

T.C.
DOKUZ EYLÜL ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
EKONOMETRİ ANABİLİM DALI
EKONOMETRİ PROGRAMI
YÜKSEK LİSANS TEZİ

YAPAY SİNİR AĞLARI YÖNTEMİ VE İKTİSADİ
GÖSTERGELERİN TAHMİNLENMESİ ÜZERİNE BİR
ARAŞTIRMA

Reyhan KAPLAN

Danışman
Prof. Dr. Mehmet AKSARAYLI

İZMİR-2019

TEZ ONAY SAYFASI



YEMİN METNİ

Yüksek Lisans Tezi olarak sunduğum “Yapay Sinir Ağları Yöntemi Ve İktisadi Göstergelerin Tahminlenmesi Üzerine Bir Araştırma” adlı çalışmanın, tarafımdan, akademik kurallara ve etik değerlere uygun olarak yazıldığını ve yararlandığım eserlerden kaynakçada gösterilenlerden oluştuğunu, bunlara atıf yapılarak yararlanmış olduğumu belirtir ve bunu onurumla doğrularım.

...../...../.....

Reyhan KAPLAN

ÖZET
Yüksek Lisans Tezi
Yapay Sinir Ağları Yöntemi Ve İktisadi
Göstergelerin Tahminlenmesi Üzerine Bir Araştırma
Reyhan KAPLAN

Dokuz Eylül Üniversitesi
Sosyal Bilimler Enstitüsü
Ekonometri Anabilim Dalı
Ekonometri Programı

Günümüz teknolojisi yeni bilgiler elde etmek için verilerin saklanması ve işlenmesi konusunda önemli ölçüde gelişme göstermiştir. Bu doğrultuda, geçmiş dönem bilgisine dayanarak, yeni dönem hakkında bilgi üretme süreci, insanlar için daha fazla önem kazanmıştır. Zamanla bu durum bireyler için önemli olduğu kadar ülkeler için de önemli bir konu haline gelmiştir. Bu tez çalışmasında, yapay sinir ağlarının tanımı yapılmış, tarihçesi, genel yapısı anlatılmış ve iktisadi göstergeler üzerine bir uygulama yapılmıştır. Tezin amacı yapay sinir ağları yöntemiyle elde edilen sonuçlar ile klasik yöntem ile elde edilen sonuçların karşılaştırılmasıdır. Zaman serilerinden oluşturulan iktisadi göstergelerin tahminlenmesinde en küçük kareler yöntemi kullanılmıştır. Yapay sinir ağları yöntemi içinde “nftool” yapısı kullanılmıştır. Uygulama bölümünde iki farklı yöntem sonuçları incelendiğinde, yapay sinir ağları ile yapılan modelin sonuçlarının daha küçük hatayı verdiği tespit edilmiştir. Birinci model bir bağımsız değişken ve bir bağımlı değişken ile ikinci model ise bir bağımlı değişken ve iki bağımsız değişken ile oluşturulmuştur. İncelenen aralıkta veri sayısının azlığı ve diğer ekonomik göstergelerin modellere dahil edilememesi nedeniyle sonuçlar arasında uçurum farklılıklar oluşmadığı görülmüştür. Günümüz teknolojisinde tüm durumlar değerlendirildiğinde yapay sinir ağları yönteminin daha kullanışlı olduğu sonucuna varılmıştır.

Anahtar Kelimeler: Yapay Sinir Ağları, Zaman Serileri, İktisadi Göstergeler

ABSTRACT
Master's Thesis
Artificial Neural Networks Method And A
Research on Forecasting Economics Indicators
Reyhan KAPLAN

Dokuz Eylul University
Graduate School of Social Sciences
Department of Econometrics
Econometrics Program

Today's technology has improved significantly in the storage and processing of data to obtain new information. Accordingly, the process of generating information about the new period has gained more importance for people based on the knowledge of the previous period. Over time, this case has become an important issue for individuals as well as for countries. In this thesis, the definition of artificial neural networks is explained, its history and general structure is explained and an application is made on economic indicators. The aim of the thesis is to compare the results obtained with the artificial neural network method with the classical method. The least squares method was used to estimate the economic indicators formed from time series. “nftool” structure was used in artificial neural network method. When the results of two different methods were examined in the application section, it was found that the results of the model made with artificial neural networks gave a smaller error. The first model is composed of one independent variable and one dependent variable, and the second model consists of one dependent variable and two independent variables. It was observed that there was no gap between the results due to the low number of data and the failure to include other economic indicators in the models. In today's technology, when all the situations are evaluated, it is concluded that artificial neural network method is more useful.

Keywords: Artificial Neural Networks, Time Series, Economic Indicators

YAPAY SİNİR AĞLARI YÖNTEMİ VE İKTİSADİ GÖSTERGELERİN TAHMİNLENMESİ ÜZERİNE BİR ARAŞTIRMA

İÇİNDEKİLER

TEZ ONAY SAYFASI	ii
YEMİN METNİ	iii
ÖZET	iv
ABSTRACT	v
İÇİNDEKİLER	vi
KISALTMALAR	ix
TABLOLAR LİSTESİ	x
ŞEKİLLER LİSTESİ	xi
GİRİŞ	1

BİRİNCİ BÖLÜM KAPSAM VE LİTERATÜR

1.1. KAPSAM	3
1.2. LİTERATÜR ARAŞTIRMASI	3

İKİNCİ BÖLÜM YAPAY SİNİR AĞLARINA GİRİŞ/GENEL BAKIŞ

2.1. YAPAY SİNİR AĞLARI GENEL TANIMI	5
2.2. YAPAY SİNİR AĞININ TARİHÇESİ	5
2.3. BİYOLOJİK SİNİR AĞININ YAPISI	8
2.4. YAPAY SİNİR AĞININ ELEMANLARI	10
2.4.1. Girdiler	11
2.4.2. Ağırlıklar	11
2.4.3. Toplama Fonksiyonu	12
2.4.4. Aktivasyon Fonksiyonu	13
2.5. YAPAY SİNİR AĞLARI KATMANLARI	14
2.5.1. Girdi Katmanı	15

2.5.2. Gizli Katman	16
2.5.3. Çıktı Katmanı	16
2.6. YAPAY SİNİR AĞI AVANTAJLARI VE DEZAVANTAJLARI	16
2.7. YAPAY SİNİR AĞLARINDA PERFORMANS ÖLÇÜTLERİ	18
2.7.1. Hata Kareler Ortalaması-HKO	18
2.7.2. Hata Kareler Toplamı-HKT	18
2.7.3. Ortalama Mutlak Hata Yüzdesi-OMHY	19
2.8. YAPAY SİNİR AĞLARI ÇEŞİTLERİ	19
2.8.1. Mimarisine Göre Yapay Sinir Ağı Çeşitleri	19
2.8.2. Öğrenme Algoritmalarına Göre Yapay Sinir Ağı Çeşitleri	22
2.8.3. Öğrenme Zamanına Göre Ağ Çeşitleri	25
2.9. YAPAY SİNİR AĞLARI KULLANIM ALANLARI	25
2.9.1. Doğrusal Yapay Sinir Ağı Uygulamaları	26
2.9.2. Doğrusal Olmayan Yapay Sinir Ağı Uygulamaları	26

ÜÇÜNCÜ BÖLÜM

ZAMAN SERİLERİ ANALİZİ

3.1. ZAMAN SERİLERİ GENEL TANIMI	28
3.2. ZAMAN SERİLERİ ANALİZİ	28
3.3. REGRESYON TEKNİĞİ İLE ANALİZ	29
3.3.1. En Küçük Kareler Yöntemi İle Tahmin Formülasyonu	29
3.3.2. En Küçük Kareler Yöntemi Varsayımları	30

DÖRDÜNCÜ BÖLÜM

UYGULAMA

4.1. UYGULAMA GİRİŞ	35
4.2. DEĞİŞKENLERİN SEÇİLMESİ VE VERİ SETİ HAZIRLANMASI	35
4.3. UYGULAMA SONUÇLARI	38
4.3.1. En Küçük Kareler Yöntemi İle Kurulan Birinci Model Sonuçları	39
4.3.2. Yapay Sinir Ağları Yöntemi İle Kurulan Birinci Model Sonuçları	44
4.3.3. Birinci Model İçin En Küçük Kareler Yöntemi ve Yapay Sinir Ağları Sonuçlarının Karşılaştırılması	48

4.3.4. En Küçük Kareler Yöntemi İle Kurulan İkinci Model Sonuçları	49
4.3.5. Yapay Sinir Ağları Yöntemi İle Kurulan İkinci Model Sonuçları	55
4.3.6. İkinci Model İçin En Küçük Kareler Yöntemi ve Yapay Sinir Ağları Sonuçlarının Karşılaştırılması	58
SONUÇ	59
KAYNAKÇA	61



KISALTMALAR

ARIMA	Otoregresif Hareketli Ortalamalar
NASAÇ	National Association of Securities Dealers Automated Quotations
ARCH	Otoregresif Koşullu Değişen Varyans
GARCH	Genelleştirilmiş Otoregresif Koşullu Değişen Varyans
ADALINE	Adaptive Linear Neuron
MADALINE	Multiple Adaptive Linear Neuron
HKO	Hata Kareler Ortalaması
MSE	Mean Squared Error
RMSE	Root Mean Squared Error
HKT	Hata Kareler Toplamı
SSE	Sum Squared Error
OMHY	Ortalama Mutlak Hata Yüzdesi
MAPE	Mean Absolute Percentage Error
EVDS	Elektronik Veri Dağıtım Sistemi
TÜİK	Türkiye İstatistik Kurumu
ADF	Augmented Dickey-Fuller Test
VAR	Vektör Otoregresyon Analizi
GSYH	Gayri Safi Yurt İçi Hasıla

TABLÖLAR LİSTESİ

Tablo 1: Yapay Sinir Ağları İle Zaman Serisi Analizi Literatür	s.3
Tablo 2: Biyolojik Sinir Ağı Ve Yapay Sinir Ağı'nın Karşılaştırılması	s.10
Tablo 3: Toplama Fonksiyonu Örnekleri	s.12
Tablo 4: İhracat ve İthalat Değişkenleri İçin Birim Kök Testi Sonuçları	s.40
Tablo 5: En Küçük Kareler Yöntemi İle Kurulan Model1	s.41
Tablo 6: Model1 Değişen Varyans İçin White Testi Sonuçları	s.43
Tablo 7: Model1 Otokorelasyon İçin Breusch-Gogfrey Serial LM Testi Sonuçları	s.44
Tablo 8: Model2 Regresyon Analizi ve Yapay sinir Ağı'nın Hata Kareler Toplamı	s.48
Tablo 9: Döviz Kuru Değişkeni İçin Birim Kök Testi Sonuçları	s.50
Tablo 10 : En Küçük Kareler Yöntemi İle Kurulan Model2	s.51
Tablo 11: Model2 İçin Değişen Varyans İçin White Testi Sonuçları	s.53
Tablo 12: Model2 Otokorelasyonu İçin Breusch-Gogfrey Serial LM Testi Sonuçları	s.54
Tablo 13: Model2 Regresyon Analizi ve Yapay sinir Ağı'nın Hata Kareler Toplamı	s.58

ŞEKİLLER LİSTESİ

Şekil 1: Biyolojik Bir Sinir Ağının Gösterimi	s.9
Şekil 2: Yapay Sinir Ağlarının Genel Yapısı	s.11
Şekil 3: Yapay Sinir Ağlarının Katmanları	s.15
Şekil 4: İleri Beslemeli Yapay Sinir Ağlarının Genel Görünümü	s.20
Şekil 5: Geri Beslemeli Yapay Sinir Ağlarının Genel Görünümü	s.21
Şekil 6: Çok Katmanlı İleri Beslemeli Geri Yayımlı Yapay Sinir Ağlarının Genel Görünümü	s.22
Şekil 7: Hata Terimlerinin Eşit Varyanslı Dağılışı	s.32
Şekil 8: Hataların Dağılımı	s.34
Şekil 9: 2007-2017 Arası İhracat Ve İthalat Değerleri (Durağanlaştırılmamış)	s.39
Şekil 10: 2007-2017 Arası İhracat Ve İthalat Değerleri Dağılımı	s.39
Şekil 11: 2007-2017 Arası İhracat Ve İthalat Değerleri (Durağanlaştırılmış)	s.40
Şekil 12: Model1 Modelin Hata, Gerçek Ve Uyum Değerleri	s.42
Şekil 13: Model1 Hataların Dağılımı	s.42
Şekil 14: Oluşturulan Yapay Sinir Ağı Yapısı	s.44
Şekil 15: Model1 Eğitim, Değerlendirme Ve Test Veri Seti İçin Ortalama Karesel Hata	s.45
Şekil 16: Ağın Çıktısı ve Gerçek Değer Arasındaki Farklar	s.45
Şekil 17: Model1Ağın Çıktısı ve Gerçek Değerler Arasındaki Farkların Dağılımı	s.46
Şekil 18: Model1Ağın Çıktısı ve Gerçek Değere Uyum	s.47
Şekil 19: 2007-2017 Arası Reel Döviz Kuru Değerleri (Durağanlaştırılmamış)	s.49
Şekil 20: 2007-2017 Arası İhracat Ve Reel Döviz Kuru Değerleri Dağılımı	s.49
Şekil 21: 2007-2017 Arası Reel Döviz Kuru Değerleri (Durağanlaştırılmış)	s.50
Şekil 22: Model2 Hata, Gerçek Ve Uyum Değerleri	s.52
Şekil 23: Model2 Hataların Dağılımı	s.53
Şekil 24: Model2 Oluşturulan Yapay Sinir Ağı Yapısı	s.55
Şekil 25: Model2 Eğitim, Değerlendirme Ve Test Veri Seti İçin Ortalama Karesel Hata	s.55

Şekil 26: Model2 Ağın Çıktısı ve Gerçek Değerler Arasındaki Farkların Dağılımı

s.56

Şekil 27: Model2 Ağın Çıktısı ve Gerçek Değere Uyumu

s.57



GİRİŞ

Modern teknolojinin gelişimi ile ileri düzey bilgisayarlar ve yapay zekâ sistemleri insanlık için vazgeçilmez bir durum haline gelmiştir. İlk bilgisayarların hayatımıza girmesinden günümüze kadar bu süreç gözlemlendiğinde, başlarda sadece basit hesaplamalar, sonra zor olan matematiksel işlemler ve veri alışverişi yapmak için kullanılan bilgisayarlar, artık verileri işleyebilen, mevcut verileri kullanarak onlar hakkında tahmin ve yorum yapabilen bir araç haline gelmiştir. Bu ilerleyişteki kilit nokta bilgisayarların insan beyninin taklidini yapmasıyla başlamıştır. İnsan beyninin taklidi yapay zekâ teknolojilerini ortaya çıkarmıştır (Öztemel, 2016,13-15).

Büyük miktarlardaki verilerden, anlamlı ve kullanılabilir bilgileri daha kısa zamanlarda üretebilmek insanoğlunu için her zaman ihtiyaç olmuştur. Bu sebepten dolayı da zaman içerisinde makine öğrenmesi, yapay zekâ gibi birbirini tamamlayan parçalar yapay sinir ağları gibi bir metot da bir arada kullanılmasıyla klasik yöntemlerin yerine alternatif yöntemler tercih edilmeye başlanmıştır.

Günümüzde ülkelerin devamlılığını sürdürebilmesi için dış ticaretle ilişkilerini sürdürebilmeleri gerekmektedir. Diğer bir ifadeyle dış ticaret ilişkisinde hem ülkemiz ekonomisi için hem de diğer ülkeler ekonomisi için ihracat ve ithalat birbirini tamamlayan önemli kalemlerdendir. İki kalem arasındaki ilişkinin tahmin edilebilmesi de ekonomistler için önemlilik teşkil etmektedir. Bu yüzden iki kalem arasındaki ilişkinin gerçeği en iyi yansıtacak değer ile tahmini geleceğe yönelik planlama çalışmaları açısından oldukça önemlidir.

Tezde çok sayıda varsayımı sağlaması gerektiren klasik yöntemler ile elde edilen sonuçların, yapay sinir ağları yöntemiyle elde edilen sonuçlar ile karşılaştırılması amaçlanmıştır. Ayrıca uygulamada kullanılan yöntemler içerisinde gerçek değerleri en yakın sonuçları veren yöntemin belirlenmesi, bunun yanında her iki yöntemin de avantajlarının ve dezavantajlarının incelenmesi amaçlanmıştır.

Tezin ilk bölümünde uygulamanın kapsamı ve literatür oluşturmaktadır. Geçmiş dönemlerde yapılmış temel uygulamalardan bahsedilmiştir.

Tezin ikinci bölümünde yapay sinir ağlarının tanımı yapılmış, tarihçesi gelişimi ve yapısı incelenmiştir. Biyolojik sinir hücreleri ile arasındaki benzerlikler ve farklılıklar açıklanmıştır.

Üçüncü bölümde zaman serilerin tanımı ve zaman serileri analizinde regresyon yönteminin kullanılmasından bahsedilmiştir. Ayrıca regresyon için en küçük kareler metodu ile tahminin varsayımları ve formülasyonları üzerinde durulmuştur.

Tezin son bölümünü uygulama bölümü oluşturmaktadır. Seçilen değişkenlerin neden seçildiği ve verilerin elde edilme sürecinden bahsedilmiştir. Bu bölümde Matlab ve Eviews programı kullanılarak analizi yapılan verilerin sonuçları verilmiştir. Sonuçlar grafikler ile desteklenerek yorumlanmıştır.



