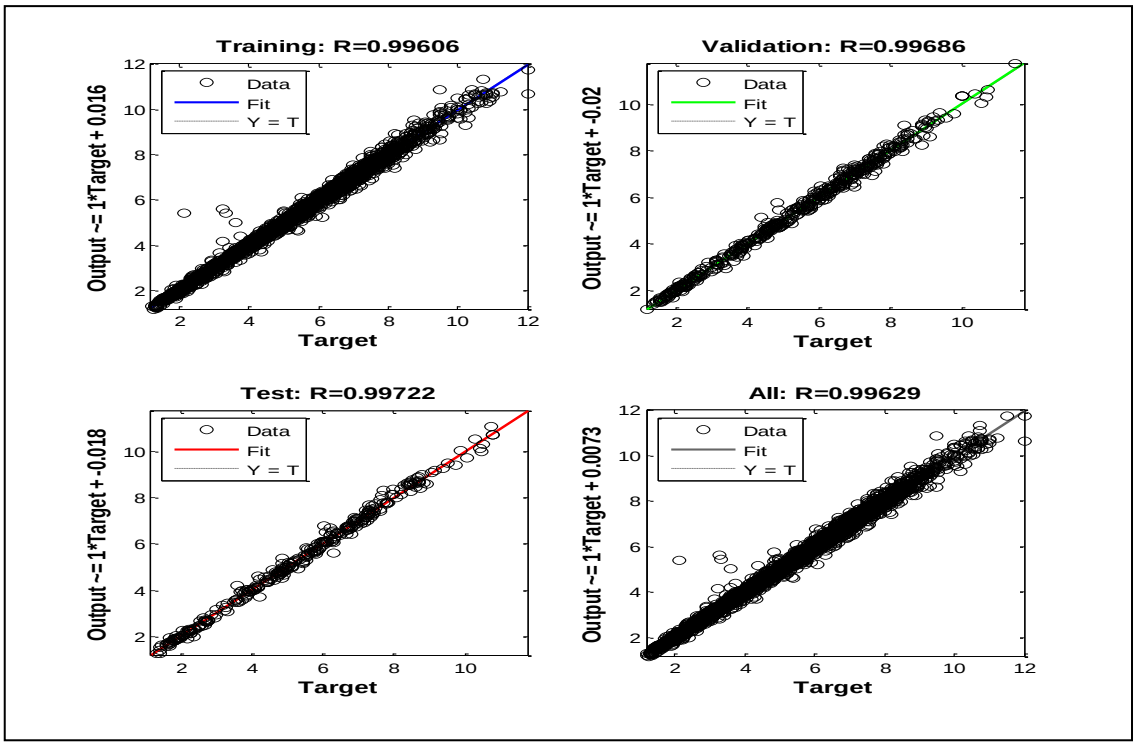
Şekil B.10 Hisse 3 nin Çıktı ve Hedef Verilerinin Ham Veriler için Gösterimi



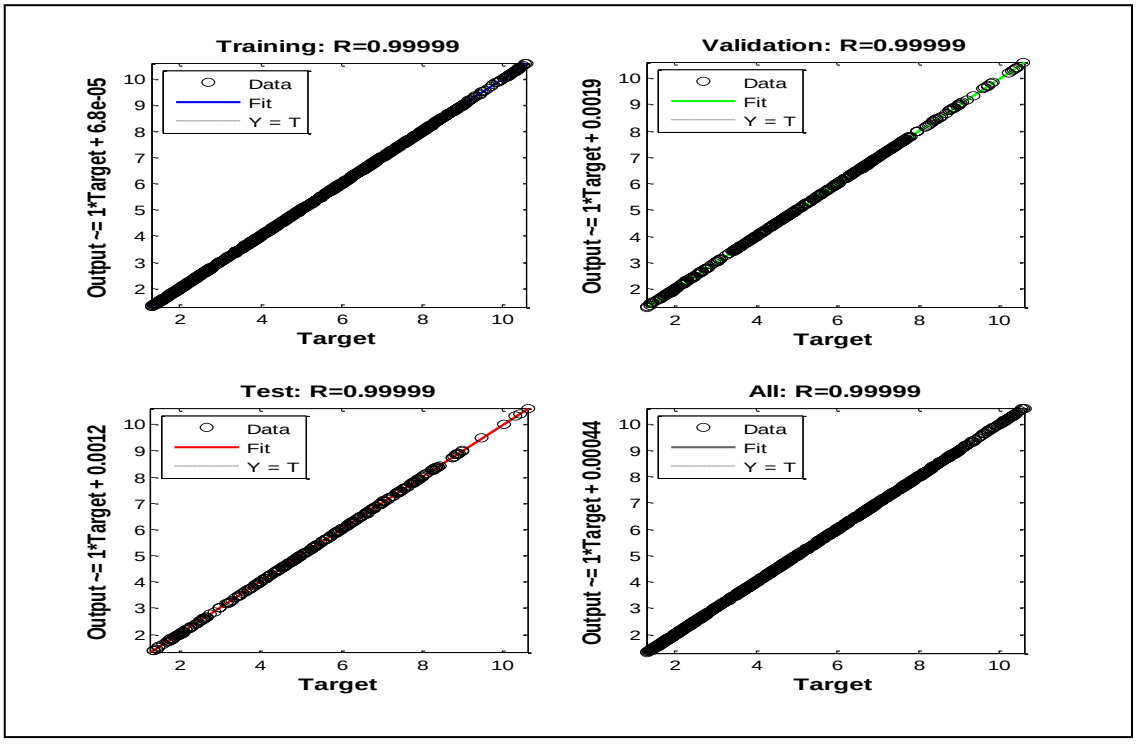
Şekil B.11 Hisse 3 nin Çıktı ve Hedef Verilerinin DB5 ve için Gösterimi



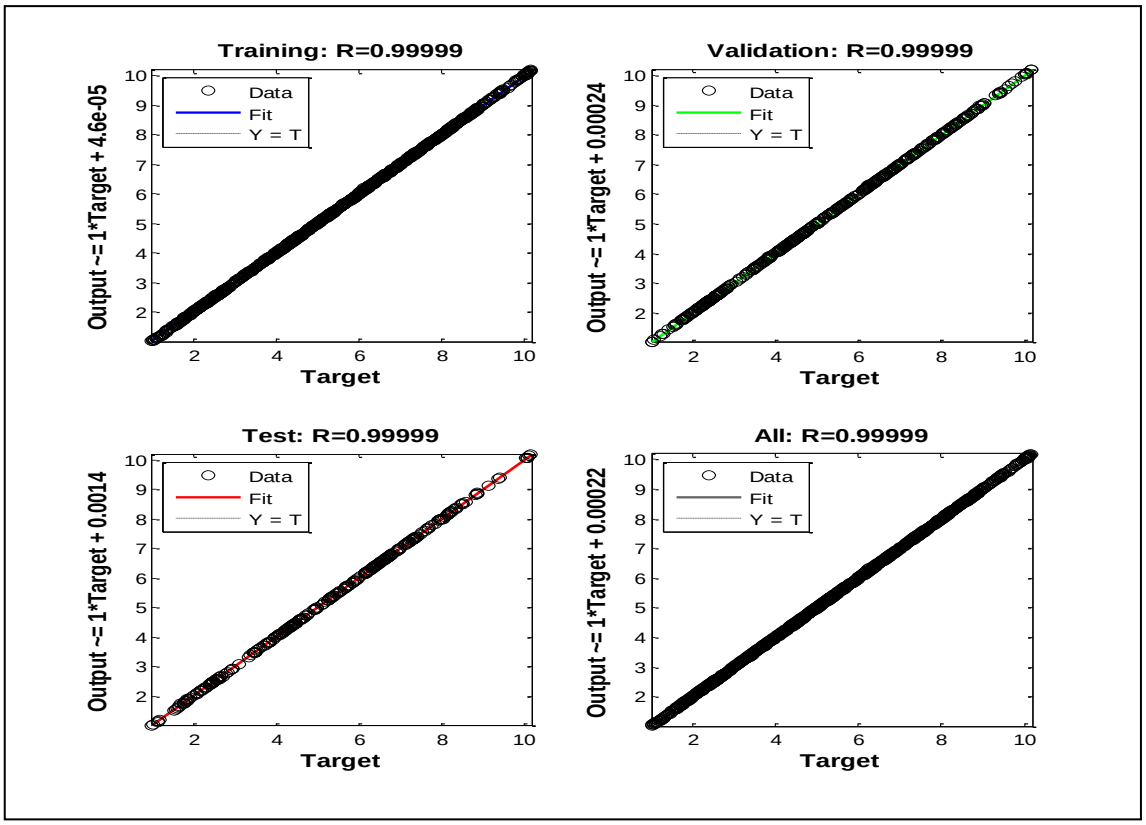
Şekil B.12 Hisse 3 nin Çıktı ve Hedef Verilerinin DB6 için Gösterimi



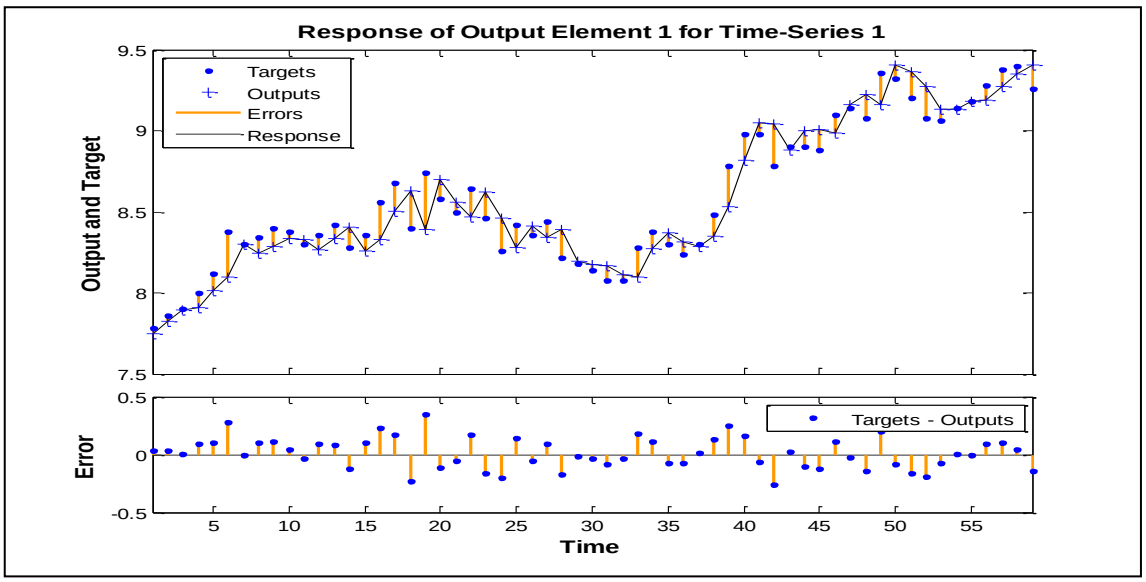
Şekil B.13 Hisse 3 ün Çıktı ve Hedef Verilerinin Regresyon Doğrularının Ham veriler için Gösterimi



