

T.C.
GEBZE TEKNİK ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ

MODEL MELEZLEME İLE FİNANSAL ZAMAN SERİSİ
ANALİZİ

Fatma SÖNMEZ ÇAKIR
DOKTORA TEZİ
İŞLETME ANABİLİM DALI

GEBZE

2018

T.C.
GEBZE TEKNİK ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ

MODEL MELEZLEME İLE FİNANSAL
ZAMAN SERİSİ ANALİZİ

Fatma SÖNMEZ ÇAKIR
DOKTORA TEZİ
İŞLETME ANABİLİM DALI

Tez Danışmanı
Prof. Dr. Hüseyin İNCE

GEBZE

2018



GTÜ Sosyal Bilimler Enstitüsü Yönetim Kurulu'nun .14../.12../.2017 tarih ve 2017/30 sayılı kararıyla oluşturulan jüri tarafından .28../.12../.2017 tarihinde tez savunma sınavı yapılan ..Fatma SÖNMEZ GAKIR.....'ın tez çalışması işletme.....Anabilim Dalında DOKTORA tezi olarak kabul edilmiştir.

JÜRİ

ÜYE

(TEZ DANIŞMANI)

: Prof. Dr. Hüseyin İNCE

ÜYE :

Prof. Dr. Salih Zeki İMAMOĞLI

ÜYE :

Doç. Dr. Erkut ALTINDAĞ

ÜYE :

Doç. Dr. Mesut KARAKAŞ

ÜYE :

Doç. Dr. Mehmet Sinan BAŞAR

ONAY

Gebze Teknik Üniversitesi Enstitüsü Yönetim Kurulu'nun
...../...../..... tarih ve/..... sayılı kararı.

ÖZET

Çalışmanın amacı; finansal zaman serilerinde kullanılan doğrusal ve doğrusal olmayan ilişkileri ortaya çıkartan modelleri ve bunlardan elde edilen melez modelleri eldeki veriler doğrultusunda karşılaştırmaktır. Çalışmada NASDAQ ve BIST100 borsa endeks değerlerinin tahmin edilmesinde ARIMA ve Yapay Sinir Ağları (YSA) modelleri kullanılmış aynı zamanda literatürdeki farklı model melezleme yöntemleri ile modeller melezlenmiş ve elde edilen tüm modeller farklı performans ölçülerine göre karşılaştırılmıştır. ARIMA modelinin kalıntıları toplam ve çarpım yöntemleri ile ayrı ayrı belirlenmiş ve bu artıklar iki modelde YSA sonuçları ile melez modelin türüne göre toplanmış veya çarpılmış, bir modelde ise YSA için girdi olarak kullanılmıştır.

Elde edilen modeller performans kriterlerine göre karşılaştırıldığında melez model ne şekilde kurulursa kurulsun, melez modellerden elde edilen sonuçlar hem NASDAQ hem de BIST100 için tekil modellerden daha iyi sonuçlar vermiştir. Aynı zamanda önerdiğimiz farklı kalıntı hesaplama değişkenleri ile melez modellerin tahmin performansı artırılmaya çalışılmıştır. Uygulaması yapılan modellerde değişkenlerdeki değişimler ile modellerde daha iyi sonuçlar elde edilmiştir.

Anahtar Kelimeler: ARIMA, Yapay sinir ağları, Melez modeller, Zaman serisi analizi, Öngörü.

SUMMARY

The purpose of study is; models that reveal linear and nonlinear relationships used in the financial time series and the hybrid models obtained from them in terms of the available data. In the study, ARIMA and Artificial Neural Networks (ANN) models were used in estimation of NASDAQ and BIST100 stock market index values. Also, hybrid models were hybridized with different model hybridization methods in the literature and all the obtained models were compared according to different performance measures. Residues of the ARIMA model were determined separately by sum and multiplication methods, and these residues were collected or multiplied by YSA results in the two models according to the new model and used as inputs in YSA in one model.

When compared to the performance criteria of obtained models, no matter how the hybrid model is built, the results from the hybrid models yield better results than the singular models for both NASDAQ and BIST100. At the same time, we tried to improve the prediction performance of hybrid models by using different residue calculation variables. In the applied models, better results were obtained in the models by changing the variables.

Key Words: ARIMA, Artificial Neural Network, Hybrid models, Time series analysis, Forecasting.

TEŞEKKÜR

En başta Doktora başlangıcımдан bu güne gelinceye kadar beni her zaman özveri ile dinleyen, benimle birlikte bu zorlu süreci atlatabilmem için çalışan Sayın Danışmanım Prof. Dr. Hüseyin İNCE hocama teşekkürü bir borç bilirim.

Beni tez aşamamda bir an yalnız bırakmayan EŞİM Özkan ÇAKIR'a, benden yardımlarını esirgemeyen kendisiyle her an gurur duyduğum KARDEŞİM Yasemin SÖNMEZ'e, Biricik ANNEM'e ve varlığını hep hissettiğim onun gurur duyması için yaşadığım Rahmetli BABAM Hasan SÖNMEZ'e emekleri için teşekkür ederim.

Bu zorlu süreçte en büyük destekçilerimden biri olan DOSTUM Tanyeri USLU ve ailesine; Arş. Gör. Ali Fehim CEBECİ hocama, sürecin zorluğunun farkında olduğu için beni her zaman rahatlatan ve destek olan Doç. Dr. Alper AYTEKİN Hocam'a şükranlarımı sunarım.

İÇİNDEKİLER

ÖZET	iv
SUMMARY	v
TEŞEKKÜR	vi
İÇİNDEKİLER	vii
ŞEKİLLER DİZİNİ	ix
TABLolar DİZİNİ	x
SİMGELER VE KISALTMALAR DİZİNİ	xi
1. GİRİŞ	1
2. ZAMAN SERİLERİ	3
2. 1. Zaman Serisi Bileşenleri	4
2. 2. Zaman Serisi Tahmin Yöntemleri	5
2. 2. 1. İstatistiksel Tahmin Yöntemleri	5
2. 2. 1. 1. Otoregresif Bütünleşik Hareketli Ortalama Modeli (ARIMA)	6
2. 2. 1. 2. Genelleştirilmiş Otoregresif Koşullu Değişen Varyans (GARCH)	9
2. 2. 2. Yapay sinir ağları	9
2. 2. 2. 1. Yapay Sinir Ağlarının Kullanım Alanları	11
2. 2. 2. 2. Yapay Sinir Ağlarının Güçlü ve Zayıf Yönleri	12
2. 2. 2. 3. Yapay Sinir Ağlarının Yapısı	14
2. 2. 2. 3. 1. YSA Katmanları	14
2. 2. 2. 3. 2. YSA Hücre Elemanları	15
2. 2. 2. 4. Yapay Sinir Ağlarında Öğrenme	19
2. 2. 2. 5. YSA Mimarileri	21
2. 2. 2. 5. 1. Tek Katmanlı İleri Beslemeli YSA	21
2. 2. 2. 5. 2. Çok Katmanlı İleri Beslemeli YSA	23
2. 2. 2. 5. 3. Geri Beslemeli Yapay Sinir Ağları	24
2. 2. 2. 6. Geri Yayılım (Backpropagation) Algoritması	26
3. MELEZ YÖNTEMLER	29
3. 1. Zhang Melez Modeli	34
3. 2. Wang'ın Melez Modeli	36
3. 3. Fard ve Zadeh'in Melez Modeli	38
3. 4. Khashei ve Bijari'nin Melez Modelleri	39

3. 5.	Khashei, Bijari ve Ardali'nin Melez Modeli	41
3. 6.	Babu ve Reddy'nin Melez Modeli	42
3. 7.	Babu ve Sure Melez Modeli	43
4.	TAHMİN UYGULAMALARI	44
4. 1.	YSA için Gizli Nöron Sayısının Belirlenmesi	44
4. 2.	Modeller için Performans (Hata) Ölçüleri	45
4. 3.	Veri Seti ve Kullanılacak Modeller	46
4. 4.	NASDAQ Borsası İçin Tahmin Uygulamaları	48
4.4.1.	ARIMA Uygulamaları	49
4.4.2.	Yapay Sinir Ağı Uygulamaları	49
4.4. 2. 1.	Temel Göstergeler ile NASDAQ Değerinin Tahmini İçin YSA	50
4.4. 2. 2.	Temel Göstergeler ile Kalıntı Tahmini İçin YSA	51
4.4. 2. 3.	Kalıntı Değerleri ile Kalıntı Tahmini İçin YSA	51
4.4. 2. 4.	Temel Göstergeler ve Kalıntı Değerleri ile Kalıntı Tahmini için YSA	52
4.4. 2. 5.	Temel Göstergeler ve Kalıntı Değerleri ile NASDAQ Değerinin Tahmini için YSA	53
4.4.3.	NASDAQ Endeksi ARIMA-YSA Melezleme Sonuçları	54
4. 5.	BIST100 İçin Tahmin Uygulamaları	56
4.5.1.	Model 1c-Model 1d ARIMA Uygulamaları	56
4.5.2.	Yapay Sinir Ağı Uygulamaları	57
4.5. 2. 1.	Temel Göstergeler ile BIST100 Değerinin Tahmini için YSA	57
4.5. 2. 2.	Temel Göstergeler ile Kalıntı Tahmini için YSA	58
4.5. 2. 3.	Kalıntı Değerleri ile Kalıntı Tahmini için YSA	59
4.5. 2. 4.	Temel Göstergeler ve Kalıntı Değerleri ile Kalıntı Tahmini için YSA	59
4.5. 2. 5.	Temel Göstergeler ve Kalıntı Değerleri ile BIST100 Değerinin Tahmini için YSA	60
4.5.3.	BIST100 Endeksi ARIMA-YSA Melezleme Sonuçları	61
5.	SONUÇ	65
	KAYNAKLAR	70
	ÖZGEÇMİŞ	78

ŞEKİLLER DİZİNİ

Şekil 2.1: Yapay Sinir Hücresinin Elemanları	15
Şekil 2.2: Tek Katmanlı YSA Yapısı	22
Şekil 2.3: Perceptron Sınıf Ayrım Grafiği	23
Şekil 2.4: Çok Katmanlı İleri Beslemeli YSA	24
Şekil 2.5: Geri Beslemeli YSA	25
Şekil 3.1. YSA-PSO Hibrit Modeli	31
Şekil 3.2. YSA ile Diğer Model Sonucunun Birleştirilmesi	31
Şekil 3.3. YSA ile Başka Bir Modelin Sonuçlarının Birleşimi	31
Şekil 3.4: Zhang'ın Melez Modeli	36
Şekil 3.5. Zaman Serisinde Doğrusal ve Doğrusal Olmayan Unsurlar	36
Şekil 3.6: Wang'ın Melez Modeli	37
Şekil 3.7: Fard ve Zadeh'in Melez Modeli	39
Şekil 3.8: Khashei ve Bijari'nin Melez Modeli	40
Şekil 3.9. Khashei, Bijari ve Ardali'nin Melez Modeli	41
Şekil 3.10: Babu ve Reddy Melez Modeli	42
Şekil 4.1: Model 2a için YSA Test Seti Sonuçları	50
Şekil 4.2: Model 3a-3b için YSA Test Seti Sonuçları	51
Şekil 4.3: Model 4a-4b için YSA Test Seti Sonuçları	52
Şekil 4.4: Model 5a-5b için YSA Test Seti Sonuçları	52
Şekil 4.5: Model 6a-6b için YSA Test Seti Sonuçları	53
Şekil 4.6: Model 2b için YSA Test Seti Sonuçları	58
Şekil 4.7: Model 3c-3d için YSA Test Seti Sonuçları	58
Şekil 4.8: Model 4c-4d için YSA Test Seti Sonuçları	59
Şekil 4.9: Model 5c-5d için YSA Test Seti Sonuçları	60
Şekil 4.10: Model 6c-6d için YSA Test Seti Sonuçları	61

TABLÖLAR DİZİNİ

Tablo 2.1: YSA Birleşme Fonksiyonları.	16
Tablo 4.1: Analiz için Kurulacak Modeller.	47
Tablo 4.2: Arima Tahminleri ile Model 3a-3b YSA Melezleme Sonuçları.	54
Tablo 4.3: Arima Tahminleri ile Model 4a-4b YSA Melezleme Sonuçları.	54
Tablo 4.4: Arima Tahminleri ile Model 5a-5b YSA Melezleme Sonuçları.	55
Tablo 4.5: YSA'ya Girdi Olarak Verilen Arima Kalıntıları ile Yapılan Melezleme Sonuçları	55
Tablo 4.6: Arima Tahminleri ile Model 3c-3d YSA Melezleme Sonuçları.	61
Tablo 4.7: Arima Tahminleri ile Model 4c-4d YSA Melezleme Sonuçları.	62
Tablo 4.8: Arima Tahminleri ile Model 5c-5d YSA Melezleme Sonuçları.	62
Tablo 4.9: YSA'ya Girdi Olarak Verilen Arima Kalıntıları ile Yapılan Melezleme Sonuçları	63
Tablo 4.10: NASDAQ Endeks Değerleri için Zaman Serisi Analiz Sonuçları.	64
Tablo 4.11: BIST100 Endeks Değerleri için Zaman Serisi Analiz Sonuçları.	64

SİMGELER ve KISALTMALAR DİZİNİ

<u>Simgeler ve</u> <u>Kısaltmalar</u>	<u>Açıklamalar</u>
AR	: Autoregressive (Oto regresif)
ARCH	: Autoregressive Conditional Heteroskedasticity (Oto regresif Koşullu Değişen Varyans)
ARFIMA	: Autoregressive Fractionally Integrated Moving Average (Kesirli Birleştirilmiş Oto regresif Hareketli Ortalama)
ARIMA	: Autoregressive Integrated Moving Average (Oto regresif Bütünleşik Hareketli Ortalama)
ARMA	: Autoregressive Moving Average (Oto regresif ve Hareketli Ortalama)
BIST100	: Borsa İstanbul 100 Endeksi
BPNN	: Back-propagation Neural Network (Geri Yayımlı Sinir Ağları)
CDPA	: Kümülatif Olasılık Dağılımı Yaklaşımı
DJIA	: Dow Jones Borsası
DVM	: Destek Vektör Makineleri
ESM	: Üstel Düzgünleştirme Modeli
GA	: Genetik Algoritma
GARCH	: Generalized ARCH (Genelleştirilmiş Oto regresif Koşullu Değişen Varyans)
HMM	: Hidden Markov Model (Gizli Markov Modeli)
İMKB	: İstanbul Menkul Kıymetler Borsası
LVQ	: Sayısallaştırılmış Öğrenme Vektörü
MA	: Moving Average (Hareketli Ortalama)
MAD	: Mean Absolute Deviation (Mutlak Ortalama Sapma)
MAE	: Mean Absolute Error (Ortalama Mutlak Hata)
MAPE	: Mean Absolute Percent Error (Ortalama Mutlak Yüzde Hata)
MEPA	: Düzensizliğin Minimizasyonu İlkesi Yaklaşımı
MLP	: Multi Layer Perceptron (Çok Katmanlı Sinir Ağı)
MSE	: Mean Square Error (Hata Kareler Ortalaması)
NASDAQ	: National Association of Securities Dealers Automated Quotations

PSO	: Partical Swarm Optimization (Parçacık Sürü Optimizasyonu)
RMSE	: Root Mean Square Error (Ortalama Hata Kareleri Karakökü)
RST	: Kaba Kümeleme Teorisi
S&P	: Standart and Poor's
SSE	: Sum of Squared Error (Hata Kareler Toplamı)
TEFE	: Toptam Eşya Fiyat Endeksi
USD	: United States Dollar (Amerikan Doları)
VAR	: Vektör Otoregresif
YSA	: Yapay Sinir Ağları

1. GİRİŞ

Öngörü; bir olay hakkında önceden ne olacağını belirleyebilme yeteneği olarak tanımlanabilir. İleri bir dönem veya zamanda ilgilenilen alan hakkında ne olacağının bilinebilmesi ya da en azından küçük bir hata payıyla tahmin edilmesi istenilen bir durumdur. Her birey yapacağı bir eylemden önce eylemin kendisine getirisinin ya da kaybının ne olacağını bilmek ister. Zaman serileri analizleri bu nedenle her alan için önemli bir analiz tekniği olmuştur. Bir uygulamada iyi sonuç veren bir model başka uygulamalarda da aynı iyi ve başarılı sonuçları vermeyebilir. Bu nedenle tahminlemede kullanılacak olan verinin yapısı ve seçilen model çok önemlidir.

Araştırma model melezleme üzerine kurulmuştur. Model melezleme ile yapılmak istenen daha iyi tahmin sonuçları verebilecek olan modellere ulaşmaktır. Literatürde yer alan melez modeller öncelikle belirlenmiş ve mevcut veriye en uygun olanının belirlenmesi için işlemler yapılmıştır. Araştırmada melez modellerin tahmin değerlerinin daha iyi olabilmesi için başka değişkenlerin kullanılmasının gerekli olup olmadığına da bakılmıştır. Bu nedenle hem önerilen modeller ile hem de değişkenler değiştirilerek elde edilen sonuçlar ile melezleme işlemleri yapılmıştır.

Araştırmanın uygulanmasında öncelikle model melezlemeye başvurulmasının nedeni birden fazla modelin birbirlerini tamamlayarak tekil olarak elde edebilecekleri faydanın üzerine çıkılmasını sağlamaktır. Çünkü herbir modelin avantajlı ve dezavantajlı olduğu farklı durumlar mevcuttur. Bu amaçla önce tekil olarak ele alınan modeller denenmiş bunlardan elde edilen bilgilere göre daha iyi sonuç vermelerini sağlamak için modeller arasında melezlemeler yapılmıştır. Melezleme ile modellerin, birbirlerinin eksiklerini tamamlayarak daha iyi tahmin yapmaları sağlanmaktadır. Daha önceden borsa endekslerinin tahmini için birçok çalışma yapılmıştır ancak burada yapılacak olan işlemlerin, farklı modellerin karşılaştırılmasında vereceği bilgiler ile farklılık oluşturacağı düşünülmektedir. Aynı zamanda farklı değişkenler modellere eklenerek daha iyi tahmin sonuçları vermeleri sağlanmak istenmiştir.

Seçilen NASDAQ ve BIST100 endeks değerlerini tahminleyeceği düşünülen iki model olarak ARIMA ve YSA seçilmiştir. ARIMA ve YSA hem tek başlarına hem de ikisi melezlenerek tahminleme işlemlerinde pek çok defa sınanmıştır. Çalışmada da aynı şekilde tek başlarına ve melezlenerek kullanılmışlardır. Çalışmada farklılığı verinin zamanı ve değişken seçimi oluşturmuştur. Literatürde yer alan değişik

metodları aynı endeks tahminlerinde bir arada görme olanağı sağlanmıştır. Ayrıca literatürde yer alan modellerdeki kalıntı hesapları farklı değişkenler ile de gerçekleştirilmiş ve kalıntı hesabında farklı değişkenler önerilmiştir. Aynı zamanda tek tür bir kalıntı hesabındansa iki yöntem kullanılarak hem toplama ile hem çarpma ile kalıntı hesapları da işleme alınmıştır.

Araştırmanın konusunu finansal zaman serilerinde tahminleme oluşturmaktadır. Bu bağlamda finansal zaman serisi olarak nitelendirilen unsurlar arasında NASDAQ ve BIST100 endeks değerleri seçilmiş ve bu endekslerin tahmini için melezleme yöntemleri kullanılmıştır. Melezleme işleminin hem yurtiçi hem yutdışı piyasalarda nasıl sonuç verdiğinin belirlenmesi için bu iki endeks değerleri seçilmiştir. Bu amaçla tezin birinci bölümünde finansal zaman serileri hakkında kısa bir bilgi verilmiş, ikinci bölümünde melez yöntemlerden bahsedilmiştir. üçüncü bölümünde ise bahsedilen melez yöntemlerle ilgili uygulama yer almıştır. Aynı zamanda üçüncü bölümde farklı model melezleme yöntemleri kullanılarak elde edilen tahmin modelleri karşılaştırılmıştır. Karşılaştırmalardan elde edilen bulgular sonuç kısmında sunulmuştur.

2. ZAMAN SERİLERİ

Pek çok alanda olduğu gibi finans alanında da ileriye görebilmek son yıllarda çok önemli bir konudur. Özellikle finans alanında tam ve kesin tahminler yapmak mümkün değildir. Çünkü finansal veriler birçok farklı değişkenden ve çevre şartlarından etkilenir. Finansal piyasalarda dalgalanma çoktur ve ne zaman ne olacağının belirlenmesi çok mümkün görülmemektedir. Finansal piyasalara yatırım yapanlar ise geçmiş durumlara bakarak karar vermeye çalışmaktadır. Ancak açıktır ki oynaklığın bu denli çok olduğu bir ortamda kaybetme olasılığı da söz konusudur. Yatırımcılar, muhtemel getirileri ile muhtemel kayıplarını daha önceden bilmek ve buna göre yatırım kararları almak istemektedirler. Bu amaca ulaşabilmek için çok çeşitli yöntemler geliştirilmiştir. Her yöntem farklı şartlar altında değişik ve birbirinden daha iyi sonuçlar verebilmektedir. Tahminleme ve sınıflandırmada kullanılan geleneksel modellerin ötesinde son zamanlarda daha modern yöntemler kullanılmaktadır. Bilgisayar teknolojisinin hızla gelişmesi ile bu tahminleme ve sınıflandırmayı kendi başlarına yapan yöntemler geliştirilmiştir. Bu yöntemler uygulama açısından diğer yöntemlere göre çok daha avantajlıdır.

Öngörü ya da tahminleme, sürelerine göre kısa-orta ve uzun dönemli olarak sınıflandırılabilir. Burada önemli olan tahminin kapsayacağı sürenin uzunluğudur (Kayım, 1986). Eğer bir zaman serisinin verileri tüm zamanlar için ölçülebiliyorsa bu şekilde oluşturulan zaman serilerine sürekli zaman serileri denilir (Chatfield,1989).

Zaman serileri ardışık zaman aralıklarında düzenli olarak ölçülen gözlemlerden oluşur. Zaman serileri ile ilgili analizler yapılmasında amaç; gözlenen değişkenlerin gelecekteki değerlerini tahmin etmektir (Chatfield, 1989). Örneğin; İMKB’de işlem gören hisse senetlerinin fiyatlarının tahmin edilmesi, işsizlik oranını tahmin edilmesi, enerji tüketiminin ya da üretiminin tahmin edilmesi gibi belirli periyodlarla ölçülen değişkenlerin gözlemleri zaman serisi oluşturur. Finansal zaman serileri ise iktisadi olarak belirlenmiş ve belirli periyodlarda gözlemlenmiş iktisadi değişkenlerin gözlem verilerinden oluşur. Hisse senedi fiyatları, menkul/gayrimenkul yatırım fiyatları, işsizlik oranları, iktisadi büyüme oranları, ithalat-ihracat tahminleri finansal zaman serilerine örnek olabilir.

Finansal zaman serilerinin analizinde; yapısal modelin oluşturulması, zaman serisi tahmin yöntemi ve modelinin belirlenmesi ile elde edilen tahminin değerlendirilmesi aşamaları bulunur. Tahmin yönteminin belirlenmesinde verinin

durumu ve özellikleri önemlidir (Box and Jenkins, 1976). Aynı zamanda elde edilmiş olan model için ileride bahsedilecek olan performans ölçütleri ile modelin kullanılabilirliği ölçülebilir.

2. 1. Zaman Serisi Bileşenleri

Zaman serileri analizleri geçmişte bir hareket gösteren zaman serisinin gelecek dönemlerde de aynı hareketi göstereceği varsayımına dayanır. Zaman serilerinin yapısı incelendiğinde dalgalı bir seyir içinde olduğu görülebilir. Dalgalandırmanın sebepleri; bir zaman serisinin zamana bağılı eğilimini gösteren trend, belirli mevsim-ay-3 ay vb. zaman dönemlerindeki birbirini izleyen dönemlerde aynı zamana denk gelen değişimlerden oluşan mevsimsellik; ekonomik dalgalanmaları gösteren konjonktür ve geçici dönemlerde ortaya çıkan birden veya rastlantısal olarak meydana gelen düzensiz dalgalanmalar olmak üzere 4 başlıkta toplanabilir (Mann, 1995; Newbold et al., 2003):

- T =Trend etkisi
- M =Mevsimlik Dalgalanmalar
- K =Konjonktürel Dalgalanmalar
- D =Düzensiz Dalgalanmalar

olmak üzere sıralanan faktörler ile bir zaman serisinde gerçekte olan değerin belirlenmesinde toplam ve çarpım yaklaşımı olmak üzere iki farklı yaklaşım kullanılabilir.

Y_t gerçek değeri gösterirken; t zamanında gerçek gözlem değeri toplama yaklaşımına göre Denklem 2.1'deki gibi hesaplanır. Denklemde e_t tahmin modelinin hatasını göstermektedir.

$$Y_t = T_t + M_t + K_t + D_t + e_t \quad (2.1)$$

Eğer t zamanında Y_t gerçek değeri çarpma yaklaşımına göre bulunacak ise bu hesaplama Denklem 2.2'deki gibi yapılır.

$$Y_t = T_t * M_t * K_t * D_t + e_t \quad (2.2)$$

Zaman serilerinde girdi verileri olarak hacim, fiyat veya günlük fiyat değişimi gibi temel göstergeler olabileceği gibi bunlardan türetilen hareketli ortalamalar, eğim çizgisi göstergeleri vb. teknik göstergeler veya içsel piyasa değeri, ekonomik çevre vb. ekonomik göstergeler de olabilir (Lawrance, 1997). Aynı çalışmada Lawrance belirlenebilecek gösterge sayısının 63 adet olduğunu göstermiş ve bunları

temel göstergeler, teknik göstergeler, JSE Endeksleri, uluslararası endeksler, altın/döviz kuru değerleri, faiz oranları ve ekonomik istatistikler olmak üzere 7 başlıkta toplamıştır.

2. 2. Zaman Serisi Tahmin Yöntemleri

Eldeki bir zaman serisinin geçmiş gözlem değerleri kullanılarak gelecekteki sahip olabileceği değerler tahminlenebilir. Zaman serileri tahmin yöntemleri farklı türlerdeki zaman serilerinde uygulanabilen yöntemleri kapsar. Analiz için kullanılan çok sayıda yöntem mevcuttur ancak çalışmada bu yöntemler; istatistiksel yöntemler ve YSA olarak incelenmiştir.

