

**T.C.**  
**GEBZE TEKNİK ÜNİVERSİTESİ**  
**SOSYAL BİLİMLER ENSTİTÜSÜ**

**YAPAY ZEKA TEKNİKLERİ İLE YATIRIM DEĞERLEMESİ**  
**ANALİZİ**

**Kadir SAYIM**  
**DOKTORA TEZİ**  
**İŞLETME ANABİLİM DALI**

**GEBZE**  
**2018**

**T.C.**  
**GEBZE TEKNİK ÜNİVERSİTESİ**  
**SOSYAL BİLİMLER ENSTİTÜSÜ**

**YAPAY ZEKA TEKNİKLERİ İLE YATIRIM**  
**DEĞERLEMESİ ANALİZİ**

**Kadir SAYIM**  
**DOKTORA TEZİ**  
**İŞLETME ANABİLİM DALI**

Tez Danışmanı  
Prof. Dr. Hüseyin İNCE  
Prof. Dr. Nihat KASAP

**GEBZE**  
**2018**

GTÜ Sosyal Bilimler Enstitüsü Yönetim Kurulu'nun ..22../.06../2018.. tarih ve 2018../.19.... sayılı kararıyla oluşturulan jüri tarafından 28/06/2018 tarihinde tez savunma sınavı yapılan Kadir Sayım'ın tez çalışması İşletme Anabilim Dalında DOKTORA tezi olarak kabul edilmiştir.

**JÜRİ**

ÜYE

(TEZ DANIŞMANI)

: PROF.DR. HÜSEYİN İNCE

ÜYE :

PROF.DR. SALİH ZEKİ İMAMOĞLU

ÜYE :

PROF. DR. HAKAN KİTAPÇI

ÜYE :

DOÇ.DR. ERKUT ALTINDAĞ

ÜYE :

DOÇ.DR. MURAT ÇEMBERCİ

**ONAY**

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

## ÖZET

Bu çalışmada geleneksel yatırım değerlendirme metodlarından olan indirgenmiş nakit akım (DCF) ve net bugünkü değer modeli ile yapay zeka tekniklerinden yapay sinir ağları ve destek vektör regresyonu modellerinin tahmin etme özelliğinin birleştirilmesi analiz edilmiştir.

Hemen hemen her sektörde yatırım kararları firmaların gelecekteki operasyonel ve finansal performansını etkilemektedir. Ancak, yatırımlar gelecek zamanla ve belirsiz iş ortamı ile ilişkili olduğu için doğası gereği risk içermektedir. Belirsizliği azaltmak için, iyi bir yatırım yönetimi kadar yatırım değerlemesi için gerekli olan değişkenlerin tahmini de önem arz etmektedir. Değerleme modellerinin temel bileşenlerinden olan satış gelirleri, maliyetler, yatırım harcamaları ve bunların yıllar içerisindeki büyüme oranlarını enflasyon oranı ve döviz kurları önemli derecede etkilemektedir. Dolayısıyla enflasyon oranını ve döviz kurlarını tahmin etmek değerlemenin sonucu açısından kritik bir önem taşımaktadır. Yatırım kararları için yatırımın finansal olarak değerlendirilmesinin yapılması gerekmektedir. DCF finansal yatırım değerlendirme için en çok kullanılan geleneksel metodlardan bir tanesidir. Ancak, birçok belirsizliğin bulunduğu bir çevrede geleneksel yatırım değerlendirme modelleri esnek olmadıklarından dolayı hatalı sonuçlar verebilmektedirler. Yatırımcıları yönlendirebilmesi için uygun bir şekilde revize edilmesi gerekmektedir. Son yıllarda yapılan çalışmalarda, yapay sinir ağları ve destek vektör regresyonu modelleri enflasyon ve döviz kuru gibi zaman serilerinin tahmininde kullanılan yapay zeka tekniklerindedir.

Bu çalışmada Türkiye enflasyonu ve USD/TRY döviz kuru yapay sinir ağları modeli ve destek vektör regresyonu metodu ile tahmin edilmiş ve elde edilen sonuçlar indirgenmiş nakit akım modeli ile birlikte kullanılarak bir hibrid metod uygulanmıştır. Bu modelin sonuçları geleneksel yöntemler ile karşılaştırılmıştır. Çalışmanın sonucuna göre yapay sinir ağları kritik değişkenlerin tahmininde başarılı sonuçlar vermiştir. Önerilen hibrid metod yatırım değerlemesinde kullanılabilir ve bu yeni yaklaşım iş dünyasında kullanılması için önerilmektedir.

**Anahtar Kelimeler: Yapay Sinir Ağları, Destek Vektör Regresyonu, Yatırım Değerlemesi, İndirgenmiş Nakit Akım**

## SUMMARY

In this study, the combination of the discounted cash flow (DCF) and the net present value, which are traditional investment valuation methods, and the forecasting ability of two artificial intelligence techniques: artificial neural networks and support vector regression are analyzed.

More or less in every sector, investment and improvement decisions affect companies' future operational and financial performance. Even though investments are one of the main drivers of profitability, the investment decision is not easy due to uncertainty. To reduce uncertainty, forecasting investment conditions and inputs is just as important as sound investment management. The main inputs for the valuation models, such as revenue, costs, capital expenditure, and their growth rates, are heavily related to inflation and exchange rates. Therefore, predicting inflation and exchange rates is a critical issue for the investment valuation output.

Discounted cash flow is traditionally the most used investment valuation method. Despite being the most common valuation method, DCF has some disadvantages which are mostly related to uncertainty conditions and the rigidity of the model itself. DCF is a practical method but it must be modified for decision makers. In recent decades, the artificial neural network and support vector regression models have been two of the artificial intelligence models used for forecasting time series including exchange rates and inflation rates.

In this study, the Turkish economy's inflation rate and the exchange rate of USD/TRY are forecast by artificial neural networks and support vector regression. The outputs obtained by these two methods implemented into the DCF model to apply a hybrid method. Finally, the results are benchmarked with conventional practices. According to the results of the study, artificial neural networks gave successful results in forecasting critical variables. The proposed hybrid method can be used for investment valuation and this new approach is recommended for the business world.

**Key Words: Artificial Neural Networks, Support Vector Regression, Investment Valuation, Discounted Cash Flow**

## TEŐEKKÜR

Tez alıőmam sırasında kıymetli bilgi ve tecrübeleri ile bana yol gösterici ve destek olan deęerli danıőman hocam sayın Prof. Dr. Hüseymn İNCE'ye, ilgisini ve önerilerini göstermekten kaçınmayan Prof. Dr. Nihat KASAP'a teőekkür ve saygılarımı sunarım. Tez alıőması sürecinde yardımlarını esirgemeyen Ali Fehim CEBECİ'ye teőekkür ederim.

Hayatımın her anında yanımda olan ve bana manevi destek veren aileme sonsuz teőekkürlerimi sunarım.



# İÇİNDEKİLER DİZİNİ

	<b><u>Sayfa</u></b>
ÖZET	iii
SUMMARY	iv
TEŞEKKÜR	v
İÇİNDEKİLER DİZİNİ	vi
KISALTMALAR DİZİNİ	ix
ŞEKİLLER DİZİNİ	x
TABLolar DİZİNİ	xi
<b>1. GİRİŞ</b>	<b>1</b>
1.1. Araştırmanın Amacı ve Yanıt Aranılan Sorular	2
1.2. Araştırma Kurgusu	5
<b>2. YATIRIM DEĞERLEMESİ VE METOTLARI</b>	<b>6</b>
2.1. Yatırımlar	6
2.2. Yatırım Değerlemesi Metotları	8
2.3. Geleneksel Yatırım Değerleme Metotları	9
2.3.1. İndirgenmiş Nakit Akımları	9
2.3.2. Geri Ödeme Süresi	15
2.4. Diğer Yatırım Değerleme Metotları	17
2.4.1. Gerçek Opsiyonlar	17
2.4.1.1. Erteleme Opsiyonu	20
2.4.1.2. İnşa Etme Süreci Opsiyonu	21
2.4.1.3. Operasyon Ölçeğini Değiştirme Opsiyonu	21
2.4.1.4. Terk Etme Opsiyonu	21
2.4.1.5. Değiştirme Opsiyonu	22
2.4.1.6. Büyüme Opsiyonu	22
2.4.1.7. Çoklu Gerçek Opsiyonlar Arasındaki Etkileşim	22
2.4.1.8. Gerçek Opsiyonlar Analizi Literatür Taraması	23
2.4.2. Bulanık Mantık ve Yatırım Değerlemesi	26

2.4.3. Hibrid Yatırım Değerleme Metotları	30
2.5. Geleneksel Yatırım Değerleme Metotlarının Dezavantajları	32
<b>3. YAPAY ZEKA TEKNİKLERİ</b>	<b>37</b>
3.1. Yapay Sinir Ağları	37
3.1.1. Yapay Sinir Ağlarının Üstün Yönleri	41
3.2. Yapay Sinir Ağları Literatür Taraması	43
3.2.1. Finans Alanında Kullanım	43
3.2.2. Elektrik Piyasası Araştırmalarında Kullanım	45
3.2.3. Proje ve Yatırım Performansı Araştırmalarında Kullanım	45
3.2.4. Diğer Sektör ve Araştırmalarda Kullanım	46
3.2.5. Bulanık Yapay Sinir Ağları	49
3.3. Destek Vektör Regresyonu	50
3.4. En Küçük Kareler Destek Vektör Makineleri	56
3.5. Destek Vektör Regresyonu Literatür Taraması	59
<b>4. DÖVİZ KURU VE ENFLASYON TAHMİN MODELLEMESİ</b>	<b>63</b>
4.1. Serbest Nakit akım Bileşenleri	63
4.1.1. Net Satışlar	66
4.1.2. Satılan Malın Maliyeti	68
4.1.3. Faaliyet Giderleri	69
4.1.4. Amortisman	69
4.1.5. Vergi	69
4.1.6. Yatırım Maliyeti	70
4.1.7. Net İşletme Sermayesi Değişimi	70
4.1.8. Çalışmaya Konu Olan Değişkenler	71
4.2. Döviz Kuru Tahmin Modelleri	72
4.3. Enflasyon Tahmin Modelleri	74
4.4. Veri Seti	75
4.5. Tahmin Modellemesi ve Çalışmaya Entegrasyonu	76
4.6. Yapay Sinir Ağları ile USD/TRY Döviz Kuru Tahmini	81
4.7. Yapay Sinir Ağları ile Türkiye Enflasyonu Tahmini	87
4.8. Yapay Sinir Ağları ile Bulunan Sonuçların DCF Modeline Aktarılması	91
4.9. Destek Vektör Regresyonu ile USD/TRY Döviz Kuru Tahmini	94
4.10. Destek Vektör Regresyonu ile Türkiye Enflasyonu Tahmini	101
4.11. Destek Vektör Regresyonu ile Bulunan Sonuçların DCF	



Modeline Aktarılması	107
4.12. Geleneksel Yöntem ile Yapılan DCF Modelinin Sonucu	110
4.13. Fiili Veriler ile Yapılan DCF Modelinin Sonucu	112
4.14. DCF Sonuçlarının Karşılaştırılması	113
<b>5. SONUÇ</b>	<b>117</b>
<b>KAYNAKLAR</b>	<b>121</b>



## KISALTMALAR DİZİNİ

### Kısaltmalar Açıklamalar

DCF	: İndirgenmiş Nakit Akım
EBIT	: Faiz ve Vergi Öncesi Kar
ERP	: Kurumsal Kaynak Planlaması
IMF	: Uluslararası Para Fonu
IRR	: İç Verim Oranı
IT	: Bilişim Teknolojileri
LSSVM	: En Küçük Kareler Destek Vektör Makineleri
MLP	: Çok Katmanlı Algılayıcı
NOPAT	: Vergi Sonrası Net Faaliyet Karı
NPV	: Net Bugünkü Değer
PP	: Geri Ödeme Süresi
RBF	: Radyal Bazlı Fonksiyon
RFID	: Radyo Frekansı ile Tanımlama
RMSE	: Ortalama Karekök Hata
SMM	: Satılan Malın Maliyeti
TÜFE	: Tüketici Fiyat Endeksi
TRY	: Türk Lirası
USD	: Amerikan Doları
WACC	: Ağırlıklı Ortalama Sermaye Maliyeti

# ŞEKİLLER DİZİNİ

<b><u>Sekil No:</u></b>	<b><u>Sayfa</u></b>
1.2: Çalışmanın Akış Diyagram Özeti	5
3.1a: Yapay Nöronun Çalışma Şekli	38
3.1b: Çok Katmanlı Algılayıcılar ve İleri Beslemeli Yapay Sinir Ağı	39
3.3a: Tek Boyutlu Lineer Destek Vektör Regresyonu	54
3.3b: Nonlinear Destek Vektör Regresyonu	56
3.4: Destek Vektör Makinelerinin Mimarisi	59
4.1a: Serbest Nakit Akım Bileşenleri	64
4.1b: Serbest Nakit Akım Bileşenlerinin Detaylı Gösterimi	66
4.1c: Kritik Değişkenlerin Serbest Nakit Akım Bileşenlerine Etkisi	71
4.1d: Çalışmada DCF Analizine Tabi Tutulan Nakit Akım Yapısı	72
4.6: USD/TRY Döviz Kuru Tahmin Modellemesi - 6 Gizli Nörona Ait Fiili ve Model Çıktılarının Grafikselleştirilmesi	86
4.7: Türkiye Enflasyonu Tahmin Modellemesi - 5 Gizli Nörona Ait Fiili ve Model Çıktılarının Grafikselleştirilmesi	91
4.9: USD/TRY Döviz Kuru Tahmin Modellemesi – $\gamma = 154,97$ ve $\sigma^2 = 8,60$ Ait Fiili ve Model Çıktılarının Grafikselleştirilmesi	100
4.10: Türkiye Enflasyonu Tahmin Modellemesi – $\gamma = 2,90$ ve $\sigma^2 = 2,45$ Ait Fiili ve Model Çıktılarının Grafikselleştirilmesi	106
4.14: Çalışmada Kullanılan Modellere Ait Yapı ve Farklılıklar	114

# TABLolar DİZİNİ

<b><u>Tablo:</u></b>	<b><u>Sayfa</u></b>
4.6a: USD/TRY Döviz Kuru Tahmin Modellemesi - Farklı Gizli Nöronlara Ait Sonuç Tablosu	85
4.6b: USD/TRY Döviz Kuru Tahmin Modellemesi - 6 Gizli Nörona Ait Fiili ve Model Çıktı Karşılaştırma Tablosu	86
4.7a: Türkiye Enflasyonu Tahmin Modellemesi - Farklı Gizli Nöronlara Ait Sonuç Tablosu	90
4.7b: Türkiye Enflasyonu Tahmin Modellemesi – 5 Gizli Nörona Ait Fiili ve Model Çıktı Karşılaştırma Tablosu	90
4.8a: Yapay Sinir Ağları Modeli ile Elde Edilen DCF'e Ait Duyarlılık Analizi Sonuçları	98
4.8b: Yapay Sinir Ağları Modeli ile Elde Edilen DCF'e Ait Değerleme Sonucu	99
4.9a: USD/TRY Döviz Kuru Tahmin Modellemesi - Farklı $\gamma$ ve $\sigma^2$ Aralıkları İçin Bulunan Optimum $\gamma$ ve $\sigma^2$ ler ile Yapılmış Çalışmaya Ait Sonuç Tablosu	99
4.9b: USD/TRY Döviz Kuru Tahmin Modellemesi – $\gamma = 154,97$ ve $\sigma^2 = 8,60$ Ait Fiili ve Model Çıktı Karşılaştırma Tablosu	100
4.10a: Türkiye Enflasyonu Tahmin Modellemesi – Farklı $\gamma$ ve $\sigma^2$ Aralıkları İçin Bulunan Optimum $\gamma$ Ve $\sigma^2$ ler ile Yapılmış Çalışmaya Ait Sonuç Tablosu	105
4.10b: Türkiye Enflasyonu Tahmin Modellemesi – $\gamma = 2,90$ ve $\sigma^2 = 2,45$ Ait Fiili ve Model Çıktı Karşılaştırma Tablosu	106
4.10b: Türkiye Enflasyonu Tahmin Modellemesi – $\gamma = 2,90$ ve $\sigma^2 = 2,45$ Ait Fiili ve Model Çıktı Karşılaştırma Tablosu	106
4.11a: Destek Vektör Regresyonu Modeli ile Elde Edilen DCF'e Ait Değerleme Sonucu	110

4.12a: Geleneksel Yaklaşım ile Elde Edilen DCF'e Ait Duyarlılık Analizi Sonuçları	111
4.12b: Geleneksel Yaklaşım ile Elde Edilen DCF'e Ait Değerleme Sonucu	112
4.13a: Fiili Veriler ile Elde Edilen DCF'e Ait Duyarlılık Analizi Sonuçları	113
4.13b: Fiili Veriler ile Elde Edilen DCF'e Ait Değerleme Sonucu	113
4.14: Çalışmada Kullanılan Modellere Ait Değerleme Sonuçları	115



# 1. GİRİŞ

Sürekli değişen iş dünyasında firmaların ekonomik başarı sağlayıp mevcut yapılarının sürdürülebilirliği için birçok adım atmaları gerekmektedir. Bu adımların en önemlilerinden bir tanesi ise yatırımlardır. Yatırımlar bir firmanın ekonomik başarısına katkı sağlamak adına seçilen yollardan biri olsa da gelecek zamanla ilişkili olduğu için büyük risk içermektedir. Firmalar yatırım kararlarını alırken belirsiz birçok değişkeni tahmin edip bu değişkenler ile bir modelleme yaparak yatırımın finansal değerlemesini bulmaya çalışmaktadır. Yapılan tahminler genellikle geçmişe yönelik veri setlerinin ileriye yönelik basit uyarlaması şeklinde olurken, özellikle değişken koşulların yaşandığı iş dünyasında bu tahminler doğru kararı alabilmek adına çok önemli bir hale gelmiştir. Satış projeksiyonu, satış fiyatları, makroekonomik veriler, girdi fiyatları, arz ve talep tahmin edilmesi gereken önemli değişkenlerden bazılarıdır.