BİRİNCİ BÖLÜM

KAPSAM VE LİTERATÜR

1.1. KAPSAM

Uygulamanın değişkenleri, Türkiye'nin 2007 ve 2018 yılları arasında yapmış olduğu ithalat ve ihracat hacimleri ile döviz kuru oluşmaktadır. Araştırmanın yöntemleri, zaman serilerinde en küçük kareler ile basit doğrusal regresyon modeli ve yapay sinir ağları yöntemleridir.

1.2. LİTERATÜR

Aşağıda yapay sinir ağları ile zaman serisi analizi yapılan belirli çalışmalar yıllara göre düzenlemiş, Tablo 1'de ifade edilmiştir.

Tablo 1: Yapay Sinir Ağları İle Zaman Serisi Analizi Literatür

Marquez ve arkadaşları (1991)	Yapay sinir ağları, regresyon modellerine bir alternatif olarak önerilmiştir. Doğrusal olan ve olmayan regresyon modelleri parametrelerle test edilmiş. Daha sonra, aynı parametrelerle yapay sinir ağları ile tahmin edilmiştir. Elde edilen sonuçlar karşılaştırılmış ve bazı performans ölçütlerine göre iki yöntemin başarısı test edilmiştir.
Wong (1991)	Yapay sinir ağları yöntemini zaman serilerinin tahmini için kullanmıştır. Ağ zaman serileri için girdi verileri olarak kullanılan zamana bağlı olarak bilginin elde edilmesini sağlamıştır.
Refenes ve arkadaşları (1994)	Yapay sinir ağları, borsa hisse senetlerinin gelişimini tahmin etmek için klasik istatistiksel tahmin yöntemleri yerine kullanılmıştır.
Cottrell ve arkadaşları (1995)	Doğrusal olan ve olmayan istatistiksel tahmin yöntemlerini yapay sinir ağları yöntemi ile birleştirerek hibrit bir yöntem elde etmeye çalışmıştır. Geliştirilen model diğer istatistiksel yöntemlerle karşılaştırılmıştır.
Hill ve arkadaşları (1996)	Aynı veri seti için önce zaman serileri yapay sinir ağları yöntemi ile analiz edilmiş. Daha sonra istatistiksel zaman serileri ile modellenmiştir. Elde edilen sonuçlar belli kriterler baz alınarak karşılaştırma yapılmıştır.

Zhang (2003)	Hem ARİMA hem de yapay sinir ağları modellerini birleştiren bir hibrit metodoloji önermiştir. Gerçek veri setleriyle yapılan deneysel sonuçlar, birleştirilmiş yöntemin; ayrı ayrı kullanılan yöntemlerden herhangi birinin elde ettiği tahmin doğruluğunu arttırmanın etkili bir yolu olabileceğini göstermiştir.
Zahrani ve Abo-Monasar (2015).	Yapay sinir ağları ve zaman serisi modellerinin birleşik tekniği mevcut günlük su tüketimi tahmini iklim verilerine dayanarak ele alınmıştır.
İnce ve Çakır (2017)	NASAÇ borsa tahmininde ARİMA ve yapay sinir ağları modelleri kullanılmıştır.
Çam ve arkadaşları (2017)	ARCH modeli; GARCH modeli ve yapay sinir ağları kullanılarak petrol fiyatlarındaki meydana gelen değişiklik 2 Ocak 2008- 23 Ekim 2017 dönemleri için tahmin edilmiş, hangi değişkenin bu değişime daha çok etkisi var tespit edilmiştir.
Özden ve Öztürk (2018)	Klasik zaman serileri analiz yöntemi ve yapay sinir ağları kullanılarak Türkiye'deki bir endüstri bölgesi için enerji ihtiyaç tahmini yapılmıştır.
Ergül (2018)	Türkiye'deki iş kazaları sonucu gerçekleşen ölüm sayıları ve sürekli olarak iş göremezlik sayıları, hem Box-Jenkins tekniği ile hem de yapay sinir ağları modellenmiştir. Her iki yöntem sonucunda elde edilen tahminler karşılaştırılmıştır.
Papuçcu (2019)	Borsa endeksi hareketlerinin makine öğrenme algoritmalarından biri olan yapay sinir ağları ve diğerleri analizi yapılmıştır.

İKİNCİ BÖLÜM

YAPAY SİNİR AĞLARINA GİRİŞ/GENEL BAKIŞ

2.1. YAPAY SİNİR AĞLARI GENEL TANIMI

İnsan beyninin işleyişinden ve biyolojik sinir hücresinden ilham alınarak geliştirilen yapay sinir ağları, öğrenebilen ve öğrendiğini işleyebilen bir yapıdır. (Widrow ve diğerlerinden aktaran, Zhang ve diğerleri, 1997: 35). Diğer bir ifade ile biyolojik sinir ağlarına benzer performans özellikleri gösteren bir bilgi işleme sistemidir (Fausentt, 1994: 3). Ağın önemli olan özelliklerinin temelinde öğrenme yapısının olması vardır. Elde olan problemin çözümü için, çok fazla miktardaki etkileşimli parçacıkların belirli bir düzenle çalışmasını mümkün kılmaktadır. Ağ örnekler ile öğrenir ve öğrendiği bilgi ile sınıflandırma, örüntü tanıma, tahmin yaparak kişiye çözüm üretir (Cura, 2008: 19).

Yapay sinir ağları, girdiler ve çıktılar arasındaki ilişkileri, biyolojik ağların yapısına ve işlevine dayanarak, insan beyninin öğrenmesini taklit ederek doğrusal olmayan ve karmaşık problemleri çözen bilgi işleme sistemidir. İnsan beyninin çözümleyemeyeceği sorunların çözümü için geliştirilen bu teknik sayesinde birçok karmaşık problem çözümlenebilir. Bunun için insan beyninin gerçekleştirdiği öğrenme, ilişkilendirme, sınıflandırma ve genelleme gibi fonksiyonları yaparak örneklerden deneyimler kazanabilir. Kazanılan deneyimler ile karar verme yapabilir (Öztemel,2016: 29). Özetle, yapay sinir ağları biyolojik bir sinir ağını simüle eden yeni bir algoritma mimarisidir (Graupe, 2013: 2).

2.2. YAPAY SİNİR AĞININ TARİHÇESİ

İnsan beyninin taklidini yaparak, bir sistem oluşturan ve sisteme öğrenme, hatırlatma ve genelleme yapma gibi yetenekler edinebilmeyi amaçlayan bilgi işleme sistemine yapay sinir ağları denir. Yapay zekâ son dönemlere damga vuran bir olgu olsa da temelinde yatan insan beyninin düşünme sistemini anlama, algılama ve açıklama isteği çok eski zamanlara ait bir istektir. Antik Yunana kadar uzanan bu isteğin ilk temel taşları Plato (İ.Ö. 427-327) ve Aristoteles (İ.Ö. 384-322) tarafından işlenmiştir. Sonrasında insanın düşünme kabiliyeti ile ilgilenen bir düşünür olan

Decartes (1596-1650) ile devam etmiştir. Yüzyıllardır süregelen merak duygusu bilim adamları tarafından beynin yeteneklerinin modellenebilmesine çalışmalarına bir kapı açmıştır. Fiziksel bileşenlerin doğru bir biçimde bir araya getirilmesi ile yapay olan modeller geliştirilmiştir. İlk yapay hücre ve ağ modellerinden sonra günümüz teknolojileri yardımıyla yapay sinir ağlarının algoritmik yapıları oluşturulmuştur (Kunt, 2014: 43).

İnsan beyninin çalışma prensibi ile ilgili ilk bilimsel eser 1890'lı yıllarda William James tarafından ortaya atılmıştır. 1940 yılından önce de yapay sinir ağları yönelik bazı çalışmalar yapılmıştır ancak bunların mühendislik değeri yoktur. Gerçek bir nöronun basit parametrik doğrusal olmayan hesaplama modelini öneren ağlar ile ilgili ilk çalışma W.S. McCulloch ve W.A. Pitts'in tarafından 1943 yılında başlamıştır. İnsan beyninin işlevlerinden biri olan hesaplama ve analiz yeteneğinden ilham alarak elektrik devrelerini kullanarak bu hücreyi geliştirmişlerdir. 1949 yılında Hebb öğrenme kavramı ile ilgili temel teoriyi anlatan bir kitap yazmıştır. Hebb'in kitabında yer alan "Hebb kuralı" ile hem sinir ağının bağlantı sayısı ile öğrenebilme hem de uyum sağlayabilmenin ilişkili olduğu tespit edilmiştir. Hebb'in kitabından sonra (1950'den sonra) bazı araştırmacılar Hebb kuralından ve teorisinden faydalanarak yapay sinir ağının etkinliğini arttırabilmek adına çalışmalar yapmıştır (Zurada, 1992: 18-20; Larsen, 1999:5-6; Keskenler, Keskenler, 2017: 11-13).

Yaşanılan gelişmelerin paralelinde 1956 yılında ortaya atılan yapay zekâ kavramı oldukça dikkat çekti. Ancak gelişen yapay zekâ çalışmaları yapay sinir ağlarından bağımsız olarak ele alınmıştır. Dikkat çeken yapay zekâ çalışmaları yapay sinir ağlarının da yerini almaya başlamıştır. Bu durum 1960 yılına kadar devam etmiş, ancak bu yıldan sonra Rosentblatt, Kohonen, Widrow, Nilssons, Grosberg, Fukushima gibi bilim adamları tarafından tekrar yapay sinir ağları çalışmaları başlatılmıştır. Widrow ve Hoff 1959 yılında Stanford Üniversitesinde ADALINE (Adaptive Linear Neuron) ve MADALINE sinir ağını önerdi. Bu ağlar mühendislik uygulamalarındaki ilk ağlar olup sonraki uygulamalarında temelini oluşturmuştur. Rosenblatt, 1960 yılının başlarında, algılayıcılardan oluşan katmanlı bir sinir ağı ve bu ağın istenen bir görevi yerine getirebilmesi amacıyla tek katmanlı algılayıcı ağın parametrelerini ayarlamak için bir algoritma önermiştir. Buradaki sinir ağının özelliği tek katmanlı, eğitilebilen ve tek bir çıkışa sahip olmasıdır.

ADALINE sinir ağı modeli Rosentblatt'ın algılayıcı modeli ile aynı özelliklere sahiptir ancak ADALINE modelinin öğrenme algoritması daha gelişmiştir. Widrow, sinir işleme ağlarının sinyal işleme içinde kullanılmasına öncülük etmiştir. Bununla birlikte, 1969'da Minsky ve Papert tarafından yapılan çalışma, tek katmanlı algılayıcı ağın basit bir görevi yerine getiremediğini ve çok katmanlı algılayıcı ağların ağırlıklarını ayarlamak için algoritmaları kullanamadıklarını göstermiştir ki bu gelişim için çok önemli olmuştur. Çünkü bu ifade, yapay sinir ağlarının bilimsel bir değerinin olmadığı ve doğrusal olmayan problemlere çözüm geliştiremediği anlamına gelmektedir. Minsky ve Papert öne attığı bu tezi desteklemek amacıyla da çalışmalarda bulunmuştur. 1965'ten 1984'e kadar devam eden dönemde, birkaç araştırmacı tarafından, daha öncü çalışmalar yapılmıştır. Sun-Ichi Amari (1972, 1977) tarafından sinir ağının eşik elemanları ve matematiksel teorisi üstünde çalışmalar yapılmıştır. Ayrıca Japonya'da Kunihiro Fukushima, 'neocognitrons' olarak bilinen bir sinir ağı mimarisi sınıfı geliştirmiştir. Görsel örüntü tanıma için bir model olan Neocognitron, biyolojik olabilirlik ile ilgilidir. Ağ retinal görüntüleri taklit eder ve iki boyutlu nöron katmanını kullanarak bunları işler. 1982'den 1986'ya kadar olan dönemde, sinir ağlarının potansiyelini önemli ölçüde artırıcı etkiye sahip birçok aydınlatıcı yayın yayınlanmıştır. John Hopfield (1982, 1984) ile yeni bir dönem başlamıştır (Zurada, 1992: 19). John Hopfield sinir ağlarının bilgisayar yazılımı ile çözülmesi zor kompleks olan problemlere çözümler üretebileceğini ispatlamıştır. Gezgin satıcı problemini yapay sinir ağları ile çözmesi ile bu ispatın en iyi örneği olmuştur (Zurada, 1992: 18-20; Larsen, 1999:5-6; Keskenler, Keskenler, 2017: 11-15).


Alanın yeniden canlanması, 1986'da James McClelland ve David Rumelhart (1986) tarafından düzenlenen Rumelhart'ın paralel programlama çalışmalarını içeren ve iki cildin yayını ile gerçekleşmiştir. Bu çalışmada tanıtılan yeni öğrenme kuralları ve diğer kavramlar, 1960'lı yılların ortalarında genel çabalarını temel alan, ağ eğitim engellerinden birini ortadan kaldırmıştır. McClelland ve Rumelhart tarafından yayınlanan bir zamanlar katmanlı ağların önceden tahmin edilemeyen bilgi işlem potansiyeli için yeni bir çağ açtı. Katmanlı ağların yeni eğitim programına ilişkin matematiksel çerçeve 1974'te Paul Werbos tarafından keşfedilmesine rağmen, o zaman büyük ölçüde fark edilmemiştir. Bu konu ile ilgili Dreyfus'un 1990'da yaptığı son açıklamalara göre, çok katmanlı ileri beslemeli sistemler için optimizasyon

yaklaşımının ilk yazarları 1969'da çok kademeli ağ eğitimi için gradyan bir çözüm elde eden Bryson, Ho ve Kelley idi. Ancak bu çalışmalar sinir ağlarının öğrenme algoritmaları için olgunlaşmamış ve benimsenememiştir. 1986 ve 1987 yıllarının başlarında birçok yeni yapay sinir ağı araştırması başlatılmıştır. Nöro-bilgisayar disiplini ile olan araştırmaların yoğunluğu, konferans gibi daha birçok alana yayılmıştır (Zurada, 1992: 20).

2.3. BİYOLOJİK SİNİR AĞININ YAPISI

İnsanlar çevresinden aldığı veriyi işler ve bilgi haline getirir. Bu bilgiler ile kararlar alabilir, problemlere çözümler üretebilir. İnsanda öğrenme işleminin nasıl gerçekleştiği tam olarak tanımlanamasa da örnekler verilerek somutlaştırılabilir. Örneğin bir bebeğin konuşmayı öğrenmesi buna verilebilecek en güzel örnektir. Yeni doğmuş bir bebek konuşamaz hatta sesleri bile çıkaramaz ancak zamanla çevresinde olan insanlar aracılığı ile kelimeler öğrenmeye başlar. İlk denemelerinde anlamsız hatta çoğu zaman anlaşılması o kadar güç sesler çıkarır ki ifade edilmeye çalışılan kelimenin tam olarak ne olduğunu anlamak zordur. Zamanla tekrar edilen kelimeler anlaşılır ve bebek için kolay ifade edilebilir olur. Gün geçtikçe söylemek istediği kelimeyi ve diğer kelimeleri daha rahat söyleyebilen bebek, bir zaman sonra konuşabilir. Bu aşamada bebeğin konuşmasına en büyük katkı anne ya da babanın kelimenin nasıl söyleneceğini bebeğe anlatması olur. Ancak belirli bir yaşa geldikten sonra, yeni duyduğumuz ve anlamını bilmediğimiz kelimeleri öğrenebilmek ya da tekrarlayabilmek için hala bebek gibi birinin anlatmasına gerek kalmaz. Özellikle kişinin kendi dilinden olan kelimeleri ilk kez duysa bile söyleyebilme yeteneği vardır. Bu yetenek sayesinde kişinin beyni ve dili artık sonuç üretebilir durumdadır. Örnekten de anlaşılacağı üzere “Öğrenme” sürecinin en önemli aşaması örnekler olmuştur (Çakır, 2018: 4-6). Öğrenmeyi gerçekleştiren biyolojik sinir hücrelerinin yapısı Şekil 1.'de gösterilmiştir. Bilgi akışının oklarının gidiş yönüne doğru ilerlemektedir.

Şekil 1: Biyolojik Bir Sinir Ağının Gösterimi



Kaynak: Jan Larsen, 1999: 3.

Gerçek sinir hücresi insan beynindeki biyolojik ağların bir parçasıdır. İşleyişin ana merkezi olan sinir hücresinde fonksiyonların yerine getirilebilmesi için tüm hücrelerin birbiri ile bağlantı içinde olması gerekmektedir. Hücreler arası bağlantılarda, hücrenin tüm parçacıkları (akson, sinaps, dendrit) görev almaktadır. Sinapslar hücrelerin aksonlarının diğer dendritlerle olan bağlantısıdır. Başka hücrelerden gelen sinyaller sinapslar yoluyla bir diğer hücreye aktarılır. Hücreden hücreye bilgi akışını gerçekleştirir. Dendritler tıpkı bir ağaç dalı gibi dallanır ve nöronun hücre çekirdeğinden gelen sinyalleri alır, sinapslara iletir. İnce ve uzun yapıda olan aksonlar sinyallerin daha iyi iletilmesine amacıyla dendritlere yol açmaktadır (Kriesel, 200: 16-18). Aksonlar bir bağlantı teli olarak görülebilir (Graupe, 2013: 5).