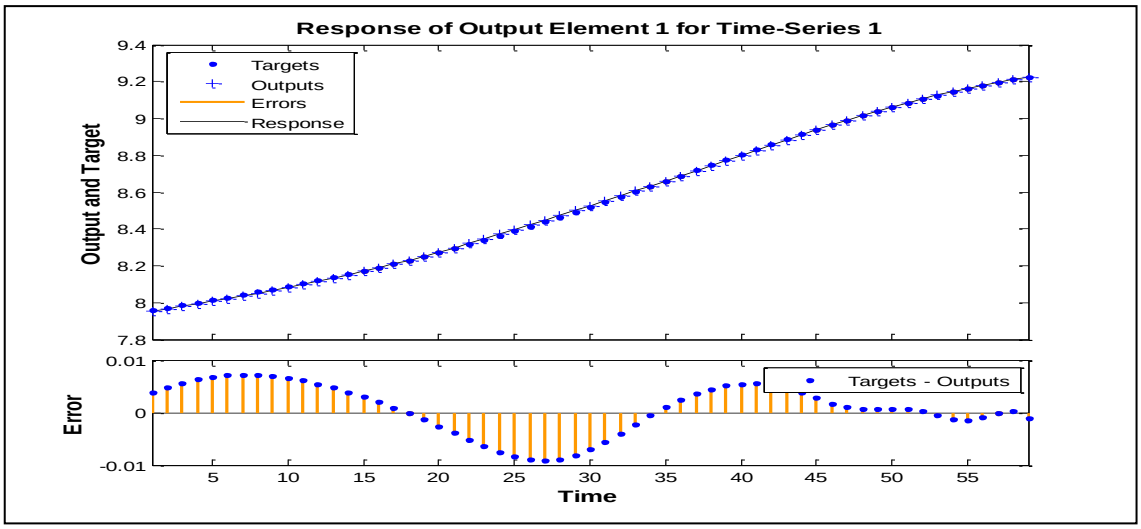
Şekil B.14 Hisse 3 ün Çıktı ve Hedef Verilerinin Regresyon Doğrularının DB5 için Gösterimi



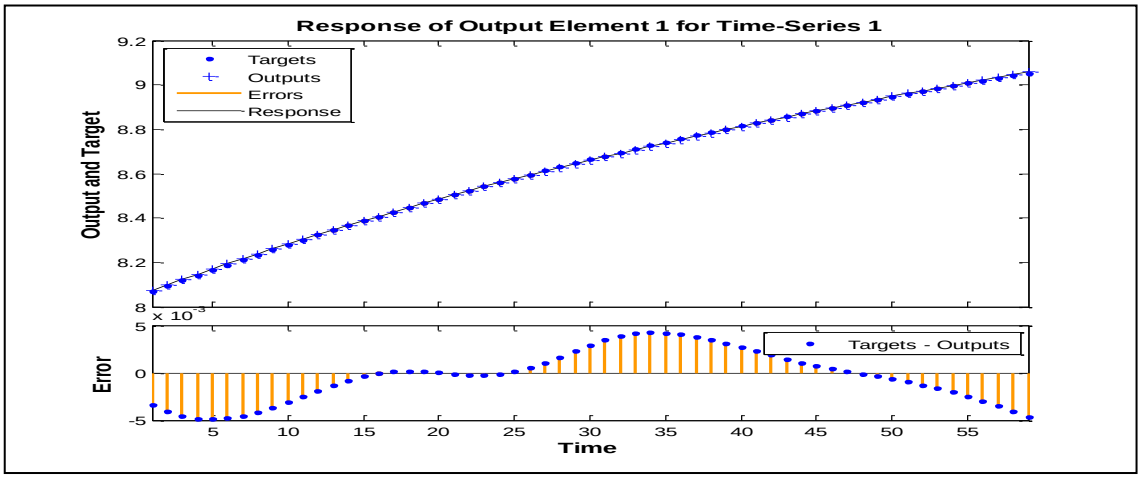
Şekil B.15 Hisse 3 ün Çıktı ve Hedef Verilerinin Regresyon Doğrularının DB6 için Gösterimi



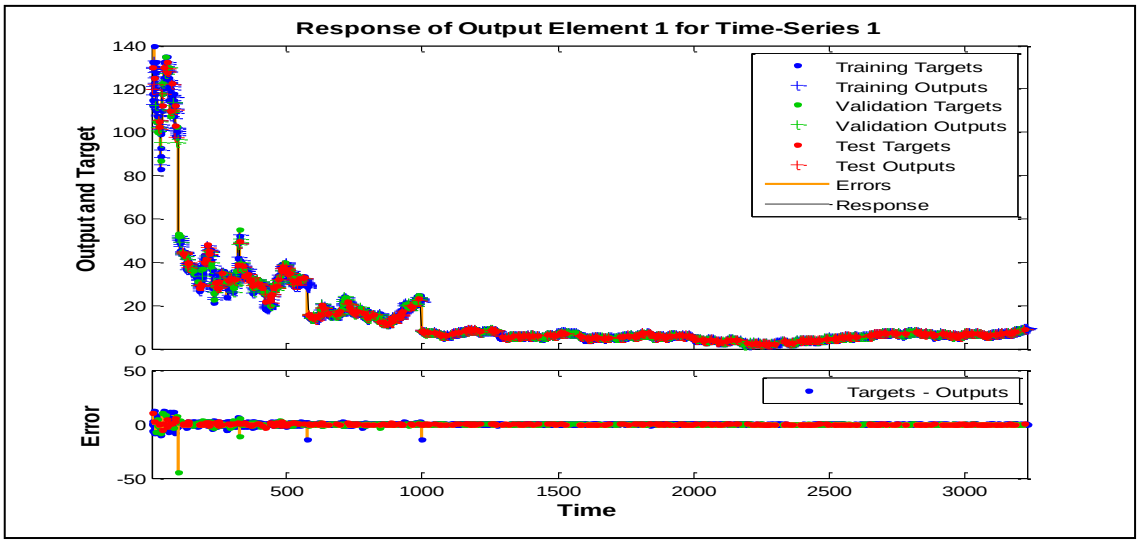
Şekil B.16 Hisse 3 ün Yeni Verilerde Çıktı ve Hedef Verilerinin Ham veriler için Gösterimi



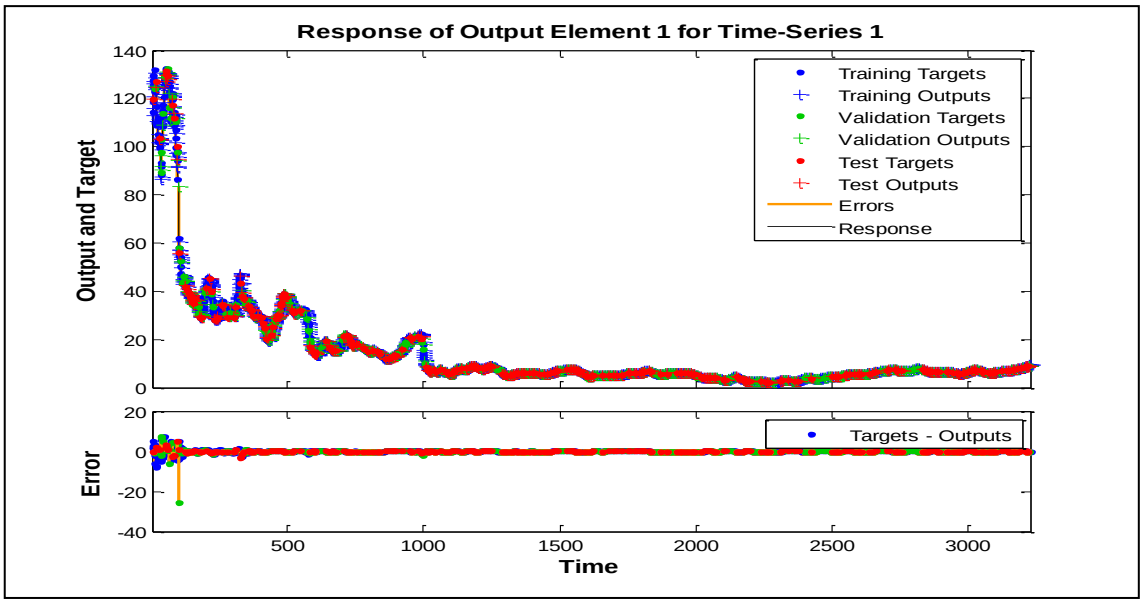
Şekil B.17 Hisse 3 ün Yeni Verilerde Çıktı ve Hedef Verilerinin DB5 için Gösterimi



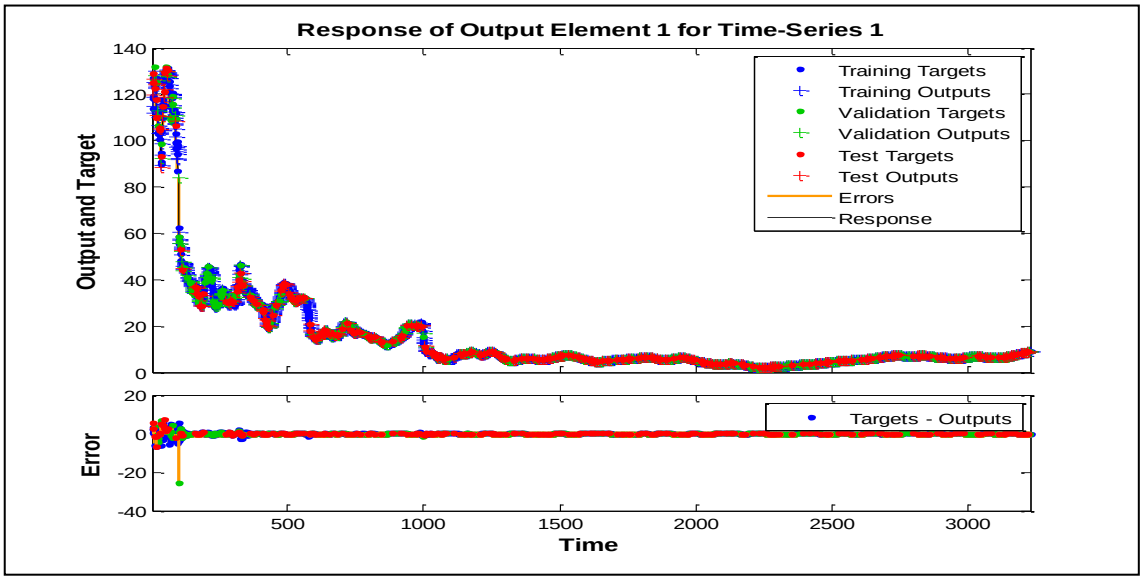
Şekil B.18 Hisse 3 ün Yeni Verilerde Çıktı ve Hedef Verilerinin DB6 için Gösterimi