2. 2.1. İstatistiksel Tahmin Yöntemleri

İstatistiksel analizlerin temelinde eldeki mevcut veriye en uygun modelin oluşturulması vardır. Tahmin yapılabilmesi ya da serinin yapısının anlaşılması için hangi zaman serisi modelinin kullanılacağına iyi bir şekilde ortaya konulması gerekir. Bunun için geliştirilmiş bazı modeller bulunmaktadır (Box et al., 1994). Doğrusal zaman serisi analizlerinde en çok kullanılan yöntemler Box-Jenkins modelleri olarak verilebilirler. Bu yöntemler verinin tamamının durağan olduğu veya durağan olmasa dahi durağanlaştırılabilirdiği veriler için çok başarılı sonuçlar vermektedirler.

Zaman serileri için veriler farklı formlara ve rassal süreçlere sahip olabilir. Modelleme yapılırken bir zaman serisi Otoregresif (AR), Hareketli Ortalama (MA) ve Bütünleşik Model olarak 3 sınıfa ayrılabilir. Bu üç sınıflandırmada da veriler bir önceki noktalara doğrudan bağlıdır (Gershenfeld, 1999). Bu üç yöntemin farklı kombinasyonlar ile Otoregresif ve Hareketli Ortalama (ARMA), Otoregresif Bütünleşik Hareketli Ortalama (ARIMA), Kesirli Birleştirilmiş Otoregresif Hareketli Ortalama (ARFIMA) modelleri oluşturulmuştur.

Belirsizlik ve risk finansal zaman serilerinde değişen varyans sorununu ortaya çıkartabilir. Değişen varyans sorununu ortadan kaldırmak için Engle (1982)'de ARCH modelini önermiştir. Bollerslev (1986)'da yapmış olduğu çalışmada ise ARCH'a göre daha esnek olduğu söylenebilen GARCH modelini ortaya atmıştır. Ortalamada ARCH (ARCH-M) modeli (Engle et al, 1987), Bütünleşik GARCH (IGARCH) modeli (Engle and Bollerslev., 1986), Üssel GARCH (EGARCH) modeli (Nelson, 1991), Eşik

ARCH (TARCH) modeli (Zakoian, 1994), Üstel ARCH (PARCH) modeli (Ding et al., 1993) ARCH ve GARCH'dan geliştirilmiştir.

Bu kısımda bu yöntemlerden ARIMA ve GARCH hakkında bilgi verilecektir.

2.2. 1. 1. Otoregresif Bütünleşik Hareketli Ortalama Modeli (ARIMA)

Elimizde bulunan bir zaman serisi kesikli, doğrusal ve durağan bir sürece sahipse Box-Jenkins modeli olarak adlandırılır. Bu yapılar doğrusal filtreleme modelleri olarak da tanınırlar (Enders, 2004). Durağanlık, serinin ortalama değerlerinin belli bir değere yaklaşmasını ya da olması beklenen değer etrafında dolaştığını ifade eder. Bir zaman serisinin ortalaması, varyansı, co-varyansı ve yüksek dereceden momentleri zamana göre sabitse böyle seriler durağan seri olurlar (Gujarati, 2003). Eğer seride durağanlık yoksa serinin modellenebilmesi için serinin durağan hale getirilmesi gerekir (Box and Jenkins, 1976). Durağan olmayan serilerde, zaman serisi modeli incelenirken sürecin zamana göre durumuna bakılır. Eğer süreç zamana göre değişiyorsa dizi durağan değildir denir. Durağan serileri modellerle ifade etmek mümkündür ancak durağan olmayan serileri basit matematiksel modellerle ifade etmek mümkün değildir. Önemli olan konu modelin verileri nasıl yansıttığıdır. Modelin açıklama kuvveti durağan olmayan seriler için çok düşüktür. Bu nedenle model tahmin amacıyla kullanılamaz. Ancak durağan serilerde kurulan model veriyi temsil etmede başarılıdır ve tahmin amaçlı olarak kullanılabilir.

ARIMA Modelini anlatmaya başlamadan AR-MA-ARMA modellerinden kısaca bahsedilecektir.

AR modelleri Yule (1927) tarafından geliştirilmiştir. AR (Autoregressive) modelleri; bir zaman serisinin herhangi bir dönemindeki gözlem değerini, çalışılmakta olan serinin önceki belli sayıda geçmiş dönem gözlem değerine ve hata terimine bağlı olarak açıklar. Bu modeller, içlerinde bulunan geçmiş dönem gözlem değeri sayısına göre isimlendirilirler. Genel olarak, “p. dereceden” model AR(p) ile gösterilir ve aşağıdaki şekildedir (Toprak, 2011):

$$w_t = m + \phi_1 w_{t-1} + \phi_2 w_{t-2} + \dots + \phi_p w_{t-p} + u_t \quad (2.3)$$

Denkleimde w_t t zamanındaki gözlem değeri , m ortalama, u_t hata, w_{t-1} , w_{t-2} ,..., w_{t-p} 1, 2,...,p dönem önceki gözlem değerini, $\emptyset$ katsayıları ise modelin parametrelerini gösterir.

MA (Moving Averages) Modelleri ise ilk defa Slutsky (1937) tarafından ortaya atılmıştır ve bu modeller bir zaman serisinin herhangi bir dönemdeki gözlem değerini aynı dönemdeki hata terimi ve ondan önceki belirli sayıda dönemin hata terimine bağlı olarak açıklayan modellerdir. Örneğin bir zaman serisinin şimdiki değeri sabit terim ile iki dönemlik hataların hareketli ortalamalarının toplamına eşittir. Genel olarak, “q. dereceden” model MA(q) ile gösterilir ve aşağıdaki şekilde yazılır.

$$w_t = \mu + u_t - \theta_1 u_{t-1} - \theta_2 u_{t-2} - \dots - \theta_q u_{t-q} \quad (2.4)$$

Denkleimde w_t t zamanındaki gözlem değeri , m ortalama, u_t hata, u_{t-1} , u_{t-2} ,..., u_{t-p} 1, 2,...,q dönem önceki hata değerini gösterken $\emptyset$ katsayıları ise hata terimleri ile ilgili katsayıları gösterir.

Zaman serileri çoğu zaman otoregresif veya hareketli ortalama süreçleri ile gösterilemeyebilir. Bu durumda AR+MA=ARMA olarak tanımlanan Otoregresif ve Hareketli Ortama modeli ile süreç gösterilir. Model Wold (1954) tarafından geliştirilmiştir. Aynı zamanda tanımlanan 3 süreç serinin durağan olduğu varsayımına dayanır. Genel olarak ARMA(p,q) şeklinde ifade edilen süreç iki modelin toplamından oluşur ve aşağıdaki şekilde gösterilir.

$$w_t = m + \emptyset_1 w_{t-1} + \dots + \emptyset_p w_{t-p} + u_t - \theta_1 u_{t-1} - \dots - \theta_q u_{t-q} \quad (2.5)$$

Denkleimde w_t t zamanındaki gözlem değeri , m ortalama, u_t hata, w_{t-1} , w_{t-2} ,..., w_{t-p} 1, 2,...,p dönem önceki gözlem değerini u_{t-1} , u_{t-2} ,..., u_{t-p} 1, 2,...,q dönem önceki hata değerini ve $\emptyset$ katsayıları gösterir.

Kısaca bilgi verdiğimiz AR(p), MA(q) ve ARMA(p,q) süreçlerindeki temel varsayım serinin durağan olduğu şeklindeydi ancak bazı durumlarda serinin durağan olmadığı zamanlar olabilir (Box and Jenkins, 1976). Birçok finansal zaman serisi durağan değildir ve özellikle zamanla değişen araçlar ve / veya varyasyonlar sergileme eğilimindedir (Mills, 2008). ARIMA modeli oluşturabilmek için durağanlık gereklidir. Modelde amaç belirlenen zaman serisine en uygun olan ve en az parametre içeren doğrusal modeli bulmak ve model kurmaktır. İstatistiksel olarak otokorelasyon ve ortalaması zamana göre sabit olan seriler durağan seri olduğundan ARIMA modeli uygulanmadan önce fark işlemleri ile trend bileşeni kaldırılarak varyans sabitleştirilir

(Maddala, 2002). Bu durumda ARIMA(p,d,q) süreci kullanılmalıdır. Bu süreç diğer süreçlerden farklı değildir ve diğer süreçleri kapsayıcı niteliktedir. ARIMA modelleri fark alma işlemleri ile durağan hale getirilen seriler için kullanışlı bir yöntemdir. Seri kaçınıcı fark alma işlemi sonucunda durağan bir hale getirilmişse d değeri bu sayıya eşit olur. Yöntem AR ve MA fonksiyonlarına fark alma işleminin eklenmesi ile aşağıdaki gibi gösterilir (Box and Jenkins, 1976):

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + \delta + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (2.6)$$

Denklemden $Z_t, Z_{t-1}, \dots, Z_{t-p}$ farkı alınmış gözlem değerlerini, $\phi_1, \phi_2, \dots, \phi_p$ gözlem değerlerinin katsayılarını, δ sabit değerini, $a_t, a_{t-1}, \dots, a_{t-q}$ hatayı ve $\theta_1, \theta_2, \dots, \theta_q$ hata terimlerinin katsayılarını göstermektedir.

ARIMA işlemlerinin aşamaları şöyle gösterilir (Box and Jenkins, 1992):

- 1.Adım: Geçici model yapısının belirlenmesi
- 2.Adım: Geçici modelde yer alacak olan parametrelerin tahmin edilmesi,
- 3.Adım: Geçici modele uygunluk testlerinin uygulanması.
- 4.Adım: Model uygun ise tahmin amacıyla kullanılması.

Geçici model yapısının belirlenmesinde ilk yapılması gereken işlem eldeki serinin grafiğini çizmek ve verinin şekilsel durumunu görmektir. Ortaya çıkan şekilde grafik sürekli artma veya azalma yönünde bir seyir izliyor ise seri durağandır denebilir (Maddala, 1992). Zaman serilerinde model yapısı belirlendikten sonra geçici olarak kurulacak modelde yer alması gereken parametreler tahmin edilmelidir. Kullanılacak modelin belirlenmesinde en küçük kareler (EKK) veya en yüksek olasılık yöntemleri kullanılabilir (Hoff, 1983). Modelin uygunluğunun test edilmesi ise iki şekilde yapılabilir. Bunlardan ilki gerçek seri ile tahmin edilen serinin otokorelasyon fonksiyonlarının karşılaştırılması diğeri verinin modele uygunluğunu test etmek için test istatistiği değeri bulmaktır. Bunun için Box and Pierce (1970)'de Q istatistiği, Ljung and Box (1978)'de düzeltilmiş Q istatistiğini önermişleridir. Uygunluk testleri yapıldıktan sonra model eğer veri için uygun ise model tahmin için kullanılabilir. Aynı zamanda hangi modelin veri için daha uygun olduğunun belirlenmesinde bazı performans ölçütleri kullanılmaktadır. Bahsedilen ölçütler ilerleyen bölümlerde verilmiştir.

2.2. 1. 2. Genelleştirilmiş Otoregresif Koşullu Değişen Varyans (GARCH)

Belirsizlik ve risk finansal zaman serilerinde değişen varyans sorununu ortaya çıkartabilir. Değişen varyans sorunu zaman serisinin tahminlenmesinde zorluk meydana getirir. Ortaya çıkan zorlukların ortadan kaldırılabilmesi için Engle (1982) yaptığı bir çalışma ile ARCH modelini önermiştir. Modelde geleneksel zaman serisi modellerinde yer alan sabit varyans koşulu kullanılmamıştır. ARCH modeli koşullu ve koşulsuz ortalamanın sıfır olduğu bir hata yapısına sahiptir. Bollerslev (1986), yapmış olduğu çalışmada geçmiş dönem verilerini de içeren ARCH'a göre daha esnek olduğu söylenebilen GARCH modelini ortaya atmıştır. GARCH modeli ARCH modellerine benzer, farkı ise hem koşullu ve koşulsuz varyansı hem de uzun dönem ortalama varyansı hesaplamaya katmasıdır. GARCH (p,q) modeli aşağıda verilen denklemler ile belirlenmektedir (Bollerslev, 1986):

$$y_i = \mu + u_i \quad (2.7)$$

$$u_i = \sqrt{h_i}v_i \text{ ve } v_i \sim N(0,1) \quad (2.8)$$

$$h_i = \alpha_0 + \sum_{i=1}^q \alpha_i u_{t-i}^2 + \sum_{i=1}^p \beta_i h_{t-i} \quad (2.9)$$

ve

$$p, q, \alpha_0 > 0; \alpha_i \leq 0, i = 1, \dots, q; \beta_i \leq 0, i = 1, \dots, p$$

Finansal bir zaman serisinde denklemlerde görülen p ve q değerleri 1 olarak alınır ve denklem

$$h_i = \alpha_0 + \alpha_1 u_{i-1}^2 + \beta_1 h_{i-1} \quad (2.10)$$

şekline dönüşür.

Verinin doğrusal olmaması durumunda model yanıltıcı sonuçlar verebileceklerdir. Doğrusal olmayan zaman serisi verilerinin modellenenebilmesi için daha kullanışlı ve daha doğru sonuçlar veren yöntemler mevcuttur.

2. 2. 2. Yapay sinir ağları

Günümüz dünyasında bilgisayar teknolojisindeki hızlı gelişmeler sayesinde bilgisayarlar ve bilgisayarların kurduğu sistemler insan hayatının vazgeçilmez bir

parçası olmuştur (Nabiyev, 2016). Her geçen gün insanların daha önceden sadece hayalini kurabildikleri, bilim kurgu romanlarına ya da filmlerine konu olan işlemler iyi şekilde geliştirilmiş ve programlanmış bilgisayarlar sayesinde yapılmaya başlanmıştır. Bilgisayarlar insanların kendi zekâlarıyla yaptıkları işleri yapmak ve insan gibi düşünüp karar vermeleri için programlanmıştır. Bu da bizi insan gibi düşünen akıllı makinelerin varlığı ile karşı karşıya getirmiştir. Bilgisayarların bahsedilen gelişmiş özelliklere sahip olması için yapılan çalışmalara Yapay Zekâ çalışmaları denilmiştir (Nilsson, 1998). Bilgisayar ortamına verilen her bir örnekten gerekli algoritma ve formülasyonların kullanılması ve bir şeyler öğrenilmesi ile ilerleyen zaman ya da zamanlar için ilgilenilen olay hakkında karar verecek düzeye ulaşılmasına ise “makine öğrenmesi” denilir (Öztemel, 2012). YSA makine öğrenmesi alanında geliştirilmiş olan en önemli uygulamalardan biridir. Örnek verileri kullanılarak genel yargılar veya sonuçlar üretilmeye çalışılır.

YSA, basit işlemci hücrelerden (nöron) oluşan, birbirine paralel ve dağılmış bir düzende çalışan, içerisinde yoğun işlemlerin sürdüğü bir yapıdır (Alexander and Morton, 1990). YSA, öğrendiği bilgiyi depolayan ve bilgiyi kullanmak için eğitilmiş yoğun ve paralel bir işlemcidir (Haykin, 1999). YSA’da işlem birimleri vardır. Her işlem birimi girdiyi bir ağırlık değeri ile ağırlıklandırır, dönüşümünü gerçekleştirir ve sonuçta çıktıları ulaşılır. YSA birbirlerinden yapay olarak tasarlanmış birden fazla yapay sinir hücresinin (nöron) birbirleriyle paralel bağlanması sonucu oluşan bir yapıdır (Rojas, 2013).

1940’lı yıllarda Donald Olding Hebb, nörolog Warren McCulloch ve matematikçi Walter Pitts nörobiyoloji alanındaki YSA çalışmalarını mühendislik alanına çekmeyi başarmış ilk yapay sinir hücresini oluşturmuşlardır (Haykin, 1999). İnsan beyninin hesap yapma özellikleri üzerinde düşünerek bu özelliklere uygun bir ağ geliştirmişlerdir. Dahası 1949’da Donald Hebb, kendi adını verdiği Hebbian öğrenme kuralını geliştirmiştir (Hebb, 1949). Kural, şimdilerde kullandığımız öğrenme kuramlarının da temelini oluşturmuştur. 1970 yılında YSA çalışmalarına sekte vuran olay ise Minsky ve Pappert tarafından yazılan bir kitap ile YSA’ya dayalı algılayıcıların bilimsel olmadığına doğrusal olmayan modellere çözüm üretmediğinin ortaya atılması olmuştur. Doğrusal olmayan ve çok katmanlı çözülmesi gereken XOR problemine çözüm üretmiyor olması YSA’ya olan ilgiyi azaltmıştır (Voorhees, 2006). YSA çalışmaları XOR probleminin çözümüne kadar

ilerleme göstermemiştir. Problemin YSA ile çözülmesinin ardından YSA tekrar eski popülaritesine ulaşmıştır (Graupe, 2013).

2.2. 2. 1. Yapay Sinir Ağlarının Kullanım Alanları

YSA mantığı geliştirildiği yıllardan beri, ağları kullanarak işlem yapmak başarılı sonuçlar getirmiştir. Çözülmesi zaman alıcı ve karmaşık problemlerin kısa zamanda ve farklı bakış açılarıyla sonuçlandırabilmesi YSA'yı her alanda çok kullanılan bir uygulama haline getirmiştir (Haykin, 1999). YSA bazen tek başına bazen ise diğer uygulamalar ile melezlenerek ya da birleştirilerek kullanılmıştır (Zhang et al., 1998). YSA'nın tek başına verdiği değerler ile diğer uygulamaların sonuçlarının karşılaştırılmasında pek çok alanda YSA'nın daha başarılı sonuçlar verebildiği görülmektedir. YSA tıp, mühendislik, sağlık, savunma, ticaret, güvenlik vs. çok farklı alanlarda başarı ile uygulanmaya devam etmektedir (Anderson, 1995). Her geçen gün YSA mantığı daha da gelişmekte daha iyi sonuçların verilebilmesi için YSA'ya yeni yaklaşımlar getirilmektedir. YSA'nın uygulama alanı konusunda bir sıkıntısı yoktur. Her türden uygulama alanına açık ve bu alanlar için bilgi üretme kapasitesine sahiptir (Wilson and Sharda, 1994).

Verinin analiz edilmesi için gerekli modelin seçiminde, tahmininde, sınıflandırılmasında, görüntü işleme dediğimiz resim tamamlama veya tanıma gibi pek çok konuda YSA etkin bir şekilde kullanılabilmektedir. Aynı zamanda bazı modeller için dezavantaj olan eksik, hatalı veya gürültülü verileri de başarılı bir şekilde işleyebilir (Elmas, 2016). Problemin çözümünde bir matematiksel modelin veya algoritmanın olmadığı durumlarda da YSA kullanımı çok yaygın ve kullanışlıdır (Nabiyev, 2016). Deneme-yanılma yolu ile bir ağ kendi kendine işlem yapmayı öğrenir ve uygulanma imkânının olduğu her yerde yeni bilgi işleme teknikleri ile bilgi üretirler (Bahadır ve Özdemir, 2016).

YSA'ları gerçek hayatta sistem modelleme, örüntü tanıma, parmak izi tanıma, ekonomik ve finansal tahminleme, finans kurumları için kredi derecelendirme, savunma sistemlerinin oluşturulması, hastalıkların önceden tanınması, endüstriyel alanlarda enerji tahminlemesi-proses akış kontrolü, pazar araştırmalarında müşteri belirleme, ürün seçimi, teknolojik alanda ses ile hareket veya ses ile işlem yapma, parmak izi veya retina tanıma, eksik resim veya bilgiyi tamamlama, güvenlik alanında görüntü temizleme alanlarında başarı ile kullanılmaktadır (Pham and Oztemel 1995).

YSA'nın tahminleme ve sınıflamadaki üstün başarısı finansal alanda da yaygın kullanılmasını sağlamıştır (Trippi and Turban, 1993). Döviz, petrol, hisse senedi vb. yatırım araçlarının değerlerinin tahminlenmesi, kurumların verilerine bakarak iflas tahminlerinin yapılması, müşterilerin kredi ödeme güçlerinin belirlenmesi ve kredi derecelendirmelerinin yapılması, firma veya kurumların risk analizlerinin yapılması gibi alanlarda YSA başarılı sonuçlar üretmektedir (Anderson, 1995; Coats and Fant, 1991).

Başarılı olduğu savunma alanında ise YSA; radar takip sistemleri, radar ekranı okuma, sinyal işleme, savunma araçlarının ya da uçakların etkin rotalarının belirlenmesi, kullanılacak silahların optimizasyonu, hedef takibi gibi alanlarda sıklıkla kullanılmaktadır (Collins and Evans, 1994; Ergezer vd., 2003).

YSA'nın en etkin kullanıldığı alanlardan biri tıp alanıdır. Hastalıkların önceden tahmin edilmesi, hastalığın sürecinin takip edilmesi, özellikle hastalıklı hücrelerin belirlenip erken teşhis, tanı ve tedavi edilmesi alanlarında başarıyla uygulanmaktadır (Demirhan, vd., 2010).

Sesin yazıya çevrilmesi, dil ayırt etme, karakter tanıma, kişisel özelliklere göre hareket analizi ve birçok optimizasyon konusunda kısacası aklımıza gelen hemen hemen her konuda bir YSA uygulamasına rastlamak mümkündür (Ergezer vd., 2003).

YSA genel olarak tahmin, sınıflandırma, veri ilişkilendirme, vektör sayısallaştırma, veri filtreleme, desen uygunluğu, kontrol, optimizasyon, arama çalışmaları, tanıma-eşleştirme ve yorumlama fonksiyonlarını gerçekleştirmek üzere kullanılmaktadır (Öztemel, 2012; Şen, 2004).

2.2. 2. 2. Yapay Sinir Ağlarının Güçlü ve Zayıf Yönleri

YSA birçok alanda başarı ile kullanılan veri analizinde üstün özellikleri olan bir uygulama olarak bilinir. Bu özelliklerinin yanı sıra uygulamanın bazı dezavantajlı/zayıf yönleri de bulunmaktadır.

YSA'ların bazı avantajlı/güçlü oldukları yönleri şöyle sıralanabilir (Berry, Linoff, 2000; Şen, 2004; Sharda and Patil, 1992; Hu, 2002): YSA, yaşanan birçok gerçek problemlerin çözümünde kullanılır. Çözülmesi zor olan en bilinmedik zamanlarda bile çözüm üretebilir. İstatistik veya benzeri teknikler için gerekli olan veri ile ilgili varsayımları yoktur. Makine öğrenmesi yapabilirler. Doğrusal olan veya olmayan çoklu giriş ve çoklu çıkışlı sistemleri kolaylıkla modelleyebilir. Kategorik

veya sürekli veriler ile kullanılabilir. Çözümlerinin yapılması için kullanılacak program sayısı çoktur ve her geçen gün sayıları artmaktadır. Geleneksel yöntemlerin bilgi işleme mantıklarından farklı şekilde bilgiyi işlerler. Değişkenlerin dönüşümlerini otomatik olarak yapabilir. Yaygın kullanım alanı bulunmaktadır. Ağ daha önce hiç görmediği örnekler üzerinden bilgi üretebilir. Eksik, gürültülü veya hata içeren veri setlerinde kullanılabilir. Ağın sahip olduğu ağırlık değerleri ne kadar doğru belirlenirse ağın performansı da o kadar yüksek değerlerde olur. Bilgi ağın geri kalanlarına da dağıtılmış olduğundan ağırlıklardan birinin kaybolması ağın çalışmasını etkilemez. Gözlem sayısının az olduğu zamanlarda da diğer modellere göre iyi sonuçlar verir

YSA'ların her ne kadar kendilerine özgü yapıları olduğu düşünülse de daha önceden geliştirilmiş tahmin, sınıflandırma, kontrol gibi modellere benzerlikleri de bulunmaktadır. Matris ve vektör hesapları, tekli ve çoklu regresyon, stokastik süreçler, korelasyon, zaman serileri çözümlemeleri gibi bazı modelleme yöntemleri ile ortak mimarileri vardır (Şen, 2004). Burada bir konudan daha bahsetmek gerekir. Mimarisinin benzediği bu modellere göre YSA, varsayımları olmayan bir sistemdir. Doğrusallık, bağımsızlık vs. varsayımları ya da ön şartları yoktur (Sarlak, 2005).

YSA özellikle doğrusal olmayan zaman serilerinin tahmininde göstermiş olduğu başarı sayesinde zaman serilerinin tahmini için çok kullanılmıştır. YSA'lar herhangi bir ön bilgiye gerek duymadan hem doğrusal hem doğrusal olmayan modelleme yaparak tahminleme yapabilir bu nedenle diğer modelleme yöntemlerine göre daha esnektir (Zhang et al., 1998).

YSA'ların sahip olduğu bazı dezavantajlı/zayıf yönleri de mevcuttur (Berry and Linoff, 2000; Şen, 2004; Öztemel, 2012; Hu, 2002). Giriş ve çıkış değişkenlerinin her birinin diğeri ile ikişerli ilişkilerinin bilinmesi mümkün değildir. Her YSA modeli içindeki ilişkiler için bir kara kutudur. Kara kutunun içinde YSA'nın nasıl çözüm ürettiği hala merak edilen bir konudur. Eğer fazla uyum sağlıyor ise bu rastgelelik gösterebilir. Algoritmalar kısa bir süre sonra yerel bir çözüme ulaşabilir. Sözel nitelikteki verileri işleyememektedir. Sadece nümerik verilerin işleminde kullanılırlar. Ağın eğitiminin ne zaman gerçekleşeceğine dair karar vermek için geliştirilmiş bir yöntem yoktur. Kabul edilebilir hata değerine veya bu değer altında bir değere inildiğinde ağın eğitimi tamamlanmış olur. Ancak bu tamamlanan eğitim ağın elde edebileceği en iyi değer elde edildiği anlamına gelmez. Bir ağın nasıl oluşturulacağına ilişkin bilgilerin olmaması başka bir dezavantajlı durumdur. YSA donanım tabanlı ve paralel işlemciler ile çalışır. Ancak şuan kullanılan makinelerin

çoğu seri işlemcilerle sahiptir. YSA gibi paralel işlemcilerle çalışan sistemlerin seri işlemcilerle yapılması çok uzun süreler alır. YSA kabul edilebilir çözümler üretebilir, kesin en iyi çözümü garanti etmez. Probleme uygun ağ yapısının çok iyi belirlenmesi gerekir. Eğer ağ belirleme işlemi uygun şekilde yapılmaz ise etkin çözümü bulunabilen bir problem çözümsüz kalabilir. Ya da daha etkin çözümler varken daha kötü çözümlerle işlemler yapmak zorunda kalabiliriz. Katman sayısı, hücre sayısı, öğrenme katsayısı gibi ağın parametre değerleri için belirli bir sayının olmaması da başka bir zayıf yanını oluşturur. Bu parametrelerin sayısı tecrübeye göre belirlenebilir. Sonuçların duyarlılık analizinde yorumlandığı gibi yorumlanması imkânsızdır.