Yatırım değerlemesi kararını etkileyecek bu değişkenlerin tahmin edilmesi için geleneksel kaynakların yanı sıra birçok yöntem kullanılır. Bunlardan bazıları yapay sinir ağları ve destek vektör makineleri gibi yapay zeka tekniklerdir. Yatırım kararları için gerekli olan değişkenlerin tahmini tek başına yeterli değildir. Bu değişkenlerin modellenmesi ve yatırımın finansal olarak değerlemesinin yapılması da gerekmektedir. Finansal değerlemeler için birçok model kullanılmakta olup bunlardan en geleneksel olanları İndirgenmiş Nakit Akımları (DCF), Net Bugünkü Değer (NPV) ve İç Verim Oranı (IRR) analizleridir. Ancak birçok belirsizliğin bulunduğu ve sürekli değişken bir çevrede geleneksel yatırım değerlendirme modelleri esnek olmadıklarından dolayı rijit sonuçlar verebilmektedirler. Bu modeller verdikleri sonuçlarla firmaları yanlış yönlendirebilmektedir. Dolayısıyla, belirsizliklerin hakim olduğu bir yatırım ortamında geleneksel modellerin yerine daha doğru sonuç verebilen modeller kullanılmalıdır.

Bu çalışmada Türkiye çimento sektörüne ait bir yatırım fırsatının değerlendirilmesi yapılacaktır. Değerleme modeli olarak DCF kullanılacak olup, kritik değişkenler olan enflasyon ve USD/TRY döviz kuru tahmini için ilk olarak geleneksel yol olan Uluslararası Para Fonu (IMF) tahminleri kullanılarak bir sonuç bulunacaktır. İkinci

yöntem olarak, yapay zeka teknikleri ile tahmin edilen değişkenler DCF modeli ile değerlemeye tabi tutulan yapının içine dahil edilecek ve bu hibrid yöntem ile bir sonuç bulunacaktır. Her iki yöntem fiili verilerle oluşturulmuş sonuç ile karşılaştırılacaktır.

## **1.1. Araştırmanın Amacı ve Yanıt Aranılan Sorular**

Yatırımlar kar beklentisi doğrultusunda yapılır fakat yatırım sonuçları genellikle beklentilerin altında bir finansal performans sergiler. Çünkü yatırım kararları alınırken yapılan tahminlerin kalitesi tartışmaya açıktır. Yatırım kararı alınırken birçok değişkenden yararlanılmaktadır. Bu değişkenler satış projeksiyonu, satış fiyatları, makroekonomik veriler, girdi fiyatları, arz ve talep vb. şeklinde sıralanabilir. Sektörel birikime dayanan özel değişkenlerin haricinde, en kritik makro değişkenler enflasyon ve döviz kurudur. Döviz kurunun önem ibraz etmesinin sebebi büyük yatırımların genellikle ithalata dayalı ekipmanlardan yapılması ve projekte edilmiş ise ihracatın yabancı para cinsinden getiri sağlamasıdır. Bu değişkenler belirli bir zaman periyodu çerçevesinde tahmin edilmektedir. Sektörden sektöre değişiklik gösteren bu periyot yaygın kullanım olarak 5 ila 20 yıl arasında değişmektedir. Yatırım değerlemesi kararını etkileyecek bu değişkenlerin zaman periyodu çerçevesinde tahmin edilmesi oldukça önem arz etmektedir. Ancak, çoğunlukla firmalar yatırım kararlarını alırken bu değişkenler ile ilgili tahminlerde fazla detaya girmeden geçmiş verileri inceleyerek basit yöntemlerle sonuca varmaktadırlar. Örneğin, ekonomik tahminlerde şu gibi basit yöntemler kullanılabilir; son birkaç yılda gerçekleşmiş verilerin büyüme ortalamasını alarak gelecek yıllara bu değeri uygulamak, son yıla ait büyüme değerini tüm gelecek periyoda uygulamak, sabit bir değer belirleyip bu değeri tüm yıllara uygulamak vs. Ancak bu yöntemler ile tahmin edilen değişkenlerin herhangi bir güçlü dayanağı olmadığı için bu tarz mesnetsiz yaklaşımlar bu araştırmanın konusu olmaktan uzaktır. Çünkü yatırım kararı değerlemesinde kullanılacak bu basit tahmin yöntemleri esnek olmadığı gibi yatırım değerlemesine esas olan nakit akışlarının bulunması anlamında da oldukça zayıf kalmaktadırlar.

Kritik değişkenlerin belirlenmesinde en yaygın kullanılan geleneksel metod, uluslararası tahmin kuruluşlarının ülke ekonomileri hakkında yaptığı tahminlerden yararlanıp ekonomik göstergelerle alakalı değişkenlerde bu verileri modelin içerisine

yerleřtirmektedir. Ancak bu yöntem dahi esneklikten uzaktır ve bu tahminlere dayalı sonuçlar ile alınan yatırım kararları beklentilerin altında ekonomik performans gösterebilmektedir.

Yatırım kararları için gerekli olan deęişkenlerin tahmini tek başına yeterli deęildir. Bu deęişkenlerin modellenmesi ve yatırımın finansal olarak deęerlemesinin de yapılması gerekir. Finansal deęerlemeler için birçok model kullanılmakta olup bunlardan en geleneksel olanı DCF metodudur. Bu geleneksel metodun yanı sıra farklı hibrid deęerleme modelleri de geliştirilmiştir. Tüm bu modellerde temel amaç geleceęe yönelik belirlenen bir zaman periyodunda yatırım tarafından yaratılacak nakit akıřlarının bugünkü deęerine getirilmesidir. Bu şekilde yaratılacak naktin bugünkü deęerinin yatırımın kendisi için gerekli olan bedelden fazla olup olmadığı incelenmektedir. Ancak birçok belirsizliğin bulunduęu ve sürekli deęişken bir çevrede geleneksel yatırım deęerleme modelleri esnek olmadıklarından dolayı rijit sonuçlar vermekte ve verdikleri sonuçlar ile firmaları yanlış yönlendirebilmektedir. Dolayısıyla, belirsizliklerin hakim olduęu bir yatırım dünyasında geleneksel modellerin yerine daha doęru sonuç verebilen modeller kullanılmalıdır.

Bu çalışmada kritik yatırım deęişkenlerinin tahmin edilmesi için yapay zeka tekniklerinin kullanılmasının daha doęru olduęu savunulmaktadır. Yapay zeka teknikleri başarı ile sonuçlanan birçok çalışmada tahmin amaçlı kullanılmış olup bu çalışmalardan sonraki bölümde bahsedilmiştir. Döviz kurları, satış projeksiyonları, fiyat tahminleri, arz ve talep, tüketim gibi birçok deęişkenin zaman serileri şeklinde tahmin edilmesinde oldukça başarılı yöntemlerden olan yapay sinir aęları ve destek vektör makineleri metotları bu çalışmada yer alacaktır. Bu çalışmada Türkiye çimento sektörüne ait bir firmanın gerçekleřtirmek istedięi bir yatırım fırsatının deęerlemesi yapılacaktır. Deęerleme modeli olarak indirgenmiş nakit akımları metodolojisi kullanılacaktır. Geleneksellikten farklılařtırmak amacı ile deęerlemeye söz konusu olan deęişkenlerin tahmini için de yapay zeka teknikleri kullanılacak ve sonuçları karşılařtırılacaktır. Bu çalışmada ulařılacak sonuçlar ile, çimento sektörü başta olmak üzere yatırım yoğun sanayi sektörlerinde yeni deęerleme metotlarının kullanılması firmaların daha güvenilir sonuçlar elde etmesine ve böylece kendilerine daha geniş manevra alanı bulmalarına yardımcı olacaktır.



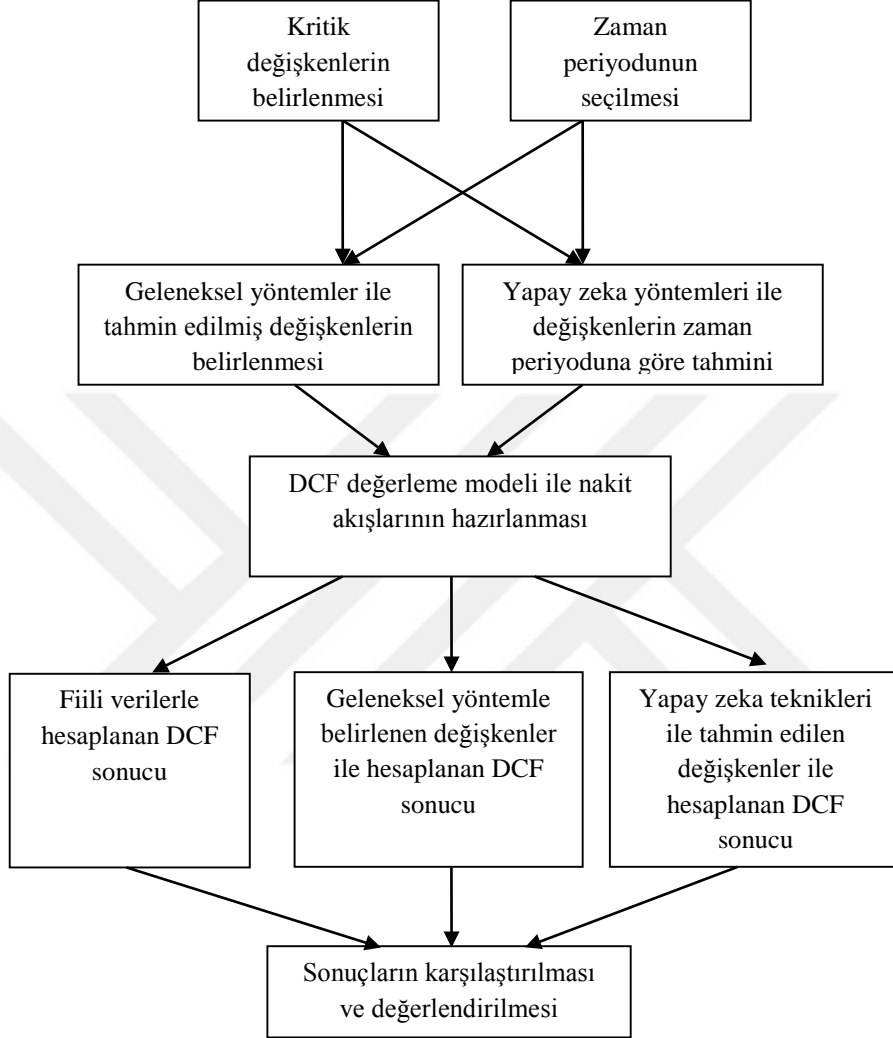
Özetle, arařtırmada birok sektörde en yaygın yatırım deęerlemesi metodu olarak kullanılan DCF'in rijit yapısını geliřtirmek hedeflenmiřtir. ünkü, son yıllarda yapılan arařtırmalarda belirsizlięin hakim olduęu iř dnyasında DCF'in stabil yapısı yeterli esneklięe sahip olmadığı iin saęlayacaęı sonuların tartıřmaya aık olduęu belirtilmektedir. Bu arařtırmada, DCF modellemelerinde kullanılan nakit akıřı serilerini oluřturan girdilerin tahmin edilmesinde yapay zeka teknikleri kullanarak, DCF sonularının gereęe daha yakın olup olmadığı sorgulanmıřtır. DCF ve NPV nin yapay zeka tekniklerinin tahmin becerisi ile birleřtirilerek hibrid bir deęerleme metodu önerilmiřtir. Arařtırma sonucunda önerilen modelin sektörde kullanılan geleneksel yöntemden daha gereki sonular vermesi hedeflenmektedir.

Arařtırmada yanıt aranan sorular ařaęıda listelenmektedir:

- 1- Geleneksel yöntemlerle yapılan yatırım deęerlemesi modellerinin sonuları hangi ölçüde gerekidir?
- 2- Yatırım deęerlemesi alıřmalarına yeni bir bakıř aısı getirilebilir mi?
- 3- Yapay zeka tekniklerinin kanıtlanmış tahmin becerileri, yatırım deęerlemesinde kullanılan girdilerin tahmininde kullanılabilir mi?
- 4- Yapay zeka teknikleri ile tahmin edilen girdiler DCF modeli ile nasıl birleřtirilebilir?
- 5- Yapay zeka teknikleri ve DCF'in birlikte kullanılması ile önerilen hibrid model ile geleneksel yöntemlerle yapılan yatırım deęerlemesi analizleri, gerek ıktılar ile yapılan sonular ile kıyaslandığında nasıl bir performans sergilemektedir?
- 6- Önerilen hibrid model iř dnyasında kullanılabilir mi?

## 1.2. Araştırma Kurgusu

Araştırmada Şekil 1.2. de belirtilen yöntem kullanılacaktır.



Şekil 1.2: Çalışmanın Akış Diyagram Özeti

## 2. YATIRIM DEĞERLEMESİ VE METOTLARI

Bu bölümde yatırım kavramının kısaca ne olduğu ve yatırımların neden önemli olduklarından bahsedilip yatırım değerlendirme metotları hakkında bilgi verilecektir.

### 2.1. Yatırımlar

Sarıaslan (2010) yatırım projesini, bir plan çerçevesinde, bir zaman döneminde, belirli kaynaklarla gerçekleştirilebilecek, mal ve hizmet üretimine yönelik ve birbiri ile ilişkili faaliyetler kümesi olarak tanımlamaktadır. Daha basit bir şekilde ifade etmek gerekirse, yatırım belirli bir kaynağın gelir sağlamak amacıyla kullanılması şeklinde tanımlanabilir.

Firmaların sürdürülebilir gelişim ve karlı büyüme hedeflerine ulaşmak için kullandığı en önemli araçlardan bir tanesi yatırımlardır. Firmalar yatırımları kar şanslarını artırmak için yapmaktadırlar (Dixit ve Pindyck, 1995). Luehrman (1998) kurumsal yatırım projeleri karar ve fırsatlarını finansal satınalma opsiyonuna benzetmektedir, çünkü şirketlerin bunu yapma kararı vardır ama buna zorunlu değildirler. Yatırım projeleri aşağıdaki gibi çeşitlendirilebilirler (Sarıaslan, 2010):

- Yeni Yatırım Projeleri
- Tamamlama – Genişletme (Tevsi) Yatırım Projeleri
- Yenileme Yatırım Projeleri
- Modernizasyon Yatırım Projeleri

Yeni yatırım projeleri tamamen yeni bir tesisin (greenfield) yapımına ilişkin yatırımlardır. Tevsi yatırım projeleri ise mevcut bir tesisi büyütme ve kapasitesini artırmak (brownfield) için yapılan yatırımları kapsar. Bir tesisin yıpranma suretiyle eskiyen çalışan ekipmanlarının değiştirilmesine yönelik yatırımlar yenileme yatırım projeleri altında değerlendirilebilir. Bir tesis işler konumda olsa bile yeni teknolojik gelişmeler çerçevesinde eski ve dezavantajlı konumda kalıyorsa, örneğin bir üretim yönteminin daha az maliyetli olmasına olanak sağlayan bir teknoloji geliştirilmiş ise,

bu tesiste yapılan modernizasyon projeleri yenileme yatırımı olarak da değerlendirilse, kısmen hazırlık ve planlama aşaması farklılık gösterdiğinden modernizasyon projeleri olarak adlandırılabilir.

Yatırım kararları ve girişimleri birçok sektör ve firma için hayati konulardan biridir. Hemen hemen her sektörde yatırım kararları firmaların finansallarını etkileyen önemli araçlardandır. Teknoloji bazlı endüstrilerde, yatırım ve gelişim kararları firmanın gelecek finansal performansını etkileyen en önemli faktördür (Zapata ve Reklaitis, 2010). Myers (1974) kurumsal finans ile yatırım kararlarının birçok kesişim noktası olduğunu belirtmiştir.

Belirsizlik bir yatırımın yapılması kararına etki eden en önemli faktörlerdendir. Her ne kadar yatırımlar firmaların karlılığına katkıda bulunan araçlardan bir tanesi olsa da belirsizlik içerdiklerinden yatırım kararı süreci kolay bir süreç değildir. Örneğin, Brennan ve Schwartz (1985) doğal kaynaklarla alakalı yatırımların özellikle fiyatlardan dolayı yüksek derecede belirsizlik içerdiğini ve bu projeleri değerlemenin kısmen zor olduğunu belirtmiştir. Ayrıca, bu durumun yatırım yapacak firmalar için bir engel oluşturduğunu ve yatırımın tahmini değerlendirilmesi probleminden dolayı firmaların bu sektöre yatırım yapmasında bir tedirginlik oluştuğuna işaret etmişlerdir. Belirsizliği azaltmak için iyi bir yatırım yönetim süreci yönetmek kadar, yatırım süreci ve koşullarını, yatırım ile alakalı finansal ve operasyonel girdileri tahmin edebilmek de oldukça önemlidir.