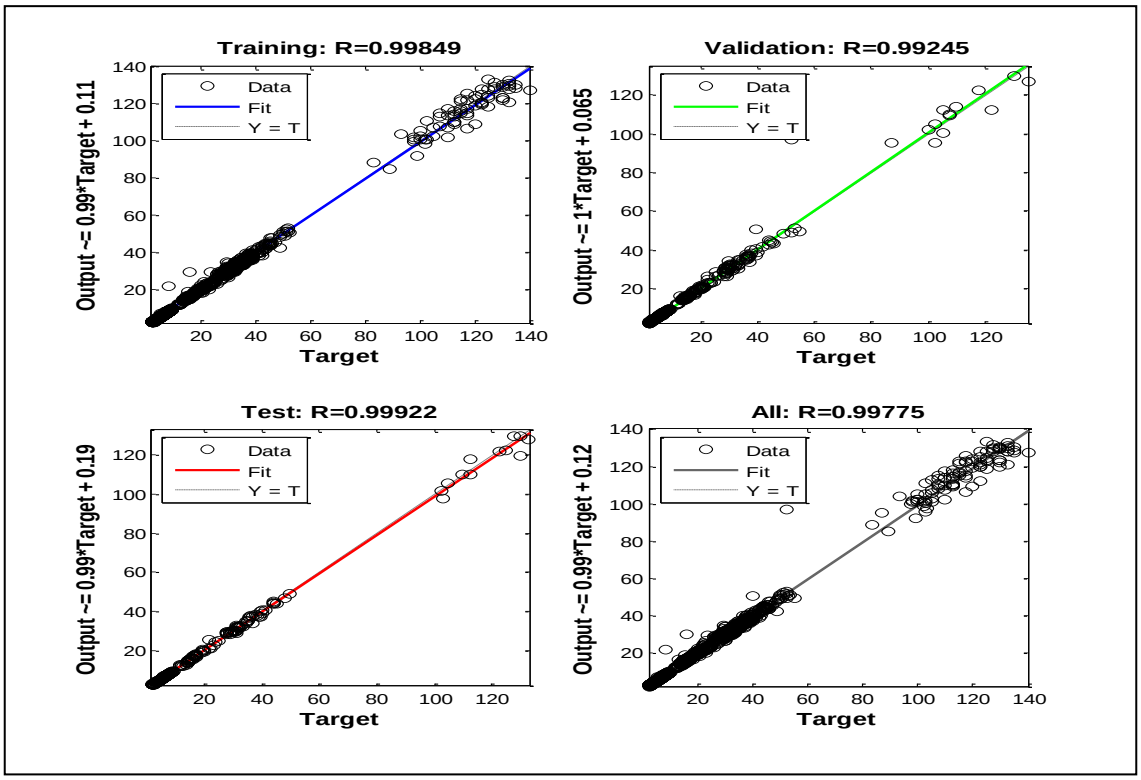
Şekil B.19 Hisse 4 ün Çıktı ve Hedef Verilerinin Ham Veriler için Gösterimi



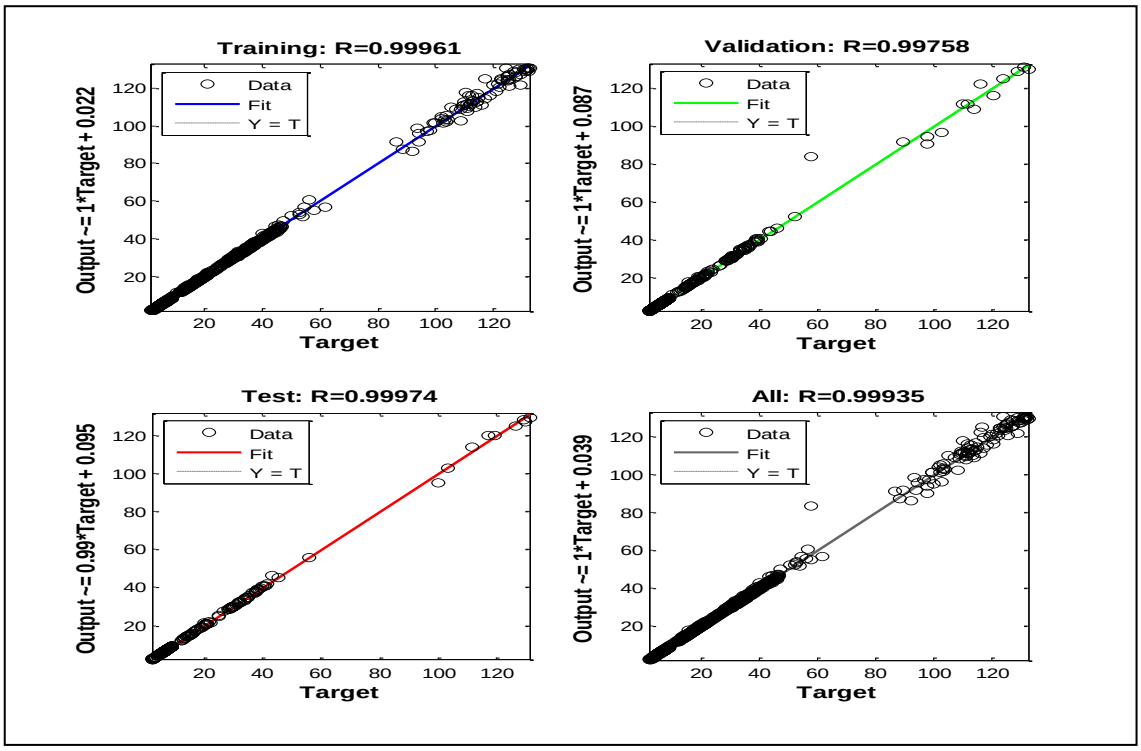
Şekil B.20 Hisse 4 ün Çıktı ve Hedef Verilerinin DB5 için Gösterimi



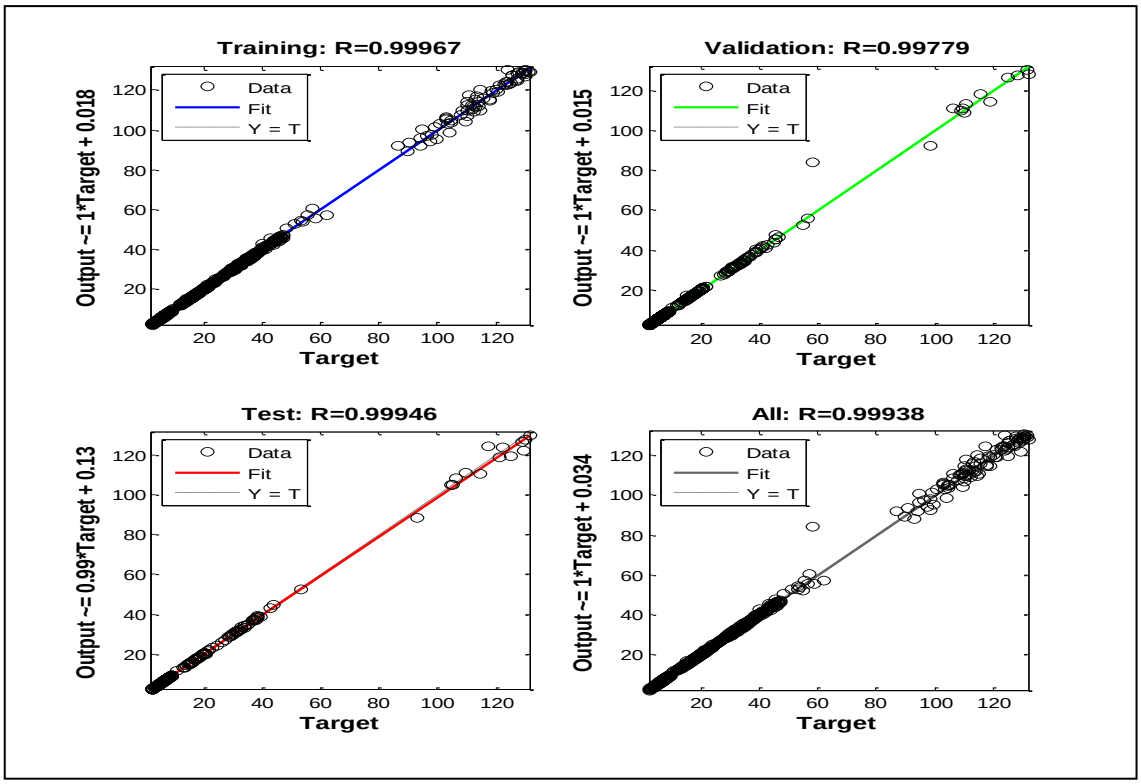
Şekil B.21 Hisse 4 ün Çıktı ve Hedef Verilerinin DB6 için Gösterimi