2.2. 2. 3. Yapay Sinir Ağlarının Yapısı

YSA insan beyninin öğrenme mantığı düşünülerek oluşturulan hücrelerden ibarettir. İnsanlar dış dünyadan aldıkları bilgi ve verilerle karar alır ve işlem yaparlar. YSA dışarıdan aldıkları bilgilerle önce öğrenmeyi gerçekleştirir sonra öğrendiklerini yeni bilgilere dönüştürürler.

2.2. 2. 3. 1. YSA Katmanları


YSA örneklerden öğrendiklerini hiç görmediği örneklerle uygulayarak bilgi üreten bir ağıdır. YSA’da farklı öğrenme yöntemleri bulunur. YSA’da insan sinir hücresine benzeyen yapılar (nöronlar) bulunmaktadır (Graupe, 2013). Yapay sinir hücresini oluşturan bu yapılar bir araya geldiğinde YSA’yı oluşturur. YSA temel olarak girdi, ara ve çıktı katmanından oluşmaktadır (Diler, 2003).

Girdi katmanı dış dünyadan gelen bilgileri toplayan katmandır. Girdi katmanında dışarıdan gelen girdi sayısı kadar sinir hücresi bulunur. Girdi katmanında girdiler genelde bir işleme tabi olmadan diğer katmana geçer (Rojas, 2013). Girdi katmanından gelen bilgiler ara katmana geldiğinde bilgi işlemesi yapılır. Bir sinir ağında tek veya çok ara katman olabilir. Ara katmanlardaki hücre sayıları birbirinden farklı olabilir. Ara katmanlardaki hücre sayısının artması işlemleri karmaşıktır ancak sinir ağına daha iyi sonuçlar üretme imkânı verir. Çıktı katmanı ara katmanda işlenen ve bilgiye dönüşen verinin son geçiş katmanıdır. Çıkış katmanından çıkan bilgi başka bir hücre veya hücrelere girdi olacaktır ya da direkt bilgi olarak hücreden çıkacaktır (Diler, 2003).

YSA'nın çalışma mantığını anlamak için insan beyninin çalışma mantığını kavramak lazımdır. İnsan beyni sinir sisteminin merkezidir. Sinir sistemini nöron adı verilen sinir hücreleri oluşturur. Bu nöronlar birbirleri ile bağlantılı ve etkileşimli hücrelerdir (Ersoy ve Karal, 2012). YSA'lar beyinden esinlenerek oluşturuldukları için beyne benzer yapıya sahiptirler. Yapay nöronlar tıpkı gerçek sinir hücreleri gibi bağlantı halindedir. Çevreden aldıkları bilgiyi toplar bunlar üzerine bazı işlemler yapar ve sonuç üretirler.

2.2. 2. 3. 2. YSA Hücre Elemanları

Bir YSA hücresinde girdiler ($X_1, X_2, \dots, X_n$), ağırlıklar ($W_1, W_2, \dots, W_n$), birleşme fonksiyonu (toplayıcı), aktivasyon fonksiyonu ve çıktı olmak üzere 5 bölüm vardır. Bu yapı Şekil 2.1'te verilmiştir.



Şekil 2.1: Yapay Sinir Hücresinin Elemanları (Haykin, 1999)).

Bir YSA'da girdiler; yapay sinir hücresine gelen bilgileri gösterirken ağırlıklar hücreye gelen bilginin önemini ve etkisini göstermektedir. Ağırlıkların pozitif negatif olması etkilerinin pozitif veya negatif olduğunu gösterir. Birleşme fonksiyonu girdiler ile ağırlıkların çarpılması ile bulunur ve değeri bize net girdi miktarını verir.

$$NET = \sum_{i=1}^n X_i \cdot W_i \quad (2.11)$$

Denklem (2.11) ile birinci girdiden n. girdiye kadar olan girdilerin her birinin kendilerine verilmiş rasgele ağırlık değerleri ile çarpılması ve toplanması anlatılmaktadır. X değerleri her bir girdiyi gösterirken, W değerleri ise her bir girdinin kendi ağırlıklarını gösterir. Tüm YSA modelleri için aynı birleşme fonksiyonunun kullanılması gibi bir zorunluluk bulunmaz. Bazı veriler için farklı birleşme fonksiyonları da belirlenebilir. Bunlardan hangisinin kullanılacağı deneme yanılma

yolu ile belirlenir. Tablo 2.1’de literatürden elde edilen bazı birleşme fonksiyonları verilmiştir (Öztemel, 2012).

Tablo 2.1: YSA Birleşme Fonksiyonları.

Net Giriş	Açıklama
$NET = \prod_1^n X_i \cdot W_i$	Birinci girdiden n. girdiye kadar olan girdilerin her birinin kendilerine rasgele verilmiş ağırlık değerleri ile çarpılması ve sonra elde edilen değerlerin birbirleri ile çarpılması ile Net Girdi elde edilmiş olur.
$NET = Max(X_i, W_i)$	Birinci girdiden n. girdiye kadar olan girdilerin her birinin kendilerine rasgele verilmiş ağırlık değerleri ile çarpılır sonra elde edilen değerlerden en büyük olanı YSA Net Girdisi olarak alınır.
$NET = Min(X_i, W_i)$	Birinci girdiden n. girdiye kadar olan girdilerin her birinin kendilerine rasgele verilmiş ağırlık değerleri ile çarpılır sonra elde edilen değerlerden en küçük olanı YSA Net Girdisi olarak alınır.
$Net = \sum sgn(X_i, W_i)$	Birinci Girdiden n. girdiye kadar olan girdilerin her birinin kendilerine rasgele verilmiş ağırlık değerleri ile çarpılır sonra elde edilen değerlerden pozitif ve negatif olanların sayısı bulunur. Büyük olan sayı YSA Net Girdisi olarak alınır.
$Net = Net(eski) + \sum (X_i \cdot W_i)$	Yapay sinir hücresine gelen bilgiler ağırlıkları ile çarpılarak toplanır. Elde edilen toplam daha önceden gelen bilgilere eklenerek Net Girdi bulunur.

Birleşme fonksiyonu ile elde edilen değerler çok büyük değerler alabilir. Birleşme fonksiyonundan sonra yapay hücrede aktivasyon fonksiyonuna geçilir.

En çok kullanılan aktivasyon fonksiyonu Sigmoid fonksiyonudur. Bu fonksiyon ağırlıklı ortalama değerini 0-1 arasında bir değere dönüştürür. Fonksiyon için yine kabul görmüş bir aktivasyon fonksiyonu yoktur. Fonksiyon hangi birleşme fonksiyonu ile olursa olsun elde edilen Net Girdi değerini işler ve mevcut YSA’nın üreteceği çıktıyı belirler. Sigmoid fonksiyonunda hem doğrusal hem doğrusal olmayan

fonksiyonların her ikisi içinde dengelenmiş çıktılar üreterek modelleme yapılabilir (Öztemel, 2012).

Sigmoid fonksiyonu aşağıdaki gibi gösterilebilir:

$$F(Net) = \frac{1}{1+e^{-Net}} \quad (2.12)$$

Denklemden yer alan “Net” değeri birleşme fonksiyonu ile elde edilen Net Girdi değeridir.

YSA’da kullanılacak bir diğer aktivasyon fonksiyonu Hiperbolik Tanjant (tansig) fonksiyonudur. Bu fonksiyonu kullanabilmek için girdi değerleri önce (-1,1) aralığında normalize edilir ve sonuç olarak çıktı değerleri de (-1,1) aralığında elde edilir. Çıktısının (-1,1) aralığında değerler olmasının arzu edildiği uygulamalar için bu fonksiyon çok kullanışlıdır (Haykin, 1999).

$$F(Net) = \frac{e^{Net} - e^{-Net}}{e^{Net} + e^{-Net}} \quad (2.13)$$

YSA’da yaygın olarak kullanılan bir diğer fonksiyonda Eşik fonksiyonudur (Yıldız, 2009). Buradaki eşikten kasıt girdilerin ağırlıklı ortalamasının ulaşabileceği bir değerdir. Ortalama, bu değere ulaşana kadar 0 bu değeri aşınca ise 1 değerini alır. Sinir hücresi belli bir eşik değerinden sonra çıktı üretmeye başlar. Eşik fonksiyonu aşağıdaki gibi gösterilebilir:

$$F(Net) = \begin{cases} 1; & \text{Eğer Net Değer} > \text{Eşik Değeri} \\ 0; & \text{Eğer Net Değer} \leq \text{Eşik Değeri} \end{cases}$$

Kullanılan başka bir aktivasyon fonksiyonu ise Adım fonksiyonudur. Bu fonksiyonun işleyişi eşik fonksiyonundaki mantığa dayanır. Sinir hücresine gelen girdilerin toplamı 0 değerine ulaşınca kadar -1, toplam 0’ı aşınca ise +1 üretmesidir. Adım fonksiyonu aşağıdaki gibi gösterilebilir:

$$F(Net) = \begin{cases} 1; & \text{Eğer Net Değer} > 0 \\ -1; & \text{Eğer Net Değer} \leq 0 \end{cases}$$

Yapay sinir hücresinde aktivasyon fonksiyonu olarak doğrusal fonksiyon kullanılabilir. Bu durumda girdilerden elde edilen Net Girdi aynen çıktı olarak üretilir. Bu modelin doğrusal olduğu durumlarda tercih edilen bir fonksiyondur. Aşağıdaki gibi gösterilebilir.

$$F(Net) = Net$$

Bir diğer aktivasyon fonksiyonu ise Adımlı Doğrusal fonksiyondur. Bu fonksiyonda yapay sinir hücresine gelen girdi toplamının durumuna bakılır. Eğer toplam 0 ile +1 arasında ise 0, girdilerin toplamı 0 dan küçük ise -1 ve girdiler toplamı

+1 den büyük ise +1 değeri çıktı olarak üretilir. Adımlı doğrusal aktivasyon fonksiyonu aşağıdaki gibi gösterilebilir.

$$F(Net) = \begin{cases} +1; & \text{Eğer } Net \text{ Değer} \geq 1 \\ 0; & \text{Eğer } 0 < Net \text{ Değer} < 1 \\ -1; & \text{Eğer } Net \text{ Değer} \leq 0 \end{cases}$$

Hem birleşme fonksiyonu hem aktivasyon fonksiyonu için geçerli bir kural da; ağı süreç elemanlarının hepsinin aynı fonksiyonu kullanmak zorunda olmamasıdır (Öztemel, 2012). En iyi fonksiyon araştırmacının denemeleri ile ortaya çıkabilecektir.

Hücresin 5. kısmı olan çıktı ise aktivasyon işlemi tarafından belirlenen değerdir. Artık yapay sinir hücresi için bilgi üretilmiştir ve üretilen bilgi dışarıya ya da başka bir hücreye tekrar bilgi girişi olarak çıkacaktır. Bir hücreden uygun sadece bir adet çıktı elde edilir. Sürecin tamamlanması için diğer süreç elemanlarına giden bilgi hep aynıdır. Bir hücrenin çıktısı başka bir hücreye girdi olur. Süreç tamamlandığında sinir ağı görevini başarmış ve üretmesi gereken bilgiyi üretmiş olur.

Çalışmada kullanılacak değişkenler seçilip düzenlendikten sonra kullanılacak ağ modelinin, kullanılacak katman sayısı ve nöron sayısı gibi bilgilerin belirlenmesi gerekir. Bir katmanda bulunan nöron veya nöronların diğer katman veya katmanlardaki nöronlara bağlanması ile “ağ topolojisi” oluşur (Tektaş ve Karataş, 2004). Her veri için uygun ağ topolojisinin bulunması önemlidir. Verinin yapısı ile değişken sayısı gibi faktörler ağ topolojisini etkiler. YSA işlemlerinin adımları aşağıdaki gibi sıralanabilir (Hu, 2002):

1. Adım: Problemin tanımlanması
2. Adım: Problem ile ilgili değişkenlerin belirlenmesi
3. Adım: Verilerin toplanması
4. Adım: Verilerin ön işlemden geçirilmesi
5. Adım: Sinir ağının tasarlanması (Ağın yapısı ve öğrenme kuralı seçilmesi).
6. Adım: Ağın eğitilmesi
7. Adım: Ağın geçerliliğine bakılıp hata tespitinin yapılması.

YSA yapısının temel amacı beklenen değer ile çıktı değeri arasındaki hatayı minimum yapacak ağın kurulmasıdır. Bunun için hatayı ağı yayarak çözüm üretilir. Hu (2002)’ya göre YSA’nın minimum hataya sahip ağı kurması için; problem ya da

çözüm bulunulması istenen olay tanımlanır. Olayı açıklayabileceği düşünülen örnekler toplanmaya başlanır. Hem test hem eğitim verileri için örneklerin toplanması gerekir. Ağın genel yapısı belirlenmelidir. Ağın kaç katmandan oluşacağı katman veya katmanlarda kaç adet süreç elemanı olacağı, kimin kime bağlı olacağı, hatanın nasıl yayılacağı ya da belirleneceği gibi sorulara cevap bulunur. Ağın öğrenme katsayısının belirlenmesi aynı zamanda gizli katmanda kullanılacak olan birleştirme ve aktivasyon fonksiyonlarının türünün seçilmesi çıktı üretilmesi için gerekli olan diğer bir aşamadır. Tecrübeler, başlangıç değerlerinin 0.1 ile -0.1 arasında olmasının daha uygun olduğunu göstermektedir (Gallant, 1993). Elde edilen çıktı ile beklenen çıktı arasındaki fark tespit edilir ve elde edilen değer kabul edilebilir sınırlar içinde değilse ağırlıklarda değişim yapılır. Son olarak örnekler ağıya sunulur ve ağın örnekleri tanıması ve bilgi üretmesi istenir. Üretilen bilgi ile hata belirlemesi yapıldıktan sonra ağırlıklar güncellenerek kabul edilebilir sınırlardaki hataya ulaşılmaya çalışılır. Ağ istenilen sonuçları vermeye başladığında test verileri ağıya sunulabilir ve çözüm üretmesi beklenir.

2.2. 2. 4. Yapay Sinir Ağlarında Öğrenme

YSA'ların ayırt edici özelliklerinden biri de öğrenebilmeleridir. Bunu yaparken YSA eldeki eğitim verilerini kullanır. Öncelikle ağıya öğrenmesini sağlayacak girdi ve çıktı değerleri öğretilir. Eğitim verileri ile öğrenme gerçekleşince sinir ağına daha önce görmediği veriler verilerek ağın analiz etmesi ve çıktıya dönüştürmesi istenir. Ağ eğitim verilerinden en uygun ağırlık değerlerini hesaplar. Ağırlık değerleri, kendisine sonradan verilen seti işlemek ve analiz etmek için kullanması gereken değerleri kapsar (Freeman, 1993).

YSA eğitime başlandığında ağırlıklar rasgele verilir. Rasgele ağırlıklar için eğitim seti verileri uygulanır. Çıkış işlemi sonunda kabul edilebilir hata payına ulaşılmış ise ağ eğitilmiştir. Aksi takdirde işlemlerde başa dönülür ve ağırlıklar yeniden ayarlanır. Bu işlem istenilen hata seviyesine ulaşıncaya kadar tekrarlanır. Hesaplanan hataya etki eden en önemli ve düzeltilebilecek etken ağıya verilmiş olan ağırlıklardır. Ağırlıkların değiştirilmesi hatayı azaltabilir. Ancak elde edilebilecek en küçük hata miktarı elde edildiğinde artık ağ eğitilmiş olur. Ağırlıkların tekrar değiştirilmesi ağın tahmin ya da işleyişinde farklılıklar yapabilir ancak farklar istatistiksel olarak önemli olamayabilir (Elmas, 2016). Hatayı azaltmanın tek yolu ya

da çaresi ağırlıkları değiştirmek değildir. Aynı zamanda sinir ağının katman veya katmanlarında bulunan yapay hücre sayısının değişimlerini takip etmek gerekir. Başta rasgele bir sayıda verilebilecek olan hücreler ilerleyen iterasyonlarda azaltılabilir veya çoğaltılabilir. Böylece hatanın azaltılması sağlanabilir. İyi bir şekilde ağırlıklandırılmış ve hücre sayısı belirlenmiş bir sinir ağı daha doğru bilgiler verecektir (Rojas, 2013).

YSA her ne kadar insan beyin hücrelerine benzetilse de bir yönden bu hücrelerden bir üstünlüğü vardır. İnsan beyin hücrelerinin hasar görmesi sonucu o zamana kadar depolanan bazı bilgiler hafızadan silinebilir. Ancak YSA'daki yapay sinir hücrelerinin ölme ihtimali yoktur. Bu nedenle YSA'daki bilgileri kaybolma veya silinme ihtimali yoktur (Öztemel, 2012). YSA kendine verilen bilgilere göre kendi ilişkilerini kurar. Kendilerine ait denklemleri yoktur. Dahası ağı içinde yapılan işlemlerin ne olduğu kesin olarak bilinemez (Aktaş, 2003). Bu özelliğinden dolayı YSA “kara kutu” olarak tanımlanabilir. Kara kutunun içindeki işlemlerin neler olduğu hangi işlemlerin yaşandığı hala bilinmemektedir.

YSA'da öğrenme “öğretmenli öğrenme” ve “kendi kendine öğrenme” gibi 2 temel alanda gerçekleştirilir (Fausett, 1994). YSA'da Öğretmenli Öğrenme, Destekleyici Öğrenme ve Öğretmensiz Öğrenme olarak 3 öğrenme stratejisi uygulanır (Öztemel, 2012).

Öğretmenli Öğrenme stratejisinde ağı olayı öğrenmesinde bir öğretmen etkisi yer alır. Tıpkı okuma yazma öğreten bir öğretmen gibi ağı öğrenmeyi gerçekleştirmesi için girdi-çıkı değerleri tam olarak sisteme öğretilir. Sistem aldığı girdiler ile oluşturması gereken çıktılar hakkında bilgi sahibi olur. Girdi ve çıktılar arasındaki ilişkiler böylelikle belirlenebilir. Ağı verilen girdiler için ağı elde etmesi gereken çıktılar sayısal olarak bellidir. Ağı kendisine gösterilen girdi-çıkı değerlerini bir nevi ezberler. Çıkması gereken değerler tam olarak bilindiğinden YSA'nın ürettiği değerler ile karşılaştırılmasında kabul edilebilir hata miktarı önemlidir. Hatanın minimizasyonu temel ilkedir. Hata payları her bir nöron için hesaplanır. Ağı bütün çıktıları ile ağıdan beklenen çıktılar karşılaştırılarak hesaplanan fark hata olarak alınır ve her bir nörona elde edilen hatadan düşen pay belirlenir. Belirlenen paylara göre ağı nöronları kendi ağırlıklarını günceller (Fırat ve Güngör, 2004).

Destekleyici öğrenme sisteminde de bir öğretmen mevcuttur. Ancak öğretmenli öğrenmede olduğu gibi her girdi değerine karşılık sistemin üretmesi gereken çıktı değerleri sisteme verilmez. Sistemden beklenen, girdilere karşılık çıktı değerlerini

kendisinin üretmesidir. Üretilen çıktılar doğru olup olmağı ile ilgili bir mekanizması vardır. Eğer üretilen çıktının doğru olduğuna karar verirse sistem öğrenme sürecini tamamlamış olur. Eğer yanlış olduğuna karar verirse öğrenme süreci doğru aralıklarda olan çıktılar elde edilmesine kadar devam eder. Zorlamalı öğretim olarak da isimlendirilebilen bu yöntemde öğretmenin “başarısız” komutuyla sistem kendini tekrar çalıştırır ve “başarılı” kararını alıncaya kadar eğitim devam ettirilir. Doğru-Yanlış, Başarılı-Başarısız gibi ikili mantık kuralı kullanılır (Şen, 2004).

Öğretmensiz öğrenme sistemde diğerlerinden farklı olarak bir öğretmen yoktur. Sistem kendisine verilmiş olan girdiler ile kendisi çıktı üretir. Aynı zamanda sistemde bir uyarı mekanizması da yoktur. Genelde sınıflandırma problemlerinde kullanılan bu yöntemde sonuçlar elde edildikten sonra sistemi çalıştıran kişinin çıktıları yorumlaması veya belirli bir şekilde ayarlaması gerekir. Öğrenme için bir öğretmen olmadığından bu öğrenmeye kendiliğinden öğrenme de denebilir. Sistemin kendi kendine bir şeyler üretmesi beklenir. Eğer sonuç hakkında hiçbir bilgi yok ise ağın ürettiği çıktının başarılı olma ihtimali olduğu gibi başarısız olma ihtimali de vardır. Bu öğrenme sistemi daha çok kümeleme çalışmalarında kullanılır (Öztemel, 2012). Kümeleme yapılırken sistem belirli özelliklere sahip değerleri aynı kümeye atar benzer olmayan verileri ise yapılmış olan kümeden uzaklaştırır. Bağlantı ağırlıkları benzer olan verilerden kümeler oluşturabilir.

2.2. 2. 5. YSA Mimarileri

YSA’lar mimari olarak temelde 3 farklı mimari yapı gösterirler. Bunlar tek katmanlı ileri beslemeli ağlar, çok katmanlı ileri beslemeli ağlar ve geri beslemeli ağlardır (Haykin, 1999).


Bir YSA’nın kaç katmanlı olduğu sorusunun cevabı kaç gizli katmanlı olduğudur. Gizli katmanlı olmayan modeller basit ve linear problemlerin çözümünde kullanılırken, gizli katman sayısı arttıkça daha karmaşık ve nonlinear problemlerin çözümünde kullanılır. Bir ağda bir veya daha fazla gizli katman bulunur. Eğer bu gizli katman olmazsa çıktı verisi ya da bilgi elde edilemez (Kartalopoulos, 1996).

2.2. 2. 5. 1. Tek Katmanlı İleri Beslemeli YSA

YSA sahip olduğu katman sayılarına göre tek ve çok katmanlı olmak üzere iki gruba ayrılabilir. Bir sinir ağında muhakkak bir giriş, bir çıkış ve en az bir adette gizli

katman olmalıdır (Benli, 2002). Katman sayısı denildiğinde bahsedilen değer, gizli katmanın sayısıdır.

Tek katmanlı YSA'da tek bir giriş ve tek bir çıkış katmanı yer alır. Ağa girdi değerleri ve girdiler için üretmesi gereken çıktı değerleri verilir. Ağ çıktıları üretmeye başlayana kadar eğitim devam eder. Çıktı değerlerine ulaşabilmesi için ağın ağırlıkları her bir iterasyonda değiştirilir. Çıktı değerlerine ulaşıldığında ağın eğitimi tamamlanmıştır ve ağ kullanıma hazırdır. Tek katmanlı YSA sadece doğrusal problemler için kullanılabilir (Gurney, 1996). Tek katmanlı algılayıcıların genel gösterimi aşağıdaki gibidir:



Şekil 2.2: Tek Katmanlı YSA Yapısı (Gurney, 1996).

Şekil 2.2'de tek katmandan oluşan bir YSA görülmektedir. n adet girdi (X) ve 1 adet çıktıdan(Y) oluşmaktadır. Ağın çıktı değeri girdiler ile ağırlıkların (W) çarpılıp eşik değeri ($\emptyset$) ile toplanması ile bulunur. Eşik değeri ağın çıktısının 0 olmaması için vardır.


$$\text{ÇIKTI} = \sum_{i=1}^n X_i \cdot W_i + \emptyset \quad (2.14)$$

İlk girdiden başlayarak n. girdiye kadar tüm girdiler ağırlıkları ile çarpılır ve eşik değer ile toplanır. Bu işlem sonucunda;

$$F(\text{Net}) = \begin{cases} 1; & \text{Çıktı Değer} > \emptyset \\ 0; & -\emptyset \leq \text{Çıktı Değer} \leq \emptyset \\ -1; & \text{Çıktı Değer} < \emptyset \end{cases}$$

elde edilen çıktı 1 veya -1 değerini alır. Eşik değer ile toplanan sonuç eğer eşik değerinden küçük ise -1, büyük ise +1 grubuna atılır ve böylelikle ayrılmış olurlar (Fausett, 1994). Sıfır değeri ile karşılaşıldığında bunun hangi sınıfa atılacağı tamamen ağı yöneten kişinin elindedir.

En basit tek katmanlı YSA “Perceptron” dur. Perceptron’lar Rosenblatt tarafından örüntü sınıflandırma amacı ile geliştirilmiştir. Perceptron’un mimarisi Hebb’in geliştirdiği mimariye benzemektedir. Modelde önemli olan eşik değeridir (Fausett, 1994). Çıktılar arasına bir veya birden fazla doğru çizilebiliyorsa, çıktılar bir veya daha fazla sınıfa bu doğrular ile ayrılabilir ise Perceptron kullanılabilir.




Şekil 2.3: Perceptron Sınıf Ayrım Grafiği.

Tek katmanlı algılayıcı olarak Perceptron ile birlikte ADALINE/MADALINE modelleri de sayılabilir. Bernard Widrow ve öğrencisi Marcian Hoff en küçük kareler veya delta kuralını kullanan ADALINE öğrenme kuralını geliştirmişlerdir (Fausett, 1994). ADALINE/MADALINE modellerinin Perceptron’dan farkı, öğrenme algoritmalarıdır. Yine bunlarda da giriş ve çıkışlar bulunmaktadır. Girdilerden elde edilen çıktılar, olması gereken çıktılar ile karşılaştırılır istenilen çıktılar elde edilene kadar ağırlıklar değiştirilir. MADALINE modeli ile ADALINE arasındaki fark ise MADALINE ünitesinin birden çok ADALINE ünitesinin birleşiminden oluşmasıdır. ADALINE üniteleri AND ve OR bağlaçları ile birbirine bağlanır (Öztemel, 2012).