Bir yatırım projenin hazırlanması ve karar aşamasına getirilmesi önemli bir süreçtir. Bu süreç içerisinde proje fikrinin altının doldurulması ve araştırma ve analizler ile desteklenmesi gerekmektedir. Fizibilite çalışmaları ve bu çalışmaların sonucu karar verme adına en önemli hazırlık sürecidir. Fizibilite çalışmaları pazar araştırması, rekabet analizleri, teknik araştırmalar ve analizlerin yanı sıra finansal analizi de içermektedir. Finansal analizler yatırımın karlı olup olmadığını ölçen metotlardan yararlanmaktadır. Finansal yatırım değerlendirme sürecinde yatırımın toplam maliyetinin belirlenmesi, proje sonrasında beklenen gelirler ve nakit girdileri bu metotlarda kullanılan temel bileşenlerdir.

Fizibilite ve yatırım değerlendirme analizleri her ne kadar yatırımın karar verilmesi aşamasında en temel unsurlar olsa da yatırımın başarıya ulaşması yönetsel beceri

ile de alakalıdır. Bennouna ve arkadaşları (2010) firmaların uzun süreli sürdürülebilir başarı gösterebilmesi için iyi bir finansal yönetim gerektiğini ve bununla ilişkili olarak yatırım karar verme sürecini iyi yönetmeleri gerektiğine işaret etmişlerdir. Yanlış yatırım kararları ileride altından kalkılamayacak yükler doğurabilir ve hatta şirketleri iflasa götürebilir ve bunun en önemli örnekleri 2000'li yıllarda yaşanan global krizde görülmüştür. Wang ve Min (2006)'e göre rekabetçi ortamda yatırım kararı için iki önemli faktör bulunmaktadır; bunlar finansal riskler ve yönetsel esnekliktir. Örneğin, belirsiz pazar koşullarında tahmin edilen kar ve getiri oranı finansal riskler düşünülmediğinde anlamını yitirmeye başlamaktadır çünkü belirsizlik ortamında nakit akışları beklentiden oldukça farklılaşabilir. Yazarlar ayrıca, yeni bir bilgi geldiğinde veya pazar koşullarındaki belirsizlik çözüldüğünde yatırımın geleceği ile ilgili fırsatlara ilişkin yeni stratejiler geliştirilebileceğini belirtmiştir.

## **2.2. Yatırım Değerlemesi Metotları**

Yatırım değerlendirme metotları karar vericilere yatırım kararını verebilmek için yeterli derecede bilgi sağlamak amacıyla kullanılmaktadırlar. Literatürde içlerinde geleneksel metotların ve hibrid modellerin de olduğu bir sürü yatırım değerlendirme metotları bulunmaktadır. Geleneksel olarak kabul görmüş, tüm dünyada en çok kullanılan yatırım projeleri değerlendirme metotları net bugünkü değer ve indirgenmiş nakit akımları metotlarıdır (Graham ve Harvey, 2002). Smith ve McCardle (1999) endüstride firmalar tarafından yatırım kararlarını belirlemek amaçlı en çok kullanılan değerlendirme metodunun net bugünkü değer olduğunu belirtmiştir. Lee (2011) indirgenmiş nakit akımları yönteminin ve geri ödeme periyodu metodunun (PP) yatırımın değerinin bulunmasına yönelik kullanılan geleneksel yöntemler olduğunu belirtmiştir.

Myers (1974) yatırımların kabul ve ret kararlarının indirgenmiş nakit akımları modeli ile yaygın bir şekilde değerlendirildiğini ve iç verim oranının ise bu yöntemin merkeziyetsizleştirme (decentralisation) aracı olduğunu belirtmiştir. Paranın zaman değeri temelli değerlendirme modeli olan DCF en az dört değişik indirgeme yöntemi ile birlikte çalışabilmektedir: NPV, IRR, değiştirilmiş iç verim oranı, karlılık indeksi (Brigham and Ehrhardt, 2002).

Geleneksel deęerleme metotlarının yanısıra bir dięer deęerleme metodu ise geręek opsiyonlar metodudur. Bennouna ve arkadaşları (2010)'na gre anapara bteleme ile alakalı literatrde son on yıldıki en byk geliřme geręek opsiyonların sıka kullanılır olmasıdır. Brach (2003), DCF ile geręek opsiyonlar metodu arasında  temel farklılıđın bulunduđunu belirtmiřtir. İlk farklılık, indirgenmiř nakit akımı ynteminde gelecekte kararlar deęiřtirilmez iken geręek opsiyonlar metodunda elde edilen yeni bilgiler ile kararların deęiřiklięe aık olmasıdır. İkinci farklılık, DCF modelinde oluřan nakit akımları deęerleme iin temeli oluřturılmaktaiken geręek opsiyonlar yaklařımında nakit akımlar gelecekteki muđlak kořullara bađlıdır. nc farklılık ise DCF modelinde duyarlılık ve senaryo analizleri statik iken geręek opsiyonlar yaklařımında deęiřen kořullara adaptasyon sađlayabilen ynetimsel kararlar mevcuttur. Sonu olarak, bu  farklılık varyasyon, bađımlılıklar ve dinamizm olarak adlandırılabilir.

### **2.3. Geleneksel Yatırım Deęerleme Metotları**

Bu blmde geleneksel metotlar tanımlanacak ve geleneksel modelleri baz alarak yapılmıř deęerleme alıřmalarına kısaca deęinilecektir.

#### **2.3.1. İndirgenmiř Nakit Akımları Yntemi**

İndirgenmiř Nakit Akımları Yntemi (DCF) bir yatırımın karlılıđını ve finansal aıdan ekiciliđini analiz eden bir deęerleme metodudur. İyi yapılandırılmıř ve uygulamasının kolay olması sebebiyle en yaygın kullanılan geleneksel yatırım deęerleme metodudur. Bu sebepten řirketlerin yatırım projelerini deęerlemesi ve semesi iin kritik bir aratır. DCF gelecek dnemlere ait projekte edilmiř nakit akımlarını genellikle ađırlıklı ortalama sermaye maliyeti (WACC) olarak adlandırılan bir iskonto oranıyla iskonto etmektedir. DCF'in yapısı geređi model ıktıları NPV ve IRR gibi dięer analizler ile birlikte kullanıma uygundur. řirketler genellikle DCF sonularını NPV ve IRR ile deęerlendirirken yatırımı yapıp yapmama kararını bu sonulara gre almaktadırlar. İskonto oranı olarak kullanılan ađırlıklı ortalama sermaye maliyeti řirketin bor maliyeti ve zsermaye maliyetinin ađırlıklı ortalaması ile hesaplanmaktadır.

$$WACC = \frac{D}{(D+E)} * C_d * (1 - T) + \frac{E}{(D+E)} * C_e \quad (1)$$

Formülde, D ve E finansmanın borç ve özsermaye oranlarını ifade etmektedir. D ve E nin toplamı %100 etmektedir.  $C_d$  borç maliyeti,  $C_e$  özkaynak maliyeti, T ise vergiyi ifade etmektedir.

Bir varlığın ekonomik kapasitesini net bugünkü değer analizi ile bulurken sonuç en çok iskonto oranına hassastır. Bu duyarlılığa rağmen, genellikle iskonto oranı seçimi çok da üzerinde durulmayan bir belirlemeye dayanmaktadır. Pazarın tetiklediği yatırım kararlarında iskonto oranı, yerine yatırım yapılacak varlığın getirisindeki riski yansıtabilmelidir (Brealey ve Myers, 2000). Garvin ve Cheeah (2004)'a göre iskonto oranı sıklıkla yanlış kullanılmakta ve bir firmanın anapara fırsat maliyeti indirgenmiş nakit akımlar için seçilmektedir. Bu durumda firmanın seçtiği iskonto oranından daha az riskli olan projeler ret edilmekte veya daha fazla risk içeren projeler kabul edilebilmektedir.

Gelecek dönemlere ait nakit akımları şirketin WACC'ı ile iskonto edilip, toplam nakit akımlarının bugünkü değere iskonto edilmesi ile NPV ye ulaşılmaktadır.

$$NPV = \sum_{i=1}^t \frac{C_i}{(1+r)^i} - C_0 \quad (2)$$

NPV, projekte edilen nakit akımlarının bugünkü değerinin hesaplanma yöntemidir. 2 nolu formülde,  $C_i$  i zaman dilimindeki net nakim akımı, r iskonto oranını (DCF analizinde genellikle WACC) ve  $C_0$  da toplam yatırım maliyetini ifade etmektedir. (Brigham & Houston, 2004). Pozitif NPV, yatırımın projekte edilen toplam getirisinin toplam maliyet ve yatırım harcamasından büyük olduğunu belirtmektedir.

T yıllarda aşağıda belirtilen şekilde nakit akım yaratan ve WACC oranı %10 olarak belirlenen örnek bir A projesinin net bugünkü değeri şu şekilde hesaplanır.

T <sub>0</sub>	T <sub>1</sub>	T <sub>2</sub>	T <sub>3</sub>	T <sub>4</sub>	T <sub>5</sub>	T <sub>6</sub>
-100	20	25	25	30	35	40

$$NPV = \frac{-100}{(1+0,1)^0} + \frac{20}{(1+0,1)^1} + \frac{25}{(1+0,1)^2} + \frac{25}{(1+0,1)^3} + \frac{30}{(1+0,1)^4} + \frac{35}{(1+0,1)^5} + \frac{40}{(1+0,1)^6}$$

$$NPV = -100 + 116 = 16$$

Altı senelik projeksiyonda yaratılan nakit akımının paranın zaman değerini de dikkate alan iskonto oranı ile indirildiğinde yatırım için harcanan tutardan daha fazla nakit yarattığı hesaplanmış ve pozitif NPV sonucu elde edilmiştir. Bu basit hesaba göre projeye yatırım kararı verilebilmektedir.

Luehrman (1998)'a göre NPV operasyona tabi olan varlıkların bugünkü değeri ile ne kadar harcama yapılması gerektiğinin farkıdır. Yani bu ifade aşağıdaki şekilde gösterilebilir:

$$NPV = \text{varlıkların bugünkü değeri} - \text{gerekli olan yatırım harcaması}$$

Net bugünkü değer metodunun özelliklerini Lee ve Shih (2011) aşağıdaki gibi listelemiştir.

- Zaman değere hükmeder ve tüm nakit akışını yansıtır.
- Bir yatırım planından elde edilecek ekonomik faydanın büyüklüğü dikkate alınmaktadır.
- NPV bir yatırımın direkt olarak şirket değerine olan katkısını temsil etmekte ve yatırımın hissedarın sermayesine ne derece etkide bulunacağını doğru bir şekilde göstermektedir.
- Değer ekleme prensibi uyumludur: Şirket değerinin toplamının birbirinden bağımsız yatırımlarının getirisinin toplamına eşit olduğunu belirtmektedir.
- Özel bir plan seçildiğinde yatırım için optimal karar yalnızca NPV metodu ile elde edilebilmektedir.
- Nakit akışları ve iskonto oranı tahminlerindeki yüksek belirsizlik ihtimalinde, tahminler gerçekten sapmaya başlamakta ve karar verme riski artmaktadır.



- Farklı yatırım seçenekleri çeşitli riskler altında ise, NPV metodu en düşük yatırımın getiri oranını tüm yatırımlar için aynı kullanarak indirgenmiş nakit akımlarını saptırmaktadır. Dolayısıyla değişik iskonto oranları kullanılmalıdır.
- NPV metodu yüksek ve düşük maliyet etkisini yansıtmamaktadır.

Luehrman (1998)'a göre NPV değerinin pozitif olması şirketin değerinin yatırımla birlikte artmasına, NPV değerinin negatif olması ise şirketin bu yatırım kararını almaması gerektiğine işaret etmektedir. Lin ve Huang (2010)'a göre belirli, sabit ve durağan bir ortamdaki yatırım projelerini değerlendirmek için NPV analizi basit ve sonuç odaklı olduğu için oldukça güçlü bir metottur. NPV'nin karar verme yöntemi kısa vadede ve düşük değerlendirme maliyeti ile hayata geçirilebilir. Geleceğin doğru tahmin edilebildiği ortamlarda karar verici yatırım projelerini uygulamaya eğilim gösterecektir. NPV analizi bir varlığın karşılaştığı riskin tüm ömrü boyunca çoğunlukla sabit kaldığı durumlarda oldukça iyi sonuçlar vermektedir (Garvin ve Cheeah, 2004).

NPV analizinin en basit kuralı pozitif NPV sonucunu veren proje ve yatırımların değerlendirilmesini işaret etmesidir. Ancak, örneğin yapılması planlanan birden fazla yatırım alternatifi var ise daha büyük bir NPV sonucu her zaman en mantıklı yatırım anlamına gelmemektedir. Bu gibi durumlarda bir başka karar verme aracı olarak IRR kullanılabilir. IRR projekte edilen nakit akımlarının bugünkü değerini sifıra eşitleyen iskonto oranıdır. Aşağıda yer alan formülde C'ler belirli bir periyoda ait nakit akımlarını, n ise toplam periyodu ifade etmektedir.

$$C_0 + \frac{C_1}{(1+IRR)^1} + \frac{C_2}{(1+IRR)^2} + \dots + \frac{C_n}{(1+IRR)^n} = 0 \quad (3)$$

Yukarıda NPV hesaplaması yapılan örnek A projesinin nakit akımına ait IRR değeri şu şekilde hesaplanır.

T <sub>0</sub>	T <sub>1</sub>	T <sub>2</sub>	T <sub>3</sub>	T <sub>4</sub>	T <sub>5</sub>	T <sub>6</sub>
-100	20	25	25	30	35	40

$$0 = \frac{-100}{(1+r)^0} + \frac{20}{(1+r)^1} + \frac{25}{(1+r)^2} + \frac{25}{(1+r)^3} + \frac{30}{(1+r)^4} + \frac{35}{(1+r)^5} + \frac{40}{(1+r)^6}$$

Bu eşitlikte r (yani IRR) 0,1487, bir başka deyişle %14,87 çıkmaktadır. Eğer bu oran projeyi yapan şirketin proje için öngördüğü karlılık oranından yüksekse proje için yatırım kararı verilebilirken, bu oran belirlenmiş olan karlılık oranından düşük ise proje reddedilebilir.

DCF metodunda belirlenen periyottaki gelir ve maliyetler nakit akımlarını oluşturan temel girdilerdir. Şirketler nakit akımları oluşturan gelir ve maliyetleri öngörerek hesaplama yapmaktadırlar. Şirketin bulunduğu sektöre göre, enflasyon oranı, döviz kurları, sektörün ve ülke ekonomisinin reel büyüme oranı, pazar payı ve üretim süreçleri çıktıları gelir ve maliyetleri oluşturan temel kalemlerdir. Özetle, şirketler yatırım ve projelere ait gelecek dönem nakit akımlarını oluşturan girdileri tahmin edip nakit akımları hesaplamakta, DCF analizi ve bu analiz ile birlikte NPV ve IRR sonuçları ile yatırımın bugünkü değerini, karlılığını ve getirisini hesaplamakta ve yatırımın yapılıp yapılmayacağına karar vermektedirler.

Eğer karar vericilerin önünde birden fazla yatırım projesi varsa ve bu projeler arasında seçim yapma zorunluluğu var ise NPV ve IRR karar vericiler açısından önemli bir seçim aracı olabilmektedirler. Böyle bir durumda maksimum pozitif NPV ve en yüksek IRR'a sahip yatırım projesi en uygun yatırım alternatifi olarak değerlendirilmektedir. Nakit akışların dengeli dağılmadığı bazı projeler söz konusu olduğunda en yüksek NPV'ye sahip proje en yüksek IRR'a sahip proje olamayabilmektedir. Bu durumda karar vericiler stratejik öncelikleri de düşünerek seçim yapmakta, genellikle NPV'ler pozitif olduğu müddetçe yüksek IRR'a sahip projeleri önceliklendirmektedirler.

İç verim oranı metodunun özelliklerini Lee ve Shih (2011) aşağıdaki gibi listelemiştir.

- Zaman değere hükmeder ve tüm nakit akışını yansıtır.
- Bir yatırım planından elde edilecek ekonomik faydanın büyüklüğü dikkate alınmaktadır.

- Bir yatırım planının karlılığı tek bir oran ile (IRR) belirtilir ve bu diğer projelerin oranları ile kolayca kıyaslama yapma olanağı verir.
- Karlılık getiri oranı ile ifade edildiğinden fon maliyeti ile kolayca karşılaştırılabilir.
- IRR bir oran olduğundan, bu metot yatırımın miktarını ve nakit akımının büyüklüğünü dikkate almamaktadır.
- Her bir ayrık yatırım projesiyle alakalı çeşitli faydaları dikkate almamaktadır.
- IRR bilinemediğinden, yatırım net nakit akımının bazen pozitif bazen de negatif olma durumu ikiden fazla periyodu aşar ise yatırımı analiz etmek zorlaşabilmektedir.
- Özel bir yatırım planı değerlendirilirken hatalı kararlar verilebilir.
- Yeniden yatırımın getiri oranını tahmin ederken uygun olmayan tahminler yapılabilir.
- Anormal nakit akımları olduğu durumlarda IRR metodu bir veya birden fazla IRR hesaplayarak tutarsız sonuç sergileyebilmektedir.

DCF metodu yatırım sonucu operasyonlardan ortaya çıkacak nakit akımlarının indirgenmesi ile bugünkü değerinin bulunması sonucu değerlendirme işlemini yapmaktadır. Myers (1984) iyi bir indirgenmiş nakit akım uygulamasının dört temel problemle karşılaşacağını belirtmiştir:

- İskonto oranının tahmin edilmesi
- Projenin gelecekte oluşacak nakit akımlarının tahmin edilmesi
- Projenin şirketin diğer varlıklarının nakit akımlarına etkisinin tahmin edilmesi
- Projenin şirketin gelecekteki yatırım fırsatlarını hangi ölçüde etkileyeceğinin tahmin edilmesi

Myers (1984) ayrıca finans teorisiyle birlikte DCF yönteminin bazı karakteristik özelliklerini şöyle özetlemiştir:

- DCF bonoları, kısmen hisse senetlerini ve sabit gelir sağlayan varlıklar için standarttır.
- DCF düzenli bir şekilde kar payı ödemesi yapan güvenli hisse senetleri için mantıklı bir yöntemdir sıkça kullanılmaktadır.
- DCF büyük büyüme fırsatları olan şirketlerle alakalı değerlemelerde yanlış sonuçlar verebilir.
- DCF araştırma ve geliştirme projeleri için uygun değildir çünkü Ar- Ge yapısı gereği opsiyonları içerir.