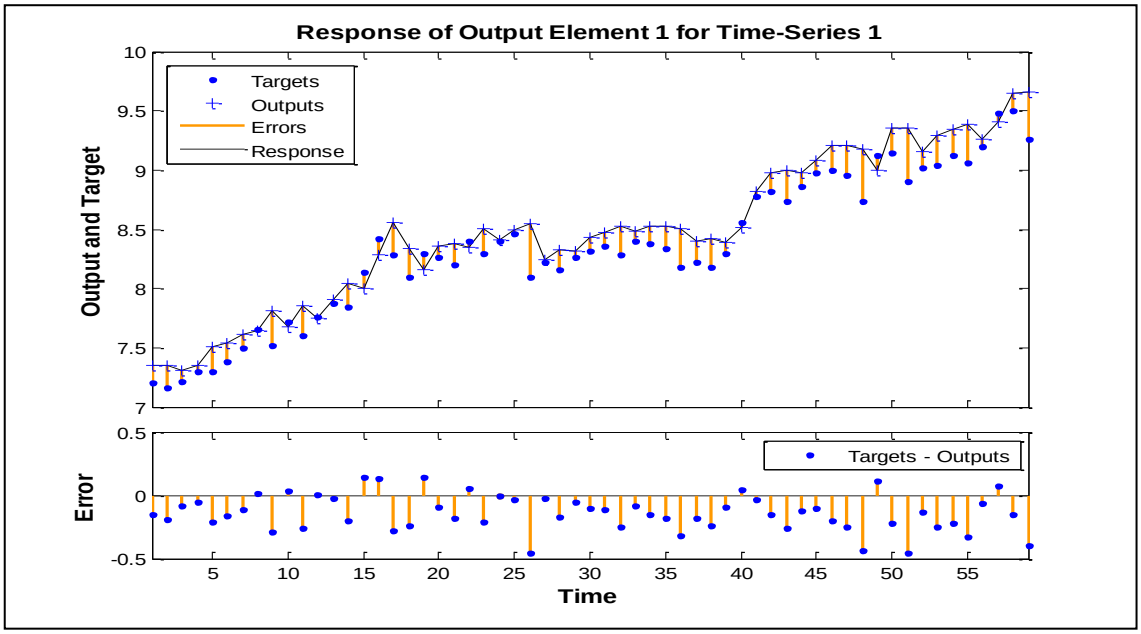
Şekil B.22 Hisse 4 ün Çıktı ve Hedef Verilerinin Regresyon Doğrularının Ham veriler için Gösterimi



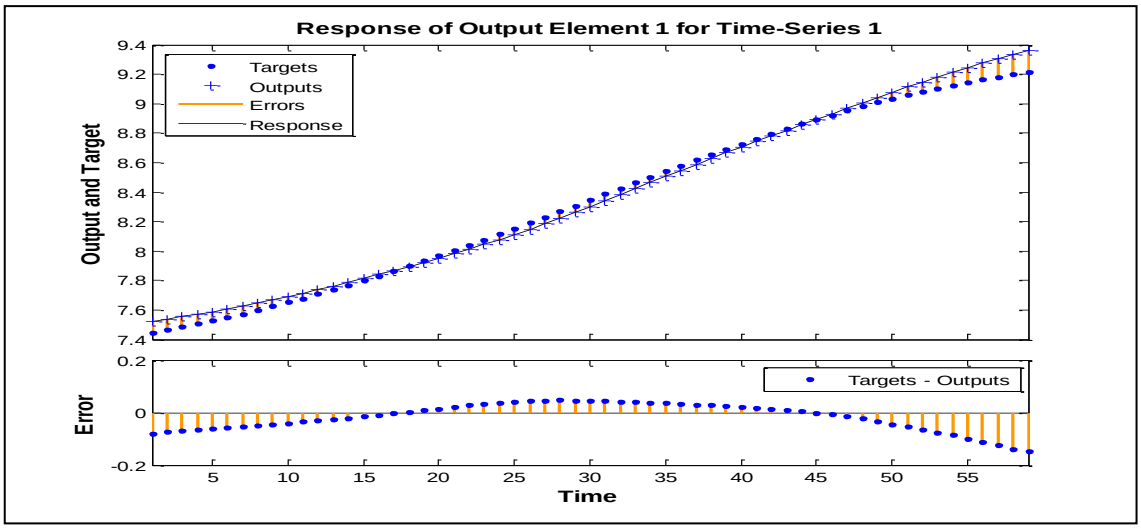
Şekil B.23 Hisse 4 ün Çıktı ve Hedef Verilerinin Regresyon Doğrularının DB5 için Gösterimi



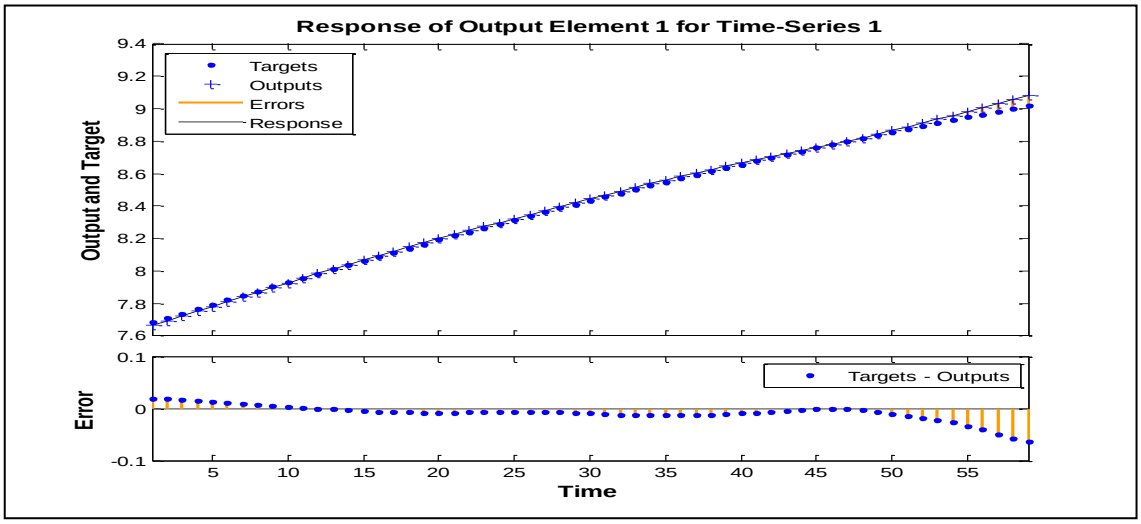
Şekil B.24 Hisse 4 ün Çıktı ve Hedef Verilerinin Regresyon Doğrularının DB6 için Gösterimi



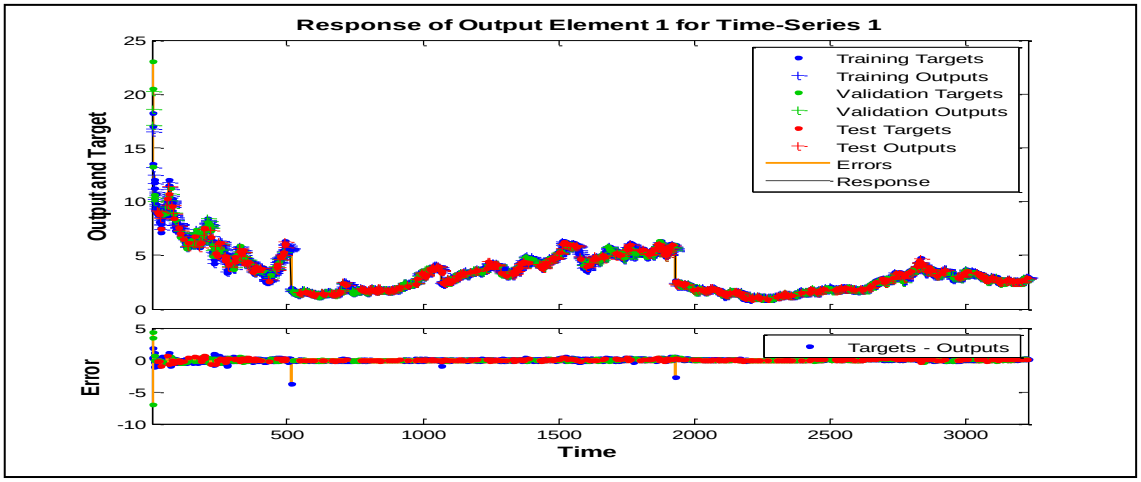
Şekil B.25 Hisse 4 ün Yeni Verilerde Çıktı ve Hedef Verilerinin Ham veriler için Gösterimi



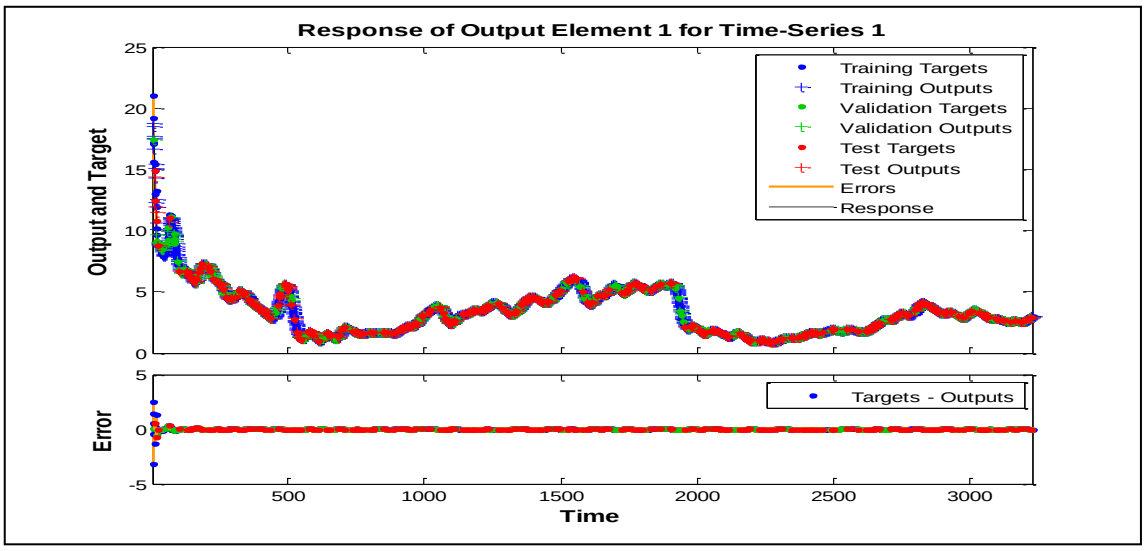
Şekil B.26 Hisse 4 ün Yeni Verilerde Çıktı ve Hedef Verilerinin DB5 için Gösterimi