2.2. 2. 5. 2. Çok Katmanlı İleri Beslemeli YSA

Tek katmanlı algılayıcılar (Perceptron, ADALINE, MADALINE) doğrusal problemlerin çözümünde kullanılmaktadır. Ancak gerçek hayattaki problemlerin birçoğu böyle bir doğrusallık göstermeyebilir. Doğrusallık varsayımının gerçekleşmediği durumlarda tek katmanlı YSA problem için sonuç üretemez. 1969 yılı tek katmanlı YSA’ların yetersiz olarak bulunduğu bir yıl olmuştur. Bu gelişme ile YSA’ya olan ilgiler azalmış hatta durma noktasına gelmiştir. Durgunluk hali çok katmanlı algılayıcıların oluşturulmasına kadar devam etmiştir.

Çok katmanlı ileri beslemeli ağlarda nöronlar arasındaki bilgi, girişten çıkışa doğru tek yönlü düzenli katmanlar halindedir. Bir katman sadece kendinden sonra gelen katmana bağlanmıştır ve bir nöronun çıktısı sadece kendinden sonra gelen nöron katmanına girdi olabilir. Aynı katmandaki başka bir nörona bağlantı yoktur (Haykin, 1999). Bu ağlara örnek olarak çok katmanlı algılayıcılar (MLP) ve sayısallaştırılmış öğrenme vektörü (LVQ) verilebilir (Saygılı, 2008). İleri beslemeli ağlarda sinir hücreleri girdi katmanı, gizli katman ve çıktı katmanı olarak adlandırılan katmanlarda işlem görür. Öğrenilmesi gereken bilgi girdi katmanında çıktı katmanına doğru hareket eder ve ayrıca bu üç katmanın birbirleriyle bağlantısı yoktur. Çok katmanlı bir ağ Şekil 2.4'teki gibi gösterilebilir (Kaynar vd., 2011).




Şekil 2.4: Çok Katmanlı İleri Beslemeli YSA (Kaynar ve Taştan 2009).

2.2. 2. 5. 3. Geri Beslemeli Yapay Sinir Ağları

Geri beslemeli ağlarda katmanlar arasında sinir hücreleri birbirleriyle bağlantılıdır ve nöronlar bir hafızaya sahiptir (Ülker and Civalek, 2002). Geri beslemeli ağlar ileri beslemeli ağlardaki gibi sadece kendinden sonraki katmana bilgi vermezler. Bir nöron kendi katmanındaki bir nörona ya da kendinden önceki katmandaki nörona girdi olarak bağlanabilir. Geri beslemeli ağlar dinamik yapı gösterir. Geri besleme, bir katmandaki nöronlar arasında olabildiği gibi diğer katmanlardaki nöronlar arasında da olabilir. Geri beslemenin yapılış şekline göre farklı mimaride ağlar oluşur (Rao and Srinivas, 2003). Ağ geri besleme sayesinde ortaya çıkan her tür hatayı belirleyip geriye dönük hata düzeltmesi yapabilir ve aynı hataları daha kolay önleyebilir. Ağdaki ağırlıkların değiştirmesinde üç durum olabilir (Haykin, 1999). Gizli katmanla çıkış katmanı arasındaki ağırlıkların değiştirilmesi, gizli

katmanlar arasındaki ağırlıkların değiştirilmesi veya girdi katmanı ile gizli katman arasındaki ağırlıkların değiştirilmesidir. Geri besleme işleminde gizli katmanlardaki ya da çıkış katmanındaki aktivasyon değerlerini bir sonraki iterasyona girdi olarak taşımakla görevlendirilmiş bulunan bir geciktirme elemanı bulunur. Geri beslemeli YSA'lar karmaşık bir çalışma düzenine sahiptir yinede dinamik hafızaları ile ön tahmin uygulamalarında başarılı olan sonuçlar verir (Saygılı, 2008).



Şekil 2.5: Geri Beslemeli YSA (Haykin, 1999).

Geri besleme bir katmandaki elemanlar arasında olduğu gibi başka katmanlardaki elemanlar arasında da olabilir. Şekil 2.9'da görülebileceği gibi en az bir hücrenin çıktısı kendisine ya da YSA'daki diğer hücrelere giriş olarak verilmektedir. Ağın t anındaki çıkış değeri $o(t)$ ise, $t+\Delta$ anındaki çıkışı $O(t+\Delta)$ olur. Buradaki Δ sabit olarak gecikme süresini gösterir (Karahana, 2011).

$$O(t+\Delta)=f(w.o(t)) \quad (2.15)$$

Bir başka ağ yapısı geri beslemeli geri yayılmalı ağlardır. Bu ağlarda bilgi yayılımı geriye doğru olmaktadır. Yalnızca bitişik katmanlarda bulunan süreç elemanları kendi aralarında iletişim halindedir. Ağın çıktıları ile beklenen değerleri arasındaki hatalar ağın öğrenme süreci aşamasında geriye doğru yayılarak azaltılmaya çalışılır (Rao and Srinivas, 2003). Ağ geri besleme sayesinde hata ile her karşılaştığında o hatadan bir şey öğrenir ve aynı hata ile bir daha karşılaştığında hatayı tanıyarak hemen çözüm üretmeyi başarır.

2.2. 2. 6. Geri Yayılım (Backpropagation) Algoritması

YSA'lar hata yaparak öğrenirler sahip oldukları öğrenme algoritması ile bu hataları belirlerler. Öğrenme algoritmasına göre belirlenen hatayı azaltmak için ağırlıklar değiştirilir ve ağırlıkların tekrar çıktı üretmesi sağlanır. Bu işlem ağırlıklar istenen çıktıları verene kadar tekrarlanır. Rumelhart et al. (1989) tarafından YSA'nın eğitim sorununu ortadan kaldırabilmek için çalışmalar başlatılmış ve geri yayılım algoritması geliştirilmiştir. Bu algoritma iki katmanlı ileri beslemeli ağların başarılı çözüm üretilmediği problemlerin çözümünde başarı sağlamıştır. Bu algoritma çok karmaşık bir matematiksel modele sahiptir (Haykin, 1999). Bir YSA'da en çok kullanılan eğitim algoritması uygulama basitliği ve uygulamadaki görüş açısı gibi avantajlarından dolayı ağırlıklı olarak en popüler algoritmalarından biri olan geri yayılım (Backpropagation) algoritmasıdır (Zhang et al., 1998). Geri yayılım algoritması gizli katman içeren YSA'lar için güçlü bir öğrenme algoritması olarak kullanılmaktadır (Şen, 2004). Algoritma güçlü çalışma sistemine sahiptir; karmaşık, doğrusal olmayan YSA'ların eğitiminde çok etkilidir ve temel amacı ağırlıklardan üretilen çıktı ile girdi değerleri arasındaki hatayı minimum yapmaktır (Verbos, 1994).

Finansal sinir ağları için en yaygın ağ mimarisi, geri besleme kullanarak eğitilmiş çok katmanlı bir geri beslemeli ağıdır. Geri besleme sistemi; ortaya çıkan hataları, eğitim sırasında çıkış katmanından giriş katmanına doğru ters yönde iletme sürecidir. Gizli ünitelerin kullanılabilecek herhangi bir eğitim hedef değerine sahip olmamaları nedeniyle hatanın geriye yayılımı gereklidir. Bu nedenle hatalara dayalı olarak eğitilmeleri gerekir. Çıkış katmanı, karşılaştırılacak bir hedef değeri olan tek katmandır. Hatalar düğümler vasıtasıyla geri iletildiğinde, bağlantı ağırlıkları değiştirilir. Eğitim, ağırlıklardaki hatalar kabul edilebilir düzeye varana kadar gerçekleştirilir (Lawrance, 1997). Geri yayılım öğrenme girdi vektörlerinin normalleştirilmesini gerektirmez; Bununla birlikte, normalleştirme performansı artırabilir (Buckland and Collins, 2002).

Eğitimin n . yinelenmesinde YSA'nın çıkış katmanındaki j . nöronunun çıkış değeri y_j , bu sinirden vermesi istenilen değer d_j , ağırlık hatası e_j , ile gösterilirse, j nöronunun hata işareti şöyle tanımlanır (Haykin, 1999):

$$e_j(n) = d_j(n) - y_j(n) \quad (2.16)$$

Anlık hata $\mathcal{V}(n)$ ile gösterilmek üzere;

$$\mathcal{V}(n) = \frac{1}{2} \sum_j e_j^2(n) = \frac{1}{2} \sum_{j \in c} (d_j - y_j(n))^2 \quad (2.17)$$

denklemini ile ifade edilmektedir. Burada c sayısı ağda bulunan nöron sayısını göstermektedir. Ağda yer alan tüm hücrelerin anlık hata değerleri toplanıp, ağdaki hücre sayısına bölüldüğünde ortalama hata değeri $\mathcal{V}(av)$ bulunur.

$$\mathcal{V}(av) = \frac{1}{N} \sum_{n=1}^N \mathcal{V}(n) \quad (2.18)$$

Geri yayılım algoritmasının temel amacı hatayı minimum yapmaktır. Geri yayılımda tüm veriler ağa gösterilip ağ hataları belirlendikten sonra geriye dönüp ağın hatasının geriye yayılımı yapılmaktadır. Buradaki mantık her bir geriye yayılımda hatanın daha da azaltılmasıdır. Her bir geriye dönüş işlemine döngü denilir (Lawrance, 1997). n döngü sayısını göstermek üzere ağın hatayı minimuma ulaştırma gösterimi aşağıdaki gibidir.

$$\sum_{t=1}^t e_{n,t}^2 < \sum_{t=1}^t e_{n-1,t}^2 < \sum_{t=1}^t e_{n-2,t}^2 \dots \sum_{t=1}^t e_{n-n,t}^2 \quad (2.19)$$

Denklem 2.19'dan da görülebileceği gibi her bir iterasyonda ağın hata değerleri azalmaktadır. Toplam hatayı azaltmak için katmanlar arasındaki ağırlıkların ayarlanması gerekir. Her bir iterasyonda ağırlıklar değiştirilerek toplam hatanın azaltılması işlemi yapılır ve ağın çıktısı ile gerçek çıktı arasındaki ortalama hata karesi azaltılır (Mehra and Wah, 1992).

Çıktı hatası δ_m ile gösterilir ise

$$\delta_m = f'(NET) \cdot e_m \quad (2.20)$$

ile bulunur. Denklemde $f'(NET)$ aktivasyon fonksiyonunun türevini gösterir.

Ara katman ile çıktı katmanı arasındaki ağırlıkların değişim miktarı ΔA_{jm}^a ; λ öğrenme katsayısı, α momentum katsayısı olmak üzere aşağıdaki denklem ile hesaplanır.

$$\Delta A_{jm}^a(t) = \lambda \delta_m \zeta_j^a + \alpha \Delta A_{jm}^a(t-1) \quad (2.21)$$

Ağın ağırlıklarının yeni değeri ise;

$$A_{jm}^a(t) = A_{jm}^a(t-1) + \Delta A_{jm}^a(t) \quad (2.22)$$

Denklemini ile yapılır.

Ara katmanı ve çıktı katmanı arasındaki ağırlık değiştirme işlemi ara katman ile girdi katmanı arasındaki ağırlıkları değiştirmek içinde uygulanır.

$$\Delta_j^a = f'(NET) \sum_m \delta_m A_{jm}^a \quad (2.23)$$

Denklem 2.21 ile 2.23 arasındaki fark hata teriminin hesaplanmasında ortaya çıkmaktadır. Ara katmanı ile girdi katmanı arasındaki ağırlık değişiminde tüm ağın

hatası hesaplanır. Eşik değeri için de yine ağırlık değişimi işlemi yapılması gerektiğinden bu aşğıdaki formül ile yapılmalıdır. $\Delta\beta_m^c$ eşik değeriindeki değişimi göstermek üzere Denklem 2.24 ağırlık değişiminin nasıl yapılacağını göstermektedir.

$$\Delta\beta_m^c(t) = \lambda\delta_m + \alpha\Delta\beta_m^c(t-1) \quad (2.24)$$

$$\beta_m^c(t) = \beta_m^c(t-1) + \Delta\beta_m^c(t) \quad (2.25)$$

Denklem 2.25 ise ağırlıkların yeni değeriinin nasıl bulunacağını göstermektedir.

3. MELEZ YÖNTEMLER

Literatüre bakıldığında zaman serilerinin analizinde kullanılmak üzere birçok modelin geliştirildiğini ve hatta geliştirilmeye devam edildiğini görebiliriz. Çünkü bilişim teknolojileri her geçen gün gelişmekte ve problemlere daha değişik algoritmalarla çözüm üretilebilmektedir. Dolayısıyla yeni algoritma, yöntem ve modellerin ortaya çıkması yeni melez modellerinde araştırılması ihtiyacını beraberinde getirmektedir.

Melez yöntemler finansal zaman serisi tahmin işinde büyük başarılar sağlamış durumdadır (Ma et al., 2015). İstatistik ve makine öğrenmesinde melez modeller kurucu öğrenme algoritmalarından elde edilenden daha iyi tahmin performansı elde etmek için çoklu öğrenme algoritmaları kullanılır (Opitz et al., 1999; Rokach, 2010). Eğitilebilir ve tahmin amacıyla kullanılabilir olduklarından bu metodlar bir denetimli öğrenme algoritmasıdır

Deneyisel olarak melezleme, modeller arasında önemli bir çeşitlilik olduğunda daha iyi sonuçlar elde etme eğilimindedir (Kuncheva et al., 2003). Model melezleme yapmanın amacı, modellerin birleşimiyle ortaya çıkacak çeşitliliği teşvik etmek daha iyi sonuçlar elde edilmesini sağlamaktır (Adeva et al., 2005).


Melezleme genel sistem performansını artırmak için birlikte çalışan öğrenme algoritmalarının uygulandığı örneklerin kümesidir. Birleştirmeler genellikle çoklu iki sınıflı çok sayıda problemin, çok sınıflı bir probleme dönüşümü için kullanılır. (Adeva et al., 2005). Melezlenmiş bir tahmin modeli tahmin etme görevinin en başarılı modelleri olarak tanınırlar. Melez modeller hakkındaki daha önceden yapılmış çalışmalar, başarını nedenini gruplar arasındaki çeşitlilik olduğunu göstermiştir. Çeşitlilik oluşturmak için değişik yöntemler mevcuttur (Oliveira and Torgo, 2014). Melez modellerle elde edilen sonuçlar ile modellerin tekil halde kullanılmaları sonucu elde edilen sonuçlar karşılaştırıldığında birbirinden alakasız bile olsalar melezleme yapmanın genel varyans veya hatayı düşürebildiği görülmüştür (Khashei et al., 2008).

Mevcut ve etkin modeller kurallarına ve çalışma prensiplerine uygun şekilde birleştirilerek bireysel olarak verilen sonuçlardan daha optimum sonuçlara ulaşılabilir. Elde edilen sonuçların karşılaştırılması ile birçok melezleme çalışmasında daha iyi ve

kullanışlı sonuçlara ulaşılmış ve bu çalışmalar belli temellerdeki değerler dikkate alınarak tekrarlanmıştır (Zhang, 2003).

Melezleme sistem performansını iyileştirmek için farklı yaklaşımlar ile yapılabilir. Bu yaklaşımlar; girdi seçimi, farklı model sonuçlarını birleştirme, farklı model sonuçlarını başka bir modele katma şeklinde ele alınabilir.


Girdi seçimi, bazı kriterler kullanarak elde mevcut veri setinden en kullanışlı değişkenlerin seçilmesi demektir. Kurulacak olan modelin daha anlamlı değişkenler ile kurulmasını sağlamak girdi seçiminin en önemli amacıdır. Böylece modelde gereksiz olan değişkenler yer almayacak ve daha hızlı çözüm üretilebilecektir (Sivagaminathan, 2007). Başlangıç çözümleri üretebilmek için modeller melezlenerek daha iyi başlangıç uygun çözümleri oluşturulabilir (Mason, et al., 1998). Literatürde girdi seçimi için melezleme işlemleri yapılmıştır. Yöntemde öncelikle bir teknik veya model ile kullanılacak değişkenler belirlenir ve bu elde edilen değişkenler başka bir modele girdi olarak sunulur. Bu yaklaşımla bir model ile kurulan çözüm başka bir modelle geliştirilmektedir. Literatürde YSA'nın eğitimi için geliştirilmiş böyle modeller yer almaktadır. YSA'nın eğitimi öğretmenli öğrenmede büyük önem taşımaktadır. Bunun için genelde gradyan tabanlı arama kullanılır ve bu yöntem ağırlık hatasının en aza indirmesi için ağırlıkların sürekli değiştirilmesi mantığına dayanır (Yaghini et al., 2013). Bu algoritmalarda öğrenme hız parametresine bağımlılık, eklenen ekstra bir katman ya da gizli nöron için yavaşlama gibi olumsuz yanları vardır. Dolayısıyla bu algoritmalar yüksek ihtimalle yerel minimuma sıkışır ve tekrar başlangıç ağırlıklarının güncellemesi yapılmalıdır (Kiranyaz et al., 2009). Metasezgisel yöntemler YSA'nın eğitiminde karşılaşılan sorunların çözümünde birçok yarar sağlarlar (Castellani and Rowlands, 2009). Sert ve karmaşık problemleri çözmek için makul bir zamanda kabul edilebilir çözümler sağlarlar. (Mendes et al. 2002) ve (Gudise and Venayagamoorthy, 2003) YSA'yı eğitmek için PSO'yu kullanmışlar yöntemlerinin performansını göstermeyen çok basit bir problem kullanarak YSA'nın PSO ile eğitiminin tekil YSA'dan daha kısa sürede ve daha etkili sonuç verdiğini göstermişlerdir.



Şekil 3.1. YSA-PSO Hibrit Modeli (Yaghini et al., 2013)


Şekil 3.1’de YSA ile PSO melez modelinin ağırlıkları belirleme de nasıl kullanıldığı gösterilmektedir. a ile YSA yapısını anlatırken, b ile gösterilen kısımda PSO ile hangi ağırlık değerlerin hesaplandığı sunulmuştur.

Farklı model sonuçlarını birleştirme yönteminde bir modelden elde edilen değerler başka bir modelden elde edilen değerler ile birleştirilerek bir sonuç elde edilir.



Şekil 3.2. YSA ile diğer model sonucunu birleştirilmesi (Babu and Sure, 2016).

Farklı model sonuçlarını başka bir modele katma yönteminde veriler öncelikle başka bir model ile ayrıştırılmış ve başka modele girdi olarak sunulur ve elde edilen sonuçlar toplanır.



Şekil 3.3. YSA ile başka bir modelin sonuçlarının birleşimi (Panigrahi and Behera, 2017).

Zaman serilerini tahmini yapmak çok geniş kapsamlı bir uygulama alanına sahiptir. Zaman serisi olmaya müsait olan yani günlük aylık yıllık vb. periyodlarla ölçülen tüm değerler zaman serisi oluşturur. Zaman serisi analizlerindeki temel amaç matematiksel modeller ile mevcut verileri kullanarak modeller oluşturmaktır. Zaman serilerinin özelliklerinin ortaya çıkarılması zor olmasına rağmen bunun için her geçen gün yeni yöntemler geliştirilmektedir. Literatürde geliştirilmiş birçok zaman serisi modeli vardır. Rasgele yürüyüş, AR, MA, ARIMA vs. bunlardan bazılarıdır. Bahsedilen modellerin veri üretiminde ki en önemli varsayımı üretilen verinin doğrusal olmasıdır (Box and Jenkins, 1976). Daha önceden kısaca bahsettiğimiz ARIMA ve YSA, tahmin yöntemlerinde sürekli kullanılmıştır. Her iki yöntem uzunca zaman tek başlarına tahmin için kullanılmış olmalarına rağmen; yöntemlerdeki bazı eksiklikler onların birlikte kullanımı fikrine sebep olmuştur. ARIMA modelleri tek başlarına kullanıldıklarında sadece doğrusal zaman serilerine kullanılabilmekte ve doğrusal ilişkiyi ortaya çıkarabilmektedir. Doğrusal olmayan ilişkiyi verememektedir. Karmaşık doğrusal olmayan zaman serisi modellemelerinde uygun bir yaklaşım olamamaktadır (Fard and Zadeh, 2014). YSA ise ARIMA modelinin bu dezavantajını aşabilmiş ancak tamamen doğrusal bir model için karmaşık sonuçlar üretmiştir. Bu durum sadece ARIMA ya da sadece YSA'nın zaman serisi modellemesinde tek başına etkili olamayacağını göstermiştir (Zhang, 2003). Bu nedenlerden dolayı yapılan bazı çalışmalarda melez yöntemler kullanılmaya başlanmış ve bir modelde dezavantaj olan bir durum, diğer modelin avantajlı kısımları ile ortadan kaldırılmıştır.

Analizi yapılan birçok zaman serisi türü hem doğrusal hem de doğrusal olmayan yapılara sahip olabilir. Doğrusal formdaki verilere uygulanabilecek bir yöntem doğrusal olmayan bir modele uygulandığında başarılı sonuçlar vermeyebilir. Zaman serisi tahminlerinde verinin yapısına göre tekil yöntemler kullanılabildiği gibi son zamanlarda melez modellerde fazlaca kullanılmış durumdadır. Borsa endeks değerleri ve bu borsalarda işlem gören şirketlerin değerleri, önemli bir aktivite olarak ülkelerin ekonomik gelişmelerinde çok önemli bir görev arz etmektedir. Hisse senetlerinin fiyatlarındaki artış şirketleri karlılıklarını artırmakta ve hisse senedi fiyatı artan şirketlere yapılan yatırım kararlarını etkilemektedir. Hisse senetlerindeki fiyat düşüşleri yatırımcıları bu şirketlerden uzaklaştırmakta bu ise şirketin piyasa fiyatının ve karlılığının düşmesine sebep olmaktadır. Tezin konusunu oluşturan borsa endeks değerlerinin tahmini konusunda da hem tekil hem de melez model uygulamalarına rastlanmaktadır.

Abraham vd. (2001) çalışmalarında farklı şirket ve hisse senedi piyasalarına ait 8 veri seti kullanılmışlardır. Bulanık Çıkarsama ile Geri Beslemeli Sinir Ağlarının melezlemesi yapılmıştır. Leigh vd. (2002) NYSE'deki borsa bileşik endeksindeki kısa dönemli artışların tahmini için örüntü tanıma ve sinir ağları ile bir melezleme yapmışlardır. Pai ve Lin (2004) zaman serisi tahmini olarak hisse senedi fiyatlarının seçildiği çalışmalarında ARIMA modeli ile DVM modellerini melezlemişlerdir. Chen vd. (2005) sinir ağları Takagi-Sugeno çıkarsaması ile model melezlemesi yapmışlardır. YSA'da kullanılacak parametreler ise PSO ile belirlenmiştir. Chen vd. (2006) çalışmalarında kaotik hisse senedi piyasasında hisse senedi fiyatlarını daha iyi tahmin etmek için esnek sinir ağları ile GA'yı melezlemişlerdir. Esnek sinir ağlarının parametrelerini ve biçimini genetik programlama ile optimize etmişlerdir. Kwon ve Moon (2007)'deki çalışmalarında YSA ile GA melezlenmiştir. YSA ile model kurulmuş, bu modele ait ağırlıklar ve parametreler ise GA ile kodlanarak çaprazlamalarla iyileştirilmiştir. Hassan vd. (2007) çalışmalarında Gizli Markov Modeli (HMM) ile YSA ve GA melezli ile yeni bir tahminleme modeli önermişlerdir. YSA ile hisse senedi fiyatları bağımsız değerler dizisine dönüştürülerek HMM'ye girdi verisi sağlanmıştır. GA ile de HMM'nin başlangıç parametreleri optimize edilmiştir. Kaynar ve Taştan (2009) zaman serilerinin tahmini için ARIMA modeli ve çok katmanlı yapay sinir ağları (multi layer perceptron-MLP) modeli birleştirilerek bir melez model oluşturmuşlardır.

Huang ve Jane (2009) çalışmalarında otomatik hisse senedi pazarının tahmin edilebilmesi ve otomatik portföy oluşturma mekanizmasının geliştirilmesi için Gri Sistemleme Teorisi, Kaba Kümeleme Teorisi ve Hareketli Ortalama Otoregresif Harici Tahminleme (ARX) modellerini melezlemişlerdir. Cheng vd. (2010) çalışmalarında kaba kümeleme teorisi (RST), kümülatif olasılık dağılımı yaklaşımı (CDPA), düzensizliğin minimizasyonu ilkesi yaklaşımı (MEPA) ve GA kullanarak yeni bir melez model önermişlerdir. Singh ve Borah (2014) çalışmalarında TYPE2 bulanık zaman serisi tahminleme yöntemini PSO ile melezlenmiş Hindistan Devlet Bankası'nın günlük hisse senedi fiyat endeksi değerlerini kullanmışlardır. Güresen vd. (2011) hisse senedi fiyat tahmin için bir çalışma yapmışlardır. Model çok katmanlı algılayıcı yapısı, dinamik YSA ve GARCH modeli ile melezlenmiş bir YSA ile kurulmuştur. NASDAQ endeksine uygulama yapılmıştır. Wang vd. (2012) Geri Yayımlı Sinir Ağları (BPNN), Üstel Düzgünleştirme Modeli (ESM) ve ARIMA'yı zaman serisinin tahmininde kullanmışlardır. Bu 3 yaklaşımın melezlendiği bir model

önerilmiştir. Pulido vd. (2014) çalışmalarında YSA ile bulanık kümeleme yöntemlerini melezlenmiş ve sinir ağlarında kullanılacak katman, katman sayısı her katmandaki nöron sayıları gibi parametreler Parçacık Sürü Optimizasyonu (PSO) algoritması ile iyileştirilmiş ve yöntemde kullanılan parametrelerin en iyilenerek daha iyi sonuçlara ulaşılmasına çalışılmıştır. Fenghua vd. (2014) tekil izge analizi ile hisse senedi piyasasındaki hisse senedi fiyatlarında trendler, dalgalanmalar ve gürültü gibi zamana göre değişen farklı ekonomik özellikleri ayırtmışlar ve detaylandırmışlardır. Ardından bu özellikler DVM'ye girdi olarak konulmuş çeşitli tahminler yapılmıştır. Xiao vd. (2014) YSA, PSO ve GA kullanarak hisse senetlerinin günlük fiyat değişimlerinin tahmini için bir model oluşturmaya çalışmışlardır. Geliştirilen modelde 3 tür YSA'ya yer verilmiştir.