Her ne kadar şirketler kendi sektörleri veya hedefledikleri yeni sektörlerle alakalı bilgilere sahip olsalar da, nakit akımlarını oluşturan elementlerden başlıcalarından olan enflasyon ve döviz kuru gibi kendi faaliyet alanlarından bağımsız ve müdahale edemedikleri girdileri tahmin etmeleri gerekmektedir. Bu durum da gelecek dönemlere ait nakit akımlarının oluşturulmasındaki en büyük zorluklardan bir tanesidir.

### 2.3.2. Geri Ödeme Süresi

Geri ödeme süresi değerlendirme metodu, yatırım projesinin yıllar içerisinde yarattığı serbest nakit akım dikkate alınarak, yatırımın toplam maliyet tutarının kaç yılda geri ödeneceğini hesaplamaktadır. Örneğin yukarıda belirtilen örnek A yatırım projesine ait yatırım tutarı ve yaratılan nakit akım projeksiyonu aşağıdaki gibi olduğu takdirde;

T <sub>0</sub>	T <sub>1</sub>	T <sub>2</sub>	T <sub>3</sub>	T <sub>4</sub>	T <sub>5</sub>	T <sub>6</sub>
-100	20	25	25	30	35	40

Geri ödeme süresi T<sub>0</sub> döneminde yapılmış yatırım tutarı miktarınca nakit akım yaratıldığı süre şeklinde hesaplanacaktır. Dolayısıyla -100 olarak harcanan yatırım

tutarı kadar, yani +100 kadar nakit akım yaratıldığı taktirde projenin geri ödemesi süresi belirlenecektir. T her bir yılı ifade etmekte iken hesaplama şu şekilde yapılabilir.

$$T_1 + T_2 + T_3 + T_4 = 20 + 25 + 25 + 30 = 100$$

Proje 4 yıl sonunda yatırım tutarı kadar nakit yaratmaktadır. Dolayısıyla projenin geri ödeme süresi 4 yıl olarak hesaplanmaktadır. Hesap yöntemi oldukça basit olan bu metotta paranın zaman değeri göz ardı edilmektedir. Örneğin yukarıdaki örnekte mevcut zamanda yatırım için harcanan 100 birim ile 4 sene süresince yaratılan 100 birim aynı değerde varsayılmıştır. Benzer şekilde 2. yılda yaratılan 25 ve 3. yılda yaratılan 25 birimin de etkisi aynı şekilde dikkate alınmıştır. Halbuki enflasyon olan bir ekonomik ortamda ve iskonto oranının sıfır haricinde belli bir seviyede belirlendiği yatırımlarda bir yıl sonra bir önceki yıl ile aynı değerde yaratılan nakit akımlar eşit olamamaktadır. Yani, örnek A projesindeki 2. yılda yaratılan 25 birimlik nakit akım ile 3. yılda yaratılan 25 birimlik nakit akım eşit olarak değerlendirilmektedir. Geri ödeme süresi yöntemi projenin genel karlılığı hakkında bilgi edinmek ve henüz bu aşamada ret edilip edilmemesini anlamak amaçlı yapılan basit bir değerlendirme metodudur ve genellikle bu analiz ile birlikte daha detaylı analizlerin yapılmasını önermektedir.

Geri ödeme süresi metodunun özelliklerini Lee ve Shih (2011) aşağıdaki gibi listelemiştir.

- Basit, hesaplaması ve anlaşılması kolay bir yöntemdir.
- Zaman, yatırım maliyetinin tamamen telafi edildiğinin belirlenmesidir.
- Yatırımın likiditesini belirleme yeteneğine sahiptir.
- Ekonomik faydayı değerlendirmemektedir.
- Paranın zaman değerini dikkate almamaktadır.
- Yatırımın en uygun likidite oranına sahip olması için geri ödeme süresinin ne olması gerektiği hakkında bir standart yoktur.

- Uzun dönemli nakit akışlarında yatırım maliyetini telafi eden zamanlardan sonraki nakit akışları önem arz etmemektedir.

## 2.4. Diğer Yöntemler

Bu bölümde son yıllarda geleneksel metotlardan ziyade daha fazla kullanılmaya başlayan yatırım değerlendirme metotları ve hibrid metotlar belirtilecek ve bu metotlar ile yapılmış çalışmalara değinilecektir.

### 2.4.1. Gerçek Opsiyonlar

Son yıllarda daha fazla kullanılmaya başlayan yatırım değerlendirme metotlarından bir tanesi gerçek opsiyonlardır (Real Options). Black ve Scholes (1973)'a göre opsiyon, "bir varlığa (asset) belirli şartlarda, belirli bir zaman periyodunda alma veya satma hakkının verilmiş olması" şeklinde tanımlanabilir. Opsiyonlar hakları temsil eder ve bir opsiyonun getirisi dayanak varlıktan bağımsız olarak hiçbir zaman sıfırdan az olamaz. Temel opsiyonun iki tipi vardır; bunlardan ilki önceden belirlenmiş bir fiyatla belli bir zamanda bir varlığı alma hakkı, diğeri ise önceden belirlenmiş bir zamanda bir fiyat olarak varlığı satma hakkıdır. Opsiyonun fiyatı dayanak varlığın şimdiki fiyatından düşük olursa (alma opsiyonu için) veya yüksek olursa (satma opsiyonu için) opsiyon için "kazançlı" tanımı kullanılır, aksi durumda "kazanç getirmeyen" terimi kullanılmaktadır. Opsiyonlar Amerikan ya da Avrupalı şeklinde adlandırılabilirler. Eğer opsiyon sadece belirlenmiş bir ileri tarihte gerçekleşecekse buna "Avrupa opsiyonu", opsiyon son tarihine kadar herhangi bir zamanda gerçekleştirilebiliyorsa buna "Amerika opsiyonu" denmektedir.

Gerçek opsiyonlar analizi, finansal araştırmalar ile ortaya çıkmış bir yaklaşımdır. Myers (1977) karın sahip olunan varlıklar ile desteklenmiş bir yatırımın nakit akışları sonucu ortaya çıkmasına ek olarak yatırımın gelecekteki fırsatlara opsiyon sunmasıyla da ortaya çıkacağını belirtmiştir.

Gerçek opsiyonlar teorisinin bir çok tanımı vardır ancak hepsi aynı konseptte işaret etmektedir. Copeland and Antikarov (2003) gerçek opsiyonu "bir aksiyonu (örneğin ertelemek, genişletmek, küçültmek veya terk etmek) önceden belirlenmiş bir maliyet ile önceden belirlenmiş bir zamanda yapma (ancak zorlama değil) hakkı" şeklinde tanımlamıştır.

Kogut and Kulatilaka (2001) “belirsiz olarak tanımlanan bir yatırım kararının uygun bir zamanda yönetim tarafından uygulanabilmesi ve geri dönüştürülebilmesi” olarak tanımlamışlardır.

Dolayısıyla, Fernandes ve arkadaşları (2011) ’na göre bu tanımlar eşliğinde yatırım fırsatı finansal satınalma opsiyonuna benzerdir. Yatırım yapma fırsatı olan bir şirket parayı şimdi veya gelecekte bir varlık için (yatırım projesi) harcama opsiyonuna sahiptir ve eğer opsiyon “kazançlı” ve pozitif getiri sağlıyor ise yatırımı yapabilir. Ters durumda ise, yani getiri miktarı negatif ise ve opsiyon “kazanç getirmeyen” olarak tanımlanabiliyorsa şirket bu opsiyona yatırım yapmayabilir.

Carlsson ve Fuller (2003)’e göre “gerçek opsiyona sahip olmak” terimi bir yatırım kararının belli bir süre boyunca yapılıp yapılmayacağını seçebilmektir. Aynı zamanda “gerçek opsiyon kuralı” ise, net bugünkü değer (NPV) eğer bekleme opsiyonunun değerinden vazgeçmeyi karşılayabilecek kadar yüksek ise yatırım yapılmasıdır. Çünkü yatırım opsiyonu geri dönüşümsüz olarak gerçekleştirilir ise yatırımın değeri azalmaktadır ve bu kayıp yatırımın fırsat maliyetidir.

Fernandes ve arkadaşları (2011) ’nın işaret ettiğine göre gerçek opsiyonlar teorisi finansal opsiyonlar yaklaşımından ortaya çıkmıştır ve temeli Black, Merton ve Scholes tarafından geliştirilen Nobel ödüllü finansal opsiyon sözleşmelerinin fiyatlaması konulu çalışmasında yatmaktadır. Opsiyon fiyatlama teorisinin finansal olsun veya olmasın tüm yatırım türleri için uygulanabilirliği vardır (Black ve Scholes, 1973). Dolayısıyla gerçek opsiyonlar teorisi opsiyon fiyatlama teorisinin doğal bir uzantısı şeklinde gelişmiştir.

Zapata ve Reklaitis (2010)’e göre gerçek opsiyonlar analizi yönetsel esnekliklerin kaydadeğer değer yarattığı durumlardaki varlık değerlemeleri için geliştirilmiştir. Piyasa ve teknolojik belirsizliklere reaksiyon verebilmek amaçlı yönetim tarafından sürekli düzenlemeler (yatırımın ertelenmesi, projenin bakış açısının değişmesi vb.) yapılıyor ise gerçek opsiyonlar metodolojisi yatırım projesinin değerlemesi için en ideal yöntem olmaktadır. Ancak aynı kaynakları kullanan ve aynı zamanda ortaya çıkan birçok projenin yer aldığı bir portföyü değerlemek istendiğinde, gerçek opsiyonlar analizi yetersiz kalmaktadır.

Garvin ve Cheeah (2004)'a göre geleneksel modellerin yetersiz kalması ile gerçek opsiyonlar modeli ve alternatif değerlendirme teknikleri geliştirilmiştir. Genel olarak gerçek opsiyon modeli iki kategoride incelenebilir: Devamlı zaman modeli ve ayrık zaman modeli (continuous-time models and discrete-time models). Uygulamanın içeriğine ve seçilen modelin uygunluğa göre her iki yaklaşım da farklı varsayımlar içerebilir

Leslie ve Michaels (1997) gerçek opsiyonlar analizinin salt değerlendirme aracı olmaktan çok stratejik bir araç olduğuna ve reaktif olmaktan çok proaktif olduğuna dikkat çekmişlerdir.

Mun (2002) finansal ve gerçek opsiyonların dokuz ayırt edici özelliği olduğunu belirtmiştir.

- Finansal opsiyonların ömürleri gerçek opsiyonlara göre daha kısadır.
- Finansal opsiyonlarda değeri belirleyen temel unsur finansal varlığın değeri iken gerçek opsiyonlarda değeri belirleyen temel unsur rekabet, yönetim ve talep ile şekillenen nakit akımlardır.
- Finansal opsiyonların değerleri genelde küçük boyutlarda iken, gerçek opsiyonların değerleri genelde oldukça büyük boyuttadır.
- Finansal opsiyonlarda opsiyonun değeri hisse değerinin değişimi ile kontrol edilmez iken, gerçek opsiyonların değeri stratejik yönetsel kararlar ve esneklik ile değişebilmektedir.
- Finansal opsiyonlarda piyasa veya rekabetin etkileri opsiyonun fiyatını belirlemek için önemli değilken, gerçek opsiyonlarda opsiyonun stratejik değeri pazar ve rekabetten etkilenmektedir.
- Finansal opsiyonlar son 30 yılda kullanılmakta iken gerçek opsiyonlar firmalar tarafından yeni kullanılmaya başlamıştır.
- Finansal opsiyonlar genellikle kapalı form parçalı diferansiyel denklemler ve azalan varyans metotları ile çözümlenirken gerçek opsiyonlar kapalı form



denklemler ve ana deęişkenlerin iki terimli binom denklemi (two binomial letters) ile simüle edilmesiyle çözümlenirler.

- Finansal opsiyonlar ticari olarak korunurlar ve fiyat bilgisi ile pazarlanırlar halbuki gerçek opsiyonlar ticari olarak kullanılırlar ve piyasada benzerlięi yoktur çünkü doğal olarak özeldirler.
- Yönetim kararları ve hareketleri finansal opsiyonların deęerlemede etkin deęilken, gerçek opsiyonun deęerini belirlemektedirler.

Rocha ve arkadaşları (2007) bilgilenme, bekleme ve terketme gibi opsiyonların olabileceęi yatırım projeleri için gerçek opsiyonlar metodunun daha doęru deęerleme sonuçları verdięine işaret etmektedirler.

Gerçek opsiyonlar bir çok tipte olabilir ancak en sık kullanılanları erteleme, inşa etme süreci, operasyon ölçeęini deęiştirme, terk etme, deęiştirme ve büyüme olarak listelenmiştir (Trigeorgis, 2000; Lee ve Shih, 2011; Reyck ve ark., 2008)

#### **2.4.1.1. Erteleme Opsiyonu**

Erteleme seçeneęi yatırımcıya parayı bekletme yeteneęini vermektedir, yani bu opsiyon yatırımcıya bir yatırım fırsatında parayı hemen harcayarak işe girişmek ya da yatırım hakkında daha fazla bilgi toplamak veya belirsizlik ortamında çözüm için beklemek gibi seçenekler vermektedir (Dixit ve Pindyck,1994). Özetle bir yatırımı erteleme yeteneęi, aynen finansal satınalma opsiyonu gibi projeye yatırım yapmak ya da yapmamak opsiyonunu sağlamaktadır. Örneęin, yönetim arazi veya kaynaklar için bir kontrat veya satın alma opsiyonu tutmakta ve bu kontratı herhangi bir yatırım işlemi yapmaksızın X yıl bekletmektedir (Lee ve Shih, 2011).

Fernandes ve arkadaşları (2011)'na göre bir yatırımı erteleme yeteneęi, daha fazla bilgi edinme ve belirsizlięi azaltma girişimleri ile gelecekte doęacak fırsatları öngörerek ve/veya gelecekte yaşanacak kayıpları düşürerek hem projeyi hem de ilgili stratejiyi geliştirmeye olanak sağlamaktadır.

Trigeorgis (2000)'in belirttięine göre erteleme opsiyonu çoęunlukla madencilik, gayrimenkul ve tarım gibi birçok sektördeki yatırımlarda kullanılmaktadır.

### **2.4.1.2. İnşa Etme Süreci Opsiyonu**

Lee ve Shih (2011) harcamalara göre yatırımları evreleme işlemiyle, eğer yeni bir bilgi alınmış ise ve bu bilgi elverişsiz ise şirkete sürecin ortasında terketme opsiyonu sağlamaktadır. Her bir evre daha sonraki evrenin değeri için bir opsiyon olarak görülmekte ve bileşik bir opsiyon olarak değerlendirilmektedir.

Majd ve Pindyck (1987)'e göre bazı yatırım projelerinde doğası gereği başlangıç zamanı ya da inşa süresi gibi tamamlanana kadar kar yaratmayan ve düzenli olarak para çıkışının yapılması gereken bazı işlemlerin yapılması gerekmektedir. Gerçek opsiyonlar bu tarz projelerin değerlemesi için uygun bir yöntemdir. Bu durumda özellikle istenmeyen olaylar meydana geldiğinde veya zarar doğuran bilgiler ulaştığında yatırımcıya yatırımı terk etme opsiyonu sunmaktadır. İlaç sanayi gibi uzun dönemli anapara ve başlangıç maliyetleri gerektiren Ar-Ge yoğun sektörlerde, inşa etme süreci opsiyonu kullanılabilir.

### **2.4.1.3. Operasyon Ölçeğini Değiştirme Opsiyonu**

Lee ve Shih (2011)'e göre eğer piyasa koşulları beklenenden daha elverişli ise firma üretim hacmini büyütebilir veya kaynak kullanımını hızlandırabilir. Tam tersi durumda ise eğer koşullar beklenenden daha olumsuz ise üretim kısıllanabilir ve yeniden başlatılabilir.

Trigeorgis (2000)'in belirttiğine göre operasyonun ölçeğini değiştirme opsiyonu (genişletme, daraltma, kapatma ya da yeniden başlama) karar vericiye esneklik kazandırmaktadır. Örneğin piyasa koşulları gelecek vaat ediyor ise yatırımcı üretim hacmini genişletebilir ya da kaynak kullanımını hızlandırabilir veya piyasa koşullarının kötü gideceği belirgin ise operasyonun ölçeğini küçültebilir. Doğal kaynaklar, tüm üretim, planlama ve inşaat, tüketici ürünleri ve ticari gayrimenkul sektörlerinde bu opsiyon önem arz etmektedir.

### **2.4.1.4. Terk Etme Opsiyonu**

Myers ve Majd (1990) bazı durumlarda pazarın yatırımın aksine gelişim gösterebileceğini ve böyle durumda terk etme opsiyonu ve hatta bazı varlıkları satma durumunun söz konusu olabileceğini belirtmişlerdir. Bu durum bütün yatırımı

kaybetmek yerine yatırımcıya alternatif sunmaktadır. Terketme opsiyonları havayolu ve demiryolu, finansal hizmetler veya belirsiz bir pazara ürün sunma gibi anapara yoğun sektörlerde ve girişimlerde önemlidir.