Özet olarak biyolojik sinir ağının yapısı ve yapay sinir ağı elemanları birbirine karşılık gelecek şekilde aşağıda Tablo 2'deki gibi adlandırılabilir (Elmas, 2011:33).

Tablo 2: Biyolojik Sinir Ağı Ve Yapay Sinir Ağı'nın Karşılaştırılması


Biyolojik Sinir Ağı	Yapay Sinir Ağı
Sinir Sistemi	Sinir Hesaplama Sistemi
Sinaps	Düğüm (Sinir, İşlem Elemanı)
Dendrit	Sinirler Arası Bağlantı Ağırlıklar
Hücre Gövdesi	Toplama İşlevi
Akson	Sinir Çıkışı

Kaynak: Çakır, 2018: 22

2.4. YAPAY SİNİR AĞININ ELEMANLARI

Yapay sinir ağlarında da biyolojik sinir hücrenin içerdiği yapıya benzer bir yapı bulunmaktadır. Biyolojik yapıda işleyişi devam ettirmek için görev alan bileşenlerin, benzer görevde bileşenler tarafından yapı içinde işleyişi devam ettirdiği görülmektedir (Graupe, 2013: 1). Şekil 2’de görüldüğü üzere basit bir ağ hücresi girdiler, ağırlıklar, toplama işlevi, aktivasyon ve çıkıştan oluşmaktadır. Şekil 2 üzerinde X_i ile gösterilen birim girdilerin; W_i ile gösterilen birim ise ağırlıkların olduğu birimdir. Girdiler ve ağırlıklar ağın en başında belirlenen parametrelerdir. Girdilerin her biri ağırlıklar ile çarpılarak toplanır. Toplama işlemi ile ağırlıklar girdilerin matematiksel değerlerini değiştirir. Toplama da bir de eşik değer denilen (b_i) sayısı bulunmaktadır. Eşik değer ağın algılayabileceği sınırı verir. Toplama işlemi de ağın kullanıcısı tarafından belirlenir. Toplama işlemi sonucunda bulunan değer, yine ağın kullanıcısı tarafından belirlenen aktivasyon fonksiyonunda işleme tabi tutulur. İşlem sonrasında elde edilen değer ise y_i yani çıkış değeridir. Her bir girdi değerine karşılık gelen bir de çıkış değeri bulunmaktadır. Giriş değerlerinin sayısı ve çıkış değerlerinin sayısı kullanıcı tarafından belirlenir. Ağda kullanıcının istediği sayıda çıktı elde edebilmek mümkündür. Ağa verilen sayı çıkış sayısı kadar sonuç üretilir (Yavuz ve Deveci, 2013: 170).

Şekil 2: Yapay Sinir Ağlarının Genel Yapısı



Kaynak: Yavuz ve Deveci, 2013: 170.

2.4.1. Girdiler

Dış dünyadan gelen bilgileri toplayan, örnek verilerin bulunduğu katman girdi katmanıdır. Bu katmanda dışarıdan gelen girdi sayısı yani örnek sayısı kadar sinir hücresi bulunur. Girdiler herhangi bir işleme tabi olmadan diğer katmana geçiş yapar (Rojas, 2013: 3-4). Ancak girdi katmanından gelen bilgiler diğer katmanlara aktarıldığında veriler işleme tabi tutulabilir (Çakır, 2018:20).

2.4.2. Ağırlıklar

Yapay hücreye gelen bilginin ne derece öneme sahip olduğunu gösteren ağırlıklar gelen bilginin nöron üzerindeki etkisini de gösterir. Ağırlıkların küçük ya da büyük bir rakamsal değerinin olması ağırlığın önemli veya önemsiz olduğu anlamına gelmez. Ayrıca bir ağırlığın değerinin sıfır olması bulunduğu ağ için önemsiz olduğunu göstermez bilakis sıfır değerini alan ağırlık o ağ için önemli bir ağırlık da olabilir. Ağırlığın artı-eksi olması pozitif-negatif etkiyi gösterirken, sıfır olması herhangi bir etkiyi göstermemektedir (Öztemel, 2016: 49). Ağırlıklar vasıtasıyla girdinin üretilen çıktı üzerindeki etkisi ayarlanabilmektedir (Kubat, 2017: 668).

2.4.3. Toplama Fonksiyonu

Bir hücreye gelen net girdi toplama fonksiyonu tarafından hesaplanır. Bu amaç doğrultusunda birçok toplama fonksiyonu bulunmaktadır. Yaygın bir kullanım alanına sahip fonksiyonların başında ağırlıkla toplamı bulmak yer alır. Girdi değerlerinin her biri kendi ağırlığı ile çarpılarak toplanır böylelikle ağa gelen net girdi miktarı bulunmuş olur (Öztemel, 2016: 49). İlgili fonksiyonun formülleştirilmiş hali aşağıdaki verilmiştir:

$$NET = \sum_{i=1}^n W_i * X_i$$

Yapay sinir ağları da her zaman yukarıda verilen formül kullanılması şartı yoktur. Kişi kendisi seçim yapabildiği gibi bazı ağ modellerinde ağ kullanacağı toplama fonksiyonu belirleyebilmektedir. Bazen gelen girdilerin değeri önem teşkil ederken bazen de gelen girdilerin sayısı önem teşkil edebilmektedir. Ancak bir problem için en uygun toplama fonksiyonunun belirlenebileceği bir kural ya da formül bulunmamaktadır. Bunun için uygun toplama fonksiyonun seçilmesi deneme yanılma yolu ile olabilmektedir. Literatürde toplama fonksiyonu olarak kullanılan fonksiyonların örnekleri Tablo 3'te verilmiştir (Öztemel, 2016:49; Çakır, 2018: 22).

Tablo 3: Toplama Fonksiyonu Örnekleri

Net giriş	Açıklama
<i>Çarpım</i> Net Girdi = $\prod_{i=1}^n X_i * W_i$	Girdilerin her biri (birinci girdiden n. girdiye kadar) kendisine verilen ağırlık değerleri ile çarpılır ve daha sonra bulunan değerler birbiri ile çarpılarak net girdi hesaplanır.
<i>Maksimum</i> Net Girdi = $\max_{i=1 \dots n} (X_i * W_i)$	Girdilerin her biri (birinci girdiden n. girdiye kadar) kendisine verilen ağırlık değerleri ile çarpılır. Çıkan sonuçlar girdiler içinden en büyüğü yapay sinir hücresinin net girdisi olarak kabul edilir.
<i>Minimum</i> Net Girdi = $\min_{i=1 \dots n} (X_i * W_i)$	Girdilerin her biri (birinci girdiden n. girdiye kadar) kendisine verilen ağırlık değerleri ile çarpılır. Çıkan sonuçlar girdiler içinden en büyüğü yapay sinir hücresinin net girdisi olarak kabul edilir.

<i>Çoğunluk</i> Net Girdi=$\sum_i \text{sgn}(X_i * W_i)$	Girdilerin her biri (birinci girdiden n. girdiye kadar) kendisine verilen ağırlık değerleri ile çarpılır. n adet girdi sonucu içinden pozitif ve negatif olanların sayısı bulunur. Büyük olan sayı hücrenin net girdisi olarak kabul edilir.
<i>Kümülatif toplam</i> Net Girdi=Net(eski)+ $\sum_{i=1 \dots n} (X_i * W_i)$	Ağın hücreğine gelen bilgiler ağırlıklı olarak toplanır ve daha önce gelen bilgilere eklenerek hücrenin net girdisi bulunur.

Kaynak: Çakır, 2018: 22

Birleştirme fonksiyonu olarak da ifade edilen toplama fonksiyonu sonucunda hesaplanan değer, doğrusal ya da doğrusal olmayan, türevlenebilir bir aktivasyon fonksiyonuna iletilir (Kubat, 2017: 668).

2.4.4. Aktivasyon Fonksiyonu

Girdi ve çıktı birimleri arasındaki eğrisel eşleşmeyi sağlayan fonksiyon aktivasyon fonksiyonudur. Doğru olarak seçilmiş bir aktivasyon fonksiyonu ağın performansını etkilemektedir (Hwang ve Ding'ten aktaran Yavuz ve Deveci, 2013: 171). Toplama fonksiyonunda olduğu gibi bir problem için en uygun aktivasyon fonksiyonunun belirlenebileceği bir kural ya da formül bulunmamaktadır. Bunun için uygun aktivasyon fonksiyonun seçilmesi deneme yanılma yolu ile olabilmektedir. Ancak genellikle hatayı minimum yapan, günümüzde en yaygın kullanılan Çok Katmanlı Algılayıcı modelinde en çok aktivasyon fonksiyonu olarak Sigmoid fonksiyonu kullanılmaktadır (Öztemel, 2003: 50). Literatürde en sık kullanılan aktivasyon fonksiyonlar aşağıdakilerdir:

➤ **Lojistik Dönüştürme Fonksiyonu (Sigmoid Fonksiyon):** Bu fonksiyon bir nörondaki değer $[0,1]$ aralığında kalmasını sağlar. Bir tür hassaslık derecesi olarak kullanılan t parametresinin değeri araştırmacıya göre değişebilir. Fonksiyonun denklemi 1.1' de verilmiştir (Cura, 2008: 21).

$$g(x) = \frac{1}{1+e^{-x}} \quad 1.1$$

➤ Hiperbolik Tanjant Dönüştürme Fonksiyonu: Lojistik dönüştürme fonksiyonunda nörondaki değer $[0,1]$ aralığında iken, hiperbolik tanjant dönüştürme fonksiyonunda aralık değeri $[-1,1]$ olarak değişir (Cura, 2008: 21).

$$g(x) = \frac{e^{\frac{x}{t}} - e^{-\frac{x}{t}}}{e^{\frac{x}{t}} + e^{-\frac{x}{t}}} \quad 1.2$$

➤ Gauss Dönüştürme Fonksiyonu: Diğerlerine göre daha nadir karşılaşılan bu fonksiyon lojistik fonksiyondaki gibi değer $[0,1]$ aralığında kalmasını sağlar (Cura, 2008: 22).

$$g(x) = e^{-\frac{x^2}{2t}} \quad 1.3$$


➤ Hiperbolik Secant Dönüştürme Fonksiyonu: Bu fonksiyon türü de diğerlerine nazaran daha az rastlanmaktadır (Cura, 2008: 23).

$$g(x) = \begin{cases} 1 & x = 0 \text{ ise} \\ \frac{2}{e^x + e^{-x}} & \text{değilse} \end{cases} \quad 1.4$$

2.5. YAPAY SİNİR AĞLARI KATMANLARI

Yapay sinir ağları modeline ilişkin genel görünüm Şekil 3'te verilmiştir. Modelin görüntüsünden de anlaşılacağı üzere basit bir yapay sinir ağı, her biri farklı işlevleri gerçekleştirmek amacıyla bir araya getirilmiş üç katmandan (tabakadan) oluşmaktadır. Bu katmanlar, girdi katmanı, gizli katman ve çıktı katmanı olarak isimlendirilir. Katmanların her birinde, bilgi işleyişini sağlayan nöronlar bulunmaktadır. Her bir katmanın işleyiş açısından farklı görevleri bulunmaktadır. Bununla birlikte katmanlar da birbirleri ile iletişim halindedir. Gizli katmanın görevlerini yerine getirebilmesi için girdi katmanından verileri alması ve işlemesi gerekmektedir. Akabinde çıktı katmanında sonuçları görebilmek için gizli katmanda verilerin istenilen işlemlere tabi tutulması (aktivasyon fonksiyonu ile işlemlerin gerçekleştirilmesi) gerekmektedir. Böylelikle girdi ve çıktı katmanları arasındaki eğrisel ilişki sağlanabilmektedir (Akbiğç, 2011: 20). Katmanlara ilişkin bilgiler aşağıda verilmektedir.

Şekil 3: Yapay Sinir Ağlarının Katmanları



Kaynak: Akbilgiç, 2011: 20

2.5.1.Girdi Katmanı

Girdi katmanı, yapay sinir ağlarının dış dünya ile olan bağlantısını sağlayan ve bilginin ağa ilk kez gösterildiği bölüm olan katmandır. Ağa girdi olarak verilen değerler matematiksel olarak hiçbir işleme tabi tutulmazlar. Girdi katmanının görevi verileri gizli katmana ulaşımını sağlamaktır. Girdi katmanında bulunması gereken nöron sayısı, bağımsız değişken (girdi değişken) sayısı kadardır. Ayrıca bazı ağ modellerinde, regresyon analizindeki eğim katsayı (sabit terim) görevini gören ekstra bir nöron daha eklenmektedir. Bu nöron “yan” olarak adlandırılmaktadır ve yan nöronuna girilen bilginin sabit olarak 1 değerini aldığı varsayılmaktadır. Girdi katmanında bağımsız değişken değerleri ve varsa yan değeri hiçbir işleme tabi tutulmamaktadır (Akbilgiç, 2011:20-21).

2.5.2.Gizli Katman

Yapay sinir ağlarının “kara kutusu” olarak bilinen kısmı gizli katmandır. İlk katman olan girdi katmanından kendisine gelen bilgiyi işlenmektedir. Birden fazla alt katmandan oluşabilmektedir. Kullanıcı tarafından kaç alt katmandan oluşacağı ve her bir alt katmanda kaç nöron bulunacağı denemeler ile belirlenir. Literatürde bu katmana ait sayıların belirlenmesi ile ilgili birtakım öneriler bulunmaktadır. Ancak en iyi sonucu veren sayının denemeler yoluyla bulunabileceği görülmüştür. Basit yapay sinir ağları modellerinde girdi katmanı doğrudan çıktı katmanına bağlanabilmektedir. Bu tür ağlar bağımlı ve bağımsız değişkenler arasındaki doğrusal modelleri modelleyebilmekte ancak doğrusal olmayan ilişkiyi modelleyememektedir. Dolayısıyla ağın çözümü doğrusal olmayan modelleri kurabilme gücünü gizli katman vermektedir (Akbilgiç, 2011:21).

2.5.3.Çıktı Katmanı

Biyolojik nörondaki aksonların karşılığı da çıktı katmandır. Gizli katmanda işlenen verilerin, sonuç halinde dış dünyaya iletildiği katmandır. Bağlantılar ile kendisine gelen bilgiyi genellikle aynen çıktı olarak kullanan ağlar mevcut iken belirli bir eşik değer fonksiyonundan geçirerek dış dünyaya ileten ağlar da bulunmaktadır. Özellikle basit yapay sinir ağları modellerinde gizli katman bulunmadığı için çıktı katmanı nöronları eşik değer fonksiyonunu çıktı katmanında kullanmaktadır. Veri setindeki açıklanan (bağımlı) değişken sayısı kadar da nöron sayısı bulunmaktadır (Akbilgiç, 2011: 21).

2.6. YAPAY SİNİR AĞI AVANTAJLARI VE DEZAVANTAJLARI

➤ Yapay sinir ağları, klasik modellerin işleyişinden farklılıkları vardır. İstatistiksel modeller bağımlı değişken ile bağımsız değişken arasındaki ilişkinin teorisini bilinmesini ve parametre dağılımları hakkında varsayımları gerekli kılmaktadır. Bu da değişkenler arasındaki ilişkinin varsayılan modele uymayan durumlarında oluşmasına neden olmaktadır. Dolayısıyla, varsayımların eksik ya da

sağlanamadığı durumlarda yapay sinir ağları parametrik istatistiksel yöntemlerden daha iyi sonuçlara ulaşabildiği söylenebilir. Ancak ağın birçok parametreye sahip olmasına ve gizli katmanların doğasına istinaden net bilgilerin bulunmaması sebebiyle bu durum kesin değildir (Aras, 2013:13).

➤ Yapay sinir ağının bütün parçaları (yapay sinir hücreleri) aynı anda çalışmaktadır. Bu özellik sayesinde, yapay sinir ağlarını diğer geleneksel araçlardan daha hızlı hareket edebilmektedir (Yakut, 2012:107).

➤ Yapay sinir ağları zaman serileri içindeki kompleks ve doğrusal olmayan fonksiyonu temsil edebilme yeteneği istenilen sonuçlara yakınsayabileceğini göstermiştir. Ekonometrik ve istatistik modellerinin model tabanlı olmasına karşıt yapay sinir ağları veri sürüşlüdür. Bağımlı ve bağımsız değişkenler arasında herhangi bir kısıtlayıcı varsayım istememektedir. Varsayımın olmaması da araştırmacılar tarafından cezbedilen bir yöntem haline gelmesini sağlamıştır (Aras, 2013:13).

➤ Yapay sinir ağları fazla kompleks ve doğrusal olmayan ilişkileri temsil edebilir. Veri desenlerinin bağımsız olarak değişmesine rağmen bir olayın farklı durumlardaki sonuçlarını tespit edebilir. Doğru ölçümlere sahip olduğumuz veriler için anlaşılması güç bir olayın içinde gerçekleşen problemlerde bile ideal bileşenler arasında değişimleri otomatik olarak yerine getirebilir. Verilerdeki ilişkiler hakkında yeterli bilgiye sahip değilsek, kullanılacak uygun bir yöntemdir (Aras, 2013:14).