Verilerin farklı modellerle belirlenip sonuçlarının birleştirildiği melez modellerinde, model sonuçları için toplama ve çarpma metodu mevcuttur. Aynı zamanda kalıntıların belirlenmesi işleminde de toplama ve çarpma metodu vardır. Kavram karışıklılığı olmaması için modeller aşamalı bir şekilde açıklanmıştır. Modeller açıklandıktan sonra tezin uygulama kısmında yer alan Tablo 4.1'de listeleme yapılmıştır.

3. 1. Zhang Melez Modeli

Zhang 2003'te geliştirdiği melez modelinde; ne ARIMA ne de YSA'nın tüm gerçek zaman serilerine uygun olmadığını çünkü serilerde gözlemler arasında doğrusal ve doğrusal olmayan korelasyon yapıları bulunduğunu ve bu nedenle bir zaman serisinin hem doğrusal hem doğrusal olmayan bileşenlerinin tahmini için bir melez model kullanılması gerektiğini göstermiştir. Hem ARIMA hem de YSA'yı ayrı ayrı uygulayan bir melez model geliştirmiştir. Bu modeli kullanarak Zhang 3 farklı zaman serisi modelini denemiş ve ortaya çıkarttığı melez modelin tek başına ARIMA ve YSA'dan daha iyi tahmin sonuçları verdiğini bulmuştur. Zhang çalışmasında kalıntının belirlenmesinde ve model melezinde toplama metodunu kullanmıştır. Modelin bir veya çok basamak ileri tahminlere uygun olduğunu iddia etmiştir.

Model melezlemesi yapıldığında her bir modelin tek başına yaptığı tahminden daha iyi performans sonuçları verdiğini iddia eden Zhang (2003) bu melez modeli kullanma düşüncesinin nedenlerini şöyle sıralamıştır:

- Veri kümesinin sahip olduğu yapının doğrusal olup olmadığını ve hangi modelin bu yapıyı daha iyi açıklayacağını bulmak zordur. Model belirsizleştikçe ve verini yapısı değiştikçe daha önceden kullanılan model bir sonraki kullanım için uygun olmayabilir. Farklı modeller birlikte kullanılarak bu belirsizlikler azaltılabilir ve daha iyi sonuçlar veren model kurulabilir.
- Eldeki veri kümesi nadiren tamamen doğrusal ya da tamamen doğrusal olmayan bir yapıya sahiptir. ARIMA doğrusal olan ilişkileri ortaya çıkartabilirken YSA hem doğrusal hem doğrusal olmayan ilişkileri işlemesine rağmen bunları eşit şekilde inceleyemez. Eğer YSA ve ARIMA'dan elde edilen desenler birleştirilirse daha iyi sonuçlar ortaya çıkabilir. Bu birleşmiş modeller tahmin performansını artırarak verilerin arasındaki farklı desenleri de yakalama ihtimali artırılabilir.

Kalıntının tahmin edilmesinde kullanılan toplama metoduna göre $\hat{r}_t$ tahmin edilen doğrusal verileri ε_t kalıntıyı ve r_t gerçek verileri göstermek üzere; gerçek veriler kalıntı terimleri ile tahmin edilen doğrusal verilerin toplamına eşittir.

$$r_t = \hat{r}_t + \varepsilon_t \quad (3.1)$$

Buna göre kalıntı terimlerini belirlemek için;

$$\varepsilon_t = r_t - \hat{r}_t \quad (3.2)$$

işlemini yapmak gerekir.

Zhang'ın zaman serisi modeli aşağıdaki şekilde gösterilebilir (Zhang, 2003):

$$y_t = L_t + N_t \quad (3.3)$$

Burada y_t gözlem değerlerini t zamanı L_t ve N_t ise doğrusal ve doğrusal olmayan bileşenleri göstermektedir. Gözlem değerleri doğrusal ve doğrusal olmayan bileşenlerin toplamından oluşur.


ARIMA-YSA melez çalışmalarında öncelikle ARIMA ile doğrusal olan bileşen t zamanında tahmin edilir ve $\hat{L}_t$ olarak alınır. ARIMA işlemi bittikten sonra elde edilen kalıntılar sadece doğrusal olmayan bir bileşen içerir ve bu aşamadan sonra başka yöntemlerle işleme devam edilmesi gerekir. YSA aşamasına gelindiğinde p sayıda girdi kullanılarak kalıntılar için bir YSA tasarlanmıştır. Bu kalıntılar Denklem (3.1) ve Denklem (3.2) kullanılarak belirlenmiştir.

$$e_t = f(e_{t-1}, e_{t-2}, \dots, e_{t-p}) + \varepsilon_t \quad (3.4)$$

Bu gösterimde f doğrusal olmayan bir fonksiyonu göstermektedir kalıntılar arasında doğrusal olmayan fonksiyon belirlendiğinde ε_t fonksiyon sonunda ortaya çıkan kalıntıyı göstermektedir. Eğer doğrusal olmayan bileşende YSA ile tahmin edilirse o zaman model;

$$y_t = \hat{L}_t + \hat{N}_t \quad (3.5)$$

şekline dönüşür ve melez tahmin modelini verir. Şekil 3.4 Zhang'ın melez modelini göstermektedir.




Şekil 3.4: Zhang'ın Melez Modeli (Babu and Sure, 2016).

Zhang modelinde, hem kalıntıları hem de melez modeli toplama fonksiyonu ile kurmuştur. Tablo 4.1.'de yer alan listede Model 1a ve Model 1c kalıntı tahmininde toplama fonksiyonu kullanılan bu modele dayanmaktadır.


3. 2. Wang'ın Melez Modeli

Zhang (2003) kurduğu melez modelinde sadece toplama metodu ile elde edilen kalıntılar için melez model tasarlamıştır. Wang et al. (2013) çalışmalarında zaman serisinin analizi için iki farklı model düşünmüştür. Kalıntının tespit edilmesi için çarpma metodunu kullanmıştır. Aynı zamanda bir zaman serisindeki doğrusal ve doğrusal olmayan unsurları aşağıdaki gibi göstermiştir:



Şekil 3.5. Zaman Serisinde Doğrusal ve Doğrusal Olmayan Unsurlar(Wang et al., 2013).

Bu doğrusal ve doğrusal olmayan ilişkileri analiz etmek için kurduğu melez modelde ise çarpma işlemi kullanmıştır. Wang'ın melez modeli Şekil 3.6'da sunulmuştur.



Şekil 3.6: Wang'ın Melez Modeli (Babu and Sure, 2016).

Kalıntının tahmin edilmesinde kullanılan çarpma metodunda gerçek veriler kalıntı terimleri ile tahmin edilen doğrusal verilerin çarpımına eşittir.

$$r_t = \hat{r}_t * \varepsilon_t \quad (3.6)$$

Buna göre kalıntı terimlerini belirlemek için;

$$\varepsilon_t = \frac{r_t}{\hat{r}_t} \quad (3.7)$$

işlemleri yapılmalıdır. Hibrit modellerin doğrusal kısımlarındaki kalıntı bu metodla belirlendikten sonra elde edilen kalıntı değerleri doğrusal olmayan kısmı gösterecektir. Daha sonra yapılan hibritleme işlemi ile bu doğrusal olmayan yapı açıklanmaya çalışılır.

$$y_t = L_t * N_t \quad (3.8)$$

Burada y_t gözlem değerlerini t zamanı L_t ve N_t ise doğrusal ve doğrusal olmayan bileşenleri göstermektedir.

Önce ARIMA ile doğrusal olan bileşen t zamanında tahmin edilir ve bu $\hat{L}_t$ olarak alınır. YSA aşamasına gelindiğinde p sayıda girdi kullanılarak kalıntılar için bir YSA tasarlanmıştır. Bu kalıntılar Denklem (3.6) ve Denklem (3.7) kullanılarak belirlenmiştir.

Eğer doğrusal olmayan bileşende YSA ile tahmin edilirse o zaman model;

$$y_t = \hat{L}_t * \hat{N}_t \quad (3.9)$$

şekline dönüşür ve melez tahmin modelini verir.

Özet olarak melez model önerisinde iki yapı kurulmuştur. Başlangıçta bir ARIMA modeli tanımlanacak, parametreler geliştirilecek ve ARIMA modeli kurulacaktır. Sonuç olarak doğrusal olmayan elementler bu modelde hesaplanacaktır. İkinci aşamada YSA doğrusal olmayan unsurlarla ilgilenecektir. Modelin çalışma prensibine göre öncelikle eldeki veriler için doğrusal bir model olan ARIMA ile kalıntı değerleri bulunmuştur. Gerçek değerler, tahmin edilen değerlere Denklem 3.7 kullanılarak oranlanmış ve elde edilen değerler kalıntı olarak isimlendirilmiştir. Çarpma metodu ile elde edilen kalıntılar YSA'ya sunulmuş ve işlem sayesinde YSA, kalıntılar için tahmin değerleri sağlamıştır (Wang et al., 2013).

Wang modelinde, hem kalıntıları hem de melez modeli çarpma fonksiyonu ile kurmuştur. Tablo 4.1.'de yer alan listede Model 1c ve Model 1d kalıntı tahmininde toplama fonksiyonu kullanılan bu modele dayanmaktadır.

3.3. Fard ve Zadeh'in Melez Modeli

Fard ve Zadeh (2014) çalışmalarında ARIMA, YSA ve dalgacık dönüşümünü kullanarak kısa dönemli yük tahmini için model önerisinde bulunmuştur. ARIMA yöntemini kullanarak doğrusal bileşeni tahmin etmiştir. Oluşturduğu yöntem 3 ana adıma sahiptir. Birinci adım ARIMA modeli ile ilgilidir ve 4 aşamadan oluşmaktadır bu aşamalar aşağıdaki gibidir:

1. Aşama; modelin tanımlanmasıdır. Bunun için ACF ve PACF değerleri kullanılarak zaman serisinin durağan ve durağan olmayan davranışları araştırılmıştır. Serinin durağan olmaması durumunda seri 1 kez farkı alınarak durağan hale getirilmiştir.


2. Aşama; parametre tahmini yapılmasıdır. Model katsayıları en küçük hata kareleri, maksimum olabilirlik ve benzeri yaklaşımlar kullanılarak belirlenmiştir.

3. Aşama; modelin geçerliliğine bakılması ve eğer model anlamsız ise atılması ve adımların tekrar edilmesidir.

4. Aşama; ARIMA zaman serisinin doğrusal kısmını tahmin etmek için kullanılmıştır.

İkinci önemli adım; ARIMA'dan gelen kalıntıların dalgacık dönüşümü ile ayrıştırılmasıdır. Kalıntıların ayrıştırılması kalıntılara tek bir sinyal gelene kadar devam etmektedir. Üçüncü adımda ise her bir eleman için bir YSA geliştirilmiştir.

ARIMA modelinin kalıntıları dalgacık ayrışımı ve YSA ile tahmin edilmektedir. Sonuç olarak ARIMA ve YSA sonuçları toplanarak tahmin yapılmıştır.



Şekil 3.7: Fard ve Zadeh'in Melez Modeli (Fard and Zadeh, 2014).

Fard ve Zadeh çalışmalarında hem kalıntı belirleme hem de model melezleme için toplama metodunu kullanmışlardır. Zhang'ın 2003'teki çalışmasından farklı olarak ARIMA'dan elde edilen kalıntıları önce dalgacık ayrışımı ile gruplaması ve sonra ayrılan herbir kalıntı için ayrı YSA kurmasıdır. YSA'lardan elde edilen değerler dalgacık birleştirilmesi(kurması) ile toparlanır ve değerler ARIMA'dan gelen doğrusal tahminle birleştirilir.

3. 4. Khashei ve Bijari'nin Melez Modelleri

Khashei ve Bijari (2010) yaptığı çalışmada, zaman serilerinin yapısının doğrusal ve doğrusal olmayan kısımlarının belirlenmesinin, zaman serisinin değerini tahmin etmek için önemli olduğunu söylemişlerdir. Tek başına ARIMA veya tek başına YSA'nın bu doğrusal ve doğrusal olmayan yapıyı açıklamasının mümkün olmadığını söyleyerek yeni bir melez önermiştir. Melez yöntem işlemleri açısından Zhang'ın melez modeline benzer ancak doğrusal olan kısım ARIMA ile işlendikten sonra elde edilen kalıntılar tek başına YSA ile işlenmemiş; hem gerçek değerler hem kalıntı değerleri geliştirilen çok katmanlı YSA'ya girdi değerleri olarak verilmiştir. Çalışma sonucunda elde edilen değerlerin Zhang'ın 2003'teki modelinden daha iyi olduğunu iddia etmiştir.

Box ve Jenkins (1976) metodolojisine dayanan modelde, bir zaman serisi doğrusal olmayan fonksiyon olarak kabul edilmektedir. Aşağıdaki denklem doğrusal olmayan bir YSA yapısını göstermek üzere;

$$y_t = f[(z_{t-1}, z_{t-2}, \dots, z_{t-m}), (e_{t-1}, e_{t-2}, \dots, e_{t-n})] \quad (3.10)$$


$$z_t = (1 - B)^d(y_t - \mu) \quad (3.11)$$

Denklemlerde e_t ; t zamanındaki kalıntıyı gösterirken m ve n sayıları tamsayıdır. Böylece ilk olarak ARIMA modeli kullanılarak kalıntılar üretilir. İkinci aşamada, kalıntılar ve orijinal verilerde bulunan doğrusal olmayan ve doğrusal ilişkileri modellemek için bir sinir ağı kullanılır. Veriler sadece doğrusal olmayan yapıdan oluşuyorsa, kalıntılar yalnızca doğrusal olmayan ilişkiyi içerecektir. Çünkü ARIMA doğrusal bir modeldir ve doğrusal olmayan ilişkiyi modelleyemez (Khashei and Bijari, 2010).

$$z_t = w_0 + \sum_{j=1}^Q w_j \cdot g(w_{0,j} + \sum_{i=1}^p w_{i,j} \cdot z_{t-i} + \sum_{i=p+1}^{p+q} w_{i,j} \cdot e_{t+p-i}) + e_t \quad (3.12)$$

Denklem (3.12)'de bulunan $w_{i,j}$ ($i = 0, 1, 2, \dots, p + q, j = 1, 2, \dots, Q$) ve w_j ($j = 0, 1, 2, \dots, Q$) bağlantı ağırlıklarını göstermektedir. p, q, Q son sinir ağına tasarım sürecinde belirlenen tamsayılardır.

Khashei ve Bijari 2010 yılındaki çalışmalarından 1 sene sonra bir melez yöntem daha ortaya atmıştır. Bu yöntemde de zaman serisinin sahip olduğu özellikleri bir önceki yöntemdeki gibi olduğunu ve bunların ayrıştırılması gerektiğini savunmuştur. Bu ayrımı yapmak için ARIMA-YSA melez modeli önermiştir. Bir önceki çalışmalarından farklı olarak YSA girdileri gerçek gözlem değerleri, ARIMA'nın tahmini değerleri ve kalıntı değerlerinden oluşmaktadır. Elde edilen tahmin değeri üzerinde herhangi bir işlem yapmadan tahmin değerlerini verir (Khashei and Bijari, 2011).



Şekil 3.8: Khashei ve Bijari'nin Melez Modeli (Babu and Sure, 2016)..

Şekil 3.8'de sunulduğu gibi Khashei ve Bijari'nin melez modellerinde sonuçları toplama ya da çarpmaya gerek yoktur. Model son halinde tahmin değerlerini verecektir. Aynı zamanda model ilk 3 melez modelden farklı olarak iki ayrı modelden elde edilen değerlerin toplama veya çarpımına değil, bir modelden elde edilen bir değer başka bir modele veri olarak eklenmesi ve bu şekilde bir melezlemenin yapılmasıdır.


Tablo 4.1'deki Model 6a, Model 6b, Model 6c ve Model 6d Khashei ve Bijari'nin melez modeline göre kurulmuştur. Aynı zamanda kalıntı verilerinin belirlenmesinde hem toplama hem çarpma yöntemi kullanılmıştır.

3. 5. Khashei, Bijari ve Ardali'nin Melez Modeli

Khashei, Bijari ve Ardali (2012) yaptıkları çalışmada Khashi ve Bijari'nin 2010 ve 2011'deki melez modellerinin varsayımlarına bağlı kalarak bir melez model daha geliştirmişlerdir. Bu modelde diğer modellerden farklı olarak ARIMA modelinden elde edilen kalıntıları sınıflandırmışlar ve olasılıksal sinir ağları kullanarak daha etkin bir melez model elde etmeye çalışmışlardır. Bu çalışmada istenilen hata düzeyine göre ARIMA modelinden elde edilmiş olan kalıntılar öncelikle sınıflandırılır bunun için;

$$y_t = Fit_{ARIMA}(t) + e_t = \hat{y}_t + e_t \quad (3.13)$$

işlemi yapılır ve kalıntılar bulunur. Elde edilen kalıntılar sınıflandırılır ve kalıntılara $\{-1, 0, 1\}$ değerleri atanır. Olasılıksal bir ağ kullanılarak bu değerler eğitilir. Elde edilmiş olan değerler hedeflenen değerlerdir ve ARIMA ile elde edilmiş olan tahmin değerleri yardımıyla adım aralığı hesaplanır. Tahmin değerlerine t zamanı hedef değeri ile adım aralığı çarpımı eklenir ve melez modelin sonucu bulunur.



Şekil 3.9. Khashei, Bijari ve Ardali'nin Melez Modeli (Khashei et al., 2012).

Zhang (2003), Wang vd. (2013), Khashei ve Bijari (2010), (2011); Khashei Bijari ve Ardali (2012) gibi çalışmalarda zaman serilerinin doğrusal ve doğrusal olmayan bileşenlerden oluştuğu iddia edilmiştir. Yapılan çalışmaların tamamında araştırmacılar ARIMA ile elde edilmiş olan sonuçların zaman serisinin doğrusal olmayan kısmını gösterdiğini söylemişler ve kalıntıların YSA ile farklı şekillerde eğitime yönelmişlerdir.

3. 6. Babu ve Reddy'nin Melez Modeli

Babu ve Reddy (2014) yaptıkları çalışmada daha önce zaman serileri ile ilgili yapılmış olan çalışmaların paralelinde hareket etmiş ve yine ARIMA ve YSA melez modeli ortaya atmışlardır. Zaman serisindeki doğrusal ve doğrusal olmayan yapıyı öncelikle ayırtmışlardır. Bu ayırışma Denklem (3.14)'te gösterilmiştir.

$$y_t = l_t + h_t \quad (3.14)$$


Diğer çalışmalarda olduğu gibi önce ARIMA ile modelleyip kalan kalıntılara doğrusal olmayan kısım işlemi yapmamışlardır. Serinin dağılımını incelemiş düşük oynaklığa sahip olan bileşenin doğrusal olduğunu ve ARIMA ile modelleneceğini, yüksek oynaklığa sahip bileşenin ise doğrusal olmadığını ve YSA ile modellenmesi gerektiğini söylemiş ve uygulamışlardır.

$$\hat{l}_t = f(l_{t-1}, l_{t-2}, \dots, l_{t-p}, n_t, n_{t-1}, \dots, n_{t-q}) \quad (3.15)$$

$$\hat{h}_t = g(h_{t-1}, h_{t-2}, \dots, h_{t-N}) + e_t \quad (3.16)$$

Sonuçta elde ettikleri değerleri Denklem (3.17)'de gösterildiği gibi toplayarak tahminde bulunmuşlardır. Modelin yapısı Şekil 3.10'da verilmiştir.

$$\hat{y}_t = \hat{l}_t + \hat{h}_t \quad (3.17)$$



Şekil 3.10: Babu ve Reddy Melez Modeli (Babu and Sure, 2016).

3. 7. Babu ve Sure Melez Modeli

Bu çalışmada, yakın zamanda geliştirilen hareketli ortalama filtre tabanlı melez ARIMA-YSA modelinin kavramlarını, bölme-ekleme basamağını içeren bir işleme tekniği ile birleştiren melez ARIMA-YSA modeli önerilmiştir. Önerilen bu melez ARIMA-YSA modelinin geliştirilmiş tahmini doğruluğu bir simülasyon deneyi kullanılarak incelenmiştir. Ayrıca, güneş lekeleri ve elektrik fiyat gibi farklı deneysel zaman serilerinde, önerilen melez model uygulanmış ve önerilen modelin diğerlerinden daha iyi performans gösterdiği ve dolayısıyla umut verici olduğu ortaya çıkarılmıştır. Bu modelin aşamaları aşağıdaki gibidir:

1. Aşama: Veri basıklık katsayısı 3'ün altında ve üstünde olanlar şeklinde ayrılmıştır. Bunlardan basıklık katsayısı 3'e eşit olanlar düşük oynaklığa sahip seri olarak adlandırılmış ve S2 grubuna alınmış; basıklık katsayısı 3'ün üzerinde olanlar yüksek oynaklık olarak adlandırılmış ve S1 grubuna alınmıştır.

2. Aşama: S2 grubu ARIMA ile tahminlenecek bir yapıda olduğundan ARIMA ile tahminlenmiştir.

3. Aşama: S1 grubu verileri uygun sayıda parçaya ayrılır ve her biri için uygun YSA modeli uygulanır.

4. Aşama: En iyi sonuçlar veren YSA yapısı yüksek oynaklığa sahip S1'in tahmininde kullanılır.

5. Aşama: 2. ve 4. aşamaların sonuçları toplanarak zaman serisinin tamamı için tahmin modeli oluşturulur.

4. TAHMİN UYGULAMALARI

Çalışmanın bu bölümünde önce kurulacak modeller hakkında kısa bilgiler verilecektir. Anlatılan bazı melezleme yöntemleri veri setine uygulanmış ve elde edilen sonuçlar yorumlanmıştır.

4. 1. YSA için Gizli Nöron Sayısının Belirlenmesi

Bir YSA ile eğitime başlanırken belirlenmesi gereken en önemli değerlerin biri YSA katmanında kaç adet gizli nöron olacağıdır. Gizli nöron sayısının belirlenmesi için kesin kurallar yoktur. Genellikle belirli sayılardan başlanarak aşamalı artırma ile uygun sayı belirlenir. Önemli bir durum da çok gizli nöron daha iyi sonuç verir diye bir kesinlik yoktur. Olması gerekenden az belirlenen nöron sayısı ağın kötü sonuçlar vermesine neden olabileceği gibi, uygun olandan daha fazla gizli nöron ağın ezberlemesine ve sadece kendisine gösterilen veride iyi sonuçlar vermesine neden olabilir (Yıldız, 2009).

“n” girdi nöronu sayısını “m” çıktı nöronu sayısını göstermek üzere literatür tarafından desteklenen birkaç gizli nöron belirleme denklemi vardır. Bunlardan biri Tang ve Fishwick tarafından verilmiştir. Çalışmalarında önerdikleri gizli nöron sayısı aşağıdaki gibidir (Tang and Fishwick, 1993):

$$n = \text{Girdi nöronu sayısı} = \text{Gizli nöron sayısı} \quad (4.1)$$

Aynı konu üzerinde çalışan Wold ise gizli nöron sayısını aşağıdaki gibi belirlemiştir (Wold;1991).

$$n = \text{Girdi nöronu sayısı} \rightarrow 2n = \text{Gizli nöron sayısı} \quad (4.2)$$

Çıktı nöronu sayısını da işleme alan gizli nöron belirleme çalışmaları olmuştur. Bunlardan biri Masters’in çalışmasında aşağıdaki gibidir (Masters, 1993):

$$n = \text{Girdi nöronu sayısı} \text{ ve } m = \text{Çıktı nöron sayısı} \rightarrow \sqrt{n * m} = \text{Gizli nöron sayısı} \quad (4.3)$$

Tez çalışmasında gizli nöron sayısı belirleme işlemine bu hesaplamalarla başlanmıştır. Kademeli değişiklikler yaparak en iyi gizli nöron sayısı belirlenmiştir.

4. 2. Modeller için Performans (Hata) Ölçüleri

Bir YSA'nın hatasının kabul edilebilir sınırlara çekilmesi ağı ürettiği bilginin doğruluğu açısından çok önemlidir. Ancak bazen ağırlıklar değiştirilse bile ağı hata değeri azaltılamayabilir. Bunun başlıca nedeni örnek seçimindeki hata, ağı genel yapısındaki yanlışlıklar, örneğin yapısının iyi anlaşılabilmesi vb. olabilir. Aynı zamanda diğer modeller için de gerçek değerler ile sistemden elde edilen çıktı değerleri arasındaki hatanın minimum olması çok önemlidir. Kurulan bir modelde elde edilen hatanın belirlenmesinde kullanılacak doğruluk ölçüleri (Al-Hamadi and Soliman, 2004; Huang & Shih, 2003):

Y_t = Gerçek değer

F_t = Modelden elde edilen çıktı değeri olmak üzere;

- Mutlak Ortalama Sapma (Mean Absolute Deviation-MAD)

$$MAD = \frac{1}{n} \sum_{t=1}^n |Y_t - F_t| \quad (4.4)$$

- Hata Kareler Toplamı (Sum of Squared Error-SSE)

$$SSE = \sum_{t=1}^n (Y_t - F_t)^2 \quad (4.5)$$

- Ortalama Hata Kareleri (Mean Square Error-MSE)

$$MSE = \frac{1}{n} \sum_{t=1}^n (Y_t - F_t)^2 \quad (4.6)$$

- Ortalama Hata Kareleri Karakökü (Root Mean Square Error-RMSE)

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - F_t)^2} \quad (4.7)$$

Bu ölçülerin dışında geliştirilmiş başka ölçülerde vardır. Bunlar hata yüzdeleri olarak isimlendirilmiş ve aşağıdaki gibi hesaplanmışlardır (Makridakis, 1982; Al-Hamadi and Soliman, 2004; Huang and Shih, 2003)).

- Yüzde Hata (Percent Error-PE);

$$PE = \frac{Y_t - F_t}{Y_t} * 100 \quad (4.8)$$

- Ortalama Mutlak Yüzde Hata (Mean Absolute Percent Error-MAPE);

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - F_t}{Y_t} \right| * 100 \quad (4.9)$$

Lewis (1982) yılında yazdığı eserinde MAPE değerinin diğer ölçümlerden daha etkin sonuçlar verdiğini ve belirli değerler arasındaki MAPE değerlerinin

değişimi açıklamakta yeterli olduğunu söylemiştir. Lewis'e göre MAPE değeri %10 dan küçük ise model yüksek doğruluğa sahip (çok iyi tahmin edici), değer %10 ile %20 aralığında ise orta derecede doğruluğa sahip (iyi tahmin edici), %20 ile %50 aralığındakilere düşük derecede doğruluğa sahip ancak kabul edilebilir, %50'nin üzerinde ise tahmin değeri yok (kötü tahmin edici) olarak sıralanabilir.