Eğer piyasa koşulları keskin bir biçimde kötüleşirse yönetim yürütmekte olduğu operasyonları terk edebilir ve mevcut ekipman ve varlıklar ikinci el olarak satılıp değerlendirilebilir (Lee ve Shih, 2011).

#### **2.4.1.5. Değişirme Opsiyonu**

Lee ve Shih (2011)'e göre fiyatlar veya talep değiştiğinde yönetim tesislerde üretilen çıktılar uyarlayabilir (üretim esnekliği) ya da aynı ürün değişik girdiler ile üretilebilir (süreç esnekliği).

Değişirme opsiyonu yatırımcıya yatırımın girdi ve çıktılarını değiştirme şansını değerlemeyi sunmaktadır ve bu pazar değişimlerine karşı büyük adaptasyon sağlayabilme esnekliği adına oldukça önemlidir. Örneğin fiyat ve talepte değişiklik olursa, bu opsiyon ile yönetim üretilen ürün tipini değiştirerek ürün esnekliğini sağlamak ya da aynı ürünü değişik girdiler ile üreterek süreç esnekliği sağlayabilmektedir (Trigeorgis, 2000; Kulatilaka ve Trigeorgis,1994).

#### **2.4.1.6. Büyüme Opsiyonu**

Kulatilaka ve Perotti (1998) bazı yatırım projelerinde gelecekte projeyi genişletme söz konusu olabildiğini ve büyüme opsiyonunun firmalara büyüme fırsatlarından elde edilecek edimlerini kazanma yeteneği vermekte olduğunu belirtmişlerdir. Yüksek teknoloji içeren stratejik sektörlerde veya ilaç sektörü gibi çoklu ürün gelişimi ve uygulaması gerekli olan sektörlerde bu opsiyon önem arz etmektedir.

Önkoşulu olan bir yatırım veya birbirleri ile ilişkili projeler zinciri daha sonrası için yeni ürün veya süreç gibi büyüme fırsatları yaratabilir (Lee ve Shih, 2011).

#### **2.4.1.7. Çoklu Gerçek Opsiyonlar Arasındaki Etkileşim**

Gerçek hayattaki projeler sıklıkla çeşitli opsiyonları içermektedir. Lee ve Shih (2011)'e göre yukarı yönlü genişleyen (potansiyeli olan) ve aşağı yönlü (korumacı)

opsiyonlar aynı ortamda zuhur edebilir. Birbirleri ile etkileşim gösteren bu opsiyonların bileşik değeri her birinin ayrı değerlerinin toplamından farklılaşabilir. Ayrıca bu opsiyonlar finansal esneklik opsiyonları ile de etkileşim gösterebilirler.

#### **2.4.1.8. Gerçek Opsiyonlar Analizi Literatür Taraması**

Gerçek opsiyonlar özellikle son yıllarda literatür çalışmalarında sıklıkça kullanılmış ve bir çok çalışmaya konu olmuştur. Aşağıda bu çalışmalardan bazıları listelenmiştir.

Kjærland (2007) belirsizlik altındaki projelerdeki en iyi değerlendirme yönteminin opsiyonlar yöntemi olduğunu belirtmiş ve Norveç'teki bir enerji projesi için gerçek opsiyonlar modeliyle bir değerlendirme yapmıştır.

Chen ve arkadaşları (2009) birçok riskin mevcut olduğu ortamdaki bilişim sistemleri yatırım projelerinin değerlemesi konusunda gerçek opsiyonlar teorisiyle bir yaklaşım uygulamışlardır. Genel ve özel riskleri birleşik bir yapı altında modelleyip kurumsal kaynak planlaması (ERP) geliştirme projesinin değerlemesinde binom modelini kullanmışlardır.

Lin ve Huang (2010)'a göre enerji sektöründe olduğu gibi günümüzde birçok sektörde gelecekle ilgili tahminler belirsizliklerden dolayı çok kolay yapılamamaktadır. Bu sebepten bir enerji tasarrufu yatırımında riski azaltmak için ve uzun dönemli bir etki sağlayabilmek adına değerlendirme yöntemi olarak gerçek opsiyonlar analizini seçmişlerdir.

Özoğul ve arkadaşları (2009) geleneksel indirgenmiş nakit akım metodunun, sağlık sektöründeki en önemli karar verme faktörlerinden ikisi olan yönetsel ve stratejik esnekliği dikkate almadığını belirtip; sağlık sektöründeki teknoloji yatırımları ve ERP sistemleri için gerçek opsiyonlar yaklaşımı ile bir değerlendirme modeli ortaya koymuşlardır. Bu değerlemede karar verme süresi "sürekli" olarak belirlenmiş ve modelde binom örgü yapısı kullanılmıştır.

Bowe ve Lee (2007) çalışmalarında log dönüşümlü binom örgü analizi kullanarak gerçek opsiyonlar bazlı bir değerlendirme metodolojisini Tayvan Yüksek Hızlı Tren Projesi yatırımına uygulamışlardır. Ayrıca bu uygulamada elde edilen

sonuçları statik nakit akım değerlendirme yöntemi sonuçları ile karşılaştırarak bir kıyaslama çalışması da yapmışlardır.

Wu ve arkadaşları (2008) opsiyonlar teorisini kullanan çoğu IT çalışmalarının tek opsiyonu dikkate aldıklarını ifade ettikten sonra ERP sistemleri için en iyi modelin analitik olmayan ve bileşik opsiyonlar içeren model olduğunu belirtmişlerdir ve belirsizlikler içeren bir ERP yönetim projesi için gerçek opsiyonlar teoremi bazlı binom ağacı yaklaşımı uygulamışlardır.

Hahn ve Dyer (2008) binom örgü yaklaşımı ile gerçek opsiyonları aynı modelde birleştirerek birçok pratik uygulamada belirlenmesi zor olan yönetsel esnekliği değerlendirmektedir. Bu model bir enerji projesini değerlendirmek için binom karar ağacı formatında ve gerçek opsiyonların uygulanması ile test edilmiştir.

Kallio ve arkadaşları (2012) Brezilya'daki bir bitkilendirme projesi yatırımı için CAPM, NPV ya da IRR gibi geleneksel modeller yerine gerçek opsiyon teoremi ile modellee yaparak değerlendirme yapmışlardır. Ancak, genellikle gerçek opsiyonlar bazlı değerlendirme çalışmalarının pazarı eksiksiz olarak öngördüğünü ve işlem maliyetleri, faiz oranlarının dalgalanması ve kısa vadeli opsiyonların kısıtlanması gibi çeşitli faktörlerin dikkate alınmadığını belirtip kullandıkları modelde gerçek opsiyon modelini genişletip mükemmel olmayan pazarlar için uyarlamışlardır.

Zapata ve Reklaitis (2010) geliştirilmiş bir gerçek opsiyonlar analizi kullanarak teknolojik olarak belirsizliklerin olduğu bir ortamdaki proje portföyünün değerlemesini yapmakta ve çalışmalarında ilaç sektöründeki bir vaka üzerinde karar ağacı analizi ve kendi önerdikleri metodun karşılaştırmasını yapmaktadırlar. Önerilen bu metod ile birbirleriyle aynı kaynakları paylaşan Ar-Ge yatırım projelerinden oluşan bir portföyün indirgenmiş nakit akımları ile yönetsel esneklikler de dikkate alındıktan sonra değerlendirilmesi yapılmıştır. Sonuç olarak, bu metod geleneksel NPV ve karar ağacı analizinin aksine gerçek opsiyonlar analizi altyapısını kullanarak portföy koşullarının en uygun değerlendirilmesini yapmaktadır.

Lee (2011) çalışmasında Tayvan'da gerçekleştirilen yenilenebilir enerji yatırımlarının değerlendirilmesini gerçek opsiyonlar analizi bakış açısıyla teorik ve ampirik açıdan incelemektedir. Çalışmada yenilenebilir enerji yatırımının doğası

gereği belirsizlikler içeren bir ortamda gerçekleştiği ve bu esnekliğin gerçek opsiyonlar analizi ile değerlendirilmesi gerektiği belirtilmiştir.

Lee ve arkadaşları (2009) gerçek opsiyonlar metodu ile çıktı fiyatlarının stokastik olduğu ve fiyatların artışı, satışların artışı ve maliyetlerin kısıtlanması gibi faktörler ile daha etkili olabilen bilişim teknolojileri (IT) yatırımlarının optimal zamanlama kararını analiz edebilmek amacıyla dinamik bir model sunmuşlardır. Yapılan çalışmada kapalı form yönteminden türetilerek IT yatırımlarının zamanlaması bulunmakta ve ayrıca bu yatırımların ekonomik canlanmalar ve ekonomik düşüşlerde artan oranlarda tepki verdiğini kanıtlanmaktadır. Çalışmanın sonucunda fiyat volatilitésinin artışının (azalışının) IT yatırımının zamanlamasında erteleme (öne alma) opsiyonunu doğuracağı bulunmuştur. Buna ek olarak bulunan bir diğer sonuç da etkinliğin azalması (artması) ve amortismanın artması (azalması) durumlarında IT yatırımlarının zamanlamasının ertelenmesi (öne alınması) söz konusu olmaktadır. Yapılan çalışmada belirsizliğin kaynağı firmanın çıktı fiyatlarıdır. Yazarlara göre bu çalışmanın üç ana amacı vardır. İlki, firmanın çıktı fiyatlarının kesin olarak bilinemediği durumlarda gerçek opsiyonlar analizi ile IT yatırımlarının değerini ortaya çıkarmaktır. İkincisi, IT yatırımlarının optimal zamanlamasını bulmaktır. Sonuncusu ise bazı temel parametrelerin etkisinin IT yatırımının zamanlamasına ve değerine nasıl etki edeceğinin duyarlılık analizi ile bulunmasıdır.

Davis ve Owens (2003) yenilenebilir enerjil kaynaklarından olan rüzgar enerjisi hakkında yaptığı çalışmada fosil kaynaklı yakıtların belirsiz fiyatlarından dolayı gerçek opsiyonlar analizini kullanmıştır ve ayrıca çalışmasında yenilenebilir enerji ile Ar-Ge çalışmalarının optimal miktarını duyarlılık analizi ile bulmuştur.

Siddiqui ve arkadaşları (2007) yenilenebilir enerji maliyetleri, Ar-Ge harcamaları, terk etme maliyetleri, bakım maliyetleri ve yenilenebilir enerji talebi gibi faktörleri dikkate alıp çeşitli piyasa riskleri altında enerji sektörü Ar-Ge projelerini gerçek opsiyonlar yaklaşımı ile değerlendirmiş ve enerji portföyünün şimdiki değerini bulmuştur.

Kumbarođlu ve arkadaşları (2008) enerji maliyetleri, kullanılabilirlik faktörü, kapasite, öğrenme oranları ve inşaat süreleri gibi faktörleri dikkate alarak gerçek opsiyon analizi orijinli bir prensip planlama modeli sunmuştur.

## 2.4.2. Bulanık Mantık ve Yatırım Deđerlemesi

Geleneksel deđerleme metotları yerine kullanılmaya başlayan bir diđer metot ise, bulanık mantık temelli deđerleme metotlarıdır. Zadeh (2008)'e göre bulanık mantık insanların iki önemli yeteneđinin biçimlendirilmesi için bir girişim olarak görülebilir. İlk yetenek belirsiz, bilgilerin eksik olduđu ve beklenmeyen durumlar ile dolu bir çevrede görüş öne sürme, sebep bildirme ve rasyonel kararlar alabilme yeteneđidir. İkinci yetenek ise herhangi bir ölçme veya hesaplama yapmadan çeşit çeşit fiziksel ve mental görevleri yerine getirebilmektir.

Zadeh (2005)'e göre bulanık mantığın seçkin özelliđi, bulanık mantıkta herşeyin bir sınırı olmasıdır ya da sınırının olmasına olanak sağlanmasıdır. Genelleştirilmiş belirsizlik teorisinde, belirsizlik granüler yapı konseptiyle (insanın gerçek dünya ile olan etkileşiminde anahtar bir rol oynayan bir konsept) alakalı olan bilgiyle ilişiktir.

Bulanık mantık bulanık deđildir ve temel olarak yaklaşık olarak akıllı yürütmeyi sağlayan kesin bir mantık yöntemidir (Zadeh, 2008). Bulanık küme teorisi (Fuzzy set theory) olasılık teorisi (possibility theory) için bir temel oluşturmaktadır (Zadeh, 1999). Bulanık mantık bir mantık sisteminden ötedir çünkü birçok kısmı vardır: Mantıksal, bulanık küme teorisi, epistemik ve bağıntısal (Zadeh, 2008).

Bulanık nakit akım analizi geleneksel nakit akım modellerine alternatif olarak birçok yazar tarafından kullanılmıştır. Bulanık küme teorisi, bulanık nakit akımlarının bulunmasını sağlamaktadır ve bu nakit akımlar insan yargılarının gelecek hakkında yetersiz ve belirsiz olmasından dolayı belirlenmiş olasılıksal nakit akımlarının yerine kullanılmaktadır (Perego ve Rangone, 1998).

Buckley (1987), bulanık nakit akımlarını ve bulanık faiz oranlarını kullanarak gelecek bulanık deđeri hesaplamak için basit formüller geliştirmiştir. Ward (1989) "flat fuzzy filter function" sayılarını kullanarak bulanık şimdiki deđer ve bulanık iç verim oranı modellerini geliştirmiştir. Chiu ve Park (1994) nakit akımların ve iskonto

oranlarının üçgen bulanık sayılar tarafından temsil edildiği bir indirgenmiş nakit akım modeli geliştirmiştir. Wang ve Liang (1995) çalışmalarında bulanık bir ortamda fayda/maliyet oranı analizini gerçekleştirmek için iki algoritma sunmuştur.

Literatürdeki bulanık mantık teorileri ile geliştirilmiş değerlendirme çalışmaları genellikle gerçek opsiyonlar analizi ile birlikte kullanılmıştır.

Ho ve Liao (2011) çalışmalarında belirsizlik altındaki yatırım proje değerlemesi için gerçek opsiyonlar analizi açısından bulanık binom açılımı yaklaşımı kullanmışlardır ve bu yaklaşımı kullanma sebepleri olarak DCF analizinin belirsizlik ortamında iyi sonuçlar vermediğine ve yönetsel esnekliği içermediğine işaret etmişlerdir. Bu yaklaşım ile projenin kendine has esneklikleri de değerlemeye yansıtılmış olmaktadır. Ayrıca, önerilen metotla birlikte projeye ait ortalama genişletilmiş bulanık NPV değeri bulunabilmektedir.

You ve arkadaşları (2012) değişken bir çevredeki ERP yatırımını yönetmek, yani belirsizlikten doğan riskleri minimize edip ERP sisteminin faydasını maksimize etmek için gerçek opsiyonlar teorisi ile bir yaklaşım öngörerek “fuzzy payoff” yöntemini kullanmıştır. Modeldeki “fuzzy payoff” yöntemi yatırımın getirisini analiz etmek için kullanılmıştır.

Carlsson ve arkadaşları (2007) yönetsel esnekliklerin yatırım projelerine önemli değerler katabileceğini ve geleneksel değerlendirme yaklaşımlarının bu esnekliği dikkate alamadığından yetersiz kalabileceğini ve bu açığın gerçek opsiyonlar yaklaşımı ile doldurulabileceğini savunup Ar-Ge projeleri için bir değerlendirme metodolojisi geliştirmişlerdir. Bu çalışmaya göre gelecekte beklenen nakit akımları trapezoidal fuzzy sayıları ile tahmin edilmektedir. Ayrıca, çalışmada sunulan metodolojinin kurumsal bir ortamda optimal Ar-Ge portföyünün seçilmesi için bir karar verme aracı olarak kullanılabilmesini belirtmişlerdir.

Wang and Hwang (2007)’a göre Ar-Ge yatırımlarıyla oluşmuş bir portföy kararını vermek oldukça zordur çünkü Ar-Ge prosesi uzun süre ister ve bu yüzden yazarlar Ar-Ge projelerindeki belirsizliklere karşı bulanık Ar-Ge portföy seçimi modeli geliştirmişlerdir. Belirgin olmayan ve esnek projeler için modellerinde bulanık küme teorisini kullanmışlardır. Geleneksel proje değerlendirme metodlarının riskli yatırım projelerini gerçek değerinin altında değerlemesinden dolayı fuzzy



bileşik opsiyon bazlı bir model ile Ar-Ge projesi değerlemeye tabi tutulmuştur. Ayrıca, bulanık sıfır-bir tamsayı programlama modeli ile belirsiz ve esnek parametreler optimal proje portföyünü belirlemek için kullanılmıştır. Önerilen model karar vericilerin belirsiz ortamlardaki Ar-Ge yatırımları arasından değerli olanları seçebilme ve değiştirebilmesine yardımcı olacaktır.

Carlsson ve Fuller (2003)'in çalışmalarının temelini oluşturan soru, karar vericilerin yatırımı yapmayı ne kadar erteletebileceğidir. Bu temel çerçevesinde çalışmalarında, beklenen nakit akımlar ve maliyetlerin bugünkü değerleri "trapezoidal fuzzy" sayılar ile tahmin edilmiş ve bulanık mantık ile desteklenmiş bir gerçek opsiyon kuralı sunulmuştur. Ayrıca, çalışmalarında bulanık sayıların olasılıksal ortalama değer ve varyansı ile optimal çalışma zamanını da belirlemişlerdir.