➤ İnsan düşüncelerinden oluşan, hatalı tanımlanmış kategorilerden oluşan girdi verilerinde ağın gücü önem teşkil etmektedir. Eğer verilecek olan karar için örneklerin tanımlanması zor ise, beşerî bir araştırmayla keşfedilemeyecek örneklerin yapay sinir ağı tarafından keşfedilebilmesi diğer bir artıdır. Veriler modele uygun olmadığı zamanlarda bile ağ adaptasyon yeteneği ile avantajlıdır (Cura, 2004: 9).

➤ Yapay sinir ağlarının diğer yöntemlere göre önemli bir eksiliği giriş ve çıkış değişkenlerinin ikiye ilişkilerinin bilinmemesidir. Değişkenler arasında direkt olarak bir ilişki yapılamaması belirsizlik oluşturmuştur. Bütün yapay sinir ağlarının bir kara

kutu olmasından kaynaklanan bu durum başlıca sebeptir. Bu yüzden ağ herhangi bir problemle ilgili üretilen çözümün nasıl ve neden üretildiği konusunda açık ve net bir bilgi vermemektedir. Bu da ağın ürettiği sonuca olan güveni azaltıcı bir etkidir (Yakut, 2012:107).

2.7. YAPAY SİNİR AĞLARINDA PERFORMANS ÖLÇÜTLERİ

Kurulan modelin sonuçlarının değerlendirilmesi için gerekli olan performans ölçütlerinin belirlenmesidir. Performans ölçütleri ağın verileri arasındaki ilişkiyi ne derece öğrendiği diğer bir ifade ile ağın gerçek değere ne kadar yakınlık gösterdiğini ifade eder (Yakut, 2012:106).

2.7.1. Hata Kareler Ortalaması-HKO (Mean Squared Error-MSE)

$$HKO = \frac{1}{n} \sum_{i=1}^n (t_i - g_i)^2 = \frac{1}{n} \sum_{i=1}^n (e_i)^2$$

t_i = i'inci birimin tahmin değeri,

g_i = i'inci birimin gerçek değeri

e_i =tahmin hatası

HKO'nın karekökü alınarak Hata Kareler Ortalamasının Karekökü elde edilebilir. Hata Kareler Ortalamasının Karekökü (Root Mean Squared Error-RMSE) de aynı performans sonucunu verdiği için aynı şekilde değerlendirilebilir.

2.7.2. Hata Kareler Toplamı-HKT (Sum Squared Error-SSE)

$$HKT = \sum_{i=1}^n (t_i - g_i)^2 = \sum_{i=1}^n (e_i)^2$$

t_i = i'inci birimin tahmin değeri,

g_i = i'inci birimin gerçek değeri

e_i =Tahmin hatası

2.7.3. Ortalama Mutlak Hata Yüzdesi-OMHY (Mean Absolute Percentage Error-MAPE)

Ortalama Mutlak Hata Yüzdesi-OMHY, istatistikte ve trend analizi tahmininde zaman serileri değerlerinin bulunmasında doğruluk ölçüsü olarak kullanılan bir yöntemdir. Aşağıdaki formül ile yüzde olarak oran cinsinden tahminin doğruluğu açıklanmaktadır:

$$OMHY = 100 * \left\{ \frac{1}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \right\}$$

A_t = t'ninci birimin gerçek değeri,

F_t = t'ninci birimin tahmin değeri

2.8. YAPAY SİNİR AĞI ÇEŞİTLERİ

Yapay sinir ağları belirli durumlara göre çeşitlilik göstermektedir. Ağ modelleri kullanılan veriye bağlı olarak (bir ağın öğrenmesi gereken giriş-çıkış bilgilerine bağlı olarak); ağın yapısına, öğrenme biçimine ve kullanılan algoritmalarına göre (yapay sinir hücreleri arası ilişkilerle ifade edilen mimarilerine) ve öğrenme zamanına göre üç ana belirleyici ölçüte göre farklılık göstermektedir (Atalay, 2015: 42).

2.8.1. Mimarisine Göre Yapay Sinir Ağı Çeşitleri


Mimarisine yani yapısına göre üç çeşit yapay sinir ağları bulunmaktadır. Bunlar “İleri Beslemeli Ağlar”, “Geri Beslemeli Ağlar”, “İleri Beslemeli Geri Yayılımlı Ağlar” olarak adlandırılır.

➤ İleri Beslemeli (Feed – Forward) Ağlar

Birden fazla katmandan (girdi katmanı, çıktı katmanı, gizli katman) oluşan ileri beslemeli ağlarda her bir katmanda en az bir nöron bulunmaktadır. Girdi katmanında

bulunan varsayımsal nöronlara değer aktaran hiçbir nöron yoktur. Daha öncesinde nöronların olamamasından dolayı bu katmanda nöronlara herhangi bir dönüşüm fonksiyonu uygulanmaz. Ağda kullanılan aktivasyon fonksiyonuna göre, gizli katmanda işlemler yapılır. Her bir nöron sırayla kendinden önce gelen bilgiyi kendinden sonra gelen nörona aktarır. Ayrıca çıktı katmanındaki nöronlarda dönüştürme fonksiyonu kullanılabilir (Cura, 2008: 23).

Şekil 4: İleri Beslemeli Yapay Sinir Ağlarının Genel Görünümü




Kaynak: Cura, 2008: 24

➤ Geri Beslemeli (Feed – Back) Ağlar

Geri beslemeli ağlardaki durum ileri beslemeli ağların tam tersi olarak işlemektedir. Ağdaki tüm nöronlar birbirleriyle bağlantı içindedir. İlk kez Hopfield tarafından kullanılan ağlar aynı isimle de literatürde yer almaktadır. Bu mimari bazı optimizasyon yöntemlerinin çözümünde kullanılmaktadır (Cura, 2008: 31). Ağdaki mantık, çıkış ve gizli katmanlardaki çıkışların giriş birimlerine veya önceki gizli

katmanlara geri gönderilmesidir. İleri beslemenin tam tersi olan bu durum geriye doğru bir akışı mümkün kılmaktadır. Ayrıca sinyaller hem ileri hem de herhangi bir nöronun çıkışından girişine aktarılabilir (Yegnanarayana'dan aktaran Atalay, 2015: 43).

Şekil 5: Geri Beslemeli Yapay Sinir Ağlarının Genel Görünümü




Kaynak: Cura, 2008: 31

➤ İleri Beslemeli Geri Yayılımlı Ağlar

Geri yayılma kuralı, ağ içinde var olan hata düzeyine göre katmanlarının her birindeki ağırlıkları yeniden hesaplamak için kullanılır. Geri yayılım hem bir katmandaki hücreler arasında hem de katmanlar arasındaki hücreler arasında yapılabilmektedir. Böylelikle ağ doğrusal olmayan dinamik bir yapı haline gelir. Aynı katmandaki sinir hücrelerinin birbirleri ile bağlantısı yoktur. Katmandaki sinir hücrelerinin her biri, bir ileri katmandaki sinir hücrelerinin her birine ayrı ayrı bağlıdır. Yani hem ileri besleme hem de geri yayılım mevcuttur. Ağdaki ileri besleme ve geriye yayılım birleşimi, ağı daha güçlü, dirençli ve daha az karmaşık hale getiriyor. İleri beslemenin ve geri yayılımın avantajları sayesinde ağ daha hızlı eğitilebiliyor. Ağ içindeki hata düzeylerine göre da katmanların ağırlıkları yeniden hesaplanması ağın kullanışlı kılmaktadır (Utkun, 2014: 274, Çetin ve diğerleri, 2006: 2).

Şekil 6: Çok Katmanlı İleri Beslemeli Geri Yayılımlı Yapay Sinir Ağlarının Genel Görünümü



Kaynak: Atalay, 2015: 44

2.8.2. Öğrenme Algoritmalarına Göre Yapay Sinir Ağı Çeşitleri

İnsan beyni, düşünme ve gözlemlene gibi eylemler aracılığıyla, öğrenme, hafızaya alma ve veriler arasında ilişki kurabilme, bu ilişkiyi ortaya çıkarabilme gibi yeteneklere sahiptir. İnsanlar doğal yeteneği sayesinde yaşayarak veya deneyimleyerek öğrenebilmektedir. Biyolojik sistemlerdeki öğrenmenin benzeri yapay sinir ağlarında mevcuttur. İnsanların öğrenme adımları bebeklerde, çocuklarda ve yetişkinlerde yaklaşık olarak aynı aşamalardan geçer. Gözlemlenmek, deneyimlemek ve tekrarlar ile öğrenme olayı gerçekleşir. Yapay sinir ağlarının öğrenme süreci de tıpkı dış ortamdan uyarıların alınması öğrenmesinin sağlandığı gibi olur. Dış ortamdan veriler (girişler) alınır, bu veriler (girişlerin) beyin merkezine iletilerek burada işlenir daha sonrasında değerlendirilip tepki verme gerçekleşir. Yapay sinir ağında da girdi katmanı ile girişler yapılır, gizli katmanda işlemler gerçekleşir ve son olarak da aktivasyon fonksiyonundan geçirilerek bir tepki çıkışı üretilir (Çuhadar, 2006: 120).

Sinir ağlarındaki verilerin çıkışa doğru ilerlemesi sonucunda “öğrenme” ya da “eğitim” denilen çıktı süreci gerçekleşmiş olur (Tezer, 2018:12). Öğrenme durumunun matematiksel olarak fonksiyon ile ifade ediliş biçimi aşağıda verilmiştir.

Öğrenme durumu;

X_i girdisi ağa girer,

$$y_i = f(w, x) = f(w^T x) = \left(\sum_{j=1}^n w_{ij} x_j \right) \quad (\text{Ocakoğlu, 2006: 20}).$$

$w_i = (w_{i1}, \dots, w_{in})^T \in R^n$ ağırlık vektörüdür,

$f(w^T x)$ etkinlik işlevidir. Ağ değerlerinin belirlenmesi giriş vektörleri ile olur.

$$ağ = (w^T x) = w_1 x_1 + w_2 x_2 + \dots + w_n x_n$$

$$y_i = ağ$$

Ağın çıkış değeri “ Ω ” olarak adlandırılan eşik düzeyi ile karşılaştırılıp ilerleme sağlanır. Örneğin, “ $\Omega = 1$ ” ele alınırsa;

$$y_i = f(ağ) = \begin{cases} 1 & \text{eğer } w^T \\ 0 & \text{eğer diğer} \end{cases}$$

(Tezer, 2018:13).

Ağ tasarımı yapılırken tanımlanması istenilen diğer parametreler;

w_i = ilk ağ ağırlığı

ϵ = giriş hata değeri

d = düzeltme katsayısı

Ağın $f(w^T x) > \Omega$ değerine ulaştığı kabul edilirse ağ çıkışa yönelir. İstenilen değer “ t_i ” gerçek değer “ g_i ” olarak ifade edilirse, hata istenilen değer ile gerçek çıkış değeri arasındaki fark olarak hesaplanır.

$$\text{hata} = e_i = (t_i - g_i)$$

$$d = \text{düzeltme katsayısı} = \Delta w_i = (e_i + \epsilon) d$$

$$\text{Eğer } g_i = 0 \text{ ve } t_i = 1 \text{ ise } w_i = (w_i + \Delta w_i)$$

Eğer $g_i = 1$ ve $t_i = 0$ ise $w_i = (w_i - \Delta w_i)$ şeklinde yeni döngünün ağırlık değerleri güncellenir. Böylelikle ilerleme gerçekleşmiş olur (Öztemel, 2012:37).

Öğrenme algoritmalarına göre ağ çeşitleri dört grup olarak ele alınmaktadır. Bunlar “Öğretmenli Öğrenme”, “Danışmansız Öğrenme”, “Destekleyici Öğrenme” ve

“Karma Öğrenme” olarak adlandırılmaktadır (Öztemel, 2012:25). Aşağıda öğrenme algoritmalarına ilişkin bilgiler verilmiştir.

➤ Öğretmenli Öğrenme (Supervised Learning)

Bu tür öğrenmelerde, yapay sinir ağı kullanılmadan önce bir öğretmen tarafından eğitilmektedir. Öğretmen kurulan ağa, öğrenilmesi beklenen olay ile ilgili örnekleri girdi veya çıktı veri setleri olarak gösterir. Diğer bir ifade ile her bir örnek için girdiler ve her bir girdinin karşılığındaki çıktı değeri ağa ağa verilir. Ağın görevi verilen bu girdiler ve çıktılar üzerinden öğretmenin belirlemiş olduğu çıktıları haritalandırmaktır. Böylelikle olayın girdileri ve çıktıları arasındaki bağlantı kurulabilir ve ilişkiler öğrenilebilir (Öztemel, 2016: 25).

➤ Danışmansız Öğrenme (Unsupervised Learning)

Bu tür öğrenmelerde, yapay sinir ağı kullanılmadan önce bir öğretmen tarafından eğitilmesine gerek yoktur. Ağa çıktı değerleri gösterilmeden sadece girdi değerleri gösterilir ve ağın kendi kendisine öğrenmesi istenilir. Bu tür öğrenme genelde sınıflandırma problemleri için kullanılır. Kullanılan ağın öğrenmesi tamamlandıktan sonra, çıktıların ne anlama geldiğini gösteren etiketlendirme ağı kullanan kişi tarafından yapılmalıdır (Öztemel, 2016: 25).

➤ Destekleyici Öğrenme (Reinforcement Learning)

Bu tür öğrenmelerde, yapay sinir ağı kullanılmadan önce, ağın öğrenmesine öğretmen (destekleyici) yardımcı olmaktadır. Öğretmen kurulan ağa, öğrenilmesi beklenen olay ile ilgili örnekleri girdi veya çıktı veri setleri olarak direkt göstermek yerine, ağın kendisine gösterilen girdilere karşılık ürettiği çıktıların doğru veya yanlış olduğunu gösteren sinyaller üretir. Gerçek değere yakın ise farklı bir sinyal, uzak ise farklı bir sinyal ile ağa bir çeşit verilen kopya ile öğretme yapar. İstenilen hataya yaklaşıp kadar öğrenme devam eder (Öztemel, 2016: 25).

➤ Karma Öğrenme

Yukarıdaki üç öğrenme türünden birkaçının birleştirilmesi ile elde edilen öğrenme türüdür. Örneğin öğretmenli öğrenme ve destekli öğrenme biçimleri

birleştirilerek karma öğrenme elde edilebilir. Radikal tabanlı ağlar ve olasılık tabanlı ağlar karma öğrenmenin örneklerindendir (Öztemel, 2016: 25).

2.8.3. Öğrenme Zamanına Göre Ağ Çeşitleri

Öğrenme zamanına göre ağ çeşitleri iki grup olarak ele alınmaktadır. Bunlar “Statik Öğrenme” ve “Dinamik Öğrenme” olarak adlandırılmaktadır (Atalay, 2015:49).

➤ Statik Öğrenme

Yapay sinir ağını kullanılmadan önce eğitilirse statik öğrenme gerçekleşmektedir. Eğitim bitiminde kullanıcı ağı istediği gibi kullanabilir. Eğitim ve öğrenme bittiği için kullanım esnasında ağın üzerindeki ağırlıklarda değişiklik yapmak mümkün değildir (Atalay, 2015:49).

➤ Dinamik Öğrenme

Dinamik öğrenme yapay sinir ağının çalıştığı süre boyunca öğrenmesini mümkün kılmaktadır. Ağın eğitim aşaması tamamlandıktan sonra da ağırlıklar değiştirilebilir. Değişim her aşamada mümkün olduğundan öğrenmesi dinamik bir yapı göstermektedir (Atalay, 2015:49).

2.9. YAPAY SİNİR AĞLARI KULLANIM ALANLARI

Widrow, Rumelhart ve Michael (1994) yapay sinir ağlarının kullanım alanlarını doğrusal olan ve doğrusal olmayan olarak ele almıştır. Elmas’a göre (2011) uygulamaların birçoğu aşağıdaki sınıflardan birine girmektedir:

- Öngörü
- Sınıflandırma
- Veri birleştirilmesi
- Veri kavramlaştırılması
- Veri süzülmesi
- Resim ve görüntü işleme

2.9.1. Doğrusal Yapay Sinir Ağı Uygulamaları

Uyarlanabilir sinir ağlarının ilk başarılı uygulamaları 1960’larda Widrow ve Hoff tarafından geliştirilmiştir. Widrow ve Hoff LMS algoritması tarafından eğitilmiş tek nöronlu lineer ağlar kullanmıştır. Eğitilmesi ve kullanımı kolay olan bu tür ağlar son yıllarda yaygın bir uygulama alanı bulmuştur. Bu alanlardan bazıları aşağıda verilmiştir (Widrow ve diğerleri 1994; 93).

- Telekomünasyon (Dijital verilerin telefon kanallarından hızlı ve doğru bir şekilde iletilmesi için kullanılmaktadır).
- Ses ve Titreşim Kontrolü (Titreşim ve gürültünün aktif kontrolü ve eşit, karşıt titreşim ve gürültü üretimi için kullanılmaktadır).
- Parçacık Hızlandırıcı Işını Kontrolü (Karşıt pozitron kırılgarlığının konumlandırma doğruluğunu azaltan sorunları gidermek için kullanılmaktadır).

2.9.2. Doğrusal Olmayan Yapay Sinir Ağı Uygulamaları

Lineer olmayan çok elemanlı sinir ağlarının başarılı ticari uygulamaları birçok durumda geri yayılım algoritmasına dayanmaktadır (Widrow, Rumelhart, Michael, 1994; 94-98; Elmas, 2011: 161-164).