4. 3. Veri Seti ve Kullanılacak Modeller

Çalışmada hem ulusal hem uluslararası borsa endeks değerlerinde karşılaştırma yapılmıştır. Bu amaçla kullanılabilecek endeksler belirlenmiş, NASDAQ ve BIST100 endeks değerleri seçilmiştir. BIST100 değerleri iç ve dış çevre şartlarından çok etkilenen bir endeks olduğundan NASDAQ için yapılan analiz sonuçları ile BIST100 endeks analiz sonuçları bu bağlamda karşılaştırılmıştır. Çevre şartlarından etkilenmenin BIST100'e göre daha az olduğu NASDAQ endeks değeri ile BIST100 endeks değerlerini hangi modelin daha iyi açıkladığı karşılaştırmalar yapılarak sunulmuştur.

Veri seti olarak Ocak 2012 tarihinden itibaren Temmuz 2017 tarihine kadar mevcut olan günlerdeki gözlemler alınmıştır. Model geliştirilirken eldeki bağımsız değişkenler t zamanını göstereceği için veri setinin bağımsız değişkenler kısmına 1 günlük öteleme yapılmış ve diğer değişkenler bulunmuştur. Uygulama kısmında amaç, ARIMA ve YSA melezlemesi yaparken hangi melez modelin daha iyi sonuçlar verdiğinin belirlenmesidir. Yapılacak işlemler ve herbir modelde kullanılacak değişkenler Tablo 4.1'de gösterilmiştir. Uygulama sonucunda hangi modelin hangi değişkenler ile nasıl sonuç verdiği gösterilmiştir.

Tablo 4.1'de açıkça görülebileceği gibi çalışmada her iki endeks değerinin belirlenmesinde 6 farklı model kullanılmıştır. Bu 6 farklı modelin en önemli ayrımlarından biri ARIMA ile hesaplanan kalıntıların toplama/çarpma yolu ile elde edilmesidir. Toplama ve çarpma yöntemi ile belirlenen kalıntılar işlemlere ayrı ayrı dâhil edilmiştir. Tablodaki diğer bir önemli ayırım 3 farklı melez modelin kurulumunda ortaya çıkmaktadır. 1. aşamada ARIMA kullanılarak NASDAQ ve BIST100 endeks değerleri için kalıntı miktarları belirlenmiştir. Kalıntıların belirlenmesinde literatürde yer alan toplama ve çarpma metodları kullanılmıştır. Bu kalıntıların hesaplanması Denklem (3.2) ve Denklem (3.7) formülleri kullanılarak yapılmıştır.

Tablo 4.1: Analiz için Kurulacak Modeller.

	Zaman Serisi Analizi			
	NASDAQ		BIST100	
	TOPLAMA	ÇARPMA	TOPLAMA	ÇARPMA
Model 1	1a) ARIMA Değişken: NASDAQ e_t Hesabı: Toplama	1b) ARIMA Değişken: NASDAQ e_t Hesabı: Çarpma	1c) ARIMA Değişken: BIST100 e_t Hesabı: Toplama	1d) ARIMA Değişken: BIST100 e_t Hesabı: Çarpma
Model 2	2a) YSA Çıktı= NASDAQ Girdi= NASDAQ t-1 NASDAQ t-2 Altın t-1 Altın t-2 EURO/USD t-1 EURO/USD t-2 FRANG/USD t-1 FRANG/USD t-1 Petrol t-1 Petrol t-2		2b) YSA Çıktı= BIST100 Girdi= BIST t-1 BIST t-2 Altın t-1 Altın t-2 EURO/TL t-1 EURO/TL t-2 USD/TL t-1 USD/TL t-1 Petrol t-1 Petrol t-2	
Model 3	3a) YSA Çıktı= e_t Girdi= Altın t-1 Altın t-2 EURO/USD t-1 EURO/USD t-2 FRANG/USD t-1 FRANG/USD t-1 Petrol t-1 Petrol t-2	3b) YSA Çıktı= e_t Girdi= Altın t-1 Altın t-2 EURO/USD t-1 EURO/USD t-2 FRANG/USD t-1 FRANG/USD t-1 Petrol t-1 Petrol t-2	3c) YSA Çıktı= e_t Girdi= Altın t-1 Altın t-2 EURO/TL t-1 EURO/TL t-2 USD/TL t-1 USD/TL t-1 Petrol t-1 Petrol t-2	3d) YSA Çıktı= e_t Girdi= Altın t-1 Altın t-2 EURO/TL t-1 EURO/TL t-2 USD/TL t-1 USD/TL t-1 Petrol t-1 Petrol t-2
Model 4	4a) YSA Çıktı= e_t Girdi= e_{t-1} e_{t-2} e_{t-3} e_{t-4} e_{t-5} e_{t-6}	4b) YSA Çıktı= e_t Girdi= e_{t-1} e_{t-2} e_{t-3} e_{t-4} e_{t-5} e_{t-6}	4d) YSA Çıktı= e_t Girdi= e_{t-1} e_{t-2} e_{t-3} e_{t-4} e_{t-5} e_{t-6}	4d) YSA Çıktı= e_t Girdi= e_{t-1} e_{t-2} e_{t-3} e_{t-4} e_{t-5} e_{t-6}
Model 5	5a) YSA Çıktı= e_t Girdi= Altın t-1 Altın t-2 EURO/USD t-1 EURO/USD t-2 FRANG/USD t-1 FRANG/USD t-1 Petrol t-1 Petrol t-2 e_{t-1} e_{t-2}	5b) YSA Çıktı= e_t Girdi= Altın t-1 Altın t-2 EURO/USD t-1 EURO/USD t-2 FRANG/USD t-1 FRANG/USD t-1 Petrol t-1 Petrol t-2 e_{t-1} e_{t-2}	5c) YSA Çıktı= e_t Girdi= Altın t-1 Altın t-2 EURO/TL t-1 EURO/TL t-2 USD/TL t-1 USD/TL t-2 Petrol t-1 Petrol t-2 e_{t-1} e_{t-2}	5d) YSA Çıktı= e_t Girdi= Altın t-1 Altın t-2 EURO/TL t-1 EURO/TL t-2 USD/TL t-1 USD/TL t-2 Petrol t-1 Petrol t-2 e_{t-1} e_{t-2}
Model 6	6a) YSA Çıktı= NASDAQ Girdi= NASDAQ t-1 NASDAQ t-2 Altın t-1 Altın t-2 EURO/USD T-1 EURO/USD T-2 FRANG/USD T-1 FRANG/USD T-1 Petrol t-1 Petrol t-2 e_{t-1} e_{t-2}	6b) YSA Çıktı= NASDAQ Girdi= NASDAQ t-1 NASDAQ t-2 Altın t-1 Altın t-2 EURO/USD T-1 EURO/USD T-2 FRANG/USD T-1 FRANG/USD T-1 Petrol t-1 Petrol t-2 e_{t-1} e_{t-2}	6c) YSA Çıktı= BIST100 Girdi= BIST100 T-1 BIST100 t-2 Altın t-1 Altın t-2 EURO/TL t-1 EURO/TL t-2 USD/TL t-1 USD/TL t-1 Petrol t-1 Petrol t-2 e_{t-1} e_{t-2}	6d) YSA Çıktı= BIST100 Girdi= BIST100 T-1 BIST100 t-2 Altın t-1 Altın t-2 EURO/TL t-1 EURO/TL t-2 USD/TL t-1 USD/TL t-1 Petrol t-1 Petrol t-2 e_{t-1} e_{t-2}

Kalıntının belirlenme yöntemine göre farklı YSA'lar kurulmuştur. 2. aşamada YSA kullanılarak tabloda sıralanmış olan girdi değişkenlerine göre NASDAQ ve

BIST100 endeksi tahmin edilmeye çalışılmıştır. 2. aşamada kurulan YSA temel göstergeler ile elde edilen bir YSA'yı göstermektedir. 3., 4. ve 5. model YSA'ların temelinde ARIMA kalıntıları; otoregresif değerlerle, temel finansal göstergelerle ve otoregresif+temel finansal göstergeler ile ayrı ayrı tahminlenmiştir. Literatürdeki modellere ek olarak farklı değişkenler kullanılması durumunda sonuçların nasıl olacağı belirlenmiştir. Bu amaçla farklı kalıntı hesaplama değişkenleri kullanılarak sınanmıştır. 6. model YSA'lar hem teknik göstergeler hem kalıntılar için kurulmuştur. Sonuçta tüm bu modellerle elde edilen performans değerleri karşılaştırılmıştır. Kullanılan YSA kodları Matlab Function kullanılarak yazılmış ve eğitim aşaması ile en iyi melez model bulunmuştur.

1. ve 2. modeller için bazı performans ölçüm değerleri hesaplandıktan sonra kalıntıların tahminlerinin yapıldığı 3., 4. ve 5. modeller kurulmuştur. 2. Model, ARIMA yönteminden tamamen bağımsız temel YSA modelidir. 6. modelde ARIMA'dan elde edilen değerler de YSA'ya girdi olarak verilmiş ve bir melezleme daha yapılmıştır. ARIMA'dan elde edilen kalıntı değerler ile YSA kurulan NASDAQ borsa endeks veri tahminlerinin kullanılması ile melez modeller oluşturulmuştur. Zhang (2003), Wang et al. (2013) ve Khashei ve Bijari (2011) melez modelleri ile ARIMA ve temel göstergelerle elde edilen YSA performans ölçüleri karşılaştırılacaktır.

4. 4. NASDAQ Borsası İçin Tahmin Uygulamaları

Bu kısımda Tablo 4.1'de verilen modeller için uygulamalar yapılacaktır. Tablonun NASDAQ endeksi için ayrılmış ilk iki sütununda kalıntıların hesabında toplama ve çarpma metodları için ayrı işlemler mevcuttur. İşlemler 6 farklı model halinde sunulmuştur.

NASDAQ Borsası değeri için kurulan modeller aşağıdaki gibi sıralanabilir:

1. Model (Model 1a ve 1b): ARIMA,
2. Model (Model 2a): Temel göstergeler ile NASDAQ borsa değerinin tahmini için YSA,
3. Model (Model 3a ve 3b): Temel göstergeler ile kalıntı tahmini için YSA,
4. Model (Model 4a ve 4b): Kalıntı değerleri ile kalıntı tahmini için YSA,
5. Model (Model 5a ve 5b): Temel göstergeler ve kalıntı değerleri ile kalıntı tahmini için YSA,

6. Model (Model 6a ve 6b): Temel göstergeler ve kalıntı değerleri ile NASDAQ borsa değerinin tahmini için YSA.

4.4.1. ARIMA Uygulamaları

NASDAQ borsası verileri kullanılarak günlük kapanış verilerine göre uygun ARIMA modeli kurulmuştur. Sonuçta ARIMA(3,1,3) NASDAQ borsa değeri için uygun sonuç vermiştir. ARIMA(3,1,3) için hesaplanan F istatistiği (Prob(F-Statistic))=0,0273 olarak bulunmuştur. Bu değerin 0,05'ten küçük olması modelin bir bütün olarak anlamlı olduğunu göstermektedir. Elde edilen model;

$$\Delta N = N_t - N_{t-1}$$

(4.1)

$\hat{N}=2,493+0,278N_{t-1}-0,308N_{t-2}+0,902N_{t-3}-0,272U_{t-1}+0,280U_{t-2}-0,933U_{t-3}$ şeklinde gösterilebilir. Modelde (N_t) mevcut gündeki NASDAQ endeks değerlerini; (N_{t-1}) bir gün sonraki NASDAQ endeks değerlerini göstermektedir. Denklem (4.1) ile 1 günlük fark serisi (N) oluşturulmuştur. $\hat{N}$ kurulan ARIMA(3,1,3) modelini göstermektedir.

Elde edilen tahmin değerleri gerçek değerlerle karşılaştırılmış ve Denklem (3.2) ve Denklem (3.7) kullanılarak hem toplama yöntemi hem de çarpma yöntemi ile kalıntılar belirlenmiştir. Bu kalıntı değerleri diğer aşamalarda YSA için farklı modellerde girdi ve çıktı olarak kullanılacaktır. Tahmin değerleri ise bazı melez modellerimizin doğrusal kısmını oluşturacaktır. ARIMA tahminine göre MSE değeri toplam fonksiyonu ile hesaplanınca 62883,8; çarpım fonksiyonu ile hesaplanınca ise 59843,6 olarak bulunmuştur. Aynı zamanda bu seri için RMSE ve MAPE değeri hesaplanmış ve elde edilen değerler işlem sonuçlarının karşılaştırıldığı Tablo 4.10'da verilmiştir.


4.4.2. Yapay Sinir Ağı Uygulamaları

YSA'da çok sayıda farklı öğrenme ve aktivasyon fonksiyonları bulunmaktadır. Bu fonksiyonlar arasında en iyi olarak nitelendirilebilecek bir yöntem yoktur. Çünkü bu fonksiyonlar farklı veri türlerinde farklı sonuçlar verirler. Hangi fonksiyonun kullanılacağı deneme yanılma yolu ile belirlenebilir. Ağ farklı gizli katman sayıları, farklı öğrenme oranları, farklı öğrenme ve aktivasyon fonksiyonları ile sürekli

eğitilmiş ve içlerinden tahmin için en iyi olan seçilmiştir. Eğitim sonunda MSE, MAPE ve RMSE değerleri ile ağın performansına bakılmıştır. Levenberg-Marquardt en iyi öğrenme fonksiyonu olarak bulunmuş, aktivasyon fonksiyonu olarak ise hiperbolik tanjant (tansig) kullanılmıştır. Uygulama verilerinin 0.70'i eğitim, 0.30'u test olarak alınmıştır. Eğitim yapılırken gizli nöron sayılarının belirlenmesinde öncelikle literatürde yer alan Denklem (4.1), (4.2) ve (4.3)'te verilen gizli nöron sayısı belirleme formülleri kullanılmıştır. Ağın aşırı öğrenip (overfitting) ezberlememesi için veri seti çok geniş alınmış, döngü sayısı her bir iterasyonda sabit tutulmuştur. Bu döngü sayıları 1000 ile sınırlandırılmış ve her durma işleminde ağın hatası ölçülmüştür. Ağ kabul edilebilir döngü sayısına ulaştığında durmuş ve sonuçları hemen yazılmıştır. Kurulan bir ağ 1000 döngü sınırında eğitim oranı, gizli nöron sayısı, öğrenme algortiması değerleri sabit tutularak en az 100 deneme yapılarak sınanmıştır. Elde edilen değerler kaydedildikten sonra diğer değerler yine sabitken gizli nöron sayıları değiştirilerek işlemlere devam edilmiştir. YSA çözümleri için MATLAB 2010a kullanılmış ve kodlamalar bu program üzerinde yapılmıştır.

4.4. 2. 1. Temel Göstergeler ile NASDAQ Değerinin Tahmini İçin YSA


İlk olarak kurulacak ağ için NASDAQ endeks değerleri YSA'nın çıktı değeri olacaktır. Girdi değerleri ise NASDAQ borsası 1 ve 2 gün gecikmeli kapanış değeri, günlük altın değerlerinin 1 ve 2 gün gecikmeli değerleri, günlük Euro/USD değerinin 1 ve 2 gün gecikmeli değerleri, günlük İsviçre Frangı/USD için 1 ve 2 gün gecikmeli değerleri ve petrol fiyatları için 1 ve 2 gün gecikmeli değerleri kullanılmıştır.. Böylece 1 bağımlı 10 bağımsız değişkenli bir YSA tasarlanmıştır. Eğitim için en iyi YSA sonucu 10 gizli nöron ve %70 eğitim oranında Şekil 4.1'deki gibi bulunmuştur.



Şekil 4.1: Model 2a için YSA Test Seti Sonuçları.

4.4. 2. 2. Temel Göstergeler ile Kalıntı Tahmini İçin YSA

İlk olarak kurulacak ağ için ARIMA'dan elde edilen toplam fonksiyonu ile hesaplanan kalıntı değerleri YSA'nın çıktı değeri olacaktır. İkinci kurulan ağda çarpma fonksiyonu ile hesaplanan kalıntı değerleri YSA'nın çıktı değeri olarak kullanılacaktır.




Şekil 4.2: Model 3a-3b için YSA Test Seti Sonuçları.

Kalıntıların tahmin edilmesinde sadece temel göstergeler kullanılmıştır. Böylece 1 bağımlı 8 bağımsız değişkenli bir YSA tasarlanmıştır. En iyi YSA sonuçları 8 gizli nöronunda toplam fonksiyonu ve çarpma fonksiyonu için Şekil 4.2'deki gibi bulunmuştur.

4.4. 2. 3. Kalıntı Değerleri ile Kalıntı Tahmini İçin YSA


YSA'nın çıktı değerleri toplama ve çarpma fonksiyonu ile elde edilen kalıntı değerleri, girdi değerleri ise kalıntı değerlerinin 1, 2, 3, 4, 5 ve 6 günlük gecikmeli değerleridir. Böylece 1 bağımlı 6 bağımsız değişkenli bir YSA tasarlanmıştır. Ağın eğitimi ağın istenen hata oranının altına düşmesi ile durdurulmuş ve elde edilen ağın test verileri için ürettiği tahminlere bakılmıştır. En iyi YSA sonucu %70 eğitim oranı ve 6 gizli nöronunda toplama ve çarpım fonksiyonu için Şekil 4.3'teki gibi bulunmuştur.



Şekil 4.3: Model 4a-4b için YSA Test Seti Sonuçları.

4.4. 2. 4. Temel Göstergeler ve Kalıntı Değerleri ile Kalıntı Tahmini için YSA


ARIMA'dan elde edilen kalıntılar YSA'nın çıktı değeri olacakken; girdi değerleri 1 ve 2 gün gecikmeli toplam fonksiyonlu kalıntı değerleri, günlük altın değerlerinin 1 ve 2 gün gecikmeli değerleri, günlük Euro/USD değerinin 1 ve 2 gün gecikmeli değerleri, günlük İsviçre Frangı/USD için 1 ve 2 gün gecikmeli değerleri ve petrol fiyatları için 1 ve 2 gün gecikmeli değerleri kullanılmıştır. Ağ istenen hata oranının altında sonuç üretmeye başladığında eğitim tamamlanmış ve test seti için sonuçlar alınmıştır. Böylece 1 bağımlı 10 bağımsız değişkenli bir YSA tasarlanmıştır. En iyi YSA sonucu 11 gizli nöron ve %70 eğitim oranında toplama ve çarpma fonksiyonu için Şekil 4.4'deki gibi bulunmuştur.



Şekil 4.4: Model 5a-5b için YSA Test Seti Sonuçları.

4.4. 2. 5. Temel Göstergeler ve Kalıntı Değerleri ile NASDAQ Değerinin Tahmini için YSA

Kurulacak ağ için NASDAQ endeks değerleri YSA'nın çıktı değeri olacaktır. Girdi değerleri ise 1 ve 2 gün gecikmeli NASDAQ borsası kapanış değerleri, günlük altın fiyatlarının 1 ve 2 gün gecikmeli değerleri, günlük Euro/USD değerinin 1 ve 2 gün gecikmeli değerleri, günlük İsviçre Frangı/USD için 1 ve 2 gün gecikmeli değerleri ve petrol fiyatları için 1 ve 2 gün gecikmeli değerleri ile ARIMA işlemi sonucu elde edilen kalıntı değerlerin 1 ve 2 gün gecikmeli değerleri kullanılmıştır. Kalıntı değerleri toplama ve çarpma fonksiyonu ile ayrı ayrı belirlenen kalıntı değerleridir. Böylece 1 bağımlı 12 bağımsız değişkenli bir YSA tasarlanmıştır. Böylece ARIMA ile YSA sonuçları bir eğitim için birleştirilmiştir. En iyi YSA sonucu 12 gizli nöronunda toplama ve çarpma fonksiyonu için Şekil 4.5'teki gibi bulunmuştur.



Şekil 4.5: Model 6a-6b için YSA Test Seti Sonuçları.

1, 2 ve 6. modellerde NASDAQ borsa endeksi tahmin edilmeye 3, 4 ve 5. modellerde endeks için hesaplanan kalıntı terimleri tahmin edilmeye çalışılmıştır. Melezleme modellerinde modelin doğrusal olmayan kısmını 3, 4 ve 5. modellerden elde edilen kalıntı tahmin değerleri oluşturacakken; modelin doğrusal olan kısmını 1. model olan ARIMA'dan elde edilen tahmin sonuçları oluşturacaktır.

4.4.3. NASDAQ Endeksi ARIMA-YSA Melezleme Sonuçları

Modeller tamamlandıktan ve değerler elde edildikten sonra Denklem (3.5) ve Denklem (3.9) kullanılarak ARIMA-YSA tahminleri melezlemesi yapılmıştır. Bu melezleme sonuçları aşağıdaki gibi elde edilmiştir.

3. modelden elde edilen kalıntı tahmin değerleri, ARIMA ile tahmin edilen değerler ile Zhang (2003) ve Wang et al. (2013) melez modellerine göre melezleme yapıldığında elde edilen modellerde seçilen performans değerleri Tablo 4.2'deki gibi bulunmuştur.

Tablo 4.2: ARIMA Tahminleri ile Model 3a-3b YSA Melezleme Sonuçları.

	1. Melez Model	MSE Değerleri	MAPE	RMSE
e_t Toplama	Zhang (2003)	43.954,1	13,11	209,65
e_t Çarpım	Wang et al. (2013)	44.212,3	12,82	210,27

Tablo 4.2 incelendiğinde kalıntıların toplama ve çarpım ile hesaplanması durumunda, melez modelde sadece doğrusal ve doğrusal olmayan tahminlerin toplamını kullanan Zhang (2003) modeli; melez modelde doğrusal ve doğrusal olmayan tahminlerin çarpımını kullanan Wang et al. (2013) modelinden daha az hatalı sonuç vermiştir.

4. modelden elde edilen kalıntı tahmin değerleri ARIMA ile tahmin edilen değerler ile Zhang (2003) ve Wang et al. (2013) melez modellerine göre melezleme yapıldığında elde edilen modellerde seçilen performans değerleri Tablo 4.3'teki gibi bulunmuştur.

Tablo 4.3: ARIMA Tahminleri ile Model 4a-4b YSA Melezleme Sonuçları.

	2. Melez Model	MSE Değerleri	MAPE	RMSE
e_t Toplama	Zhang (2003)	45.128,4	21,41	212,43
e_t Çarpım	Wang et al. (2013)	45.237,2	22,03	212,69

Tablo 4.3 incelendiğinde Zhang (2003) modeli, Wang et al. (2013) modelinden daha az hatalı sonuç vermiştir. Sonuçlar birbirine oldukça yakın çıkmıştır.

5. modelden elde edilen kalıntı tahmin değerleri ARIMA ile tahmin edilen değerler ile Zhang (2003) ve Wang et al. (2013) melez modellerine göre melezleme yapıldığında elde edilen modellerde seçilen performans değerleri Tablo 4.4'deki gibi bulunmuştur.

Tablo 4.4: ARIMA Tahminleri ile Model 5a-5b YSA Melezleme Sonuçları.

	3. Melez Model	MSE Değerleri	MAPE	RMSE
e_t Toplama	Zhang (2003)	51.487,1	8,19	226,90
e_t Çarpım	Wang et al. (2013)	46.337,2	6,95	215,26

Tablo 4.4 incelendiğinde ise Zhang (2003) modelinin, Wang et al. (2013) modelinden daha kötü bir tahmin sonucu verdiği görülebilecektir.

6. modelde ARIMA'dan elde edilen kalıntı tahmin değerleri YSA'ya temel göstergeler ile birlikte girdi olarak verilmiş ve Khashei ve Bijari (2010) melezlemesine uygun bir melezleme işlemi yapılmıştır. Modelden elde edilen performans değerleri Tablo 4.5'teki gibi bulunmuştur.

Tablo 4.5: YSA'ya Girdi Olarak Verilen ARIMA Kalıntıları ile Yapılan Melezleme Sonuçları (Model 6a ve Model 6b)

	4. Melez Model	MSE Değerleri	MAPE	RMSE
e_t Toplama	Khashei ve Bijari (2010)	43.420,1	17,36	208,37
e_t Çarpım	Khashei ve Bijari (2010)	46.305,4	21,14	215,19

Tablo 4.5 ARIMA kalıntı tahminlerinin ve gerçek değerlerin, temel göstergeler ile kurulmuş YSA'ya eklenmesi ile elde edilen melez model sonucunu vermektedir. Khashei ve Bijari (2010) melez modelinin uygulandığı bu modelde, YSA'ya toplama fonksiyonu ile eklenen kalıntıların Zhang (2003) ve Wang et al. (2013) melez modellerinden ve sadece temel göstergelerin kullanıldığı Model 2a'dan daha iyi tahmin sonucu vermiştir. Kalıntının çarpma ile hesaplandığı durumda ise model; ARIMA, temel göstergelerle kurulan YSA ve ARIMA tahminleri ile Model 5a-5b YSA melezleme sonuçlarından daha iyi tahmin sonucu vermiştir.

Sonuç olarak modellerin birbirleri ile karşılaştırması yapıldığında temel göstergelerin kullanıldığı NASDAQ endeks tahmininin ARIMA yöntemi ile

melezlenmesi sonucunda hem toplama hem çarpma fonksiyonu için işlemler yapılmıştır. Hangi değişkenler kullanılarak kalıntılar hesaplanırsa hesaplanırsın melez modellerin saf modellere (ARIMA ve YSA) göre daha iyi tahmin sonucu verdiği açıkça görülecektir.

4. 5. BIST100 İçin Tahmin Uygulamaları

Çalışmanın bu kısımda yine Tablo 4.1’de verilen modeller için uygulamalar yapılacaktır. Tablonun BIST100 endeksi için ayrılmış son iki sütununda kalıntıların hesabında toplama ve çarpma metodları için ayrı işlemler mevcuttur. İşlemler 6 farklı model halinde sunulmuştur.

BIST100 endeks değeri için kurulan modeller aşağıdaki gibi sıralanabilir:

1. Model (Model 1c ve 1d): ARIMA,
2. Model (Model 2b): Temel göstergeler ile BIST100 borsa değerinin tahmini için YSA,
3. Model (Model 3c ve 3d): Temel göstergeler ile kalıntı tahmini için YSA,
4. Model (Model 4c ve 4d): Kalıntı değerleri ile kalıntı tahmini için YSA,
5. Model (Model 5c ve 5d): Temel göstergeler ve kalıntı değerleri ile kalıntı tahmini için YSA,
6. Model (Model 6c ve 6d): Temel göstergeler ve kalıntı değerleri ile BIST100 borsa değerinin tahmini için YSA.