Karsak ve Tolga (2001) birçok alternatif seçeneğin bulunduğu bir kümeden en uygun ileri üretim sistemini seçebilmek için bir bulanık karar algoritması sunmuşlardır. Normalde kantitatif olmayan esneklik ve kalite gelişimi gibi hem ekonomik hem de stratejik değerlendirme kriterleri seçme kriteri olarak öngörülmüştür. İleri üretim sistemi seçme sürecinin ekonomik tarafı bulanık indirgenmiş nakit akım analizi ile değerlendirilmiştir. Karar verme algoritması, uzmanların ekonomik ve stratejik kriter ağırlıklarını puanlamasını ve belirlenen seçme kriterlerine karşı ileri üretim sistemi yatırım alternatiflerinin uygunluk durumunu bütünleştirerek bulanık uygunluk dizinlerini (fuzzy suitability indices) hesaplamaktadır. Bulanık dizinler daha sonra ileri üretim sistemi yatırım alternatiflerini sıralamak için kullanılmaktadır. Üçgen bulanık numaralar; periyodik nakit akımlar, faiz oranı, enflasyon oranı vb. gibi finansal tahminlerin doğasında bulunan belirsizlik kriterlerini belirlemek için kullanılmaktadır.

Lee ve Lee (2011)'nin çalışmasında tedarik zincire adapte edilen bir radyo frekansı ile tanımlama (RFID) projesinin değerlendirilmesi gerçek opsiyonlar analizi ile yapılmaktadır. Yazarlara göre RFID gibi karmaşık bir teknolojinin değerlendirilmesi için gerçek opsiyonlar analizini kullanmak mantıklı bir seçimdir, ancak saf gerçek opsiyon kuralı tahmin edilen nakit akımlarının ve maliyetlerin bugünkü değerini belirlerken çoğu zaman gerçekçi olmayan tek bir rakam atamaktadır. Bu çalışmada bahsedilen problemi çözmek için tahmin edilen nakit akımlarının ve maliyetlerin

bugünkü deęeri için trapezoidal fuzzy sayılar kullanılarak gerek opsiyonlar analizi ile deęerleme yapılması anlatılmıştır. Sonu olarak, RFID gibi geliřmiř bir teknolojik yatırım deęiřtirme, uzatma, erteleme ve vazgeme gibi bir ok opsiyon ve risk ierdięi iin yatırım deęerleme yntemi olarak gerek opsiyonlar analizi; daha da geeki ve pratik bir yaklařımla fuzzy gerek opsiyonlar modeli kullanılmıştır.

Tao ve arkadaşları (2007) bir nkleer santraldeki IT yatırımını deęerlendirirken bulanık risk analizi ve gerek opsiyonlar metodu orijinli kapsamlı bir model geliřtirmişlerdir.

Ual ve Kahraman (2009) alıřmalarında Carlsson ve Fuller'in nerdięi hibrid yaklařımı riskli nakit akımlarında daha iyi sonular veren "discrete compounding" bakıř aısıyla incelmіřtir. Yatırım projesinin erken ařamalarında erteleme ve bulanıklıęı giderme (defuzzification) opsiyonlarını neren yeni bir gerek opsiyonlar deęerleme modeli ele alınmıştır. nerilen bu model enerji alanındaki bir yatırımda kullanılmış ve sonu olarak erken bulanıklıęı giderme opsiyonunun yapılması sonucu ortaya ıkmıştır. Bulanıklıęı giderme opsiyonu, bulanık mantıkta lülebilir sonular reten bir sretir.

Kuchta (2001) her bir projenin ıktı, fayda ve kaynaklarının etkileřimlerini dikkate alarak ve bulanık sayıları kullanarak belirsiz NPV modeli geliřtirmiřtir. Yazar alıřmasında bulanık sıfır-bir tamsayı programlama yntemini formle edip bu modeli herbir bulanık parametre deęerinin alfa-seviye kmesinin minimum deęerini kullanan sıfır-bir tamsayı programlama modeline dnřtrmüşür.

Majlender (2008) her yeni bir bilgi elde edinildięinde bu bilgi ışığında yatırım stratejisini optimal olarak ne kadar deęiřtirilmesi gerektięini analiz edip uygulayabilen, karar ařaması uygulaması modelini sunmuş ve bu model iin bulanık gerek opsiyon yaklařımını kullanmıştır.

Mohamed ve McCowan (2001) inřaat yatırımı projeleri iin geici veya srekli olan belirsizlięi de dikkate alıp projeleri deęerlendirmek ve semek iin bulanık kme teorisini uygulamışlardır.

Ual ve Kahraman (2009) 'ın belirttięine gre Garcia (2004) enerji sektrndeki bir yatırım projesi iin bulanık gerek opsiyon deęerlemesi

kullanmıştır. Yazar zamanlama kararı ve değişik yatırım alternatifleri arasından bir seçim yapmak için Carlsson ve Fuller (2003)'in önerdiği modelden yararlanmıştır.

Zeng ve arkadaşları (2007) yatırım değerlemesi için geleneksel net bugünkü değer metodunu gerçek opsiyonlar metodu ile karşılaştırmış, ele aldıkları enerji yatırımdaki belirsizliği analiz etmiş ve yatırım miktarı ve nakit akışların her ikisinin de bulanık sayılar olması durumunda yatırım kararının nasıl verileceğini tartışmışlardır.

### **2.4.3. Hibrid Yatırım Değerleme Metotları**

Bazı çalışmalarda birden fazla metottan yararlanılarak hibrid bir model yaratılmış ve değerlemeler bu şekilde analiz edilmiştir.

Pierru ve Babusiaux (2008) uluslararası bir enerji firmasının yatırım projelerinin değerlendirilmesinde vergi uygulamalarından dolayı ülkeden ülkeye değişik değerler oluşması üzerinde bir araştırma yapmışlardır. Ödenen faizler üzerindeki mevcut farklı vergi uygulamaları firmaların çeşitli yatırım projeleri arasında borçlarını en uygun şekilde pay etmesine yol açmaktadır. Bu kapsamda geliştirilmiş “vergi sonrası ağırlıklı ortalama sermaye maliyeti” metodu standart metotlara göre birçok avantaj sunmakta ve özellikle borçlanma finansmanının önemli olduğu enerji sektörü gelişim ve yatırım projelerinin değerlemesine oldukça uygunluk göstermektedir. Yazarlar çalışmalarında enerji sektöründeki bir yatırım projesinde geliştirilmiş vergi sonrası ağırlıklı ortalama sermaye maliyeti metodunu kullanmayı tartışmışlardır.

Won (2009) geliştirdiği modelde doğal kaynaklardaki yatırım kararı için opsiyon değerini ve optimal zamanlamayı izlenebilir ve en gerçek haliyle yansıtmayı sağlayan bir yaklaşım öne sürmüştür. Bu fiyatlama modelinde şirketlerin gerçekleştirmek istedikleri projelerini daha doğru ve kolay bir şekilde değerlemeleri hedeflenmiştir. İlk olarak, bu modeldeki metodoloji ve varsayılan değişkenler diğer modellere göre farklılık göstermektedir. Örneğin, ürün fiyatları ve geliştirme maliyetleri stokastik olarak değerlendirilmekte ve Martingale yapısı içerisinde kapalı-form çözümüne tabi tutulmaktadır. İkinci olarak, kömür ile ilgili gerçek veriler toplanmakta ve kolay uygulanabilir ve çözüme yönelik bir fiyatlama formülü

oluşturulmaktadır. Doğal kaynaklar ile ilgili yatırım projeleri riskli olduğundan benzer karakteristiğe sahip belli bir sayıda örnek bulmak zor olmaktadır ve gerçek opsiyon modelinde olduğu gibi ampirik test işlemi fiyatlama için bir diğer zorluk olmaktadır. Doğal kaynaklar ile ilgili yatırımların doğası gereği içerdiği özelliklerden dolayı klasik NPV yöntemi değerlendirme açısından yeterli olmamaktadır. Sonuç olarak, nakit giriş ve çıkışının belli olmadığı durumlarda dahi geliştirilen bu model kullanılabilirliktedir.

Smit ve Trigeorgis (2006 ve 2007) yapmış oldukları çalışmalarda gerçek opsiyonlar teorisi ile oyun teorisini harmanlayarak belirsiz ortamdaki rekabetçi stratejiler için bir model sunmuşlardır.

Cox ve arkadaşları (1979) ayrık zamanlı binom opsiyonu değerlendirme modeli geliştirmişlerdir. Bu model sezgisel doğası, yürütmesinin kolay olması ve birçok opsiyona geniş uygulanabilirliği sebebiyle gerçek opsiyonlar değerlendirme metodu kadar popüler olmuştur.

Reyck ve arkadaşları (2008) NPV'nin belirlilik eşitliği versiyonunu kullanarak gerçek opsiyonlar bazlı değerlemeye alternatif bir yaklaşım geliştirmişlerdir ve bu modelde farklı iskonto oranlarının türevini alan karar ağacı analizi metodunu kullanmışlardır. Temelde, NPV metodolojisinin gerçek opsiyonlarla değerlendirme yapmak için nasıl geliştirilebileceğini göstermek istemişlerdir. Kullandıkları yapının temel yatırım projesinin değerinin bilindiği ve bunun etrafında şekillenen esneklikleri belirleyen gerçek opsiyonlar teorisinin bakış açısından çok tamamen belirsizlik ortamdaki projelerde dahi geçerli olduğunu savunarak multinomiyal ağaç yapısının da kullanılacağını belirtmişlerdir.

Jiménez ve Pascual (2008) 'e göre NPV metodu ile yatırım projesinin riskini, getirisini ve değerini hesaplayan PRRV analizi anapara bütçeleme kararının verilmesinde önemli bir yer tutmaktadır. Modelde ortaya çıkan en önemli zorluk nakit akışlarının tahmin edilmesidir. Farklı nakit akım bileşenlerinin hesabında farklı projeksiyon kriterleri gerekebilir. Dolayısıyla, yazarlar çalışmalarında her bir nakit akım bileşeni için beklenen ve tercih edilen projeksiyon kriterlerinin oluşturulmasını sağlayan bir PRRV metodu geliştirmişlerdir.

Babusiaux ve Pierru (2009) bir projenin net bugünkü değerini hesaplamak için “yeri değiştirilmiş eşitlik (displaced equity)” denilen yeni bir yaklaşım sunmuşlardır. Basit bir formül ile hesaplanan bu yaklaşımda kısmen borç ile finanse edilmiş yatırımlar analiz edilmektedir. Bu yaklaşıma göre, her yıl ödenmeden kalan borç miktarı özkaynak ile yer değiştirmekte ve her yıl projenin değeri borç ve özkaynak miktarlarına göre hesaplanmaktadır. Sonuç olarak, oluşabilecek ödenmeden kalan borç miktarları tahmin edilebilirse, yeri değiştirilmiş eşitlik metoduna göre projenin net bugünkü değeri kolaylıkla hesaplanabilir.

Kleczyk (2008) ilaç sektörü ile alakalı çalışmasında NPV metodunu stokastik baskınlık metodu ile harmanlayarak belirsizlik faktörü karşısında daha doğru sonuç elde edeceğini varsaymıştır.

## **2.5. Geleneksel Yatırım Değerleme Metotlarının Dezavantajları**

Luehrman (1997) ve Myers (1984) hazır kaynaklar ile yapılan yatırım kararlarında geleneksel değerlendirme metotlarının yeterli olduğunu savunmuşlardır. Benzer şekilde, Garvin ve Cheeah (2004)’a göre bu tip durumlarda, operasyonlar genellikle güvenilir ölçüde tahmin edilebilir nakit akışları yaratacaklardır. Geleneksel değerlendirme ayrıca temel faydası maliyet tasarrufu olan ekipman değişimi gibi mühendisliğe özgü yatırımlarda iyi sonuçlar vermektedir.

Lee ve Lee (2011)’ye göre teknolojik gelişmelerle ilgili yatırım projelerinin değerlemesinde genellikle net bugünkü değer ve yatırımın getirisi modeli sıklıkla kullanılmaktadır. Ancak bazen doğası gereği yeni IT yatırımlarının değerini ölçmek zor olmaktadır. Dolayısıyla karmaşık yeni teknoloji yatırımlarının değerlemesini doğru yorumlayabilmek adına kapsamlı aynı zamanda da kolayca anlaşılabilir metodolojilerin kullanılması gereklidir.

Liao ve Ho (2010) proje değerlemesinde kullanılan geleneksel yöntemlerden indirgenmiş nakit akımları yönteminin, net bugünkü değer ve iç verim oranı gibi ölçülebilir sonuçlar verdiğine vurgu yapıp, DCF yönteminin iki büyük dezavantajı olduğunu belirtmişlerdir. Bunlardan ilki DCF’in en önemli parametresi olan nakit akımlarının belirsiz karar verme ortamlarında kusursuz bir şekilde tahmin

edilmesinin mümkün olmamasıdır. İkincisi ise yatırımlardaki yönetsel esnekliklere ait değerlerin DCF analizinde yansıtılmamasıdır. Yazarlara göre bu her iki sebep önemli stratejik yatırım projeleri değerlemelerinde doğru olmayan değerlendirme sonuçlarına yol açabilmektedir.

Carlsson ve Fuller (2003) DCF metodu parametreleri olan nakit akımlar ve iskonto oranlarının tahmininin zor olması sebebiyle metodun özellikle girişimci yatırım projelerinin belirsiz ortamları için yetersiz olduğu belirtilmiştir.

Uçal ve Kahraman (2009)'a göre geleneksel değerlendirme metodları belirsizlik altında daha az uygulanabilirliğe sahiptirler. Gerçek opsiyonlar yaklaşımı ise belirsizliği minimize ederek daha doğru sonuçlar vermektedir. Ayrıca yatırım projelerinde daha sonraki zamana erteleme veya gerekli olduğunda terketme gibi opsiyonlar olacak ise değerlendirme için gerçek opsiyonlar analizi geleneksel DCF metoduna göre daha belirgin sonuçlar vermektedir.

Lee (2011)'ye göre Ar- Ge, ilaç, yenilenebilir enerji ve biyoteknoloji gibi birçok sektördeki yatırım tipleri için DCF modeli limitli kalmaktadır. Yazar bu önerisini şu fikirlerle savunmaktadır. Rekabetçi bir pazarda kullanılan kaynak iyi bir getiri oranının garantisini vermemektedir. Bu gibi koşullarda belirsizliğin artış derecesi yeni planlama etkisi yaratacaktır. Örneğin bir elektrik santrali yatırımında oluşması muhtemel düşük elektrik fiyatları gibi istenmeyen piyasa koşulları söz konusu ise, bu tarz belirsizliklerle bu yatırım karlı olamayacaktır. Bu gibi belirsizlikler altında geleneksel karar verme metodları yetersiz kalmaktadır. Ayrıca yazar DCF metodunun pozitif NPV sağlayan projeyi seçerken, IRR metodunun anapara maliyetinden daha yüksek bir IRR'a sahip projeleri seçmekte olduğunu ancak DCF ve IRR'ın finansal riskleri ve yönetsel esnekliği dikkate almamakta olduğuna işaret etmektedir.

Garvin ve Cheeah (2004) stabil ekonomik ortamda ve risklerin gayet tahmin edilebilir olduğu durumlarda NPV analizinin oldukça doğru sonuçlar verdiğini, ancak DCF ve NPV nin katı dizayn edilmiş yapısının örneğin altyapı projeleri gibi belirsizlik içeren yatırımlarda yetersiz kaldığını belirtmektedirler. Bu nedenle altyapı projelerini ve esneklik faktörünü ele alarak geleneksel değerlendirme modellerinin yetersizliğini savunmuşlardır. Yazarlara göre altyapı gelişim projeleri sıklıkla projeyi daha iyi tanımlama ve bilinmeyen verileri bulma aşamalarına yoğunlaşmak için

birçok fırsat vermektedir. Ayrıca esneklik genellikle yönetimin belirsizlikle mücadele etmek adına sezgisel bir yaklaşımı şeklinde ortaya çıkmaktadır. Bununla birlikte, çevresel etki değerlendirme veya jeoteknik arařtırmalar gibi ilk planlama ve fizibilite çalışmalarını yatırımı deęiřtirebilecek verileri ortaya çıkarabilmektedir. Altyapı projelerini esnek dizayn etmek projeyi talepteki artış veya azalış gibi deęişen kořullara adapte etmektedir. Ařamalı inřa etme süreci, karar vericilere piyasa kořulları hakkında daha fazla bilgi edinmesini ve elde edilen bilgiler ile piyasanın daha belirgin olmasını saęlamaktadır. Özetle, esneklik dinamik çevre kořullarına daha etkin ve daha az maliyet ile reaksiyon göstermeyi saęlamaktadır. Esneklik projeye deęer katmakta ancak karřılıęında zaman, daha karışık yapı ve maliyet demektir. Ama esneklięin kattıęı deęerin önemini anlayabilmek için maliyetine kıyaslanması gerekmektedir ki geleneksel modeller bu analiz için yetersiz kalmaktadırlar.

Limitli esneklięinden dolayı deęişken yatırım ortamında DCF modeli pek de kullanılıřlı deęildir (Dixit ve Pindyck, 1995; Herath ve Park, 1999) ve ayrıca DCF yatırım kararlarındaki yönetimsel esneklięi etkin ve doęru bir biçimde yansıtamadıęı için yatırımın gerçek deęerini göz ardı etmektedir (Garvin ve Hayes, 1982).

Smith ve Nau (1995) geleneksel modellerin riskli yatırımların proje deęerini dikkate almayıp yüksek risk içerip yüksek getiri saęlayacak projeleri ret edebildięine iřaret etmiřtir.

Trigeorgis (1996), geleneksel anapara bütçeleme metod ve/veya indirgenmiř nakit akım yaklaşımının operasyonun esneklięine uyum saęlayamayacaęını belirtip bu kořullarda doęru sonucu ancak opsiyonlar yaklaşım teknięinin vereceęini ifade etmiřtir. Yazar ayrıca, yatırım projelerinin esneklik opsiyonlarından olan beklenilmeyen piyasa geliřmelerine verilecek tepki ve sonraki ařamalardaki karar seęeneklerinin standart NPV kuralı gibi geleneksel indirgenmiř nakit akımı yaklaşımları ile ölçülemeyeceęini belirtmiřtir.