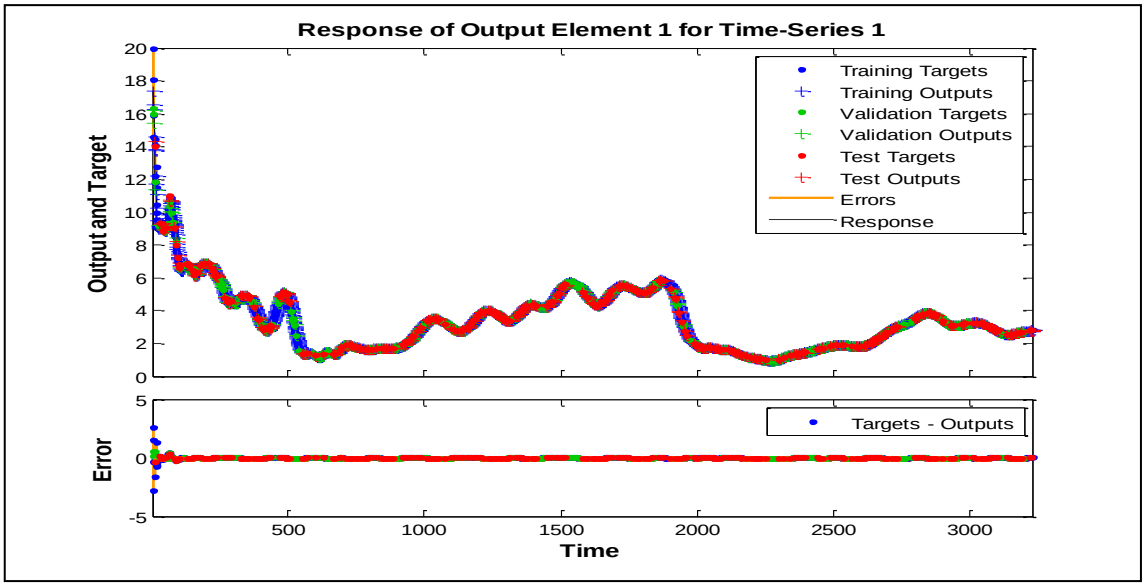
Şekil B.27 Hisse 4 ün Yeni Verilerde Çıktı ve Hedef Verilerinin DB6 için Gösterimi



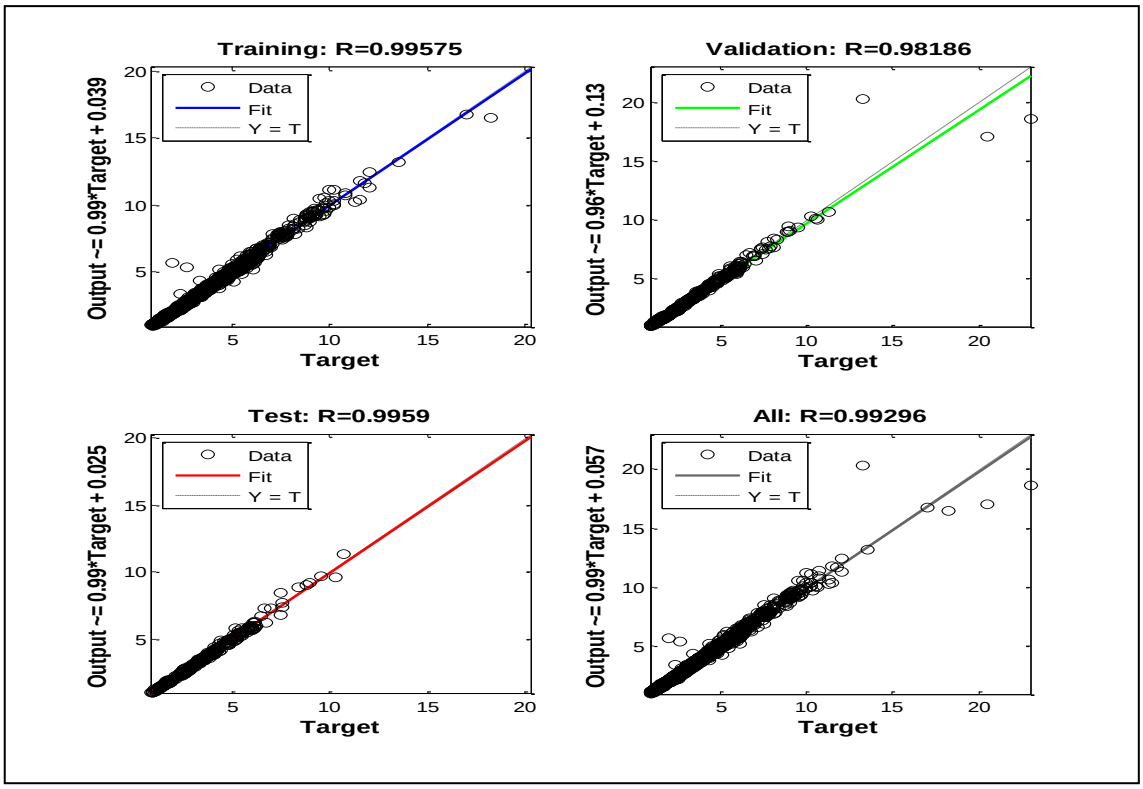
Şekil B.28 Hisse 5 in Çıktı ve Hedef Verilerinin Ham Veriler için Gösterimi



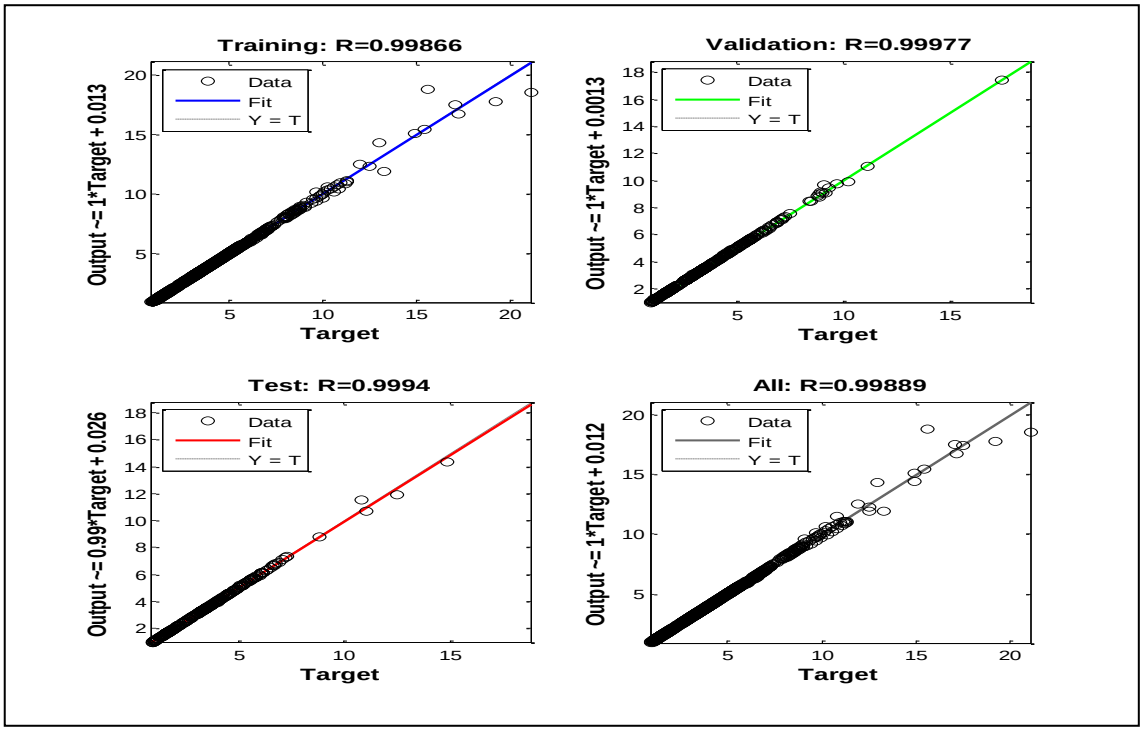
Şekil B.29 Hisse 5 in Çıktı ve Hedef Verilerinin DB5 için Gösterimi



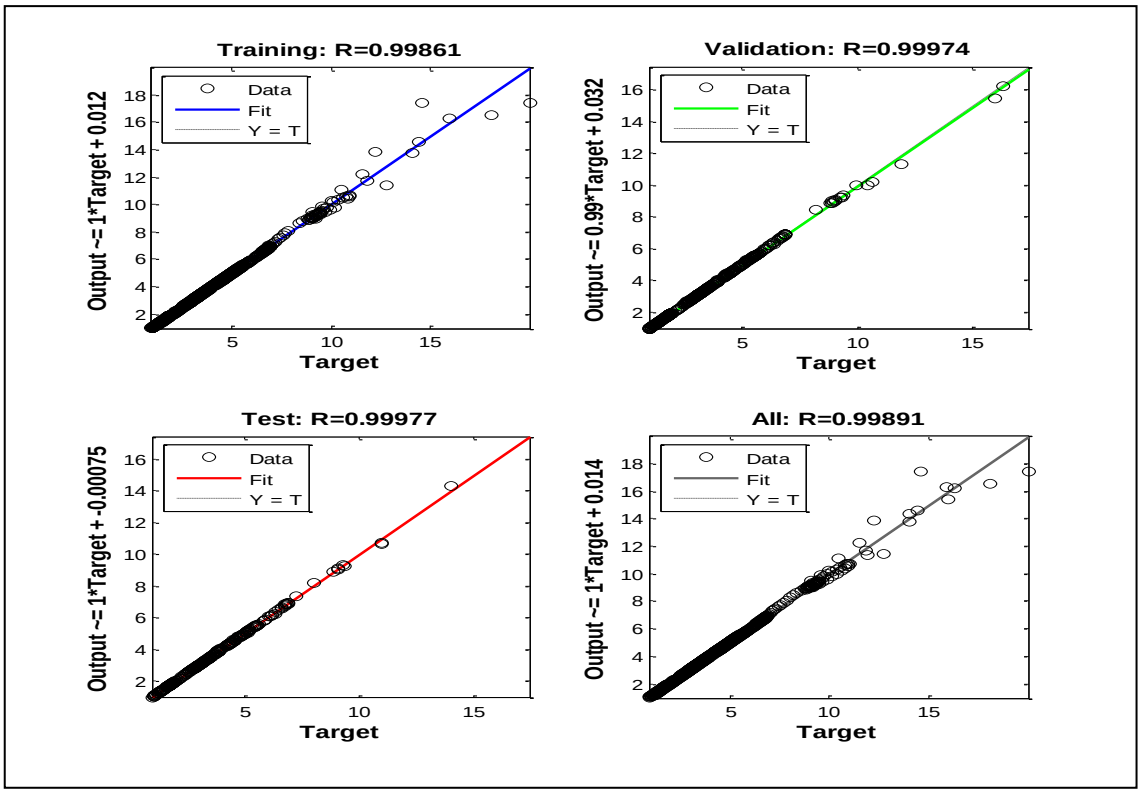
Şekil B.30 Hisse 5 in Çıktı ve Hedef Verilerinin DB6 için Gösterimi