- Kredi Kartı Sahtekarlığı Tespiti (Amerika’daki American Express, First USA Bank gibi birçok banka tarafından kredi kartındaki sahtekarlığın tespit edebilmek amacıyla kullanılmaktadır).
- Makine Tarafından Basılan Karakterleri Tanıma (Mitsubishi Electric Corp, Verifone Inc gibi şirketler tarafından ‘Sharp’s Optical Character Recognition Systems’ benzer bir sistem kullanılmaktadır).
- İmalatta Kalite Kontrolü (Endüstride kalite kontrolü için kullanılmaktadır).
- Tıbbi Uygulamalar (Kanserli hücrelerin yerlerini belirleyebilmek amacıyla kullanılmaktadır).
- Finansal Tahmin ve Portföy Yönetimi (Büyük yatırımların ar-ge araştırmalarında tahminlerinde, ödünç para risk incelemesinde kullanılmaktadır).

- Kredi Onayı (Ticari bankalar kredi kartı şirketleri, ticari borç verme kuruluşları tarafından kredi işlemlerinde karar verici olarak; şirket kredi riskini değerlendirmek için kalıp analizi ve sinir ağlarını kullanan bir hibrit sistem kullanılmaktadır).
- Emlak Analizi (Emlak fiyatlarının tahmini ve analizi için kullanılmaktadır).
- Pazarlama Analizi (Pazar araştırmalarında tahmin için kullanılmaktadır)
- Havacılık Sektörü (Havayolu oturma düzenin belirlenmesi, bagajda tehlikeli maddelerin anlaşılması gibi işlemlerde kullanılmaktadır).
- Petrol Rafinerisi İşlem Kontrolü (hem rafineri işlemlerinde hem de yer altındaki gaz ve petrol alanlarının tespitinde kullanılmaktadır).
- Otomotiv Uygulamaları (Özel bir kara taşıtının sürücüsüz olarak seyrinin gerçekleştirilmesinde kullanılmaktadır).
- Elektrik Motoru Arıza Tahmini (Motor sorunlarında erken uyarı alabilmek için kullanılmaktadır).
- Endüstriyel Uygulama (İşlem denetim sistemi olarak ürün geliştirmede ve ürün kalitesinin yükseltilmesinde kullanılmaktadır).
- Biyomedikal Uygulamalar (RNA ve DNA incelenmesinde, hastalara verilen ilaç karşısında hastaların tepkisini incelemeye, hastalık tanımlarında kullanılmaktadır.)
- İlaç Geliştirme (İlaçların hayvanlar üzerinde denenip verdikleri tepkiler ile daha az maliyetli ve zaman tasarruflu ilaç geliştirmede kullanılmaktadır).
- İletişim Sanayi (Telefon hatlarının ve belge geçerlerin güncellenmesinde; hatlar üzerinde olabilecek yankıların giderilmesinde kullanılmaktadır).

ÜÇÜNCÜ BÖLÜM

ZAMAN SERİLERİ ANALİZİ

3.1. ZAMAN SERİLERİ GENEL TANIMI

Herhangi bir olaya ilişkin gözlemlerin zamana göre sıralı bir şekilde düzenlenmesi ile elde edilen veriler zaman serisini oluşturmaktadır. Serinin belirli bir zaman aralığında, gözlemlenmiş olan olaya ilişkin, bilgiler elde edilmesi zaman serileri analizi olarak tanımlanabilir (Kaynar, Taştan 2009; 162). Her seri zaman serisi olma özelliğini taşımamaktadır. Bir serisin zaman serisi olarak nitelendirilebilmesi için zamana bağlı bir durumun olması gerekmektedir. Bir değer bir önceki değerden etkilenmesi, diğer bir ifade ile bir değer bir önceki değerden bağımsız olarak ele alınması o değerler serisinin zaman serisi olmadığı anlamına gelmektedir. Ayrıca bir değer kendinden önceki değerden etkilenmiş ise iki değer bir zaman serisi oluşturmaz. Özetle zaman serisi olarak nitelendirilen serilerin her bir değerinin bir önceki değerden etkilenmesi ve bu durumun zamana bağlı olması gerekmektedir (Seker, 2015: 23-24).

3.2. ZAMAN SERİLERİ ANALİZİ

Serinin belirli bir zaman aralığında, gözlemlenmiş olan olaya ilişkin, bilgiler elde edilmesi zaman serileri analizi olarak tanımlanabilir. Geçmiş zaman dilimlerinden oluşan bir veri dizisi yardımıyla geleceğe yönelik tahminler yapmayı ve stokastik olan bu süreci modelleyebilmeyi amaçlayan yöntemdir (Kaynar, Taştan 2009; 162). Zaman serisi analizinde amaç verilerin zamana bağlı değişimleri incelemektir. Zaman ilerledikçe verilerde meydana gelen değişim gözlenmek istenildiği gibi “zaman” olgusunun da kendi içindeki değişim önemli olabilmektedir. Örneğin bir çağrı merkezine gelen çağrı sayısı incelenmek istendiğinde, gün içinde gelen çağrı sayısı günün belli saatlerinde fazla; günün belli saatlerinde ise az olmaktadır. Bu da çağrı merkezine gelen çağrı sayısının zamana bağlı olarak değişim gösterdiği anlamına gelmektedir (Seker, 2015: 23-24). Box -Jenkins zaman serileri için kullanılan tekniklerden biridir. Ancak bu teknikte sadece bir serinin geçmiş dönemlerinden yararlanılmaktadır (Hamzaçebi ve Kutay, 2004: 228).

3.3. REGRESYON TEKNİĞİ İLE ANALİZ

Regresyon, bir veya daha fazla değişkenin başka bir değişken ile ilişkisinin incelenebilmesi için modellenen bir modeldir. Değişkenler arasında sebep-sonuç ilişkisi barındırması gerekmektedir. Regresyon tekniğinde bağımlı değişken açıklanan değişken olarak, bağımsız değişken(ler) ise açıklayıcı değişken(ler) olarak adlandırılmaktadır. İki değişken arasındaki bu ilişkiyi açıklayabilmek için doğrusal ve doğrusal olmayan matematiksel formlardan yararlanılabilir. Amaç o konu ile ilgili tahminlerde bulunabilmek veya kestirimler yapabilmektir (Şahinler, 200:57; Hamzaçebi ve Kutay, 2004; 240). Montgomery'e göre etkinin incelenmesi için en çok kullanılan istatistiksel teknik, regresyon analizidir. Mühendislik, fiziksel ve kimyasal bilimler, ekonomi, yönetim, yaşam-biyolojik bilimler ve sosyal bilimler dahil olmak üzere hemen hemen her alanda regresyon analizi kullanımı görülmektedir (Douglas C. M., Elizabeth A. P., Geoffrey G.V., 2012).

3.3.1. En küçük Kareler Yöntemi İle Tahmin Formülasyonu

Amaç gözlemlerin birbirine doğrudan uzaklıklarının karelerinin toplamının en küçük yapılmasına dayanmaktadır. Minimizasyon için yapılan işlemler de bu doğrultuda oluşturulmuştur (Şenesen Ü., Şenesen G.G., 2014:55).

Ana kütle için regresyon doğrusu, 2.1. olarak tanımlanırsa bu denklemdeki β_i 'lerin birebir gözlenmesi mümkün değil. Bu yüzden β_i 'lerin tahminleri (örneklem üzerinden elde edilen tahmini β_i 'ler) ile denklem 2.2. formunda ifade edilir.

$$Y_i = \beta_1 + \beta_2 X_i + u_i \quad 2.1$$

$$Y_i = \hat{\beta}_1 + \hat{\beta}_2 X_i + \hat{u}_i \quad 2.2$$

$$Y_i = \hat{Y}_i + \hat{u}_i \quad 2.3$$

$$\begin{aligned} \hat{u}_i &= Y_i - \hat{Y}_i \\ &= Y_i - \hat{\beta}_1 - \hat{\beta}_2 X_i \end{aligned} \quad 2.4$$

$$\begin{aligned}\Sigma \hat{u}_i^2 &= \Sigma (Y_i - \hat{Y}_i)^2 \\ &= \Sigma (Y_i - \hat{\beta}_1 - \hat{\beta}_2 X_i)^2\end{aligned}\tag{2.5}$$

Denklem 2.5 eşitliğini minimize eden parametre tahmincilerin değerlerini bulabilmek için eşitliğin parametrelere göre türevlerinin alınması ve sıfıra eşitlenmesi gerekmektedir.

$$\frac{\partial}{\partial \hat{\beta}_1} \Sigma \hat{u}_j^2 = \frac{\partial}{\partial \hat{\beta}_1} \Sigma (\hat{Y}_i - \hat{\beta}_1 - \hat{\beta}_2 X_i)^2\tag{2.6}$$

$$\Sigma y_i = n\hat{\beta}_1 + \hat{\beta}_2 \Sigma X_i\tag{2.6.1}$$

$$\frac{\partial}{\partial \hat{\beta}_2} \Sigma \hat{u}_j^2 = \frac{\partial}{\partial \hat{\beta}_2} \Sigma (\hat{Y}_i - \hat{\beta}_1 - \hat{\beta}_2 X_i)^2\tag{2.7}$$

$$\Sigma Y_i X_i = \hat{\beta}_1 \Sigma X_i + \hat{\beta}_2 \Sigma X_i^2\tag{2.7.1}$$

2.6.1 ve 2.7.1 de belirtilen denklem sisteminde eş anlı çözüm yapıldığında parametrelere ait tahmin değeri elde edilmiş olur.

$$\hat{\beta}_1 = \bar{Y} - \hat{\beta}_2 \bar{X}\tag{2.8}$$

$$\hat{\beta}_2 = \frac{\Sigma xy - \frac{(\Sigma x) \cdot (\Sigma y)}{n}}{\Sigma x^2 - \frac{(\Sigma x)^2}{n}}\tag{2.9}$$

3.3.2. En küçük Kareler Yöntemi Varsayımları

Basit doğrusal regresyon analizi tahminlenmesi için kullanılan yöntemlerin için en yaygın olanları “En Küçük Kareler” ve “En Yüksek Olabilirlik” yöntemidir. Hata karelerini minimize etmeyi amaçlayan bu iki yöntemde katsayıları tahmini

yapıldığında benzer sonuçlar verdiği görülmektedir (Şenesen Ü., Şenesen G.G., 2014:55).

Regresyon analizi modele dayalı bir yöntem olduğu için belirli varsayımların sağlanması gerekmektedir. Bağımlı ve bağımsız değişkenlerin taşınması gereken özelliklerin yanı sıra hata teriminin de taşınması gereken özellikler bulunmaktadır. Bu özellikler regresyona it varsayımları da oluşturmaktadır. En küçük kareler yönteminin varsayımlarını aşağıda verilmiştir (Tarı, 2018: 22-27; Myers, 1990: 9-12; Weisberg S., 1985: 204-226).

1. u_i hata terimi olarak tanımlanırsa, u_i ortalaması sıfır stokastik bir değişken olma özelliği taşımaktadır. Hangi değeri alacağı önceden bilinmeyen, aldığı değerler şansa bağlı olarak ortaya çıkan “rassal”, “tesadüfi” bir değişkendir. Bağımsız değişkenlerin tamamının modele alınamaması, modelin matematiksel biçiminin yanlış seçilme durumu, değişkenlere ait ölçümlerin hatalı ölçümlemesi, insanların doğası gereği farklılık göstermesi gibi nedenlerden dolayı hata terimi oluşmaktadır. Hata terimi negatif ve pozitif değerlerden oluşmakta ve bahsedilen sebeplerin toplamından meydana gelmektedir. Bundan dolayı şansa bağlı olarak değişmekte ve değerleri önceden bilinmemektedir.


2. Hata terimi normal dağılıma sahip olmalıdır. Regresyon katsayılarının anlamlılıkları ile ilgili test uygulamak gerektiği için hata teriminin dağılımının normal olması gerekmektedir. Hatalar kendi ortalamaları etrafında normal dağılım eğrisi şeklinde simetrik bir dağılım göstermektedir. Hata teriminin normal dağılıp dağılmadığı, Lilliefors grafik testi, Ki kare Uygunluk testi ve Jarque-Bera ile test edilebilir.

3. Hata teriminin birbirini izleyen değerleri arasında ilişki (otokorelasyon) yoktur. Diğer bir ifade ile hata teriminin i . değeri kendinden önceki ya da sonraki j . değeri ile bağımlı değildir. İlişkinin olmaması hata terimlerinin birbirini etkilemediğinin göstergesidir. Bu varsayım gereği herhangi iki hata terimi arasındaki kovaryans sıfıra eşittir.

4. Hata teriminin varyansı sabit olup sıfıra eşittir. Literatürde bu durum eşit varyanslılık olarak da adlandırılmaktadır. Varyans, bağımsız değişkendeki değişimlere karşılık değişmeyip sabit kalmaktadır. Diğer bir ifade ile varyans bağımsız

değişkenin bir fonksiyonu değildir. Şekil 7’de hata terimlerinin varyanslarının eşit dağılımının geometrik olarak bir örneği verilmiştir.

Şekil 7: Hata Terimlerinin Eşit Varyanslı Dağılışı



Kaynak: Wooldridge J. M. 2012: 53

5. Bağımsız değişkenin hata terimi ile ilişkisi yoktur ve stokastik değildir. Otokorelasyonda olduğu gibi ilişkinin olmaması kovaryansların sıfıra eşit olduğu anlamına gelmektedir. Bu varsayım sağlandığı takdirde bağımsız değişkenin bağımlı değişken üzerinde etkisi bireysel olarak belirlenebilir .

6. Bağımsız değişkenin tekrarlı örneklerle göre sabit olması gerekmektedir. Yani aynı bağımsız değişken değerleri için aynı bağımlı değişken değerleri söz konusudur.

7. Bağımsız değişkenin varyansı sonlu ve pozitif bir sayı olmalıdır. Bağımsız değişkenin değerlerinin sabit kabul edilmesi, tüm değerlerinin birbirine eşit olduğu anlamına gelmemektedir. Ancak bağımsız değişkenin değerlerinin eşit olması tüm bağımsız değişken değerlerinin ortalamadan farkının toplamının sıfır olması demek olduğu için tahmincilerin tahmini sadece varyansın sonlu olması ile mümkün olmaktadır.

8. En küçük kareler yöntemi varsayımların en önemlilerinden biri model spesifikasyonunun doğru yapılmış olduğudur. Model seçimi yapılırken doğrusal

ilişkiler baz alınıp doğrusal bir model kurulduğunda eğrisel ilişki söz konusu ise model formunda hata yapılmış demektir. Modele gerekli olan değişkenlerin alınmaması da spesifikasyona neden olan diğer bir unsurdur. Tüm bu sebepler kurulan modelin güvenilir olmayacağı anlamına gelmekte bu yüzden de dikkat edilmesi gerekmektedir.

9. Bağımsız değişkenler arasında ilişkinin olmaması birden fazla bağımsız değişkeni olan modeller için geçerli bir var sayıdır. Bağımsız değişkenler arasındaki ilişkinin varlığı çoklu doğrusal bağlantı sorununu beraberinde getirmektedir. Bu da istenen bir durum değildir.


Bağımlı ve bağımsız değişken için de aşağıda belirtilen gereklilikler söz konusudur (Osborne J., Waters E. 2002:1).

1. Regresyonun en önemli varsayımlarından biri bağımlı değişkenin dağılımının normal olmasıdır. Normal şartlarda hataların normal dağılımlı olması bağımlı değişkenin de normal dağılımlı olması anlamına gelmektedir Verilerin normal olmaması, aykırı-uç değerleri içermesi, basıklığın veya çarpıklığın çok büyük olması anlamlılık testlerini bozabilir. Normallik analizi birçok yöntemle yapılabilmektedir. Bunlar; normallik testi olan Kolmogorov, Smirnov testi ile incelenebileceği gibi, görsel olarak (P-P grafikleri ve basıklık çarpıklık değerlerinin incelenmesiyle yapılabilmektedir. İki değişkenli ya da çok değişkenli veri temizleme özellikle çoklu regresyonda çok önemli bir yere sahiptir. Veri temizliği ile aykırı – uç değerlerin çıkarılması Tip 1 ve Tip 2 hatalarının olasılığını azaltabileceğini ve tahminlerin doğruluğunu iyileştirebileceğini göstermektedir (Osborne J., Waters E. 2002:1-2).

2. Bağımlı ve bağımsız değişkenler arasında istatistiksel olarak anlamlı doğrusal bir ilişki olmalıdır. Standart lineer tek/çok değişkenli regresyon analizi ancak değişkenler arasındaki ilişki doğrusal ise doğru olarak kullanılabilir. Doğrusal ilişki korelasyon analizi ve grafikler ile incelenebilir. Lineer bir form kullanılmayacaksa doğrusal olmayan ilişkinin varlığı araştırılmalıdır. Doğrusal olmayan ilişkileri saptayabilmenin üç temel yolu Cohen, Pedhazur, Berry ve Feldman gibi araştırmacılar tarafından önerilmektedir. Birinci yöntem önceki araştırmacılar tarafından ortaya konulan teorilerin incelenmesidir. Analize başlamadan önce doğrusal olmayan ilişki için teoride bahsedilen ilişkiler incelenebilir. Ancak önceki araştırmacılar da doğrusal olmayan ilişkilerin olasılığını göz ardı edebileceğinden

kusursuz bir yöntem sayılmamaktadır. İkinci yöntem ise artık hataların incelenmesi yöntemidir. Birçok yazılım programında kolayca hesaplanabilen standartlaştırılmış değerlerin bir fonksiyonu olarak standartlaştırılmış artıklar incelenebilir. Şekil 8’de eğrisel ve doğrusal ilişkiyi gösteren dağılım diyagramında noktaların olduğu form incelendiğinde sağ taraf eğrisel ilişkiyi; sol taraf ise doğrusal ilişkiyi göstermektedir. Eğriselliği inceleyebilmenin son yöntemi de eğrisel bileşenlerin parçası olan karesel ve kübik formlar ile çalışmaktır. Yani doğrusal olmayan regresyon seçeneği ile çalışılırsa değişkenler arasındaki ilişki doğrusal olmayan yönleriyle de en iyi biçimde değerlendirilmiş olmaktadır. Böylelikle değişkenler arasındaki ilişkinin doğrusal mı yoksa eğrisel mi olduğuna karar verilebilmektedir (Osborne J., Waters E. 2002:1-2).