Dixit ve Pindyck (1995) çalışmalarında net bugünkü deęer metodunun kullanım açısından kolay olduęunu ancak yatırımın deęiřtirilme ve ertelenme seęenekleri hakkında yanlış sonuçlar verdięini belirtmiřtir. Bir projenin net bugünkü deęerinin pozitif olması durumunda bu durumun yatırım projesinin hemen devreye

almak manasına gelmeyeceğini ve bazen pozitif NPV'ye sahip projelerin ertelenmesi durumunda NPV değerinin daha da gelişim göstereceğine işaret etmişlerdir.

Smith ve McCardle (1999) anapara maliyeti orijinli indirgeme metodlarının eğer yatırım projelerinin yapısı firmanın yapısından farklı ise soruna yol açtığına işaret edip her bir farklı proje için o projenin kendi anapara maliyetine odaklanıp farklı iskonto oranlarının alınması gerektiğini belirtmişlerdir. Hatta eğer projeye esneklik katılmak isteniyorsa bir adım daha atıp riskli, belirsiz ve yönetsel esneklik gerektirecek bir ortam söz konusu ise tek bir projeye farklı zaman periyotları için farklı iskonto oranlarının uygulanması gerektiğini belirtmişlerdir.

Mun (2002) DCF temelli geleneksel yatırım değerlendirme metodlarının yatırım fırsatının veya varlığın özünde bulunan bazı özellikleri dikkate almadığına işaret etmiştir.

Çeşitli projelerin esneklik ve stratejik değer yaklaşımı geleneksel DCF teknikleriyle düzgün olarak ölçülememektedir çünkü bu yatırımların simetrik olmayan yapıları ve gelecekte yaşanan olaylara olan bağımlılıkları kararın verileceği bugünkü zamanda belirsizdir (Trigeorgis, 1996)

Fernandes ve arkadaşları (2011)'na göre günümüzdeki yatırımların karakteristiğine bakarsak göze çarpan en önemli özellikler yatırımların riskli ve belirsiz ortamda yapıldıklarıdır. Dolayısıyla bu tarz yatırım projelerini değerlendirirken DCF metodu yetersiz kalmaktadır. Bu tarz geleneksel değerlendirme metodları, örneğin projenin geri dönüşü hakkında zımni ve keskin varsayımlar yapmaktadırlar. Böylece bu varsayımlara göre yatırımlar geri döndürülemez ve harcamalar telafi edilemez olarak tarif edilmektedirler.

Marreco ve Carpio (2006)'ya göre geleneksel metodların aksine gerçek opsiyonlar teorisi yüksek seviyedeki belirsizlik altında değişik senaryolara tepki verebilen yönetsel esnekliği değerleyebilmektedir ve bu teori belirsizlik altındaki yatırım projelerinin değerlemesini yapmaya olanak sağlayan modern bir ekonomik yaklaşımdır.

Wu ve Tseng (2006) geleneksel yatırım değerlendirme metodları olan DCF ve NPV metodlarının birçok akademisyen ve şirket yönetici tarafından yaygın bir



şekilde kullanılmasına rağmen anapara bütçeleme için yetersiz kaldığını belirtmişlerdir.

Myers (1977) ilk defa DCF modelinin Ar-Ge yatırımları için uygulanamayacağına işaret etmiştir.

Liao ve Ho (2010) DCF'in ayrılmaz parçaları olan nakit akım ve iskonto oranının belirlenmesinin zor olduğuna dikkat çekmiş, ayrıca DCF'in genellikle geçmiş verileri referans alarak çalışan bir analiz yöntemi olduğu için inovatif yatırım projelerinin değerlemesinde yatırımcıyı yanlış yönlendirebileceğini belirtmişlerdir.

Enerji sektörü için yapılmış çalışmalar (Tseng ve Barz, 2002; Deng ve Oren, 2003) yüksek volatile olan bu sektördeki yatırımlarda, geleneksel değerlendirme modellerinin yatırımın değerini bulmakta yetersiz kaldığını vurgulamaktadır.

Yatırımlar sıklıkla gelecekte büyüme fırsatları yaratırlar veya beklenmedik türde gelişebilirler (örn. projeyi erteleme veya terketme), dolayısıyla bu gelişmelerle veya yeni alınacak bilgiler ile süreci takip eden nakit akışlarında keskin değişimler yaşanabilir. Bu gibi durumlarda DCF metodu bu esnekliğin değerini ihmal etmektedir (Amram ve Kulatilaka,1999; Trigeorgis, 2000; Dixit ve Pindyck, 1995; Myers, 1984)

Wang ve Min (2006) belirsizlik altında geleneksel karar verme metotları yetersiz kaldığını belirtmiştir çünkü ne DCF modelinin ne de IRR'ın finansal riskleri ya da yönetsel esnekliği dikkate almadıklarına işaret etmişlerdir.

### **3. YAPAY ZEKA TEKNİKLERİ**

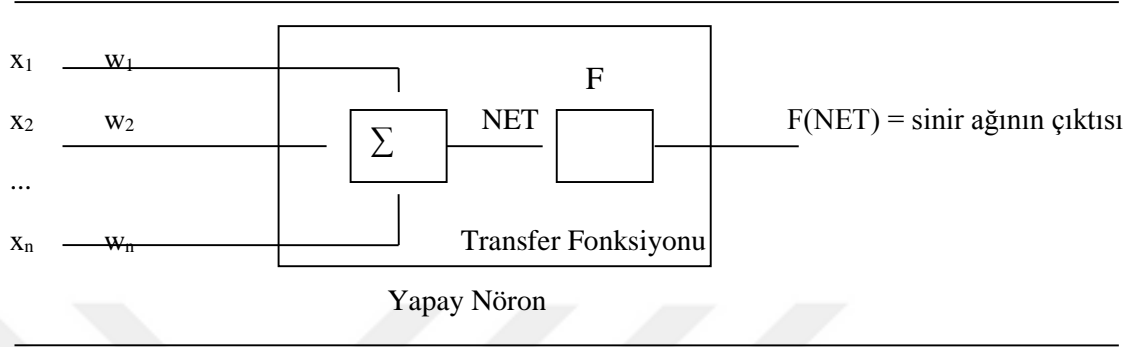
Firmalar yatırım kararlarını alırken belirsiz olan birçok değişkeni tahmin etmek durumunda kalmaktadırlar. Yapılan tahminler genellikle geçmişe yönelik veri setlerinin ileriye yönelik basit uyarlaması şeklinde olurken, özellikle değişken koşulların yaşandığı iş dünyasında bu tahminler doğru kararı alabilmek adına çok önemli bir hale gelmiştir. Satış projeksiyonu, satış fiyatları, makroekonomik veriler, girdi fiyatları, arz ve talep tahmin edilmesi gereken önemli değişkenlerden bazılarıdır. LeVee (1993)'ye göre bir firmanın karar verme sistemini destekleyecek en önemli role sahip olan faktörlerden birisi satış tahminleridir ve doğru satış tahminleri yapabilme becerisi karar vericiye üretim ve girdi maliyetlerini ve satış fiyatlarını doğru hesaplayabilmeyi sağlamaktadır. Yatırım değerlemesi kararını etkileyecek bu değişkenlerin tahmin edilmesi için birçok yöntem kullanılmakta olup bunlardan bir kısmı yapay zeka teknikleri olarak adlandırılmaktadır. Yapay sinir ağları ve destek vektör regresyonu bu metotlardan ikisidir. Bu bölümde yapay zeka teknikleri modellerinden bahsedilerek bu yöntemi kullanarak yapılan tahmin çalışmalarına yer verilecektir.

#### **3.1. Yapay Sinir Ağları**

Yapay sinir ağları metodu yapılan çalışmalar kapsamında birçok şekilde açıklanmıştır. Lubecke ve arkadaşları (1998) yapay sinir ağları metodunun insandaki sinir sisteminin bilgisayar bazlı simülasyonu olduğunu belirtmiştir. Mukherjee ve Biswas (1997) yapay nöronun biyolojik nöronun oldukça benzeri bir modeli olduğunu ve matematiksel bir operasyonu ve/veya iki değeri karşılaştırma işlemini yürütebilmekte olduğunu belirtmiştir. Sermpinis ve arkadaşları (2012) sinir ağları teriminin insan beynindeki nöronlar arasındaki biyolojik bağlantılarından geldiğini belirtmişlerdir. Kuo ve arkadaşları (2002) yapay sinir ağları modelinin katmanlar halinde bulunan ve birbirlerine kontrollü hatlar ile bağlanıp bir ağ oluşturmuş olan nöronlardan oluştuğunu belirtmektedirler. Hamzaçebi ve arkadaşları (2009) yapay sinir ağları yönteminin insan beyninin sınıflandırma, şablon tanımlama ve tahmin etme becerilerinin imitasyonu olduğunu belirtmiştir. Tüm bu açıklamalar sonrasında

denilebilir ki, sinir ağı terimi insan beynindeki nöronların arasındaki biyolojik bağlantılardan türemiştir.

Bu metotta matematiksel bazlı nöronlar kullanılır ve bu yapay nöronlar aşağıda Şekil 3.1a'da tasvir edilmektedir.



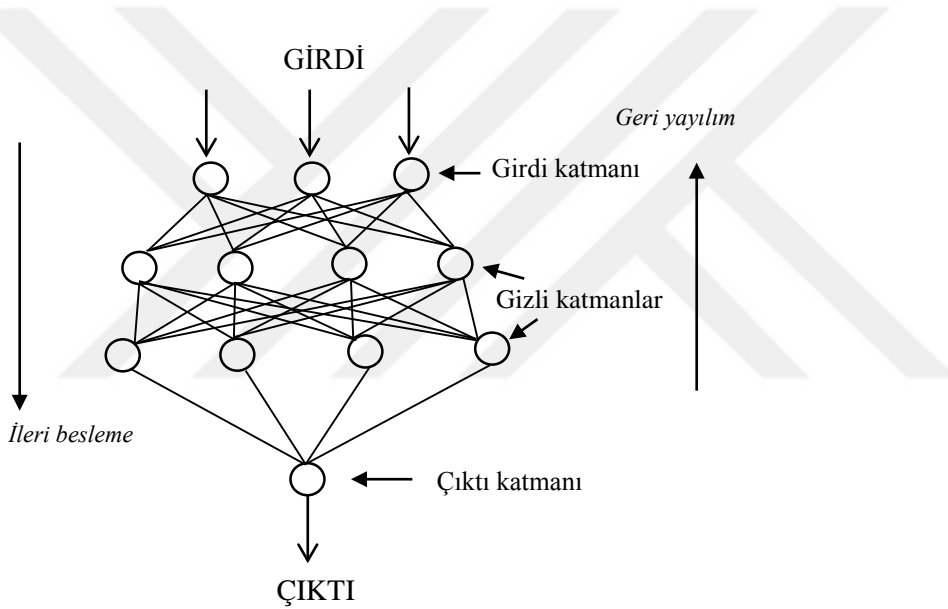
Şekil 3.1a: Yapay Nöronun Çalışma Şekli (Lubecke ve ark., 1998)

$x_1, x_2, \dots, x_n$  girdiler ve  $w_1, w_2, \dots, w_n$  ise bunların ağırlıklarını temsil etmektedirler. Matematiksel olarak girdiler ve ağırlıkları vektör olarak görülebilirler. Toplam girdi sinyali  $NET: \sum x_i w_i$  şeklinde tanımlanabilmektedir.  $NET$  değeri  $F$  aktarma fonksiyonu ile  $F(NET)$  değerini alıp nöronun çıktı sinyali olarak tanımlanmaktadır (Lubecke ve ark., 1998). Yapay sinir ağı birbirlerine belli ağırlıklar ile bağlı olan nöronlar denilen temel işlevsel elementlerden oluşmaktadır. Tipik bir yapay sinir ağı üç nöron katmanından oluşmaktadır: Girdi katmanı nöronları, gizli katman nöronları ve çıktı katmanındaki nöronlar (Hamzaçebi ve ark., 2009; Lubecke ve ark., 1998).

Bir yapay sinir ağı yapısında spesifik bir mimari mevcuttur. Yukarıda da belirtildiği gibi girdi ve çıktı katmanlarının yanı sıra bu mimari gizli katmanları ve bu katmanlardaki gizli nöronları da içermektedir. Nöronlar arasındaki bağlantılar birden fazla tipte gerçekleştirilebilir. Bu bağlantılar ve çalışma tiplerine göre bir çok yapay sinir ağı yöntemi mevcuttur. Dolayısıyla yapay sinir ağları metodunun yapısal olarak farklı modelleri mevcuttur. Ko ve Lin (2008) yapay sinir ağları metodunun yaygın kullanılan beş şekli olduğunu belirtmişlerdir: Geri yayılım ağı (backpropagation network - BPN), radyal bazlı fonksiyon (radial basis function - RBF), destek vektör makinesi (support vector machine - SVM), kendini örgütleyen haritalar (self organization maps - SOM) ve çok katmanlı algılayıcı (multi layer perceptron –

MLP). Sermpinis ve arkadaşları (2012) yapay sinir ağı mimarisinin çeşitleri olduğunu ve en çok kullanılanının MLP olduğunu belirterek bu yapının özellikle zaman serili finansal tahminde oldukça başarılı olduğunu belirtmişlerdir.

Çok katmanlı algılayıcılar geri yayılım ile eğitilen ileri beslemeli katmanlardan ve ağdan oluşmaktadır. Bu ağ aşağıda da belirtileceği gibi öğrenme ve sonuç verme aşamalarında statik şablon sınıflandırması kullanarak çalışmaktadır. İleri beslemeli bildirimli yapay ağ olarak da adlandırılan bu yapı aşağıda Şekil 3.1b’de gösterilmiştir (Mukherjee ve Biswas, 1997). İleri beslemeli bildirimli yapay sinir ağında sinir birimleri değişik tabakalarda sınıflandırılmıştır. Bu tabakalar bir girdi katmanı, birden fazla gizli katman ve çıktı katmanından oluşmaktadır.



Şekil 3.1b: Çok Katmanlı Algılayıcılar ve İleri Beslemeli Yapay Sinir Ağı (Mukherjee ve Biswas, 1997)

Yapay sinir ağı operasyonlarında öğrenme ve test etme (training and testing) şeklinde iki temel faz bulunmaktadır. Öğrenme aşaması, yapay sinir ağı yönteminin oluşturduğu toplam hatalara karşılık ağırlık katsayılarını ayarlamayı, test etme aşaması ise yapay sinir ağı metodunun örneği ezberlemek yerine veri setinin genelleştirilip genelleştirilmediğini belirlemektedir (Lubecke ve ark.,1998). Zhang ve arkadaşları (1998) yapay sinir ağlarının güçlü şablon sınıflandırması ve algılama yeteneğinin olduğunu belirterek bu modelin deneyim kazanarak öğrenebildiğini ve

genelleme yapabildiğini belirtmişlerdir ve bu sebepten günümüzde endüstri, iş dünyası ve bilimsel alanda sıklıkla kullanıldığını açıklamışlardır. Yapay nöron diğer nöronlardan veya direkt olarak çevreden girdileri almaktadır. İki nöron arasındaki bağlantı hattının değişken bir ağırlığı vardır ve bu ağırlık bağlantının gücünü göstermektedir. Yapay nöron kendisine girdi olarak gelen tüm verileri ve ağırlıklarını toplayarak formüle etmektedir. Daha sonra dönüşüme uğrayan bu değerler çıktı olarak değerlendirilmektedir (Mukherjee ve Biswas, 1997)

Hamzaçebi ve arkadaşları (2009) yapay sinir ağları yöntemini şu şekilde özetlemişlerdir: Yapay sinir ağları modeli zaman serileri tahmininde oldukça değerli bir araçtır. Yapay sinir ağları yöntemi ile çok zamanlı tahmin yapılmak istendiğinde yinelemeli ve direkt olmak üzere iki metot kullanılabilir. Yinelemeli metoda göre ilk tahmin yapılacak periyoda ait veri geçmiş varsayımlara göre belirlenmektedir. Daha sonra bu tahmini değer girdi olarak kullanılmakta ve bir sonraki periyot tahmin edilmektedir. Süreç bu şekilde yinelemeli olarak tahminlerle oluşmaktadır. Direkt tahmin metodunda ise, birbirini izleyen periyotlar tek bir seferde tahmin edilmektedir. Ancak, bu metot gelecek periyotlar için yapılacak tahminler için sadece gözlenmiş verilerin kullanıldığı zamanlarda daha iyi sonuçlar vermektedir. Yazarlar çalışmalarında yinelemeli ve direkt yöntemleri kullanarak tahmin yapmış ve sonuçlarını karşılaştırmışlardır. Çalışmanın sonucuna göre yapay sinir ağları diğer metotlara göre ve aynı zamanda direkt metot yinelemeli metoda göre daha iyi sonuçlar vermiştir.

Zhang (2004)'a göre yapay sinir ağları ile tahmin yöntemi veri hazırlama, ağ yapısını kurma, model seçme ve değerlendirme aşamalarından oluşmaktadır. Mandal ve arkadaşları (2006)'na göre yapay sinir ağları modelinin en fazla zaman alıcı ve dikkat gerektirici aşaması süreç öncesi data hazırlık aşamasıdır. Bu aşamada model ham datayı işleyerek girdi ve çıktı arasındaki ilişkiyi analiz ederek öğrenmektedir ve bunu yaparken normalleştirme, sıralama ve korelasyon gibi matematiksel modeller kullanmaktadır. Mukherjee ve Biswas (1997) yapay sinir ağlarının örnekler aracıyla öğrendiğini, bu örneklerin de girdi ve çıktı parametreleri olarak modeli etkilediğini belirtmişlerdir. Böylece model girdi ve çıktı arasındaki ilişkiyi haritalayarak öğrenmektedir.