4.5.1. Model 1c-Model 1d ARIMA Uygulamaları

BIST100 verileri kullanılarak günlük kapanış verilerine göre uygun ARIMA modeli kurulmuştur. Sonuçta ARMA(4,1,4) borsa değeri için uygun sonuç vermiştir. ARMA(4,1,4) için hesaplanan F istatistiği (Prob(F-Statistic))=0,014 olarak bulunmuştur. Bu değerin 0,05’ten küçük olması modelin bir bütün olarak anlamlı olduğunu göstermektedir. Elde edilen model;

$$\Delta B = B_t - B_{t-1} \quad (4.2)$$

$$\hat{B} = 34,97475 - 0,18663B_{t-1} + 0,547768B_{t-2} - 0,224818B_{t-3} - 0,947601B_{t-4} + 0,188113U_{t-1} - 0,554148U_{t-2} + 0,258364U_{t-3} + 0,946634U_{t-4}$$

şeklinde gösterilebilir. Modelde (B_t) mevcut gündeki BIST100 endeks değerlerini; (B_{t-1}) bir gün sonraki BIST100 endeks değerlerini göstermektedir. Denklem (4.2) ile

1 günlük fark serisi (B) oluşturulmuştur. $\hat{B}$ kurulan ARMA(4,1,4) modelini göstermektedir.


Elde edilen tahmin değerleri gerçek değerlerle karşılaştırılmış ve Denklem (3.2) ve Denklem (3.7) kullanılarak hem toplama yöntemi hem de çarpma yöntemi ile kalıntılar belirlenmiştir. Kalıntı değerleri diğer aşamalarda YSA için farklı modellerde girdi ve çıktı olarak kullanılacaktır. Tahmin değerleri ise bazı melez modellerimizin doğrusal kısmını oluşturacaktır. ARIMA tahminine göre MSE değeri toplam fonksiyonu ile hesaplanınca 84.320.640; çarpım fonksiyonu ile hesaplanınca ise 81.250.140 olarak bulunmuştur. Aynı zamanda bu seri için RMSE ve MAPE değeri hesaplanmış ve işlem sonuçlarının karşılaştırıldığı Tablo 4.10'da verilmiştir.

4.5.2. Yapay Sinir Ağı Uygulamaları

Ağ farklı gizli katman sayıları, farklı öğrenme oranları, farklı öğrenme ve aktivasyon fonksiyonları gibi yollarla sürekli eğitilmiş ve içlerinden tahmin için en iyi olan seçilmiştir. Levenberg-Marquardt en iyi öğrenme fonksiyonu olarak bulunmuş aktivasyon fonksiyonu olarak 'tansig' kullanılmıştır. Uygulama verilerinin 0.70'i eğitim, 0.30'u test olarak alınmıştır. BIST100 için NASDAQ borsasında ARIMA için kullanılan aynı tarih aralığı kullanılmıştır. Ağlar NASDAQ endeks tahmininde olduğu gibi önce belli bir hata payının altına düşene kadar eğitilmiş sonra test verileri ile işlemler gerçekleştirilmiştir. Eğitim sonunda MSE, MAPE ve RMSE değerleri ile ağın performansına bakılmıştır. Kodlar yine Matlab2010a kullanılarak yazılmıştır.

4.5. 2. 1. Temel Göstergeler ile BIST100 Değerinin Tahmini için YSA


İlk olarak kurulacak ağ için BIST100 endeks değerleri YSA'nın çıktı değeri olacaktır. Girdi değerleri ise 1 gün gecikmeli BIST100 borsası 1 ve 2 gün gecikmeli kapanış değeri, günlük altın değerlerinin 1 ve 2 gün gecikmeli değerleri, günlük Euro/TL değerinin 1 ve 2 gün gecikmeli değerleri, günlük USD/TL için 1 ve 2 gün gecikmeli değerleri ve petrol fiyatları için 1 ve 2 gün gecikmeli değerleri kullanılmıştır. Böylece 1 bağımlı 10 bağımsız değişkenli bir YSA tasarlanmıştır. Eğitim için en iyi YSA sonucu 10 gizli nöron ve %70 eğitim oranında Şekil 4.1'deki gibi bulunmuştur.



Şekil 4.6: Model 2b için YSA Test Seti Sonuçları.

4.5. 2. 2. Temel Göstergeler ile Kalıntı Tahmini için YSA


Kalıntının tahmin edilmesinde farklı değişkenler kullanarak yapılacak ilk hesaplama temel göstergelerin kullanılması şeklinde olmuştur. Tablo 4.1. de yer alan temel göstergeler kalıntı tahmininde kullanılmış ve elde edilen değerler ile melez model sonuçları iyileştirmeye çalışılmıştır. İlk olarak kurulacak ağ için ARIMA'dan elde edilen toplam fonksiyonu ile hesaplanan kalıntı değerleri YSA'nın çıktı değeri olacaktır. İkinci kurulan ağda ARIMA'dan elde edilen çarpma fonksiyonu ile hesaplanan kalıntı değerleri çıktı değeri olarak kullanılacaktır. Kalıntıların tahmin edilmesinde sadece temel göstergelere yer verilmiştir. Böylece 1 bağımlı 8 bağımsız değişkenli bir YSA tasarlanmıştır. En iyi YSA sonuçları 10 gizli nöronda toplam fonksiyonu ve çarpma fonksiyonu için Şekil 4.7'deki gibi bulunmuştur.



Şekil 4.7: Model 3c-3d için YSA Test Seti Sonuçları.

4.5. 2. 3. Kalıntı Değerleri ile Kalıntı Tahmini için YSA


Kalıntı değerleri ile kalıntının hesaplanması literatürde birçok çalışmada yer almaktadır. Melez modellerimizin temelinde de bu şekilde bir kalıntı hesabı vardır. YSA'nın çıktı değerleri toplama ve çarpma fonksiyonu ile elde edilen kalıntı değerleri, girdi değerleri ise kalıntı değerlerinin 1, 2, 3, 4, 5 ve 6 günlük gecikmeli değerleridir. Böylece 1 bağımlı 6 bağımsız değişkenli bir YSA tasarlanmıştır. En iyi YSA sonucu %70 eğitim oranı ve 6 gizli nöronda toplama ve çarpım fonksiyonu için Şekil 4.8'teki gibi bulunmuştur



Şekil 4.8: Model 4c-4d için YSA Test Seti Sonuçları.

4.5. 2. 4. Temel Göstergeler ve Kalıntı Değerleri ile Kalıntı Tahmini için YSA

Modelde kullanılacak kalıntının tahmin edilmesinde hem temel göstergeler hem de kalıntıların geçmiş gözlem değerleri kullanılarak değişken farklılaşması sağlanmıştır. Girdi değerleri 1 ve 2 gün gecikmeli toplam fonksiyonlu kalıntı değerleri, günlük altın değerlerinin 1 ve 2 gün gecikmeli değerleri, günlük Euro/TL değerinin 1 ve 2 gün gecikmeli değerleri, günlük USD/TL için 1 ve 2 gün gecikmeli değerleri ve petrol fiyatları için 1 ve 2 gün gecikmeli değerleri kullanılmıştır. Çıktı değeri ise ARIMA'dan elde edilen kalıntı değerleri olmuştur. Böylece 1 bağımlı 10 bağımsız değişkenli bir YSA tasarlanmıştır. En iyi YSA sonucu 11 gizli nöron ve %70 eğitim oranında toplama ve çarpma fonksiyonu için Şekil 4.9'daki gibi bulunmuştur.




Şekil 4.9: Model 5c-5d için YSA Test Seti Sonuçları.

4.5. 2. 5. Temel Göstergeler ve Kalıntı Değerleri ile BIST100 Değerinin Tahmini için YSA


Bu model de tahmin edilen BIST100 endeks değeridir ve tahminde temel göstergeler ile kalıntılar tahmin için kullanılmıştır. BIST100 endeks değerleri YSA'nın çıktı değeri olacaktır. Girdi değerleri ise 1 ve 2 gün gecikmeli BIST100 borsası kapanış değerleri, günlük altın fiyatlarının 1 ve 2 gün gecikmeli değerleri, günlük Euro/TL değerinin 1 ve 2 gün gecikmeli değerleri, günlük USD/TL için 1 ve 2 gün gecikmeli değerleri ve petrol fiyatları için 1 ve 2 gün gecikmeli değerleri ile ARIMA işlemi sonucu elde edilen kalıntı değerlerin 1 ve 2 gün gecikmeli değerleridir. Böylece 1 bağımlı 12 bağımsız değişkenli bir YSA tasarlanmıştır. ARIMA ile YSA sonuçları bir eğitim için birleştirilmiştir. En iyi YSA sonucu toplama ve çarpma fonksiyonu için Şekil 4.10'daki gibi bulunmuştur.

1, 2 ve 6. modellerde BIST100 borsa endeksi tahmin edilmeye 3, 4 ve 5. modellerde endeks için hesaplanan kalıntı terimleri tahmin edilmeye çalışılmıştır. Melezleme modellerinde modelin doğrusal olmayan kısmını 3, 4 ve 5. modellerden elde edilen kalıntı tahmin değerleri oluşturacakken; modelin doğrusal olan kısmını 1. model olan ARIMA'dan elde edilen tahmin sonuçları oluşturacaktır.



MSE= 70.236.408 RMSE= 8.380,72
MAPE= 19,02

Model (6c)



MSE= 65.003.028 RMSE= 1.055,47
MAPE= 18,03

Model (6d)

Şekil 4.10: Model 6c-6d için YSA Test Seti Sonuçları.

4.5.3. BIST100 Endeksi ARIMA-YSA Melezleme Sonuçları

Modeller tamamlandıktan ve değerler elde edildikten sonra Denklem (3.5) ve Denklem (3.9) kullanılarak ARIMA-YSA tahminleri melezlemesi yapılmıştır. Bu melezleme sonuçları aşağıdaki gibi elde edilmiştir.

3. modelden elde edilen kalıntı tahmin değerleri, ARIMA ile tahmin edilen değerler ile Zhang (2003) ve Wang et al. (2013) melez modellerine göre melezleme yapıldığında elde edilen modellerde seçilen performans değerleri Tablo 4.6'daki gibi bulunmuştur.

Tablo 4.6: ARIMA Tahminleri ile Model 3c-3d YSA Melezleme Sonuçları.

	1. Melez Model	MSE Değerleri	MAPE	RMSE
e_t Toplama	Zhang (2003)	68.002.341	35,01	8.246,35
e_t Çarpım	Wang et al. (2013)	61.975.604	21,18	7.872,46

Tablo 4.6 incelendiğinde kalıntıların toplama ve çarpım ile hesaplanması durumunda, melez modelde sadece doğrusal ve doğrusal olmayan tahminlerin toplamını kullanan Zhang (2003) modeli; melez modelde doğrusal ve doğrusal olmayan tahminlerin çarpımını kullanan Wang et al. (2013) modelinden daha hatalı sonuç vermiştir. Bu modelde kalıntı tahmininde sadece önerilen değişkenler kullanılmıştır.

4. modelden elde edilen kalıntı tahmin değerleri ARIMA ile tahmin edilen değerler ile Zhang (2003) ve Wang et al. (2013) melez modellerine göre melezleme yapıldığında elde edilen modellerde performans değerleri Tablo 4.7'teki gibi bulunmuştur.

Tablo 4.7: ARIMA Tahminleri ile Model 4c-4d YSA Melezleme Sonuçları.

	2. Melez Model	MSE Değerleri	MAPE	RMSE
e_t Toplama	Zhang (2003)	72.745.130	18,45	8.529,08
e_t Çarpım	Wang et al. (2013)	69.136.042	15,36	8.314,81

Tablo 4.7 incelendiğinde Zhang (2003) modeli, Wang et al. (2013) modelinden daha hatalı sonuç vermiştir. Modelde kalıntı tahmininde sadece kalıntıların geçmiş dönemleri kullanılmış ve elde edilen sonuçlar melezlenmiştir.

5. modelden elde edilen kalıntı tahmin değerleri ARIMA ile tahmin edilen değerler ile Zhang (2003) ve Wang et al. (2013) melez modellerine göre melezleme yapıldığında elde edilen modellerde performans değerleri Tablo 4.8'deki gibi bulunmuştur.

Tablo 4.8: ARIMA Tahminleri ile Model 5c-5d YSA Melezleme Sonuçları.

	3. Melez Model	MSE Değerleri	MAPE	RMSE
e_t Toplama	Zhang (2003)	72.664.030	21,68	8.524,32
e_t Çarpım	Wang et al. (2013)	71.000.042	14,16	8.426,15

Tablo 4.8 incelendiğinde ise Zhang (2003) modelinin, Wang et al. (2013) modelinden daha kötü bir tahmin sonucu verdiği görülebilecektir.

6. modelde ARIMA'dan elde edilen kalıntı tahmin değerleri YSA'ya temel göstergeler ile birlikte girdi olarak verilmiş ve Khashei ve Bijari (2011)'nin melezlemesine uygun bir melezleme işlemi yapılmıştır. Modelden elde edilen performans değerleri Tablo 4.9'daki gibi bulunmuştur.

Tablo 4.9: YSA'ya Girdi Olarak Verilen ARIMA Kalıntıları ile Yapılan Melezleme Sonuçları (Model 6c ve Model 6d)

	4. Melez Model	MSE Değerleri	MAPE	RMSE
e_t Toplama	Khashei ve Bijari (2010)	70.236.408	18,21	8.380,72
e_t Çarpım	Khashei ve Bijari (2010)	65.003.028	6,05	8.062,45

Tablo 4.9 ARIMA tahminlerinin, kalıntı ve gerçek değerlerin, temel göstergeler ile kurulmuş YSA'ya eklenmesi ile elde edilen melez model sonucunu vermektedir. Khashei ve Bijari (2010) melez modelinin uygulandığı bu modelde, sadece YSA'ya çarpma fonksiyonu ile eklenen kalıntıların Zhang (2003) ve Wang et al. (2013) melez modellerinden, ARIMA'dan ve sadece temel göstergelerin kullanıldığı Model 2a'dan daha iyi tahmin sonucu vermiştir. Kalıntının toplama ile hesaplandığı durumda ise model; ARIMA, temel göstergelerle kurulan Model 2b ve ARIMA tahminleri ile Model 5c-5d ve Model 4c YSA melezleme sonuçlarından daha iyi tahmin sonucu vermiştir. Modeller içinde MAPE değerine göre en iyi sonuç ise Khashei ve Bijari'nin kalıntıların çarpma ile hesaplandığı melez modelinde ortaya çıkmıştır.

Sonuç olarak modellerin birbirleri ile karşılaştırması yapıldığında temel göstergelerin kullanıldığı BIST100 endeks tahmininin ARIMA yöntemi ile melezlenmesi sonucunda hem toplama hem çarpma fonksiyonu için işlemler yapılmıştır. Hangi değişkenler kullanılarak kalıntılar hesaplanırsa hesaplanırsa melez modellerin saf modellere (ARIMA ve YSA) göre daha iyi tahmin sonucu verdiği Tablo 4.11'de açıkça görülecektir.

Tablo 4.10: NASDAQ Endeks Değerleri için Zaman Serisi Analiz Sonuçları.

NASDAQ Borsası Endeks Tahmini Modelleri											
e_t	Performans Ölçüleri	1.Model ARIMA (Model 1a-1b)	2. Model YSA (Model 2a)	1. Melez Model (3a-3b ve ARIMA)		2. Melez Model (4a-4b ve ARIMA)		3. Melez Model (5a-5b ve ARIMA)		4. Melez Model (6a-6b ve ARIMA)	
				Zhang (2003)	Wang et al. (2013)	Zhang (2003)	Wang et al. (2013)	Zhang (2003)	Wang et al. (2013)	Khashei ve Bijari (2010)	
e_t Toplama	MSE	62.883,8	47.463,7 11,08 217,86	43.954,1		45.128,4		51.487,1		43.420,1	
	MAPE	24,28		13,11		21,41		8,19		7,36	
	RMSE	250,77		209,65		212,43		226,90		208,37	
e_t Çarpma	MSE	59.843,6			44.212		45.237,2		46.337,2		46.305,4
	MAPE	13,08			12,82		22,03		6,95		21,14
	RMSE	244,63			210,27		212,69		215,26		215,19

Tablo 4.11: BIST100 Endeks Değerleri için Zaman Serisi Analiz Sonuçları.

		BIST100 Borsası Endeks Tahmini Modelleri									
e_t	Performans Ölçüleri	1.Model ARIMA (Model 1c-1d)	2. Model YSA (Model 2b)	1. Melez Model (3c-3d ve ARIMA)		2. Melez Model (4c-4d ve ARIMA)		3. Melez Model (5c-5d ve ARIMA)		4. Melez Model (6c-6d ve ARIMA)	
				Zhang (2003)	Wang et al. (2013)	Zhang (2003)	Wang et al. (2013)	Zhang (2003)	Wang et al. (2013)	Khashei ve Bijari (2010)	
e_t Toplama	MSE	84.320.640	81.735,332 13,18 9.040,8	68.002.341		72.745.130		72.664.030		70.236.408	
	MAPE	32,18		35,01		18,45		21,68		18,21	
	RMSE	9.182,63		8.246,35		8.529,08		8.524,32		8.380,72	
e_t Çarpma	MSE	81.250.140			61.975.604		69.136.042		71.000.042		65.003,028
	MAPE	25,56			21,18		15,36		14,16		6,05
	RMSE	9.013,89			7.872,46		8.314,81		8.429,15		8.062,45

5. SONUÇ

Çalışma model melezleme ile finansal zaman serisi tahmini için yapılmıştır. Amaç, farklı zaman serileri için en uygun yalın ya da melez modeli belirlemektir. Bu amaçla öncelikle NASDAQ ve BIST100 borsa endeks değerleri tahmin edilmeye çalışılmıştır. Literatürde yer alan yalın ve melez modeller bu amaçla belirlenmiş, değişkenler yine literatür destekli olarak seçilmiş ve modeller kurulmuştur. Mevcut melez modellere değişken farklılaştırması da yapılarak daha iyi tahmin yapılabilirliği de sorgulanmıştır. Farklı endeksler için nasıl sonuçlar verdiği ortaya çıkartılmıştır.

Çalışmada ayrıca melez yöntemler kullanarak finansal zaman serileri analiz sonuçları karşılaştırılmıştır. Çalışmanın uygulama kısmında her iki endeksin değişimlerini açıklamak için değişkenler belirlenmiştir. Literatürde yer alan kalıntı belirleme yöntemleri olan toplama ve çarpma fonksiyonu ile kalıntılar her iki endeks için de belirlenmiştir. Kalıntıların belirlenmesi ve ARIMA ile tahminleme analizimizin ilk kısmını oluşturmuştur. Zaman serileri doğrusal olan ve doğrusal olmayan yapıyı aynı anda ihtiva edebilir. Bu işlem bize açıklamaya çalıştığımız değişimin doğrusal olan kısmını vermiştir. Doğrusal olmayan kısmın belirlenmesi için ise YSA kullanılmıştır. YSA hem doğrusal hem doğrusal olmayan ilişkilerin ortaya çıkarılmasında çok etkili bir yöntemdir.

Çalışmada zaman ve değişken sınırlılıklarımız mevcuttur. Veriler Ocak 2012 ile Haziran 2017 arasındaki dönemi kapsamaktadır. Değişken olarak seçilen göstergeler için de aynı zaman sınırı mevcuttur. Zaman serisi tahmininde kullanılabilecek onlarca değişken vardır ve bunlar içinden bazıları seçilerek veri setleri oluşturulmuştur. Veri setleri oluşturulurken aynı tarihte mevcut olan günler kullanılmıştır. Veri temizleme işlemi ve gürültü azaltma bu şekilde gerçekleştirilmiştir.

Tez çalışmasında yöntem olarak yalın ARIMA, yalın YSA ve ARIMA-YSA melez yöntemi kullanılmıştır. Veriler NASDAQ ve BIST100 endeks değerlerini tahmin edebilmeleri için değişkenler ile açıklanmaya çalışılmıştır. Tezde önemli olan konulardan biri de modellerden elde edilen kalıntı değerlerinin nasıl hesaplanacağı ile ilgilidir. Bu bağlamda kalıntı değerlerinin belirlenmesinde hem toplama hem çarpma metodu kullanılmıştır. Elde edilen kalıntı değerleri modellere eğitim için verilmiş ve sonrasında da melezleme işlemleri yapılmıştır. Kalıntı hesabında da farklılıklar

yapılmış ve en iyi kalıntı hesabı, en iyi model durumlarına da bakılmıştır. Her bir modellemeyen sonra performans göstergeleri hesaplanmış ve son olarak en iyi ya da en az hataya sahip model her iki endeks verileri için de ortaya konmaya çalışılmıştır.

Yapılmış olan bu tez zaman serisi tahmininde melezleme yöntemlerini kapsamlı bir şekilde anlatmaktadır. Model melezleme ile yapılmış diğer çalışmalardan farklı olarak değişkenler ve zaman boyutu genişletilmiş ve melez model konusunda kapsamlı bir kaynak olması sağlanmıştır. Değişkenler, her açıdan modellerde kullanılarak hem artık hesaplamasında hem melezleme çalışmalarında nasıl sonuçlar verdikleri toplu bir şekilde görülebilmektedir. Bu açılardan literatüre yol gösterici olarak da katkı sağlaması amaçlanmıştır.

Analizin ilk kısmı olan ARIMA'dan sonra 3 farklı YSA modeli ile kalıntıların tahminlemesi yapılmıştır. Kalıntı tahmininde temel göstergeler, kalıntıların gecikmeli değerleri ile hem kalıntı hem temel göstergeleri içeren modeller kullanılmıştır. Aynı zamanda bu 3 farklı model önce toplam sonra çarpım fonksiyonu ile hesaplanan kalıntılar için yapılmıştır. Aynı zamanda bu işlemlerin tamamı NASDAQ ve BIST100 endeksleri için tekrarlanmıştır.

Kalıntı tahmini dışında kurulan YSA (Model 2a-Model 2b), NASDAQ ve BIST100 endeks kapanış değerlerinin tahmini amacıyla yapılmıştır. Bu yapılan işlemlerin amacı YSA tahminleri ile ARIMA ve melez model tahmin sonuçlarını karşılaştırmaktır. Kurulan YSA'da kapanış fiyatları çıktı değeri olurken temel göstergeler girdi değerleri olarak kullanılmıştır.

ARIMA ve kalıntılar için kurulan YSA'lardan sonra tez çalışmamızın ana konusu olan melezleme işlemine geçilmiştir. Literatürde yer alan melezleme tekniklerine göre ARIMA'dan elde edilen tahmin değerleri ile YSA'lardan elde edilen kalıntı değerleri toplanmıştır veya çarpılmıştır. Melezleme modellerinde modelin doğrusal kısmını ARIMA'dan elde edilen tahmin değerleri, doğrusal olmayan kısmını ise YSA'lardan elde edilen kalıntı tahminleri oluşturmaktadır. Burada önemli olan hangi kalıntı belirleme yöntemi ile belirlenen kalıntının daha iyi bir tahmin olduğunun belirlenmesidir.

İlk uygulama için NASDAQ endeks değerleri kullanılmıştır. ARIMA-YSA tahminleri melezlemesi yapılmıştır. Bu melezleme sonuçlarında (Model 3a-Model 3b) Zhang (2003) modeli; Wang et al. (2013) modelinden daha az hatalı sonuç vermiştir. Ancak Wang modelinde elde edilen MAPE değeri Zhang modelinden daha düşük olmuştur. Burada ortaya çıkarılan değişken seçimi ile ilgili bir durumdur. Zhang(2003)

modelinde kalıntı değerlerinin YSA'ya verilmesinde sadece kalıntı değerlerinin kendisi kullanılmıştır. Ancak çalışmada temel göstergeler ile elde edilen kalıntı tahminlerinin ARIMA ile melezlenmesinin, kalıntıların kendisi ile elde edilen tahminlerin ARIMA ile melezlenmesinden daha iyi tahmin sonucu verdiği görülmüştür. Aynı durum bu ilk melezleme de Wang ve diğerlerinin melez modeli için de geçerlidir. Değişken seçimi iki melez model içinde daha az hatalı sonuçlar elde edilmesini sağlamıştır.

4. modelden elde edilen kalıntı tahmin değerleri ARIMA ile tahmin edilen değerler ile Zhang (2003) ve Wang et al. (2013) melez modellerine göre melezleme yapıldığında (Model 4a-Model 4b) Zhang modeli, Wang'ın modelinden tüm performans ölçüleri için daha az hatalı sonuç vermiştir. Sonuçlar birbirine oldukça yakın çıkmıştır. Burada her iki model için de kalıntı hesabında kalıntıların geçmiş dönemleri kullanılmıştır.

NASDAQ endeks değerleri tahmini için; kurulmuş olan 5. modelden elde edilen kalıntı tahmin değerleri ARIMA ile tahmin edilen değerler ile Zhang ve Wang ve diğerlerinin melez modellerine (Model 5a-Model 5b) göre melezleme yapıldığında ise Zhang modelinin, Wang ve diğerlerinin modelinden daha kötü bir tahmin sonucu verdiği görülebilecektir. Wang modeli tüm performans ölçülerinde Zhang modelinden daha iyi sonuçlar vermiştir. Bu modellerin ikisi de kalıntının tahmininde kalıntı ve temel göstergelerin bir arada kullanılmasının daha hatalı sonuçlar vereceğini göstermiştir.

6. modelde ARIMA'dan elde edilen kalıntı tahmin değerleri YSA'ya temel göstergeler ile birlikte girdi olarak verilmiş ve Khashei ve Bijari (2010) melezlemesine uygun bir melezleme işlemi yapılmıştır. Khashei ve Bijari (2010) melez modelinin uygulandığı bu modelde, YSA'ya toplama fonksiyonu ile eklenen kalıntıların Zhang (2003) ve Wang et al. (2013) melez modellerinden ve sadece temel göstergelerin kullanıldığı Model 2a'dan daha iyi tahmin sonucu vermiştir. Kalıntının çarpma ile hesaplandığı durumda ise model; ARIMA, temel göstergelerle kurulan YSA ve ARIMA tahminleri ile Model 5a-5b YSA melezleme sonuçlarından daha iyi tahmin sonucu vermiştir. NASDAQ endeks tahmini için performans ölçülerinin tamamında en iyi sonuç veren Khashei ve Bijari'nin melez modeli olmuştur. Bu model bize

ARIMA'dan elde edilen kalıntı değerlerinin diğer temel göstergeler ile aynı anda YSA'ya girdi olarak verilmesinin daha iyi sonuç üretebileceğini göstermiştir.