Şekil 8: Hataların Dağılımı



Kaynak: Osborne J., Waters E. 2002: 2

3. Değişkenler hatasız ölçümlenmiş varsayılır. Sosyal bilimler araştırmaların niteliği ve ilgilenilen birçok değişkenin de ölçülmesi zor olması sebebiyle ölçüm hatasını belli bir endişe kaynağı haline getirdiği anlamına gelmektedir. Bu kaygının gereği verilerin elde edilmesi aşamasında maksimum dikkat sarf edilmelidir. Yanlış, güvenilirmez ölçümlenmiş verilerin analiz sonuçları basit korelasyon ve regresyonda, Tip 2 hata riskini artırır ve ilişkilerin düşük tahmin edilmesine neden olur (Osborne J., Waters E. 2002:2).

DÖRDÜNCÜ BÖLÜM

UYGULAMA

4.1. UYGULAMAYA GİRİŞ

Uygulamanın amacı, ekonomik rasyolar arasındaki ilişkinin tahmini için kullanılan regresyon analizinden daha iyi sonuç verebilecek bir yöntemle model tahmini yapmak. Böylelikle klasik regresyon analizinin varsayımlarının sağlanamadığı durumlarda aynı regresyon analizi gibi neden sonuç ilişkisi gerektiren değişkenler için kullanılabileceğini göstermektir. Literatürdeki daha ileri seviye ağlar neden sonuç ilişkisini bile gerektirmeyen değişkenler için kullanılabilen sonuçlar üretilebileceğini göstermiştir (Elmas, 2011:162). Sonuçlara gerçeği en iyi yansıtacak yöntem ile ulaşılması, iki değişkenin ilişkisine dair ileriye dönük kararlar verilmesinde yol gösterici olacağı düşünülmektedir.

Regresyon, istatistik biliminde çok kullanılan tekniklerin başında gelmektedir. Ayrıca regresyon problemlerine yapay sinir ağları yaklaşımı birçok bilim adamı tarafından kullanılan bir yöntem olmuştur. Araştırmacılar ağın işleyişini regresyon modelleri ile arasındaki ilişkiyi açıklayarak anlamaya çalışmışlardır. Çalışmalarda doğrusal, doğrusal olmayan, basit/çoklu, parametrik olan/ olmayan lojistik, gibi birçok regresyon modeli ile karşılaştırılmıştır (Güneri N., Apaydın A, 2004: 176).

4.2. DEĞİŞKENLERİN SEÇİLMESİ VE VERİ SETİNİN HAZIRLANMASI

Doğrusal regresyon analizi için belirli varsayımların sağlanması gerekmektedir. İkinci bölümde bahsedilen varsayımlardan biri olan iki değişken arasında ilişkinin bulunması, değişken seçimi yapılırken dikkat edilen unsurlardan ilkidir. Bu yüzden değişkenlerin seçimi yapılırken bu unsur göz önünde bulundurulmuştur.

Araştırma değişkenleri seçiminin ilk adımını makale taraması oluşturmaktadır. Literatürde zaman serileriyle çalışılmış değişkenler incelenmiştir. Bununla beraber Granger Nedensellik analizi yapılmış, değişkenler arası nedensellik ilişkisi belirlenmiş olan ikili gruplar incelenmiştir.

Aktaş, Türkiye'nin 1996-2006 yılları arasındaki verilerle ihracat, ithalat ve ekonomik büyüme arasındaki nedensellik ilişkisi araştırılmıştır. Sonuçlar kısa dönemde ithalat, ihracat ve ekonomik büyüme arasında iki yönlü nedensellik ilişkisi olduğunu, uzun dönemde, ihracattan ithalata, ithalattan ihracata, büyümeden ihracata ve büyümeden ithalata doğru tek yönlü bir nedensellik ilişkisi olduğunu göstermiştir (Aktaş, 2009: 35).

Gül ve Ekici, Türkiye'de reel döviz kurları ile ihracat ve ithalat arasındaki etkileşimin varlığını ve yönünü Granger nedensellik testi kullanılarak araştırılmıştır. Sonuçlar incelendiğinde, reel döviz kurları ile ihracat ve ithalat arasında eş bütünleşme ilişkinin varlığı görülmüştür. Reel döviz kuru ile ihracat ve ithalat arasında bulunan nedensellik ilişkisi, ihracat ve ithalattan reel döviz kuruna doğru tek yönlü bir ilişki olduğu tespit edilmiştir (Gül ve Ekinci, 2006: 165).

Akkaş ve Öztürk, çalışmasında Türkiye'de ihracat, ithalat ve GSYH arasındaki nedensellik ilişkileri analiz etmiş akabinde ilgilenilen dönemde ekonomik büyümede ihracata dayalı büyüme teorisinin mi yoksa ithalata dayalı büyüme teorisinin mi geçerli olduğu test etmiştir. Makalede Hem Granger nedensellik hem de Toda-Yamamoto nedensellik testlerinden yararlanılmıştır. Sonuçlar incelendiğinde, GSYH'den ithalata çift yönlü, ihracata tek yönlü bir ilişki tespit edilmiştir (Akkaş ve Öztürk, 2016:1329).

Özer ve Erdoğan, Türkiye'de 1987-2006 yılları arasında reel ekonomik büyüme, ithalat ve ihracat arasındaki nedensellik ilişkisini incelemiştir. Granger nedensellik test sonuçları incelendiğinde değişkenler arasında tek yönlü bir nedensellik olduğunu, yani ihracattan ekonomik büyüme ve ithalata ve ithalattan ekonomik büyümeye doğru bir nedensellik ilişkisi olduğu tespit edilmiştir (Özer ve Erdoğan, 2006:255).

Bilgin ve Sahbaz, 1987-2006 yılları arasındaki aylık verileri kullanarak Türkiye için ihracat ve büyüme arasındaki ilişkiyi incelemiştir. Test sonuçlarına göre ihracata dayalı büyüme belirtilen dönem için doğrulanmıştır (Bilgin ve Sahbaz, 2009:177).

Korkmaz, çalışmasında Türkiye'nin toplam ihracat ve ekonomik büyüme değişkenleri arasındaki nedensellik ilişkisi araştırılmıştır. Sonuçlar değerlendirildiğinde ihracattan büyümeye doğru tek yönlü nedenselliğe rastlanmıştır.

Çalışmada literatüre uyum sağlayacak şekilde, ihracata dayalı büyüme hipotezini destekler nitelikte sonuçlar elde edilmiştir (Korkmaz, 2014: 161).

Çetintaş makalesinde büyüme oranı ve enflasyon arasındaki ilişkiyi ele almıştır. Makale içinde yer verilen geçmiş döneme ait araştırmaların bulguları incelendiğinde iki değişken arasında bir ilişki olduğu tespit edilmiştir (Çetintaş, 2003:141-152).

Nedensellik analizinin bir ileri düzeyi olan VAR tekniği ile yapılan analizlerde ele alınan değişkenler de incelenmiştir. Aktaş makalesinde döviz kuru ile ihracat ve ithalat arasındaki ilişkiyi VAR tekniği ile incelemiştir. Sonuçlara göre reel döviz kuruna karşı ithalat ve ihracatın tepkisiz kaldığı ancak reel döviz kurunun ithalat ve ihracata karşı tepkisiz kalmadığı sonucuna ulaşılmıştır. Ayrıca ithalatın, ihracatı önemli ölçüde etkilediği ve ihracatın da ithalata önemli ölçüde bağımlı olduğu sonucuna ulaşılmıştır (Aktaş, 2010:136). Bunun yanında geçmiş dönemlerde yapay sinir ağları ve regresyon tekniklerinin karşılaştırılmasında kullanılan değişkenler de incelenmiştir. Zaman serileri kendi başına bir olgu olmasından dolayı değişken seçiminde verilerin grafik üzerindeki seyri de incelenmiştir.

Literatürdeki çalışmaların özeti olarak, ilk model için ihracat ve ithalat değişkenleri uygulamanın bağımlı ve bağımsız değişkeni olarak seçilmiştir. İkinci model için reel döviz kuru da modele eklenmiştir. Aktaş'ın makalesinde reel döviz kuru tepkisiz kalmış ancak Tapşın makalesinde döviz kurunun hem ihracatı hem ithalatı etkilediği sonucuna ulaşılmıştır. Ülkemizde ihracatın, döviz kuru ve ithalat ile ilişkisinin nedensellik yönü ekonomik ve yönetsel açıdan değerlendirilmiştir. Yıllık veriler üzerinde yapılan çalışma sonucunda ithalat değişkenini ihracat değişkenine doğru bir ilişkisinin olduğu görülmüştür. Ayrıca ihracatı da dolaylı olarak etkilediği bulgusu elde edilmiştir (Tapşın G., Karabulut A, 2013: 190-205).

Veriler “Elektronik Veri Dağıtım Sistemi” üzerinden mevsimsel etkilerden arındırılmış halinde elde edilmiştir (EVDS, TÜİK üzerinden veri alan bir site olduğu için aslında verilerin temeldeki kaynağı TÜİK olarak verilebilir). Verilerin logaritması alınmıştır. Mevsimsel etkilerden arındırılmış verilerin durağan olup olmadığı kontrol edilmiştir. Durağan olmadığı anlaşılan veriler fark işlemi ile durağanlaştırılmıştır.

Verilerin analizi için Eviews 10.0 ve MATLAB R2019a programı kullanılmıştır.

İki model tasarlanmıştır. Birinci modelde sadece ithalat ve ihracat verileri değerlendirilmiştir. İkinci modelde ise döviz kuru, ithalat ve ihracat verileri kullanılmıştır. İstenilen zaman aralığında istenilen türde başka değişkenlere bazen ulaşılammış, ulaşıldığında da modelde çoklu doğrusal bağlantıya neden olmuştur. Bu yüzden regresyon analizine daha çok açıklayıcı değişken eklenememiştir. Ekonomik göstergelerin birbiriyle güçlü ilişki içinde olması regresyon tekniğini sınırlandıran bir sorundur. Çalışmada teorik olarak tasarlanan ekonometrik verilerin model sonuçları ile uygulama bölümünde değerlendirilmiştir.

Kurulan modellere ilişkin tahminlenen regresyon denklemi matematiksel olarak aşağıda verilmiştir. Formülasyonda Y bağımlı değişkeni, a sabit terimi, X_i ise bağımsız değişkenleri ifade etmektedir.

- Model1 için regresyon denklemi: $Y = a + bX_1$

Y: İhracat, X_1 : İthalat

- Model2 için regresyon denklemi: $Y = a + bX_1 + X_2$


Y: İhracat, X_1 : İthalat, X_2 : Döviz Kuru

4.3. UYGULAMA SONUÇLARI


Model1 için mevsimsel etkilerden arındırılmış verilerin hareketleri seyri Şekil 9'da verilmiştir. İhracat ve ithalat verilerin birbiri ile benzer hareketler gösterdiği, ortalama etrafında dağılmadığı yani durağanlıktan uzak olduğu görülmüştür. Grafiğin seyri incelendiğinde dalgalanmaların olduğu ancak 2009-2016 arasında daha kısa dalgalanmaların olduğu görülmektedir. 2008 ile 2009 yılı arasında altınca ayda ciddi anlamda bir düşüş yaşandığı görülmektedir. Ayrıca ithalattaki düşmenin ihracattan daha fazla olduğu tespit edilmiştir. Serinin bu tarihler arasında daha durağan olduğu tespit edilmiştir. Şekil 10'daki değişkenlere ait ilişki grafiği incelendiğinde, doğrusal bir ilişkinin olduğu gözle görülmektedir. Bunun yanı sıra iki değişken arasında istatistiksel olarak anlamlı pozitif yönlü ve doğrusal bir ilişkinin ($r=0,84$; $p<0,01$) olduğu tespit edilmiştir.

4.3.1. En Küçük Kareler Yöntemi İle Kurulan Birinci Model Sonuçları

Şekil 9: 2007-2017 Arası İhracat Ve İthalat Değerleri (Durağanlaştırılmamış)



Şekil 10: 2007-2017 Arası İhracat Ve İthalat Değerleri Dağılımı




Tablo 4: İhracat ve İthalat Değişkenleri İçin Birim Kök Testi Sonuçları

Birim kök		Seviye		1.Fark	
		ADF		ADF	
		t istatistik	p	t istatistik	p
İhracat		0,814	0,886	-18,82	0,000*
t kritik değeri	%1	-2,582			
t kritik değeri	%5	-1,194			
t kritik değeri	%10	-1,615			
İthalat		0,736	0,874	-15,33	0,000*
t kritik değeri	%1	-2,582			
t kritik değeri	%5	-1,943			
t kritik değeri	%10	-1,615			

* $p < 0,05$

Verilerin logaritması alındıktan sonra, birim kök varlığı ADF birim kök testi ile test edilmiştir. Buna göre serilerin sevide durağan olmadıkları ($p > 0,05$); ancak birinci farklarını alındığında durağan oldukları tespit edilmiştir ($p < 0,05$), (Tablo 4).

Şekil 11: 2007-2017 Arası İhracat Ve İthalat Değerleri (Durağanlaştırılmış)



Serilerin fark işleminden sonra grafik üzerindeki seyri incelendiğinde ortalama etrafında dağılım gösterdiği görülmektedir (Şekil 11).

Serilerde durağanlığın sağlanmasından sonra en küçük kareler yöntemi kullanılarak tasarlanan regresyon modelinin ilki kurulmuştur. Kurulan modelin sonuçları aşağıda denklemde verilmiştir (Tablo 5).

Tablo 5: En Küçük Kareler Yöntemi İle Kurulan Model1

Dependent Variable: FARKIH

Method: Least Squares

Date: 07/02/19 Time: 10:01

Sample (adjusted): 2007M02 2017M12

Included observations: 131 after adjustments


Variable	Coefficient	Std. Error	t-Statistic	Prob.
FARKIT	0.690745	0.068174	10.13213	0.0000
C	0.001589	0.007119	0.223201	0.8237
R-squared	0.443150	Mean dependent var		0.005697
Adjusted R-squared	0.438833	S.D. dependent var		0.108588
S.E. of regression	0.081344	Akaike info criterion		-2.165101
Sum squared resid	0.853581	Schwarz criterion		-2.121205
Log likelihood	143.8141	Hannan-Quinn criter.		-2.147264
F-statistic	102.6601	Durbin-Watson stat		2.908094
Prob(F-statistic)	0.000000			

Modeldeki anlamlılık incelendiğinde, kurulan modelin anlamlı olduğu tespit edilmiştir. Modelin hata kareler toplamı 0,8535 olarak elde edilmiştir. Modelde bağımsız değişkenin bağımlı değişkeni açıklama gücünü gösteren adjusted R-squared değeri de 0,438 bulunmuştur. İhracat değişkeninde meydana gelen değişikliğin %44'ü ithalat değişkeni tarafından açıklanabildiği görülmektedir (Tablo 5).

Modelin varsayımları gereği modelde değişen varyansın varlığı, hataların normal dağılımı ve otokorelasyon varlığı, incelenmelidir. Modeldeki tüm bu değerlerin anlamlı ve %95 güven düzeyinde kabul edilebilir olması için de varsayımların sağlanması gerekmektedir.

Şekil 12'de modele ait hataların ve gerçek değerler ile regresyon elde edilen değerlerin görsel hali mevcuttur. Genel anlamda gözle görülen bir uyum gerçekleşmiştir. Uyumun aksine büyük hatalarında seri boyunca var olduğu görülmektedir.

Şekil 12: Model1 Hata, Gerçek Ve Uyum Değerleri




➤ Hataların Normalliğinin Sınanması: Jarque-Bera normallik testi ile test edilebilir. Ayrıca hatalara ilişkin grafikler ile de görsel olarak incelemek normal dağılıp dağılmadığı araştırılabilir.

H_0 : Hatalar normal dağılımlıdır.

H_1 : Hatalar normal dağılımlı değildir.

Şekil 13. Model1 İçin Hataların Dağılımı



Jarque-Bera test istatistiğinin olasılık değeri incelendiğinde $p > 0,05$ olduğu ve H_0 hipotezi 0,05 hata payı ile reddedilemez olduğu görülmüştür. Sonuç olarak hataların normal dağıldığı görülmüştür (Şekil 13).

➤ Değişen Varyansın Varlığının Sınanması: En çok kullanılan testlerden biri White testidir.

H_0 : Değişen varyans yoktur.

H_1 : Değişen varyans vardır.