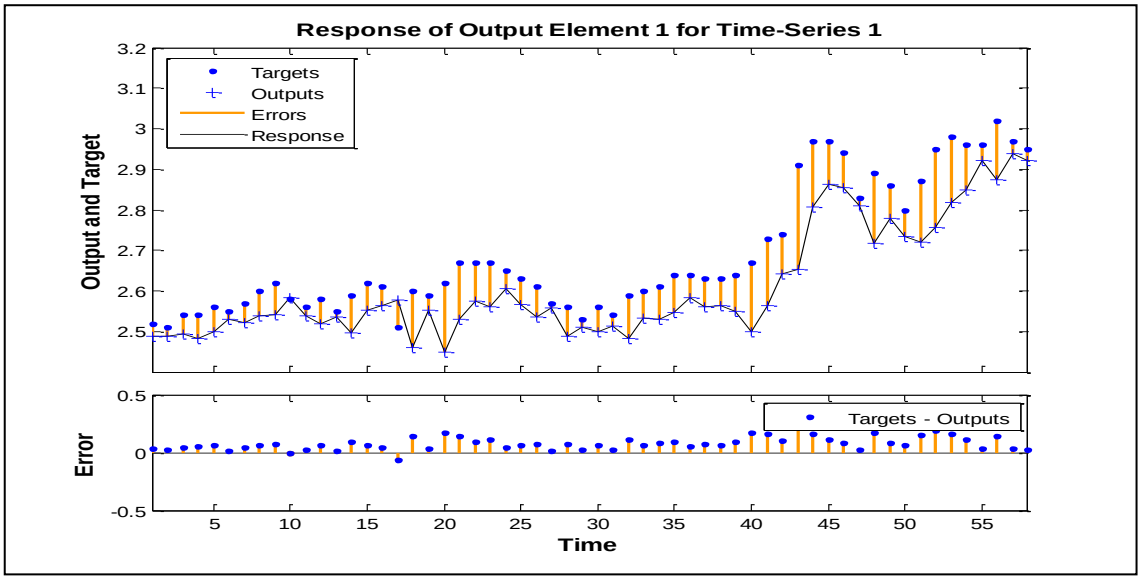
Şekil B.31 Hisse 5 in Çıktı ve Hedef Verilerinin Regresyon Doğrularının Ham veriler için Gösterimi



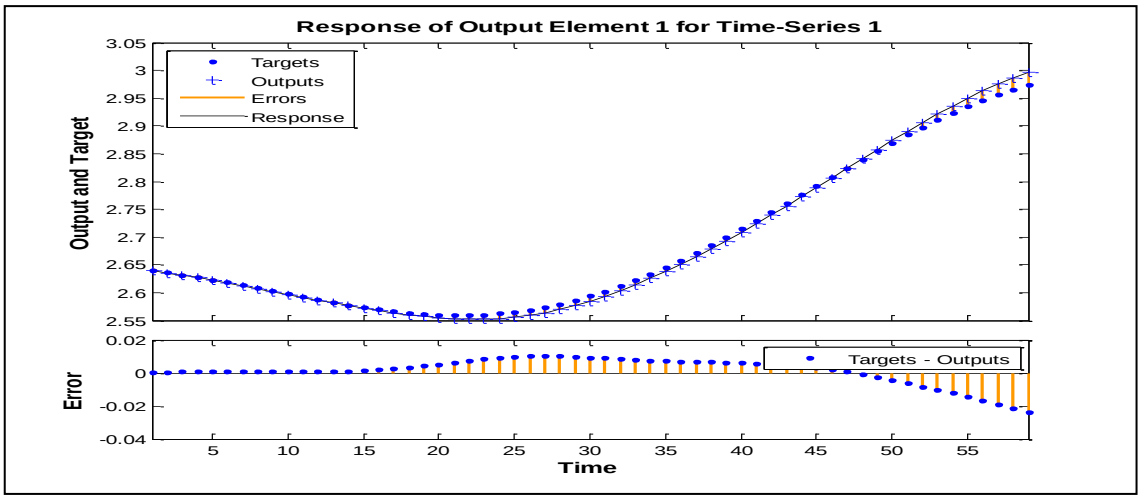
Şekil B.32 Hisse 5 in Çıktı ve Hedef Verilerinin Regresyon Doğrularının DB5 için Gösterimi



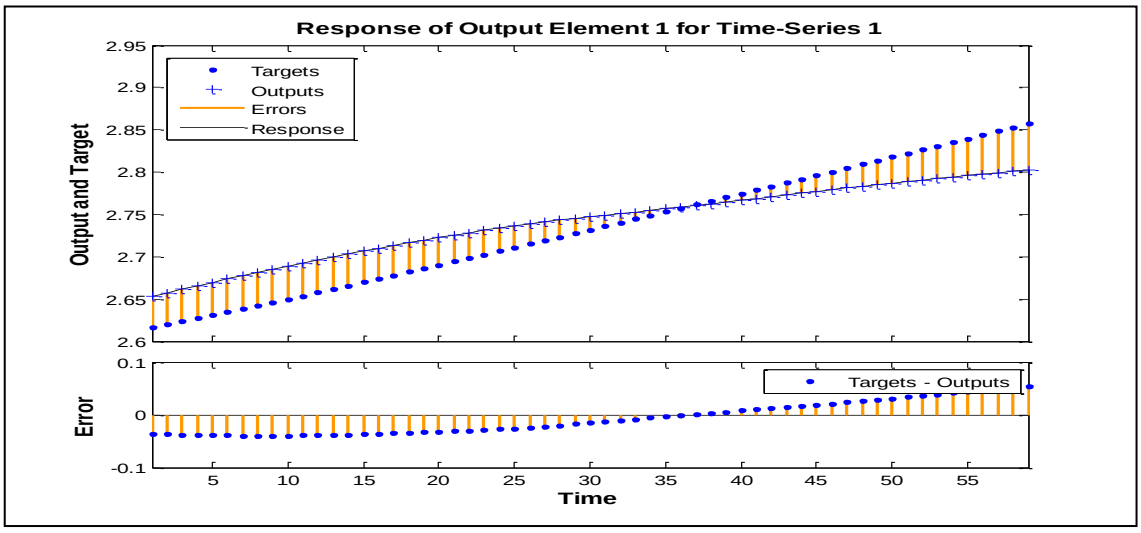
Şekil B.33 Hisse 5 için Çıktı ve Hedef Verilerinin Regresyon Doğrularının DB6 için Gösterimi



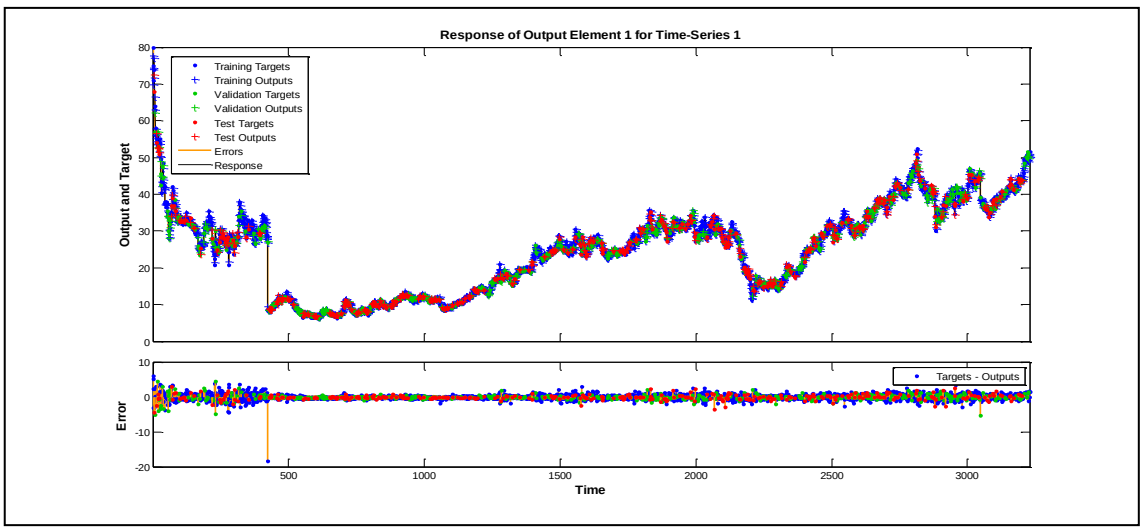
Şekil B.34 Hisse 5 in Yeni Verilerde Çıktı ve Hedef Verilerinin Ham veriler için Gösterimi



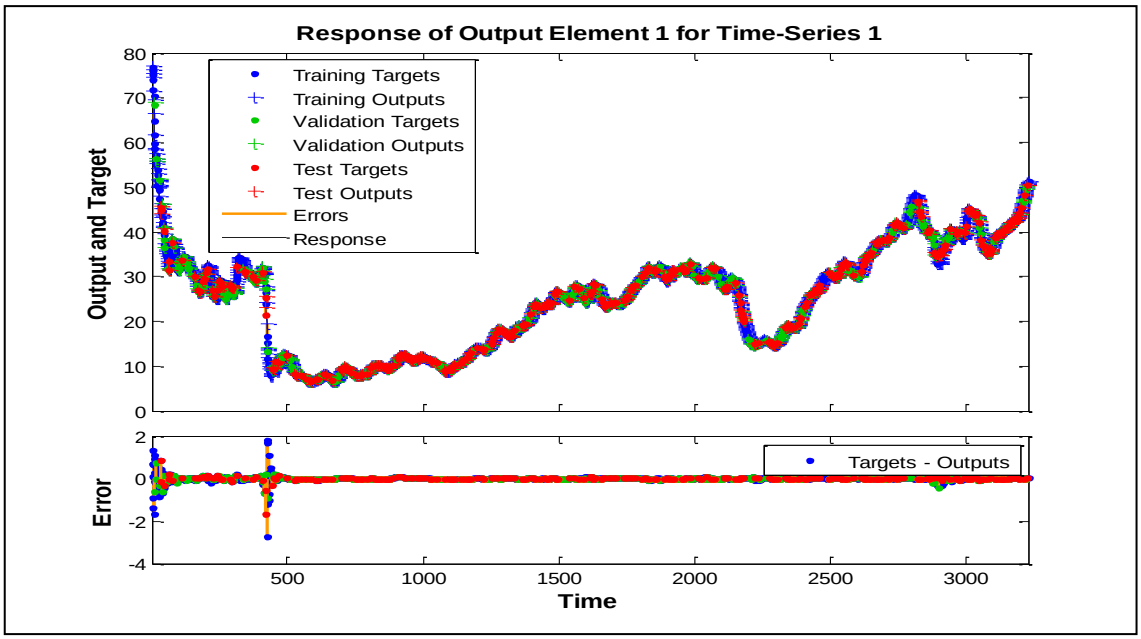
Şekil B.35 Hisse 5 in Yeni Verilerde Çıktı ve Hedef Verilerinin DB5 için Gösterimi