BIST100 endeks değerleri için modeller tamamlandıktan ve değerler elde edildikten sonra ARIMA-YSA tahminleri melezlemesi yapılmıştır. Bu melezleme sonuçlarında Model 3c-Model 3d için Zhang (2003) modeli, Wang et al. (2013) modelinden tüm performans ölçülerinde daha kötü sonuç vermiştir. Model 4c-4d için yine Zhang modeli, Wang modelinden tüm performans ölçülerinde daha kötü sonuç vermiştir. Model 5c-Model 5d için ise Zhang modelinin, Wang modelinden daha kötü bir tahmin sonucu verdiği Tablo 4.11'de görülebilecektir. Burada dikkat edilmesi gereken bir konu yine değişken seçiminde ortaya çıkmıştır. Kalıntının tahmin edilmesinde temel göstergelerin kullanıldığı modeller diğer tüm modellere göre daha iyi sonuçlar vermiştir.

BIST 100 için kurulan 6c ve 6d modellerinde, ARIMA'dan elde edilen kalıntı tahmin değerleri YSA'ya temel göstergeler ile birlikte girdi olarak verilmiş ve Khashei ve Bijari (2010)'nin melezlemesine uygun bir melezleme işlemi yapılmıştır. Khashei ve Bijari'nin melez modelinin uygulandığı bu modelde, sadece YSA'ya çarpma fonksiyonu ile eklenen kalıntıların Zhang (2003) ve Wang et al. (2013) melez modellerinden, ARIMA'dan ve sadece temel göstergelerin kullanıldığı Model 2a'dan daha iyi tahmin sonucu vermiştir. Kalıntının toplama ile hesaplandığı durumda ise model; ARIMA, temel göstergelerle kurulan Model 2b ve ARIMA tahminleri ile Model 5c-5d ve Model 4c YSA melezleme sonuçlarından daha iyi tahmin sonucu vermiştir. BIST100 için kurulan tüm modeller incelendiğinde ise Model 3d'nin bütün temel ve melez modellerden daha iyi bir tahmin sonucu verdiği görülebilir.

Özetle; NASDAQ Endeks tahmininde Khashei ve Bijari (2010) modelinde ARIMA tahminlerinin, kalıntı ve gerçek değerlerin, temel göstergeler ile kurulmuş YSA'ya eklenmesi ile elde edilen melez modeli, BIST100 Endeks tahmininde ise doğrusal ve doğrusal olmayan tahminlerin çarpımını kullanan Wang et al. (2013) modeli en iyi sonuçları vermiştir.

Sonuç olarak modellerin birbirleri ile karşılaştırması yapıldığında temel göstergelerin kullanıldığı BIST100 endeks tahmininin ARIMA yöntemi ile melezlenmesi sonucunda hem toplama hem çarpma fonksiyonu için işlemler

yapılmıştır. Hangi değişkenler kullanılarak kalıntılar hesaplanırsa hesaplanırsın melez modellerin saf modellere (ARIMA ve YSA) göre daha iyi tahmin sonucu verdiği açıkça görülecektir. Değişken seçiminin hatayı azaltmada etkili olduğu tekrar kanıtlanmıştır. Değişkenlerin seçimi hatanın azalmasında ve modelin daha tutarlı sonuçlar vermesinde çok etkilidir. Modelleme veya model melezleme ile ilgilenen araştırmacıların değişkenleri belirlerken dikkatli olmaları sonuçların daha açıklayıcı olmasını sağlayacaktır.

KAYNAKLAR

- Abraham, A., Nath, B., & Mahanti, P. K., (2001), “Hybrid Intelligent Systems for Stock Market Analysis”, In Computational science-ICCS, Springer Berlin Heidelberg, 337-345.
- Adeva, J.J.G., Beresi, U., & Calvo, R., (2005), “Accuracy and Diversity in ensembles of text categorisers”, CLEI Journal, 9(1), 1-12.
- Aghababaeyan, R., & TamannaSiddiqui, N., (2011), “Forecasting the Tehran Stock Market by artificial neural network”, International Journal of Advanced Computer Science and Applications, Special Issue on Artificial Intelligence, 13-17.
- Aktaş, R., (2003), “Mali başarısızlığın öngörülmesi: İstatistiksel yöntemler ve yapay sinir ağı karşılaştırılması”, Ankara Üniversitesi SBF Dergisi, 58(04).
- Alexander, L., Morton, H., (1990), “An Introduction to Neural Computing”, Chapman and Hall, London, 468.
- Al-Hamadi, H. M., & Soliman, S. A., (2004), “Short-Term Electric Load Forecasting Based On Kalman Filtering Algorithm With Moving Window Weather And Load Model”, Journal of Electric Power Systems Research, 47– 59.
- Anderson, J. A., (1995), “An Introduction to Neural Networks”, Massachusetts Institute of Technology Press, USA.
- Babu, C. N., & Sure, P., (2016), “Partitioning and Interpolation Based Hybrid ARIMA–ANN Model for Time Series Forecasting”, Sādhanā, 41(7), 695-706.
- Babu, C.N. and Reddy, B.E., (2014), “A Moving-Average Filter Based Hybrid ARIMA– ANN Model Forforecasting Time Series Data”, Applied Soft Computing, 27– 38.
- Bahadır E., Özdemir A.Ş., (2016), “Akademik Başarı Tahmininde Yapar Sinir Ağları”, 1. Baskı, Burç Yayınevi.
- Benli Y., (2002), “Finansal Başarısızlığın Tahmininde Yapay Sinir Ağı Kullanımı ve İMKB’de Bir Uygulama”, Muhasebe Bilim Dünyası Dergisi, 17-30.
- Berry, M.A., & Linoff, G.S., (2000), “Mastering Data Mining: The Art and Science of Customer Relationship management”, Industrial Management & Data Systems, 100(5), 245-246.
- Bollerslev, T., (1986), “Generalized Autoregressive Conditional Heteroskedasticity”, Journal of Econometrics, 31, 307-327.
- Box, G.E.P. and Pierce, D.A., (1970), “Distribution of the Residual Autocorrelations in Autoregressive Integrated Moving Average Models”, Journal of the American Statistical Association, 65:1509-1526.

- Box, G.E.P. and Jenkins, G.M., (1976), "Time Series Analysis: Forecasting and Control", Holden Day, London, 1-80.
- Box, G.E.P., Jenkins, G.M and Reinsel, G.C., (1994), "Time Series analysis: Forecasting and a Control" , Prentice Hall, New Jersey, 224-307.
- Buckland, M., & Collins, M., (2002), "AI Techniques for Game Programming" Premier press.
- Castellani, M., & Rowlands, H., (2009), "Evolutionary artificial neural network design and training for wood veneer classification", Engineering Applications of Artificial Intelligence, 22(4), 732-741.
- Chatfield, C., (1989), "The Analysis of Time Series:An Introduction", Chapman and Hall, London, 333.
- Chen, W., Zhang, R. T., Cai, Y. M., & Xu, F. S., (2006), "Particle Swarm Optimization for Constrained Portfolio Selection Problems", In Machine Learning and Cybernetics, 2006 International Conference, 2425-2429.
- Chen, Y., Abraham, A., Yang, J., & Yang, B., (2005), "Hybrid Methods for Stock Index Modeling", In Fuzzy Systems and Knowledge Discovery Springer Berlin Heidelberg, 1067-1070.
- Cheng, C. H., Chen, T. L., & Wei, L. Y., (2010), "A Hybrid Model Based On Rough Sets Theory and Genetic Algorithms for Stock Price Forecasting", Information Sciences, 180(9), 1610-1629.
- Coast, P.K.and Fant, L.F., (1991), "A Neural Network Approach to Forecasting Financial Distress", Journal of Business Forecasting, 10(4), 9-12.
- Collins, A. and Evans, A.,(1994), "Aircraft Noise and Residential Property Values", Journal of Transport Economics and Policy, 28(2), 175-197.
- Cremers, M., (2002), "Stock Return Predictability: A Bayesian Model Selection Perspective", Review of Financial Studies, 15, 1223-1249.
- Demirhan, A., Kılıç, Y. A., & İnan, G., (2010), "Tıpta Yapay Zeka Uygulamaları" Yoğun Bakım Dergisi, 9(1), 31-41.
- Diler, A. İ., (2003), "İMKB Ulusal-100 Endeksinin Yönünün Yapay Sinir Ağları Hata Geriye Yayma Yöntemi İle Tahmin Edilmesi Türkiye’de Bankalar, Sermaye Piyasası ve Ekonomik Büyüme: Koentegrasyon Ve Nedensellik Analizi", İMKB Dergisi, 25-26, pp. 65-81.
- Ding, Z., Granger, C. W. J. ve Engle, R. F., (1993), "A Long Memory Property of Stock Market Returns and a New Model", Journal of Empirical Finance, 83-106.
- Elmas Ç., (2003), "Yapay Sinir Ağları Kuram, Mimari, Eğitim, Uygulama", 1. Baskı, Ankara, Türkiye, Seçkin Yayıncılık.
- Elmas Ç., (2016), "Yapay Zeka Uygulamaları", 3. Baskı, Seçkin Yayıncılık.

- Enders, W., (2004), “Applied Econometric Time Series, by Walter”, Technometrics, 46(2), 264.
- Engle, R. F., (1982), “Autoregressive Conditional Heteroskedasticity with Estimates of the Variance of U.K. Inflation”, *Econometrica*, 50, 987- 1008.
- Engle, R. F. ve Bollerslev, T., (1986), “Modeling the Persistence of Conditional Variances”, *Econometric Reviews*, 5, 1–50.
- Engle, R. F., Lilien, D. M. ve Robins, R. P., (1987), “Estimating Time Varying Risk Premia in the Term Structure: The ARCH-M Model”, *Econometrica*, 55, 391–407.
- Ergezer, H., Dikmen, M., & Özdemir, E., (2003), “Yapay Sinir Ağları ve Tanıma Sistemleri. Pivolka, 2(6), 14-17.
- Ersoy, E., & Karal, Ö., (2012), “Yapay Sinir Ağları ve İnsan Beyni”, *İnsan ve Toplum Bilimleri Araştırmaları Dergisi*, 1(2), 188-205.
- Fard, A.. & Akbari-Zadeh, M.R., (2014), “A Hybrid Method Based on Wawelet, ANN and ARIMA Model For Short Term Load Forecasting”, *Journal of experimental&Theoretical Artifical İntelegence*, 26(2) 167-182.
- Fausett, L., (1994),”Fundamentals of Neural Networks: Architectures, Algorithms and Applications”, Prentice Hall, Englewood Cliffs.
- Fenghua, W. E. N., Jihong, X. I. A. O., Zhifang, H. E., & Xu, G. O. N. G., (2014), “Stock Price Prediction based on SSA and SVM”, *Procedia Computer Science*, 31, 625-631.
- Fırat, M., & Güngör, M., (2004), “Askı Madde Konsantrasyonu ve Miktarının Yapay Sinir Ağları ile Belirlenmesi, *Teknik Dergi*, 15(73).
- Freeman, J. A., (1993), “Simulating Neural Networks with Mathematica”, Addison-Wesley Publising Company.
- Gallant, S.I., (1993), *Neural Network Learning and Expert Systems*, MIT Press, Cambridge.
- Gershenfeld, N. A., (1999), “The Nature of Mathematical Modeling”, Cambridge university press.
- Graupe, D., (2013), “Principles of Artificial Neural Networks, World Scientific, (7).
- Gudise, V. G., & Venayagamoorthy, G. K., (2003), “Comparison of Particle Swarm Optimization and Backpropagation as Training Algorithms for Neural Networks”, In *Swarm Intelligence Symposium (SIS'03)*, Proceedings of the 2003 IEEE, 110-117.
- Gujarati, D. N., (2003), “Basic Econometrics”, Fourth Edition, McGraw Hill.
- Guresen, E., Kayakutlu, G., & Daim, T. U., (2011), “Using Artificial Neural Network Models İn Stock Market Index Prediction”, *Expert Systems with Applications*, 38(8), 10389-10397.

Gurney, K., (1996), “Computers and Symbols Versus Nets and Neurons”, UCL Draft Papers, No:1, U.K.

Hamzaçebi C., (2011), “Yapay Sinir Ağları Tahmin Amaçlı Kullanımı: Matlab ve Neurosolutions Uygulamalı”, Ekin Basım Yayın Dağıtım, Ankara.

Hassan, M. R., Nath, B., & Kirley, M. (2007), “A Fusion Model of HMM, ANN and GA for Stock Market Forecasting”, Expert Systems with Applications, 33(1), 171-180.

Haykin, S., (1999), “Neural Networks- A Comprehensive Foundation”, Prentice Hall, 2. Edition, New Jersey.

Hebb, D. O., (1949), “The Organization of Behavior: A Neuropsychological Theory”, New York: Wiley and Sons.

Hoff, J.C., (1983), “A Practical Guide to Box-Jenkins Forecasting”, Belmont, CA:Wadsworth INC., 316.

Hu, C., (2002), “Advanced Tourism Demand Forecasting: ANN and Box-Jenkins Modelling”, Doktora Tezi, Purdue University, MI, USA.

Huang, S.-J., & Shih, K.-R., (2003), “Short-Term Load Forecasting Via ARIMA Model Identification Including Non-Gaussian Process Considerations”, IEEE Transactions on Power Systems, 18, 673– 679.

Huang, K. Y., & Jane, C. J., (2009), “A Hybrid Model for Stock Market Forecasting and Portfolio Selection Based on ARX, Grey System and RS Theories”, Expert Systems with Applications, 36(3), 5387-5392.

JingTao, Y. A. O., & Tan, C. L., (2001), “ Guidelines for Financial Forecasting with Neural Networks, Neural Information Processing, Shanghai.

Karahan, M., (2011), “İstatistiksel Tahmin Yöntemleri: Yapay Sinir Ağları Metodu ile Ürün Talep Tahmini Uygulaması”, Doktora Tezi, Selçuk Üniversitesi Sosyal Bilimler Enstitüsü, Konya.

Kartalopoulos, Stamatios V., (1996), “Understanding Neural Networks and Fuzzy Logic Basic Concepts and Applications”, New York: IEEE Press.

Kayım, H., (1986), “İstatistiksel Ön Kestirim Yöntemleri”, H.Ü. İ.İ.B.F. Yayın No:II, Ankara .

Kaynar, O., & Taştan, S., (2009), “Zaman Serileri Tahmininde Arima-Mlp Melez Modeli”, Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi, 23(3).

Kaynar, O., Yilmaz, I., & Demirkoparan, F., (2011), “Forecasting of Natural Gas Consumption with Neural Network and Neuro Fuzzy System”, Energy Education, Science and Technology, 26(2), 221-238.

Keleş, E., & Çepni, S., (2006), “Beyin ve öğrenme” *Türk Fen Eğitimi Dergisi*, 3(2), 66-82.

- Khashei, M., Bijari, M., (2011)., “A Novel Hybridization of Artificial Neural Networks and ARIMA Models for Time Series Forecasting”, *Applied Soft Computing* 11, 2664–2675, 2011.
- Khashei, M., Bijari, M., Ardali, G.A.R., (2012), “Hybridization of Autoregressive Integrated Moving Average (ARIMA) with Probabilistic Neural Networks (PNNs)”, *Computers & Industrial Engineering*, 63, 37–45.
- Khashei, M., Hejazi, S.R., Bijari, M., (2008), “A New Hybrid Artificial Neural Networks and Fuzzy Regression Model for Time Series Forecasting”, *Fuzzy Sets and Systems* 159, 769 – 786.
- Kiranyaz, S., Ince, T., Yildirim, A., & Gabbouj, M., (2009), “Evolutionary Artificial Neural Networks by Multi-Dimensional Particle Swarm Optimization. *Neural networks*, 22(10), 1448-1462.
- Kuncheva, L. and Whitaker, C., (2003), “Measures of Diversity in Classifier Ensembles, *Machine Learning*, 51, 181-207.
- Kutlar, A., & Turgut, T., (2006), “Türkiye’deki Başlıca Ekonomi Serilerinin ARFIMA Modelleri ile Tahmini ve Öngörülebilirliği”, *Kocaeli Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 1(11), 120-149.
- Kwon, Y. K., & Moon, B. R. (2007), “A Hybrid Neurogenetic Approach for Stock Forecasting”, *Neural Networks, IEEE Transactions*, 18(3), 851-864.
- Lawrence, R., (1997), “Using Neural Networks to Forecast Stock Market Prices, *University of Manitoba*.
- Leigh, W., Paz, M., & Purvis, R., (2002), “An Analysis of A Hybrid Neural Network and Pattern Recognition Technique for Predicting Short-Term Increases in The NYSE Composite Index”, *Omega*, 30(2), 69-76.
- Lewis, C. D. (1982), “Industrial and business forecasting methods: A practical guide to exponential smoothing and curve fitting”, *Butterworth-Heinemann*.
- Ljung, G.M., Box, G.E.P., (1978), “On a Measure of Lack of Fit in Time Series Models”, *Biometrika*, 65, 297-303.
- Ma Z., Dai Q. & Liu N., (2015), “Several Novel Evaluation Measures for Rank-Based Ensemble Pruning with Applications to Time Series Prediction”. *Expert System with Applications*, 42(1), 280-292.
- Maddala, G.S.& Inn-Moo Kim., (2002), “Unit Roots, Cointegration and Structural Changes”, *Cambridge University Press, U.K.*, 18.
- Mann, S.P., (1995), “Statistics for Business and Economics”, *Wiley, USA*, 879.
- Makridakis, S., Andersen, A., Carbone, R., Fildes, R., Hibon, M., Lewandowski, R., & Winkler, R., (1982), “The Accuracy of Extrapolation (Time Series) Methods: Results of A Forecasting Competition”. *Journal Of Forecasting*, 1(2), 111-153.

- Mason, A.J., Ryan, D.M., & Panton, D.M., (1998), "Integrated Simulation, Heuristic and Optimisation Approaches to Staff Scheduling", *Operations Research*, 46(2), 161-175.
- Masters, T., (1993), "Practical Neural Network Recipes in C++", Academic Press, New York, 25-50.
- Mehra, P., & Wah, B. W., (1992), "Artificial Neural Networks: Concepts and Theory", Los Alamitos IEEE Computer Society Press, 680.
- Mendes, R., Cortez, P., Rocha, M., & Neves, J., (2002), "Particle Swarms for Feedforward Neural Network Training", *Neural Networks Proceedings of the 2002 International Joint Conference*, 2, 1895-1899.
- Mills, T. C., & Markellos, R. N., (2008), "The Econometric Modelling of Financial Time Series", Cambridge University Press.
- Nabiyev, V. V., (2016), "Yapay Zeka", 5. Baskı, Seçkin Yayıncılık, Ankara.
- Nelson, D. B., (1991), "Conditional Heteroskedasticity in Asset Returns: A New Approach", *Econometrica*, 59, 347-370.
- Newbold, P., Carlson, W.L., Thorne, B.M., (2003), "Statistics for Business and Economics", Pearson Education INC., Upper Saddle River, N.J: Prentice Hall, 850.
- Nilsson, N. J., (1998), "Artificial intelligence: a new synthesis", Elsevier.
- Oliveira, M., & Torgo, L., (2014), "Ensembles for Time Series Forecasting", In *Proceedings of the Sixth Asian Conference on Machine Learning*, 360-370.
- Opitz, D., Maclin, R., (1999), "Popular Ensemble Methods: An Empirical Study", *Journal of Artificial Intelligence Research* 11, 169-198.
- Öztemel E., (2012), "Yapay Sinir Ağları", 3. Baskı, Papatya Yayıncılık, İstanbul.
- Pai, P. F., & Lin, C. S., (2004), "A Hybrid ARIMA and Support Vector Machines Model in Stock Price Forecasting", *Omega*, 33(6), 497-505.
- Pham, D. T., & Öztemel, E., (1995), "An Integrated Neural Network and Expert System Tool for Statistical Process Control. Proceedings Of The Institution Of Mechanical Engineers", Part B: *Journal of Engineering Manufacture*, 209(2), 91-97.
- Pulido, M., Melin, P., & Castillo, O., (2014), "Particle Swarm Optimization Of Ensemble Neural Networks With Fuzzy Aggregation For Time Series Prediction Of The Mexican Stock Exchange", *Information Sciences*, 280, 188-204.
- Rao, Ananda M ve Srinivas, J., (2003), "Neural Networks Algorithms and Applications", Pangbourne England, Alpha Science International Ltd.
- Rojas, R., (2013), "Neural Networks: A Systematic Introduction", Springer Science & Business Media.

- Rokach, L. (2010)., "Ensemble-Based Classifiers". Artificial Intelligence Review, 33 (1-2).
- Rumelhart, D.E., Hinton, G.E., & Williams, R.J., (1988), "Learning Representations by Back-Propagation Errors", Cognitive Modeling, 5(3), 1.
- Sarlak, N. (2005), "Evaluation and Modeling of Streamflowdata: Entropy Method, Autoregressive Models with Asymmetric Innovations and Artificial Neural Networks", Doktora Tezi, METU, Ankara.
- Saygılı, Y., (2008), "İstatistiksel Yöntemlerle Yapay Sinir Ağları Uygulamalarının Karsılaştırılması: Milli Savunma Bakanlığı Bütçesinin Öngörülemleri", Kara Harp Okulu Savunma Bilimleri Enstitüsü, Ankara.
- Sharda, R., Patil, R.B., (1992), "Connectionist Approach to Time Series Prediction: An Empirical Test", Journal of Intelligent Manufacturing, 3, 317-232.
- Singh, P., & Borah, B., (2014), "Forecasting Stock Index Price Based on M-Factors Fuzzy Time Series and Particle Swarm Optimization", International Journal of Approximate Reasoning, 55(3), 812-833.
- Sivagaminathan, R.K., & Ramakrishnan, S., (2007), "A Hybrid Approach for Feature Subset Selection Using Neural Networks and Ant Colony Optimization" Expert System with Applications, 33(1), 49-60.
- Şen Z., (2004), "Yapay Sinir Ağları İlkeleri", Su Vakfı Yayınları, İstanbul.
- Tang, Z. And Fishwick, P.A., (1993), "Feedforward Neural Nets as Models for Time Series Forecasting", ORSA Journal on Computing, 5(4), 374-385.
- Tektaş, A., ve Karataş, A., (2004), "Yapay Sinir Ağları ve Finans Alanına Uygulaması: Hisse Senedi Fiyat Tahminlemesi", Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi, 18(3-4).
- Tektaş, M., Akbaş, A., Topuz V., (2002), "Yapay Zekâ Tekniklerinin Trafik Kontrolünde Kullanılması Üzerine Bir İnceleme", 1. Uluslararası Trafik ve Yol Güvenliği Kongresi, Gazi Üniversitesi, Ankara, 551-559.
- Trippi, R.R. and Turban, E., (1993), "Neural Network in Finance and Investment: Using Artificial Intelligence to Improve Real-World Performance", Chicago.
- Ülker, M. & Cıvlek, Ö., (2002), "The Buckling Analysis of Axially Loaded Columns with Artificial Neural Networks", Turkish Journal of Engineering and Environmental Sciences, 26(2), 117-126.
- Voorhees, W. R. (2006), "Neural Networks and Revenue Forecasting: A Smarter Forecast?", International Journal of Public Policy, 1(4), 379-388.
- Wang, J. J., Wang, J. Z., Zhang, Z. G., & Guo, S. P., (2012), "Stock Index Forecasting Based on A Hybrid Model", Omega, 40(6), 758-766.

Wang, L., Zou, H., Su J., Li, L., Chaudhry, S., (2013), “An ARIMA-ANN Hybrid Model for Time Series Forecasting”, *Systems Research and Behavioral Science*, 30(3), 244–59.

Wilson, R.L. and Sharda, R., (1994), “Bankruptcy Prediction Using Neural Networks” *Decision Support System*, 13(5), 545-557.

Xiao, Y., Xiao, J., Lu, F., Wang, S., (2014), “Ensemble Anns-PSO-GA Approach for Day-Ahead Stock E-Exchange Prices Forecasting”, *International Journal of Computational Intelligence Systems*, 7(2), 272-290.

Verbos, P. J., (1994), “The Roots of Backpropagation: From Ordered Derivatives to Neural Networks and Political Forecasting”, (Vol. 1), John Wiley&Sons.

Yaghini, M., Khoshraftar, M. M., Fallahi, M., (2013), “A Hybrid Algorithm for Artificial Neural Network Training”, *Engineering Applications of Artificial Intelligence*, 26(1), 293-301.

Yakut, E., Elmas, B., Yavuz, S., (2014), “Yapay Sinir Ağları ve Destek Vektör Makineleri”, *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 19(1).

Yıldız B., (2009), “Finansal Analizde Yapay Zeka”, Ankara, 1. Baskı, Detay Yayıncılık.

Zakoian, J. M., (1994), “Threshold Heteroskedastic Models”, *Journal of Economic Dynamics and Control*, 18, 931-944.

Zhang, G., Patuwo, B. E., & Hu, M. Y., (1998), “Forecasting with Artificial Neural Networks”, *The State of The Art. International Journal Of Forecasting*, 14(1), 35-62.

Zhang, G.P., (2003), “Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model”, *Neurocomputing* 50, 159-175.

ÖZGEÇMİŞ

Fatma SÖNMEZ ÇAKIR 1980 Sivas doğumludur. İlk-Orta ve Lise eğitimini Kocaeli Gölcük'te, Üniversite ve Yüksek Lisans eğitimini Cumhuriyet Üniversitesi'nde tamamlamıştır. Yüksek Lisans eğitimi bittikten sonra 4 sene boyunca özel bir öğretim kurumunda usta öğretici olarak çalışmış ve 2009 yılında Bartın Üniversitesi İşletme Anabilim dalında Araştırma Görevlisi olarak işe başlamıştır. 2012 yılında aynı Üniversite'de Yönetim Bilişim Sistemleri bölümü Öğretim Görevlisi kadrosuna geçmiştir. Aynı sene Gebze Teknik Üniversitesi'nde Doktora eğitimine başlamıştır.