Tablo 6: Model1 İçin Değişen Varyans İçin White Testi Sonuçları

Heteroskedasticity Test: White
Null hypothesis: Homoskedasticity

F-statistic	0.554792	Prob. F(2,128)	0.5756
Obs*R-squared	1.125831	Prob. Chi-Square(2)	0.5695
Scaled explained SS	0.731723	Prob. Chi-Square(2)	0.6936

White test istatistiğinin olasılık değeri incelendiğinde $p > 0,05$ olduğu ve H_0 hipotezi 0,05 hata payı ile reddedilemez olduğu görülmüştür. Sonuç olarak sabit varyans olduğu görülmüştür (Tablo 6).

➤ Otokorelasyon Varlığının Sınanması: En çok kullanılan testlerden biri Breusch-Gogfrey Serial LM testidir. Bununla beraber grafiksel olarak da otokorelasyon incelenmiştir.

H_0 : Otokorelasyon yoktur.

H_1 : Otokorelasyon vardır.

Tablo 7: Model1 Otokorelasyonu İçin Breusch-Gogfrey Serial LM Testi Sonuçları

Breusch-Godfrey Serial Correlation LM Test:
Null hypothesis: No serial correlation at up to 1 lag


F-statistic	36.42232	Prob. F(1,128)	0.0000
Obs*R-squared	29.01871	Prob. Chi-Square(1)	0.0000

Breusch-Gogfrey Serial LM test istatistiğinin olasılık değeri incelendiğinde $p < 0,05$ olduğu ve H_0 hipotezi 0,05 hata payı ile reddedilebilir olduğu görülmüştür. Sonuç olarak otokorelasyon olduğu görülmüştür (Tablo 7).

4.3.2. Yapay Sinir Ağları Yöntemi İle Kurulan Birinci Model Sonuçları


Aynı veri seti için Matlab üzerinde yapay sinir ağları yöntemi ile eğri uydurma yapılmıştır. Veri setinin %80'i eğitim verisi, %10'u değerlendirme verisi ve %10'u test verisi olarak ele alınmıştır. Öğrenme algoritmalarından Levenverg-Marquardt'ın daha iyi sonuç verdiği denemeler ile görülmüştür. Gizli katman sayısı da denemeler sonunda 10 olarak belirlenmiştir. Analiz sonucunda elde edilen performanslar içinde, ortalama karesel hatası en küçük olan sonuç seçilmiştir. Elde edilen uygulama sonuçlarına ilişkin grafikler aşağıda verilmiştir.

Şekil 14: Model1 Oluşturulan Yapay Sinir Ağı Yapısı




Matlab üzerinde oluşturulan yapay sinir ağının mimarisi Şekil 14'te gösterilmiştir. Görüldüğü üzere 10 gizli katmandan ve bir girdi verisinden oluşturulmuştur.

Şekil 15: Model1 Eğitim, Değerlendirme Ve Test Veri Seti İçin Ortalama Karesel Hata




Oluşturulan ağ modeli 12 iterasyonda ortalama karesel hatayı minimum edecek sonuca ulaşmıştır (Şekil 15).

Şekil 16: Model1 Ağın Çıktısı ve Gerçek Değer Arasındaki Farklar




Eğitim, değerlendirme ve test veri setlerinde hataların büyüklüğünü, artı ya da eksi olduğunu görselleştiren Şekil 16’da, noktalara uzanan çizgiler hataları göstermektedir.

Şekil 17: Model1 Ağıın Çıktısı ve Gerçek Değerler Arasındaki Farkların Dağılımı



Ağın tahmin ettiği değerler ile gerçekleşen değer arasındaki farkların eğitim, değerlendirme ve test veri setlerindeki hataların dağılımını vermektedir. Örneğin eğitim veri setinde -0,1488 hata ile tahmin edilen değerlerin sayısının 4 olduğu görülmüştür (Şekil 17).

Şekil 18: Model1 Ağıın Çıktısı ve Gerçek Değere Uyumu



Ağın eğitim, değerlendirme ve test veri setleri için tahmin etmiş olduğu regresyon doğruları Şekil 18’de verilmiştir. Her bir grafikte yatay eksen gerçekleşen değeri; dikey eksen tahminlenen değeri gösterir. $Y=T$ doğrusu ağ sonucunda istenen durumdur. Grafikte üzerindeki noktalar $Y=T$ doğrusu üzerinde olması istenir. Tahminlenen değerlerin kesikli doğru üzerine yakın olması istenir. Kesikli olmayan doğru ile kesikli doğrunun eğitim, değerlendirme ve test veri setinde paraleliğe yaklaşması ağın uyumunun ve öğrenmesinin iyi olduğunu göstermektedir.

4.3.3. Birinci Model İçin En Küçük Kareler Yöntemi ve Yapay Sinir Ağları Sonuçlarının Karşılaştırılması


Tablo 8: Model1 Regresyon Analizi ve Yapay sinir Ağının Hata Kareler Toplamı

Zaman	Yapay Sinir Ağları	En Küçük Kareler
2018/1	0.005124	0.002201
2018/2	0.005473	0.00756
2018/3	0.008616	0.00759
2018/4	0.004867	0.000751
2018/5	0.002077	0.00255
2018/6	0.007869	0.014943
2018/7	3.88E-06	0.003512
2018/8	0.000134	0.043421
2018/9	0.004772	0.004784
2018/10	0.011179	2.48E-05
2018/11	0.000102	1.15E-06
2018/12	0.021963	0.000324
HKT	0.072181	0.087662

Elde edilen modeller ışığında, 2018 yılının 12 ayı için tahminler elde edilmiştir. Aylık olarak elde edilen tahmin sonuçları hem regresyon hem yapay sinir ağları için ayrı ayrı olarak incelenmiştir. Oluşturulan yapay sinir ağları test veri setinden hesaplanan hata kareler toplamı 0,07218 olarak elde edilmiştir. Aynı veri seti regresyon analizi için bulunan regresyon doğrusunda yerine konulunca elde edilen hata kareler toplamı 0,08766 olarak hesaplanmıştır. Yapay sinir ağları ile elde edilen hata kareler toplamı en küçük kareler yönteminde elden edilen değerden daha küçüktür (Tablo 8).


4.3.4. En Küçük Kareler Yöntemi İle Kurulan İkinci Model Sonuçları

Şekil 19: 2007-2017 Arası Reel Döviz Kuru Değerleri (Durağanlaştırılmamış)



Döviz kuruna ait grafiğin seyri incelendiğinde giderek azalan bir trendin ve konjektürel döngünün olduğu gözlemlenmiştir (Şekil 19). Veriler aylık olmasına rağmen döngüsünün periyodu daha uzun sürelidir.

Şekil 20: 2007-2017 Arası İhracat Ve Reel Döviz Kuru Değerleri Dağılımı



İhracat ile döviz kuru arasında negatif yönlü ve doğrusal bir ilişkinin olduğu görülmektedir ($r=-0,51$; $p<0,01$), (Şekil 20).


Tablo 9: Döviz Kuru Değişkeni İçin Birim Kök Testi Sonuçları

Birim kök		Seviye		1.Fark	
		ADF		ADF	
		t istatistik	p	t istatistik	p
Döviz Kuru		0,863	0,340	-8,676	0,000*
t kritik değeri	%1	-2,582			
t kritik değeri	%5	-1,194			
t kritik değeri	%10	-1,615			

* $p<0,05$

Reel döviz kurunun logaritması alındıktan sonra, birim kök varlığı ADF birim kök testi ile test edilmiştir. Buna göre serinin sevide durağan olmadığı ($p>0,05$); ancak birinci farkı alındığında durağan olduğu tespit edilmiştir ($p<0,05$), (Tablo 9).

Şekil 21: 2007-2017 Arası Reel Döviz Kuru Değerleri (Durağanlaştırılmış)



Serinin fark işleminden sonra grafik üzerindeki seyri incelendiğinde ortalama etrafında dağılım gösterdiği görülmektedir (Şekil 21).

Reel döviz kuru için de durağanlığın sağlanmasından sonra en küçük kareler yöntemi kullanılarak tasarlanan regresyon modelinin ikincisi kurulmuştur. Kurulan modelin sonuçları aşağıda denklemde verilmiştir (Tablo 10).

Tablo 10 : En Küçük Kareler Yöntemi İle Kurulan Model2

Dependent Variable: FARKIH				
Method: Least Squares				
Date: 10/20/19 Time: 20:18				
Sample (adjusted): 2007M02 2017M12				
Included observations: 131 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
FARKIT	0.692115	0.068396	10.11929	0.0000
FARKRDK	-0.157460	0.276886	-0.568684	0.5706
C	0.001265	0.007160	0.176680	0.8600
R-squared	0.444553	Mean dependent var		0.005697
Adjusted R-squared	0.435874	S.D. dependent var		0.108588
S.E. of regression	0.081559	Akaike info criterion		-2.152357
Sum squared resid	0.851429	Schwarz criterion		-2.086513
Log likelihood	143.9794	Hannan-Quinn criter.		-2.125602
F-statistic	51.22251	Durbin-Watson stat		2.907696
Prob(F-statistic)	0.000000			


Modeldeki anlamlılık incelendiğinde, kurulan modelin anlamlı olduğu tespit edilmiştir. Modelin hata kareler toplamı 0,8514 olarak elde edilmiştir. Modelde bağımsız değişkenin bağımlı değişkeni açıklama gücünü gösteren adjusted R-squared değeri de 0,445 bulunmuştur. İkinci değişken olarak eklenen döviz kuru değişkeninin modelde anlamlı bir etkisinin olmadığı tespit edilmiştir ($p>0,05$). Bu yüzden modele eklenen değişken modelin açıklama gücünde olağan bir artış olmamıştır. Buna karşın modelde hata kareler toplamında da çok küçük artış olmuştur (Tablo 10).

Döviz kuru değişkeni model içinde istatistiksel olarak anlamlı bir katsayıya sahip olmadığından model için kullanılabilir bir değişken değildir. Aslında gerçek değerlerin dağılım grafiği incelendiğinde iki değişken arasında negatif yönlü bir doğrusal bir ilişkinin varlığı görülmüştü. Ancak fark işleminden sonra bu ilişki kurulan modelde yansımamıştır. Tasarlanan ikinci modelde eklenen değişkenin modelden çıkarılması en küçük kareler yöntemi için doğru bir adım olmasına rağmen yapay sınır ağları ile karşılaştırma yapabilmek adına modelde bırakılmıştır.

En küçük kareler yöntemi ile kurulan regresyon modelin varsayımları gereği modelde değişen varyansın varlığı, hataların normal dağılımı ve otokorelasyon varlığı, incelenmelidir. Modeldeki tüm bu değerlerin anlamlı ve %95 güven düzeyinde kabul edilebilir olması için de varsayımların sağlanması gerekmektedir. Eklenen değişken ile varsayım kontrolü yapılmalıdır.

Şekil 22’de modele ait hataların ve gerçek değerler ile regresyon elde edilen değerlerin görsel hali mevcuttur. Kurulan birinci modeldekine benzer bir seyir izlenmiş, gözle görülen bir uyumun gerçekleşmiştir. Hataların dağılımının birinci modele bu kadar benzemesindeki en büyük etken, eklenen ikinci değişkenin (reel döviz kuru) model için istatistiksel bir anlam ifade etmemesinden kaynaklanmaktadır. Kurulmuş olan modelde pozitif ve negatif değerli hatalar mevcuttur.

Şekil 22: Model2 Hata, Gerçek Ve Uyum Değerleri




➤ Hataların Normalliğinin Sınanması: Birinci modelde kullanılan Jarque-Bera normallik testi, ikinci model içinde kullanılmıştır. Aynı zamanda görsel olarak da hataların dağılımı incelenmiştir.

H_0 : Hatalar normal dağılımlıdır.

H_1 : Hatalar normal dağılımlı değildir.

Şekil 23: Model2 Hataların Dağılımı



Jarque-Bera test istatistiğinin olasılık değeri incelendiğinde $p > 0,05$ olduğu ve H_0 hipotezi 0,05 hata payı ile reddedilemez olduğu görülmüştür. Sonuç olarak hataların normal dağıldığı görülmüştür (Şekil 23).

➤ Değişen Varyansın Varlığının Sınanması: White testi ikinci model için de kullanılmıştır.

H_0 : Değişen varyans yoktur.

H_1 : Değişen varyans vardır.

Tablo 11: Model2 İçin Değişen Varyans İçin White Testi Sonuçları

Heteroskedasticity Test: White
Null hypothesis: Homoskedasticity

F-statistic	0.513086	Prob. F(5,125)	0.7660
Obs*R-squared	2.634503	Prob. Chi-Square(5)	0.7561
Scaled explained SS	1.758469	Prob. Chi-Square(5)	0.8815

White test istatistiğinin olasılık değeri incelendiğinde $p > 0,05$ olduğu ve H_0 hipotezi 0,05 hata payı ile reddedilemez olduğu görülmüştür. Sonuç olarak sabit varyans olduğu görülmüştür (Tablo 11).

➤ Otokorelasyon Varlığının Sınanması: Breusch-Gogfrey Serial LM testi kullanılmış grafik üzerinde de otokorelasyonun arlığı tespit edilmiştir.

H_0 : Otokorelasyon yoktur.

H_1 : Otokorelasyon vardır.

Tablo 12: Model2 Otokorelasyonu İçin Breusch-Gogfrey Serial LM Testi Sonuçları


Breusch-Godfrey Serial Correlation LM Test: Null hypothesis: No serial correlation at up to 2 lags			
F-statistic	21.13641	Prob. F(2,126)	0.0000
Obs*R-squared	32.90929	Prob. Chi-Square(2)	0.0000

Breusch-Gogfrey Serial LM test istatistiğinin olasılık değeri incelendiğinde $p < 0,05$ olduğu ve H_0 hipotezi 0,05 hata payı ile reddedilebilir olduğu görülmüştür. Sonuç olarak otokorelasyon olduğu görülmüştür (Tablo12).

Aynı veri seti için Matlab üzerinde yapay sinir ağları yöntemi ile eğri uydurma yapılmıştır. Veri setinin %80'i eğitim verisi, %10'u değerlendirme verisi ve %10'u test verisi olarak ele alınmıştır. Öğrenme algoritmalarından Levenverg-Marquardt'ın daha iyi performansa sahip olduğu görülmüştür. Gizli katman sayısını belirleyebilmek için denemeler yapılmış ve sonunda 4 olarak belirlenmiştir. Analiz sonucunda elde edilen performanslar içinde, ortalama karesel hatası en küçük olan sonuç seçilmiştir. Elde edilen sonuçlara ilişkin grafikler aşağıda verilmiştir.


4.3.5. Yapay Sinir Ağları Yöntemi İle Kurulan İkinci Model Sonuçları

Şekil 24: Model2 Oluşturulan Yapay Sinir Ağı Yapısı




Matlab üzerinde oluşturulan yapay sinir ağının mimarisi Şekil 24'te gösterilmiştir. Görüldüğü üzere 4 gizli katmandan ve iki girdi verisinden oluşan bir ağ mimarisi vardır.

Şekil 25: Model2 Eğitim, Değerlendirme Ve Test Veri Seti İçin Ortalama Karesel Hata




Oluşturulan ağ modeli 12 iterasyonda ortalama karesel hatayı minimum edecek sonuca ulaşmıştır (Şekil 25).

Şekil 26: Model2 Ağıın Çıktısı ve Gerçek Değerler Arasındaki Farkların Dağılımı



Ağın tahmin ettiği değerler ile gerçekleşen değer arasındaki farkların eğitim, değerlendirme ve test veri setlerindeki hataların dağılımını vermektedir. Örneğin eğitim veri setinde -0,1569 hata ile tahmin edilen değerlerin sayısının 2 olduğu görülmüştür (Şekil 26).

Şekil 27: Model2 Ağın Çıktısı ve Gerçek Değere Uyumu



Ağın eğitim, değerlendirme ve test veri setleri için tahmin etmiş olduğu regresyon doğruları Şekil 27’de verilmiştir. Her bir grafikte yatay eksen gerçekleşen değeri; dikey eksen tahminlenen değeri gösterir. $Y=T$ doğrusu ağ sonucunda istenen durumdur. Grafikte üzerindeki noktalar $Y=T$ doğrusu üzerinde olması istenir. Tahminlenen değerlerin kesikli doğru üzerine yakın olması istenir. Kesikli olmayan doğru ile kesikli doğrunun eğitim, değerlendirme ve test veri setinde paraleliğe yaklaşması ağın uyumunun ve öğrenmesinin iyi olduğunu göstermektedir. Kesikli doğru ile kesikli olmayan doğrunun yakınlığının elde edilen dört görselde birbiri ile benzer olması ağın hatasının da az olduğunu göstermektedir.