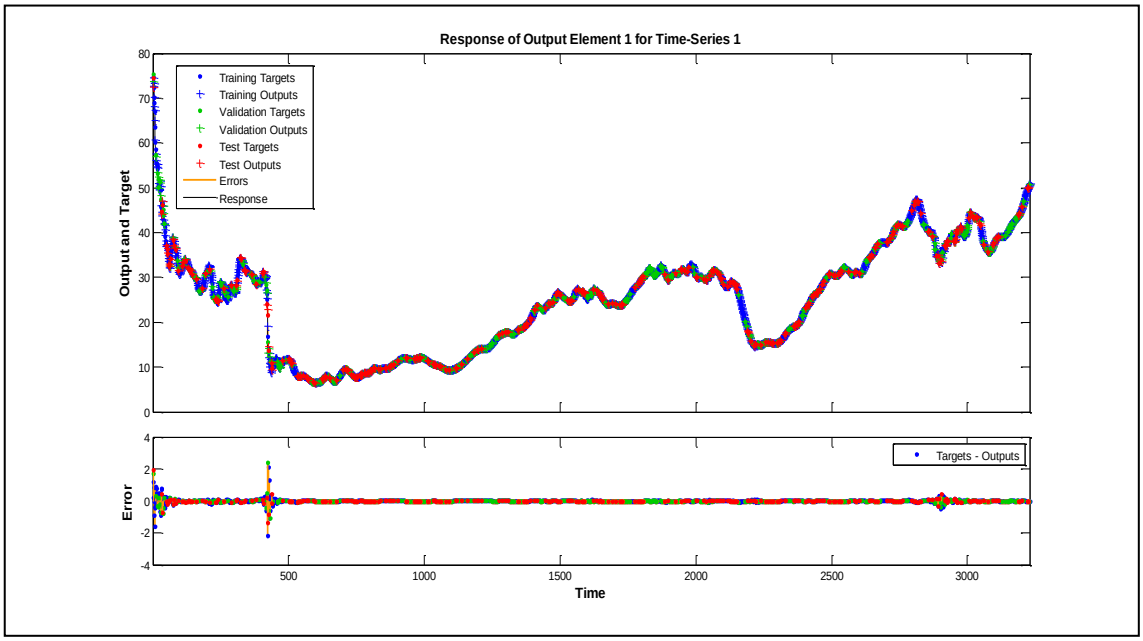
Şekil B.36 Hisse 5 in Yeni Verilerde Çıktı ve Hedef Verilerinin DB6 için Gösterimi



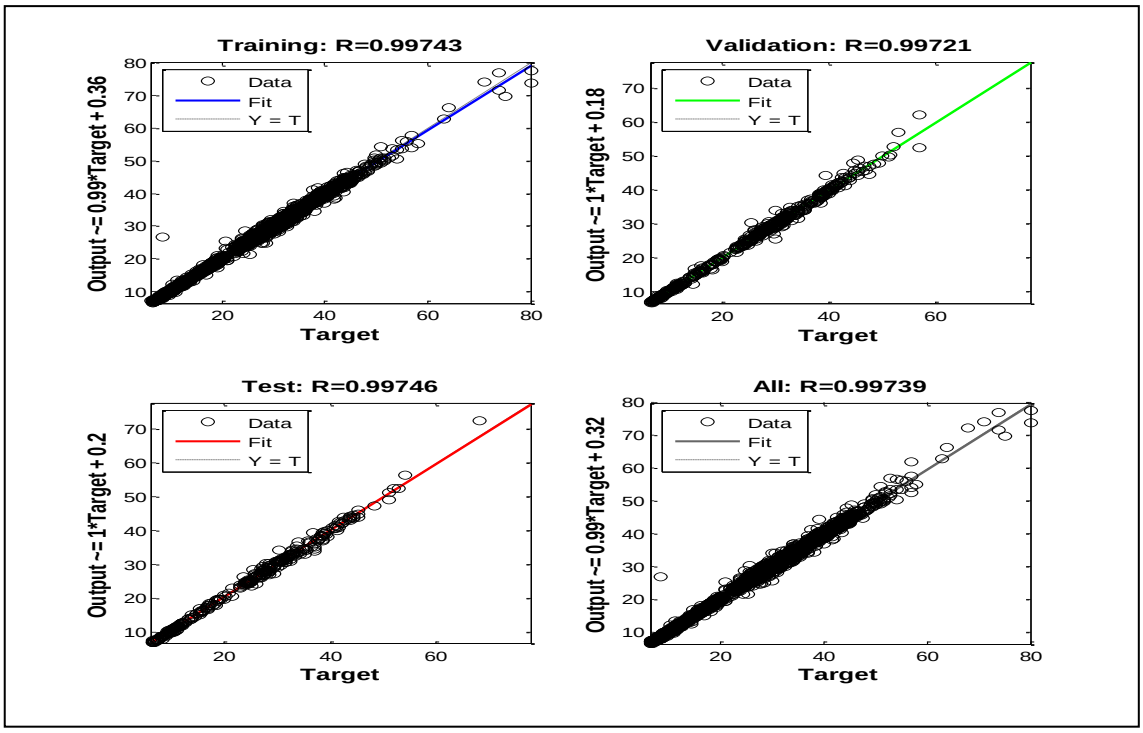
Şekil B.37 Hisse 6 nın Çıktı ve Hedef Verilerinin Ham Veriler için Gösterimi



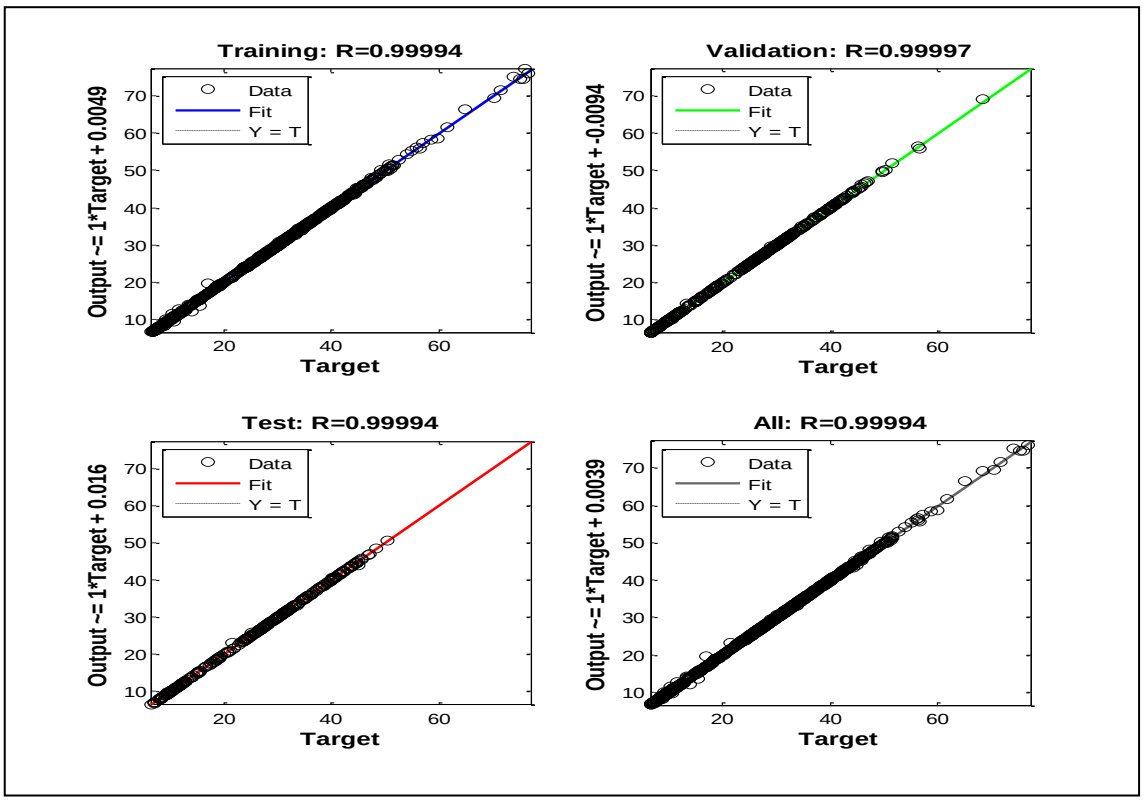
Şekil B.38 Hisse 6 nın Çıktı ve Hedef Verilerinin DB5 için Gösterimi



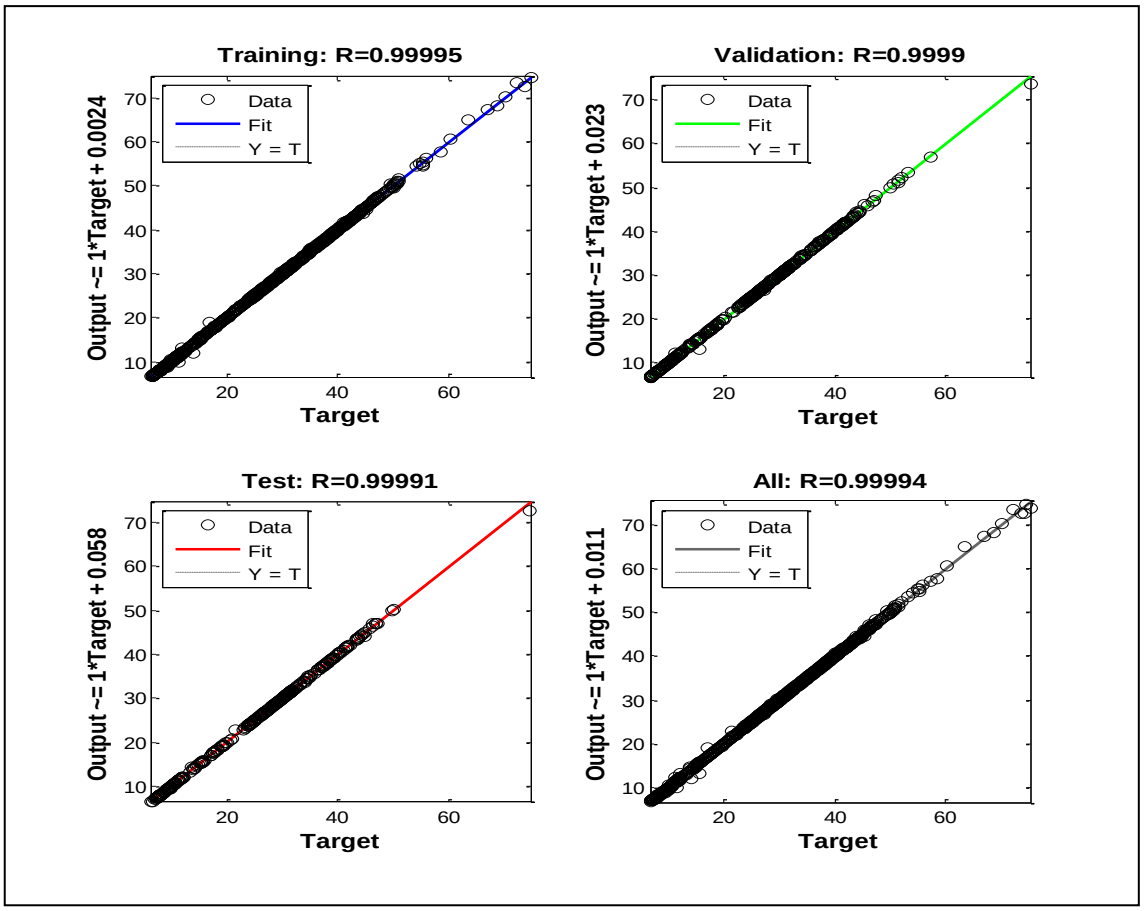
Şekil B.39 Hisse 6 nın Çıktı ve Hedef Verilerinin DB6 için Gösterimi



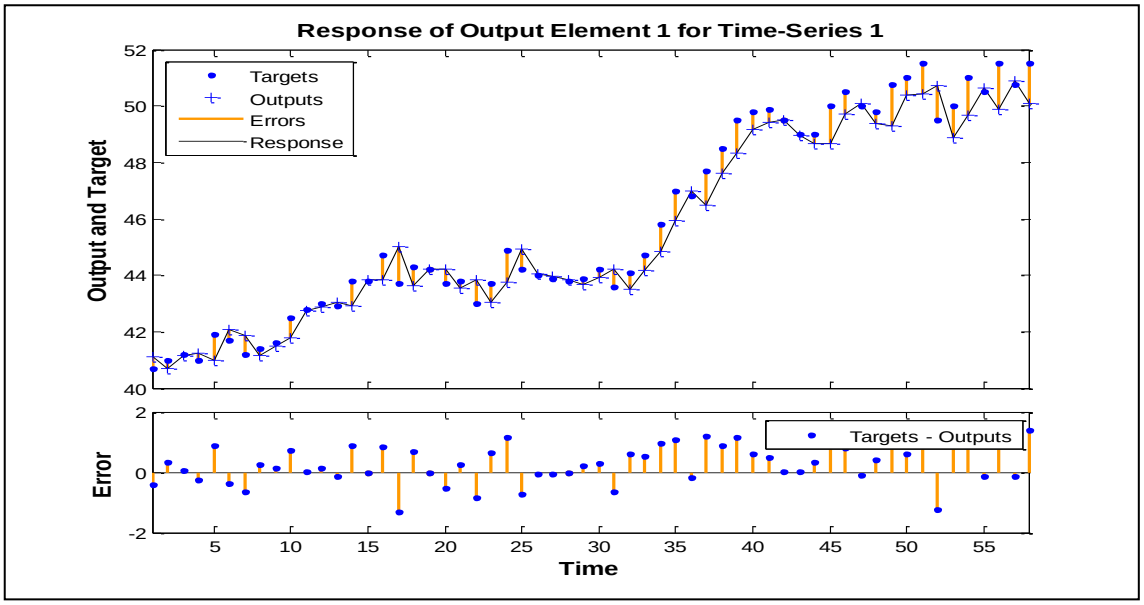
Şekil B.40 Hisse 6 nın Çıktı ve Hedef Verilerinin Regresyon Doğrularının Ham veriler için Gösterimi



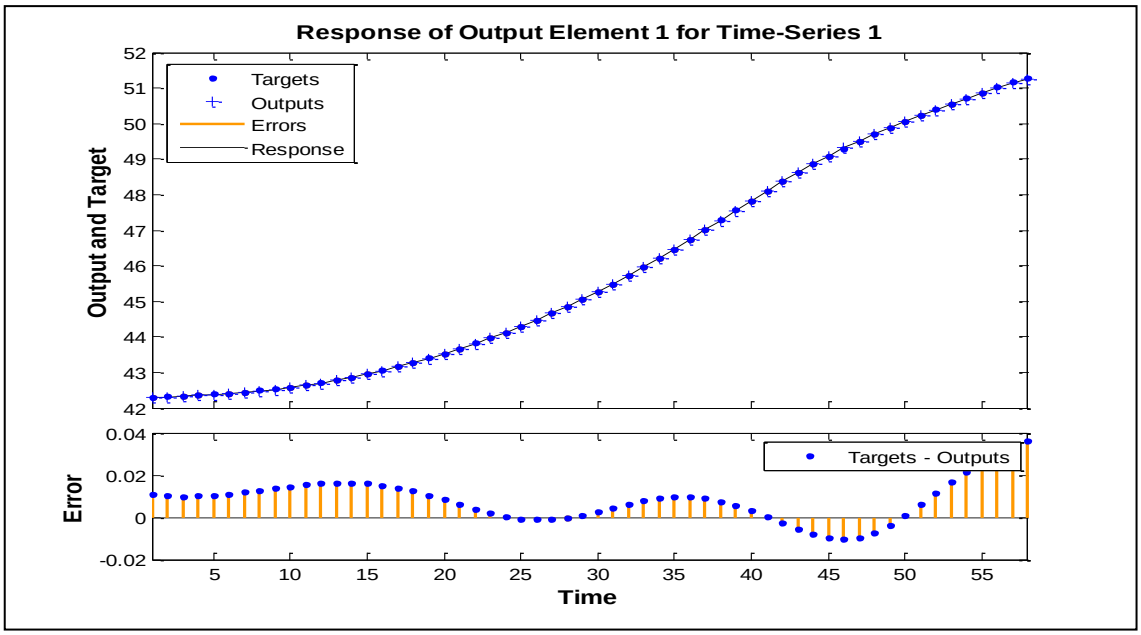
Şekil B.41 Hisse 6 nın Çıktı ve Hedef Verilerinin Regresyon Doğrularının DB5 için Gösterimi



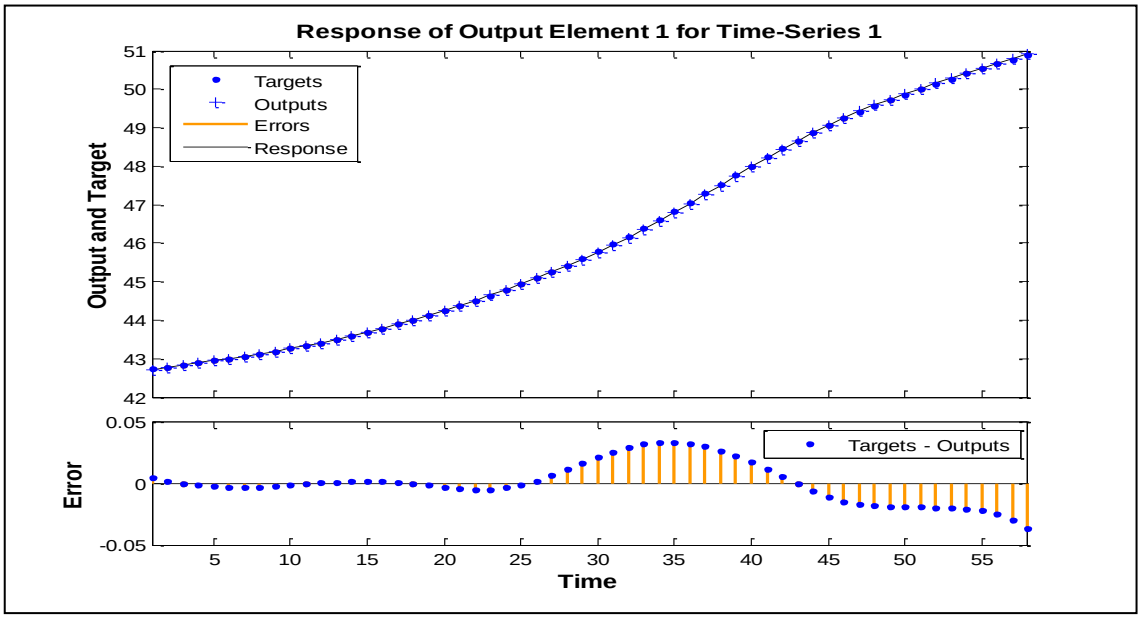
Şekil B.42 Hisse 6 nın Çıktı ve Hedef Verilerinin Regresyon Doğrularının DB6 için Gösterimi



Şekil B.43 Hisse 6 nın Yeni Verilerde Çıktı ve Hedef Verilerinin Ham veriler için Gösterimi



Şekil B.44 Hisse 6 nın Yeni Verilerde Çıktı ve Hedef Verilerinin DB5 için Gösterimi



Şekil B.45 Hisse 6 nın Yeni Verilerde Çıktı ve Hedef Verilerinin DB6 için Gösterimi

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı :HASAN AYKUT KARABOĞA

Doğum Tarihi ve Yeri :1989 / ADIYAMAN

Yabancı Dili :İngilizce

E-posta : karaboga@yildiz.edu.tr

ÖĞRENİM DURUMU

Derece	Alan	Okul/Üniversite	Mezuniyet Yılı
Lisans	İstatistik Bölümü	Yıldız Teknik Üniversitesi	2012
Lise	Matematik - Fen	Gölbaşı Yabancı Dil Ağırlıklı Lisesi	2007

İŞ TECRÜBESİ

Yıl	Firma/Kurum	Görevi
2012	Yıldız Teknik Üniversitesi	Araştırma Görevlisi
2012	Amasya Üniversitesi	Araştırma Görevlisi

YAYINLARI

Bildiri

1. Demir, İ., Karaboğa, H. A., "An Application On Estimated Value Of Stocks Using Artificial Neural Networks", **2nd International Eurasian Conference on Mathematical Sciences and Applications (IECMSA-2013)**, Saraybosna, 2013

2. Karaboğa, H. A., Demir, İ., "An Application On Stock Price Prediction With Neural Network By Using Wavelet Transform", **3rd International Eurasian Conference on Mathematical Sciences and Applications (IECMSA-2014)**, Vienna, AUSTRIA, 2014