4.3.6. İkinci Model İçin En Küçük Kareler Yöntemi ve Yapay Sinir Ağları Sonuçlarının Karşılaştırılması

Tablo 13: Model2 Regresyon Analizi ve Yapay sinir Ağının Hata Kareler Toplamı

Zaman	Yapay Sinir Ağları	En Küçük Kareler
2018/1	0.003238601	0.004313138
2018/2	0.008789071	0.016881576
2018/3	0.006602243	0.008113732
2018/4	0.008894084	0.009081169
2018/5	0.000495542	0.000406053
2018/6	0.004661965	3.33828E-05
2018/7	0.000863313	0.000887037
2018/8	2.09121E-05	0.001168504
2018/9	0.006932758	0.007922986
2018/10	6.50023E-07	0.010028959
2018/11	8.86501E-06	3.22627E-05
2018/12	0.013800129	0.016984354
HKT	0.054308134	0.075853152

Oluşturulan yapay sinir ağları test veri setinden hesaplanan hata kareler toplamı 0,054308 olarak elde edilmiştir. Aynı veri seti regresyon analizi için bulunan regresyon doğrusunda yerine konulunca elde edilen hata kareler toplamı 0,075853 olarak hesaplanmıştır. Regresyon analizi ile elde edilen hataların yüksek olmasının sebeblerinden biri eklenen değişkenin istatistiksel olarak anlamlı olmaması ve tahmin edilen katsayının standart hatasının çok büyük olmasından kaynaklanmaktadır. Bu nedenle ikinci modelin sonuçları sağlıklı bir şekilde yorumlanamamaktadır. Buna karşın ise yapay sinir ağı eklenen değişken ile tasarlanan birinci ağdan daha iyi bir performans göstermiştir (Tablo 13).

SONUÇ

Yapay sinir ağıları ihracat ile ithalat ve döviz kuru arasındaki ilişkiyi tahmin edebilmede en iyi sonuca ulaşabilmek, yani tahmini değerler ile gerçekleşen değerler arasındaki farkın minimum olduğu değerleri belirleyebilmek için, iki model tasarlanmıştır. Tasarlanan modeller iki farklı programda iki yöntem ile değerlendirilmiştir. Eviews programında en küçük kareler ile regresyon, Matlab programında “nftool” ile yapay sinir ağı yapılmıştır. İstatistik ve ekonometri bilim dalında tahminleme için yıllardır kullanılan regresyon tekniğine bir alternatif olabileceği düşüncesinden dolayı aynı veriler yapay sinir ağına tabi tutulmuştur. İki yöntemin sonuçları, iki model için karşılaştırılmıştır.

Uygulama sonuçlarından biri olarak regresyon varsayımları sınanmıştır. Yapılan testler sonucunda kurulan ilk modelin değişkenleri arasında doğrusal bir ilişkinin olduğu, hatalarının normal dağıldığı, sabit varyansın olduğu tespit edilmiştir. Ancak modelin hata terimleri arasında otokorelasyon olduğu da görülmüştür. İstenmeyen bu durumla karşılaşılmasının en büyük nedenlerinden biri modele yeteri kadar bağımsız değişken alınmaması durumudur. İkinci modelde eklenen değişken sonuçları değiştirmemiştir. Eklenen değişkenin istatistiksel olarak anlamsız olması sebebiyle ilk model ile neredeyse aynı sonuçlar elde edilmiştir. Diğer taraftan Tarı, regresyon analizinde otokorelasyon saptanmış olması durumunda tahmin edilen katsayı varyanslarının gerçek varyans değerinden daha küçük, sapmalı ve tutarsız olacağını belirtmiştir. R^2 değerinin olduğundan daha büyük çıkacağını bunun yanında t ve F istatistiklerine güven aralıklarına güvenilmemesi gerektiğini belirtmiştir (Tarı, 2018: 195-196).

Regresyon analizleri sonucunda elde edilen sonuçların varsayımları tam sağlayamaması nedeniyle tam güvenilir bir sonuç elde edilememiştir. Yine de elde edilen bulguların karşılaştırılması için ortak payda olarak hata kareler toplamı elde edilmiştir. Çıkan sonuçlar incelendiğinde hata kareler toplamının yapay sinir ağlarında daha küçük olduğu tespit edilmiştir.

Döviz kuru hareketleri sonucunda, dış ticaretteki karlılığın bir bölümünün ya da tamamının dış piyasalar tarafından yok edilmesi, kur politikası sayesinde dış denge üzerinde sağlanması amaçlanan olumlu etkinin zayıflaması ve politikanın etkisini

kaybetmesi anlamına gelmektedir. Döviz kuru ve ihracat arasındaki ilişkiyi anlamak dış ticaret dengesini kurabilmekte önemli bir adımdır. Ayrıca yapılan ithalat da ülkenin dış ticaret dengesi üzerinde önemli bir etki oluşturmaktadır. Bir ülke içinde ithalatın çok yüksek olması, o ülkenin üretmediği ya da ürettiğinin yetmediğinin göstergesidir. İhtiyacından fazlasını üretemeyen bir ülke de ihracat yapamaz sürekli ithalata yönelebilir. Bu yüzden ekonomik göstergeler arasındaki ilişkileri doğru anlamak ve modellemek ülkelerin kalkınmasına sağlayacaktır. Çavdar kitabında yapay sinir ağları ile finansı buluşturmuştur. Yeni yöntemlerin ve hibrit yöntemlerin kullanımının avantajlarından bahsetmiştir. Özetle bu ekonomik göstergelerin aralarındaki ilişkileri anlayarak, modelleyerek ülkelerin ekonomi politikalarında daha sağlam adımlar atılabilir.

Yapay zeka teknolojisinin sunmuş olduğu bu hizmetlerin daha iyi değerlendirilmesi için var olan yöntemlerin de zayıf ve güçlü noktalarının bilinmesi gerekmekte olduğu sonucuna varılmıştır. Daha iyi bulgular elde edebilmek için farklı veri setleriyle çalışılabilir. Böylelikle ülkelere ve işletmelere ilişkin zaman serileri kullanılarak gerçeği en iyi yansıtacak tahminler elde edilebilir. Bununla beraber değinilmesi gereken önemli bir husus, halihazırda var olan yöntemlerin birçoğu varsayım temellerine dayanmaktadır. Uygulama içinde verilen örnekte olduğu gibi, varsayımları eksik sorunlu modellerde, geleneksel modeller yerine yapay sinir ağlarından faydalanılabilir.

KAYNAKÇA

Akbilgiç, O. (2011). *Hibrit Radyal Tabanlı Fonksiyon Ağları İle Değişken Seçimi ve Tahminleme: Menkul Kıymet Yatırım Kararlarına İlişkin Bir Uygulama*. İstanbul: İstanbul Üniversitesi Sosyal Bilimler Enstitüsü.

Akkaş, İ., Öztürk, M. (2016). Türkiye'de İhracat, İthalat Ve Ekonomik Büyüme Arasındaki Nedensellik İlişkilerinin Analizi. *Journal of International Social Research*. 9(42).

Aktaş, C. (2009). Türkiye'nin İhracat İthalat ve Ekonomik Büyüme Arasındaki Nedensellik Analizi. *Kocaeli Üniversitesi Sosyal Bilimler Dergisi*. (18): 35-47.

Aktaş, C. (2010). Türkiye’de Reel Döviz Kuru İle İhracat Ve İthalat Arasındaki İlişkinin VAR Tekniği İle Analizi. *ZKÜ Sosyal Bilimler Dergisi*. 6(11): (123-140).

Al-Zahrani, M. A., Abo-Monasar, A. (2015). Urban Residential Water Demand Prediction Based On Artificial Neural Networks And Time Series Models. *Water Resources Management*. 29(10): 3651-3662.

Aras, S. (2013). *Yapay Sinir Ağları İle Zaman Serisi Tahminlemesinde Yeni Bir Model Seçim Stratejisi*. İzmir: Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü.

Atar, B . (2010). Basit Doğrusal Regresyon Analizi İle Hiyerarşik Doğrusal Modeller Analizinin Karşılaştırılması. *Journal of Measurement and Evaluation in Education and Psychology*.1(2): 78-84.

Bilgin, C., Sahbaz, A. (2009). Türkiye’de Büyüme Ve İhracat Arasındaki Nedensellik İlişkileri. *Gaziantep Üniversitesi Sosyal Bilimler Dergisi*. 8(1). 177-198.

Cottrell, M., Girard, B., Girard, Y., Mangeas, M., Muller, C. (1995). Neural Modeling For Time Series: A Statistical Stepwise Method For Weight Elimination. *IEEE Transactions On Neural Networks*. 6(6): 1355-1364.

Cura, T. (2004). *Karar Verme Aracı Olarak Yapay Sinir Ağları İle Portföy Optimizasyonu*. İstanbul: İstanbul Üniversitesi Sosyal Bilimler Enstitüsü.

Cura, T. (2008). *Uygulamalı Modern Sezgisel Teknikler*. İstanbul: Papatya Yayıncılık.

Çakır, F.S. (2018). *Matlab Kodları Ve Matlab Toolbox Çözümleri*. İstanbul: Nobel Yayıncılık.

Çam, S., Ballı, E., Sigeze, Ç. (2017). Petrol Fiyatlarındaki Oynaklığın Arch/Garch Modelleri Ve Yapay Sinir Ağları Algoritması İle Tahmini. *Uluslararası Yönetim İktisat Ve İşletme Dergisi*. 13(5): 588-597.

Çavdar Ç.Ş. (2018). *Finans Alanında Yapay Zekâ ve Ekonometrik Uygulamalar*. Ankara: Seçkin Yayıncılık.

Çetin, M., Uğur, A., Bayzan, Ş. (2006). İleri Beslemeli Yapay Sinir Ağlarında Backpropagation (Geriye Yayılım) Algoritmasının Sezgisel Yaklaşımı. *Akademik Bilişim Kongresi Pamukkale Üniversitesi*.

Çetintaş, H. (2003). Türkiye'de Enflasyon ve Büyüme. *İstanbul Üniversitesi Siyasal Bilgiler Fakültesi Dergisi*. (28):141-153.

Çuhadar, M. (2006). *Turizm Sektöründe Talep Tahmini için Yapay Sinir Ağları Kullanımı ve Diğer Yöntemlerle Karşılaştırmalı Analizi Antalya İlinin Dış Turizm Talebinde Uygulama*. (Basılmamış Doktora Tezi). Isparta: Süleyman Demirel Üniversitesi Sosyal Bilimler Enstitüsü.

Elmas, Ç. (2011). *Yapay Zeka Uygulamaları*. Ankara: Seçkin Yayıncılık.

Ergül, B., (2018). Türkiye’deki İş Kazalarının Zaman Serisi Analiz Teknikleri ve Yapay Sinir Ağları Tekniğı İle İncelenmesi. *Karaelmas İş Sağlığı ve Güvenliğı Dergisi*. 2(2): 63-74.

Fausett, L., (1994). *Fundamentals of Neural Networks: Architectures, Algorithms and Applications*. Prentice Hall.

Gujarati, D. N., Porter, D. C. (2014). *Temel ekonometri*. Çev. Ümit Şenesen, Gülay Günlük Şenesen. İstanbul. Literatür Yayıncılık.

Gül, E., Ekinci, A. (2006). Türkiye’de Reel Döviz Kuru İle İhracat Ve İthalat Arasındaki Nedensellik İlişkisi: 1990-2006. *Dumlupınar Üniversitesi Sosyal Bilimler Dergisi*. (16).

Güneri N., Apaydın A. (2004). Öğrenci Başarılarının Sınıflandırılmasında Lojistik Regresyon Analizi ve Sinir Ağları Yaklaşımı. *Ticaret ve Turizm Eğitim Fakültesi Dergisi*. (1): 170 – 188.

Hamzaçebi, C., Kutay, F. (2004). Yapay Sinir Ağları İle Türkiye Elektrik Enerjisi Tüketiminin 2010 Yılına Kadar Tahmini. *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 19(3): 227-233.

Haykin, S. (1994). *Neural Networks: A Comprehensive Foundation, First Edition*. New York: MacMillan College Publishing Company.

Hill T., O’Connor M. and William R. (1996). Neural Network Models for Time Series Forecasts. *Management Science*. 42(7): 1082-1092.

https://www.academia.edu/6712812/%C4%B0leri_Beslemeli_Yapay_Sinir_A%C4%9Flar%C4%B1nda_Backpropagation_Geriye_Yay%C4%B1l%C4%B1m_Algoritma_s%C4%B1n%C4%B1n_Sezgisel_Yakla%C5%9F%C4%B1m%C4%B1
(19.09.2019).

Ince, H., Çakır, F. S. (2017). Analysis Of Financial Time Series With Model Hybridization. *Journal of Economics Finance and Accounting*. 4(3): 331-341.

Kaynar, O., Taştan, S. (2009). Zaman Serisi Analizinde MLP Yapay Sinir Ağları Ve Arıma Modelinin Karşılaştırılması. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*. (33): 161-172.

Korkmaz, S. (2014). Türkiye Ekonomisinde İhracat ve Ekonomik Büyüme Arasındaki Nedensellik İlişkisi. *Business and Economics Research Journal*. 5 (4). 119-128).

Kriesel,D.(2007).ABriefIntroductiontoNeuralNetworks
http://www.dkriesel.com/en/science/neural_networks, (7 Kasım 2011).

Kubat, C. (2017). Yapay Zekâ: Yapay Sinir Ağları. *Matlab Yapay Zekâ ve Mühendislik Uygulamaları*: 667-710. İstanbul: Deniz Ofset Matbaacılık.

Kunt, F. (2014). *Bulanık Mantık Ve Yapay Sinir Ağları Yöntemleri Kullanılarak Konya İl Merkezi Hava Kirliliği Modellemesi*. Konya: Selçuk Üniversitesi Fen Bilimleri Enstitüsü.

Marquez, L., Hill, T., Worthley, R., Remus, W. (1991). Neural Network Models As An Alternative To Regression. In *Proceedings Of The Twenty-Fourth Annual Hawaii International Conference On System Sciences IEEE*. 4: 129-135.

Montgomery D.C., Peck E.A., Vining G. (1992). *Introduction to Linear Regression Analysis*.
www.academia.edu/37074224/Douglas_C._Montgomery_Elizabeth_A._Peck_G._Geoffrey_Vining_-_Introduction_to_Linear_Regression_Analysis_2012_Wiley ,
(25.06.2019).

Myers, R. H. (1990). *Classical And Modern Regression With Applications*. Boston: Pws – Kent.

Ocakoğlu, G. (2006). *Lojistik Regresyon Analizi Ve Yapay Sinir Ağları Tekniklerinin Sınıflama Özelliklerinin Karşılaştırılması Ve Bir Uygulama*. Bursa: Uludağ Üniversitesi Sağlık Bilimleri Enstitüsü.

Osborne, J., Waters, E. (2002). Four Assumptions Of Multiple Regression That Researchers Should Always Test Practical Assessment. *Research Evaluation*. 8(2): 1-9.

Özden, S., Öztürk, A. (2018). Yapay Sinir Ağları Ve Zaman Serileri Yöntemi İle Bir Endüstri Alanının (İvedik Osb) Elektrik Enerjisi İhtiyaç Tahmini. *Bilişim Teknolojileri Dergisi*. 11(3): 255-261.

Özer, M., Erdoğan, L. (2006). Türkiye'de İhracat, İthalat Ve Ekonomik Büyüme Arasındaki İlişkilerin Zaman Serisi Analizi. *Ekonomik Yaklaşım*. 17(60-61). 93-110.

Öztemel, E. (2016). *Yapay Sinir Ağları*. İstanbul: Papatya Yayıncılık Eğitim.

Pabuçcu, H., (2019). Borsa Endeksi Hareketlerinin Makine Öğrenme Algoritmaları İle Tahmini. *Uluslararası İktisadi Ve İdari İncelemeler Dergisi*. (23): 179-190.

Refenes, A. N., Zapraniş, A., Francis, G. (1994). Stock Performance Modeling Using Neural Networks: A Comparative Study With Regression Models. *Neural Networks*. 7(2): 375-388.

Seker, S. E. (2015). *Zaman Serisi Analizi (Time Series Analysis)*. <http://ybsansiklopedi.com/>, (01.06.2019).

Tapşın G., Karabulut A. (2013). Reel Döviz Kuru, İthalat Ve İhracat Arasındaki Nedensellik İlişkisi: Türkiye Örneği . *Akdeniz İktisadi Ve İdari Bilimler Fakültesi Dergisi*. (26): 190-205.

Tarı, R. (2018). *Ekonometri*. Kocaeli: Umuttepe Yayınları.

Weisberg, S. (1985). *Applied Linear Regression*. Newyork: Wiley Ltd.

Widrow, B., Rumelhart, D. E., Lehr, M. A. (1994). Neural Networks: Applications İn Industry, Business And Science. *Communications of the ACM*. 37(3): 93-106.

Wong, F. S. (199). A 3D Neural Network For Business Forecasting. In *Proceedings Of The Twenty-Fourth Annual Hawaii International Conference On System Sciences IEEE*. 4: 113-123.

Wooldridge J. M. (2012). *Indroductory Econometrics A Modern Approach*.
[https://economics.ut.ac.ir/documents/3030266/14100645/Jeffrey M. Wooldridge In troductory Econometrics A Modern Approach 2012.pdf](https://economics.ut.ac.ir/documents/3030266/14100645/Jeffrey_M._Wooldridge_Introductory_Econometrics_A_Modern_Approach_2012.pdf),
(19.09.2012).

Yakut, E. (2012). *Veri Madenciliği Tekniklerinden C5.0 Algoritması ve Destek Vektör Makineleri ile Yapay Sinir Ağlarının Sınıflandırma Başarılarının Karşılaştırılması: İmalat Sektöründe Bir Uygulama*. (Basılmamış Doktora Tezi). Erzurum: Atatürk Üniversitesi Sosyal Bilimler Enstitüsü.

Zhang, G. P. (2003). Time Series Forecasting Using A Hybrid ARIMA And Neural Network Model. *Neurocomputing*. 50(17): 159-175.