Hamzaçebi ve arkadaşları (2009)'nın belirttiğine göre tipik bir yapay sinir ağları modeli nöronlardan oluşan katmanların kombinasyonundan oluşmaktadır. Yapay sinir ağları yönteminin tahmin amaçlı en çok kullanılan şekli MLP'dir. Zaman serileri tahmininde kullanılacak çok katmanlı algılama yöntemi için girdi, gizli ve çıktı nöronlarının sayısı gibi değişkenlerin belirlenmesi oldukça önemlidir. Bu parametrelerden en önemlileri girdi nöronlarının, gizli katmanların ve gizli nöronların sayısıdır. Çalışmaların sonuçlarına göre daha az gizli nöron ve katman olması daha istenen bir durumdur.

Gizli nöron sayısını belirlemek oldukça önemli ve zorlayıcı bir süreçtir. Bu aşama için genellikle deneme yanılma yöntemi kullanılsa da çeşitli formülasyonlar da mevcuttur. Katz (1992) ve Bailey ve Thompson (1990) gizli nöron sayısı için aşağıdaki denklemleri önermektedirler.

$$a) \quad N*1,5 \leq X \leq N*3$$

$$b) \quad X = N*0,75$$

Denklemlerde N girdi sayısını gösterirken, X gizli nöron sayısını göstermektedir.

### 3.1.1. Yapay Sinir Ağlarının Üstün Yönleri

McGuire (1997) yapay sinir ağlarının aşağıdaki durumlarda başarılı olduğunu kanıtladığını belirtmiştir:

- Düşük kalitede ya da eksik verilere sahip olan bir problem,
- Ağ eğitecek kadar bol örnek bulunduğu zaman,
- Uygulama eğer birden fazla tipte girdi verisi içeriyorsa,
- Bilgi bazlı bir sistem için matematiksel simülasyon ya da kurallar bütünü modeli belirlenemiyor ise,

Panda ve Narasimhan (2007)'a göre yapay sinir ağları modelinin diğer lineer ve lineer olmayan modellere karşı daha fazla avantajı olduğu için özellikle finansal modellemelerde tercih edilmektedirler. Yamin ve arkadaşları (2004)'na göre birçok

tahmin modeli olmasına rağmen yapay sinir ağı modeli kolay uygulanabilmesi, sade bir metot olması ve iyi sonuçlar vermesinden ötürü oldukça fazla dikkat çekmekte ve kullanılmaktadır. Zhang ve arkadaşları (1998)'na göre yapay sinir ağlarının tahmin modelleri için kullanılması yeni değildir. Modelin ilk olarak tahminlerde kullanılması 1964 yılındaki bir çalışmada gerçekleşmiştir. Hu (1964) hava durumu tahmininde yapay sinir ağlarını kullanmıştır ancak o zamanda çok katmanlı ağlara yönelik algoritma eksikliğinden araştırma kısıtlı şekilde yapılabilmektedir. Zhang ve arkadaşları (1998) 1980ler ve sonrasında geri yayılım algoritmasının bulunması ile yapay sinir ağları modelinin sıklıkla tahmin amaçlı çalışmalara konu olduğunu belirtmişlerdir ve ayrıca çalışmalarda birçok yapay sinir ağları modeli önerildiğini ancak en çok kullanılanlardan birinin MLP (çok katmanlı algılayıcı) olduğunu söylemişlerdir. Yazarlara göre, MLP çeşitli katmanlardan oluşmaktadır. İlk ya da en alt katman dışarıdan verilerin alındığı girdi katmanıdır. Son ya da en üst katman ise problem çözümünün elde edildiği çıktı katmanıdır. Girdi ve çıktı katmanları gizli katman denilen bir ya da birden fazla katman ile birbirlerinden ayrılmaktadırlar.

Kuo ve arkadaşları (2002)'a göre yapay sinir ağları modeli birçok defa zaman serileri tahminleri için kullanılmıştır. Ancak, yine yazarların belirttiğine göre yapay sinir ağları modeli değişken oranlı zaman serileri ve çok değişkenli zaman serilerinde de kullanılmıştır. Zhang ve ark. (1998)'na göre 1980lerden beri zaman serileri tahmininde kullanılan yöntemlerden birisi yapay sinir ağları yöntemidir ve bu yöntem lineer ve lineer olmayan zaman serilerine uyarlanarak genellikle geleceği tahmin etmek için kullanılmaktadır. Yapay sinir ağları girdi ve çıktı değişkenlerinin arasındaki ilişki varsayımlarına ve başlangıç bilgisine ihtiyaç duymadan lineer ve lineer olmayan modelleme yapmaktadır. Bu sebepten yapay sinir ağları tüm diğer modellere göre oldukça esneklik ve uygulanabilirlik sağlamaktadır.

Zhang ve arkadaşları (1998) yapay sinir ağlarının geleneksel modellere olan üstünlüklerini şu dört sebeple açıklamışlardır. Son zamanlarda yapay sinir ağlarının geleneksel modellere nazaran daha yaygın kullanılmasının sebeplerinden ilki yapay sinir ağlarının geleneksel modellerin aksine veri orijinli olması ve deneyim kazanma yolu ile öğrenme yetisine sahip olmasıdır. Bu bağlamda bu model çok değişkenli lineer olmayan, parametrik olmayan bir istatistik metodu olarak değerlendirilebilir.

İkinci sebep yapay sinir ağlarının genelleme yapabilmesidir. Modele sunulan veri seti model tarafından analiz edilip öğrenildikten sonra örneklemin görünmeyen kısmı (gelecekteki davranışlar) kirlili (bulanık) içerikte olsa bile yapay sinir ağları modeli bu kısmı açıklığa kavuşturabilmektedir. Üçüncüsü, yapay sinir ağları modeli evrensel fonksiyon kestirimcileridir. Yani genel çalışmalar göstermiştir ki bir sinir ağı kesintisiz bir fonksiyonu istenilen doğrulukta tahmin edebilmektedir. Yapay sinir ağları sisteminin fonksiyonel formları geleneksel tahmin metotlarına göre daha esnek ve geneldir. Dördüncüsü ise yapay sinir ağları lineer olmayan bir modeldir. Geleneksel modeller, örneğin Box-Jenkins ve ARIMA, zaman serileri ile çalışırken bu serilerin lineer süreçler tarafından oluşturulduğunu farz ederler. Lineer modeller detaylıca incelenebilir, kolay uygulanabilir ve açıklanabilir modellerdir. Ancak, lineer olmayan bir yapıyı lineer olarak değerlendirmek tamamen uygunsuz olabilir. Çünkü gerçek dünyada sistemler genellikle lineer değildir.

## **3.2. Yapay Sinir Ağları Literatür Taraması**

Yapay sinir ağları modeli zaman serileri tahminleri için birçok çalışmada kullanılmışlardır. Bu çalışmaların yapıldığı alanlardan bazıları makroekonomik verilerin tahmini, fiyat tahminleri, talep tahminleri, mühendislik, hava durumu vb. başlıklarından oluşmaktadır.

### **3.2.1. Finans Alanında Kullanım**

Panda ve Narasimhan (2007) Hint Rupisi/Amerikan Doları paritesini haftalık verilerden yararlanarak yapay sinir ağları yöntemi ile tahmin etmeye çalışmışlardır. Çalışmada ayrıca yapay sinir ağları ve diğer tahmin modellerinin tahmin doğruluğunu karşılaştırmışlardır. Altı tahmin değerlendirme kriterine göre yapay sinir ağları modeli sonuçlarının lineer otoregresif ve rasgele değişme metotlarına göre üstünlük sağladığını saptamışlardır. Hill ve arkadaşları (1996) yapay sinir ağları modelinin performansını ölçmek ve tahmin gerçekleştirmek amacıyla yıllık, aylık ve çeyreklik zaman verilerini, lineer ve lineer olmayan seri yapılarını kullanarak geniş bir açıdan olaya yaklaşmışlardır. Chen ve arkadaşları (2009) opsiyon fiyatlaması tahminlerinde yapay sinir ağlarını kullanarak konvansiyonel tahmin metotlarının yanı sıra yapay sinir ağlarının da opsiyon fiyat tahminleri için bir alternatif olduğunu belirtmişlerdir.



Hu ve Tsoukalas (1999) Avrupa Para Sistemi içerisindeki 11 para birimi ve bunların 15 sene içerisindeki hareketlerini veri seti olarak kullanarak içerisinde yapay sinir ağı modelinin de olduğu dört modeli kullanarak tahmin performanslarını incelemiştir. Çalışma sonuçlarına göre yapay sinir ağı modeli iyi bir performans sergilemiştir. Sermpinis ve arkadaşları (2012) Avrupa Merkez Bankası verilerini kullanarak Euro/Dolar paritesini yapay sinir ağını yöntemini kullanarak tahmin etmeye çalışmışlardır. Chen ve Leung (2004) uluslararası finans anlamında döviz kurlarının tahmin edilmesinin hep önemli bir konu olduğuna dikkat çekerek son yıllarda yapay sinir ağı modelinin tahmin metodu olarak kullanılmaya başladığını belirtmişlerdir. Çalışmalarında çok değişkenli ekonomik model ile yapay sinir ağı modelinin güçlü yönlerinden yararlanmak adına hibrid bir model kullanmışlardır.

Angelini ve arkadaşları (2008) yapay sinir ağını kredi risk değerlemesi alanına başarılı bir şekilde uyarlamışlardır. Çalışmalarında biri standart ileri beslemeli ağ diğeri de özel amaçlı mimari olmak üzere iki yapay sinir ağı modeli kullanmışlardır. Veri seti olarak küçük ve orta ölçekli İtalyan şirketlerine ait verileri kullanılmıştır. Çalışma sonucunda yapay sinir ağı modelinin kredi risk değerlemesi konusunda da oldukça başarılı bir model olduğunu kanıtladıklarını belirtmişlerdir. Khashman (2010) geri yayımlı öğrenme algoritması bazlı yapay sinir ağı modelini kullanarak kredi risk sistemlerini değerlendirmektedir. Çalışmada kredi başvurusunu kabul ya da ret edebilecek, üç yapay sinir ağı modeli tanımlanmıştır.

Jasemi ve arkadaşları (2011) hisse senedi piyasası zamanlaması için geleneksel Japon mum çubukları yöntemi ve yapay sinir ağı metodunu kullanarak yeni bir model geliştirmişlerdir. Lubecke ve arkadaşları (1998) yapay sinir ağı metodunun döviz kurlarının tahmininde kullanılan diğer metotlara alternatif olup olamayacağını araştırmışlardır. Marcellino (2004) içerisinde yapay sinir ağılarının da bulunduğu birçok model ile Avrupa Para Birliği makroekonomik değişkenlerini tahmin etmeye yönelik bir çalışma gerçekleştirmiştir.

### **3.2.2. Elektrik Piyasası Arařtırmalarında Kullanım**

Yapay sinir aęları finansal tahminlerin yanı sıra birçok sektör ve alıřmada kullanılmıřtır. Örneęin Marvuglia ve Messineo (2012) İtalya'daki kısa vadeli ev elektrięi tüketimini yapay sinir aęları modeli ile tahmin etmeye alıřmıřtır. Moghaddam ve arkadaşları (2011) elektrik piyasasında günlük fiyatların tahmin edilmesinin ok kritik olduęunu belirterek bu tahmini gerekleřtirmek adına yapay sinir aęlarını da ieren hibrid bir modelleme yapmıřlardır. Singhal ve Swarup (2011) elektrik fiyatı ile alakalı deęiřkenlerin arasındaki karmařık iliřkiler dikkate alındıęında, yapay sinir aęlarının en uygun tahmin yöntemi olduęunu belirtmiřlerdir.

Mandal ve arkadaşları (2006) elektrik fiyatlarının tahmininin enerji piyasalarında oldukça önemli olduęunun altını izerek gemiř fiyat verilerinden yararlanarak geleceęi tahmin etme konusunda yapay sinir aęları modelini kullanarak sonuç almaya alıřmıřlardır. alıřmanın sonucuna göre oldukça kısa periyotlarda bile (günlük) elektrik fiyatı tahminlerinde yapay sinir aęları modeli doęru sonuçlar verebilmektedir.

### **3.2.3. Proje ve Yatırım Performansı Arařtırmalarında Kullanım**

Fioretti (2006) yatırım kararı verme sürecini yapay sinir aęları modeline benzetmiř, nöronların yatırım yapma kararını alacak olan firmalara, onların aęırlıklarını da yatırım kararını etkileyebilecek esnek hızlandırıcılara benzeterek yatırım kararı alma modelini yapay sinir aęları metodu ile gerekleřtirmeye alıřmıřtır. Chi ve Tang (2005) 59 Tayvan menřeli firmayı inceleyerek, bu firmaların yeniden yapılanma dönemine gittikleri zamanlarda yatırımcılarına kazandırdıęı ya da kaybettirdięi yatırım miktarlarını incelemek amacıyla geliřtirdikleri modelde yapay sinir aęlarını kullanmıřlardır. Tan ve arkadaşları (2006) üretim teknolojisi yatırım kararlarının zamanının doęruluęunu ölçümleyebilmek adına geliřtirdikleri hibrid modelde yapay sinir aęları metodundan da yararlanmışlardır.

Chen (2012) kendini örgütleyen harita optimizasyonu, bulanık mantık kontrolü ve hiper dikkörtgen bileřimli yapay sinir aęları modellerini ieren hibrid bilgi

paylaşımli bir model geliřtirip Çin'deki yabancı inřaat sektöru yatırımlarının performansını deęerlendirmiřtir.

Lee ve arkadařları (1998) parametrik olmayan bir yaklařımla küme analizi ve yapay sinir aęları modelini birlikte kullanarak yazılım projesi geliřtirme maliyetlerini tahmin edecek bir model geliřtirmiřlerdir. Bu model sadece doęru maliyet tahmini yapmakla kalmayıp aynı zamanda aęın öęrenme verimlilięini artırmaktadır.

Kumar ve arkadařları (2008) yazılım geliřtirme maliyetlerinin řirketler için kritik öneme sahip olduęunu belirterek dalgalı yapay sinir aęları modelini kullanarak maliyet tahminini geręekleřtirmiřlerdir.

Lau ve arkadařları (2010)'nın belirttięine göre radyal bazlı fonksiyon sinir aęları metodu, tünel inřaatı projelerinin girdileri ve çıktıları arasındaki lineer olmayan iliřkiler düşünöldüęünde doęru, esnek ve verimli sonuçlar vermektedir. Yazarlar ęalıřmalarında Hong Kong'daki bir tünel inřaatına ait verileri ve radyal bazlı fonksiyon sinir aęı modelini kullanımıřlardır.

Tařkın ve Güneri (2006) yapay sinir aęlarının çok katmanlı algılayıcı ve radyal bazlı fonksiyon modellerini kullanarak riskli projelerin ekonomik analizini geręekleřtirmiřlerdir. Riskli projeler analitik modeller ile arařtırılmıř ve yapay sinir aęı yaklařım sonuçları karřılařtırılmıřtır. Modelde beklenen maliyet ve varyansları yapay sinir aęının çıktı katmanını oluřturmuřtur. ęalıřmanın sonucuna göre riskli projelerin girdileri Gaussian daęılım fonksiyonu ile genelleřtirilir ise çok katmanlı algılayıcı sinir aęı modeli riskli projelerin deęerlendirilmesi konusunda bařarılı olmaktadır.

### **3.2.4. Dięer Sektör ve Arařtırmalarda Kullanım**

Mukherjee ve Biswas (1997) yüksek sıcaklık altında betonun mekanik davranıřının lineer olmadıęını belirterek yapay sinir aęlarını nükleer mühendislik alanındaki bir arařtırmada kullanımıřtır ve oldukça bařarılı sonuçlar elde ettiklerini paylařımıřlardır.

Wei ve Lee (2007) yapay sinir aęları bazlı iki model kullanarak trafik kazalarının süresini tahmin edecek bir ęalıřma geręekleřtirmiřlerdir.

Efendigil ve arkadaşları (2009) tedarik zinciri yönetiminde belirgin olmayan müşteri taleplerinin tahmininin kritik bir öneme sahip olduğunu belirterek yetersiz bilginin olduğu bulanık bir ortamda tahmin gerçekleştirebilmek amacıyla yapay sinir ağları ve uyarlanabilir ağ bazlı bulanık çıkarsama tekniğinin karşılaştırmasını yapmışlardır.

Yapay sinir ağları modelinin farklı bir alanda kullanılmasına örnek olarak Zhang ve arkadaşları (2009)'nın yapay sinir ağları modeli kullanarak sinema filmlerinin gelirlerini tahmin edebilme çalışması verilebilir. Söz konusu çalışmada çok girdili ve çok çıktılı, çok katmanlı yapay sinir ağı modeli kullanılmıştır.

Khashei ve Bijari (2010)'nin belirttiğine göre yapay sinir ağları en doğru sonuçları verebilen ve en yaygın kullanılan tahmin modellerinden birisidir ve sosyal, ekonomik, mühendislik, döviz kurları ve hisse senetleri konuları gibi bir çok alanda kullanılmaktadır. Ayrıca yazarlar yapay sinir ağları modelinin gün geçtikçe yeni yapılar ile kullanılmakta olduğunu belirtip çalışmalarında söz konusu model ile yine bir tahmin modeli olan ARIMA'yı hibrid bir model şeklinde kullanıp belirledikleri veri setleri üzerinde çalışmalar yapmışlardır.

Ko ve Lin (2008) portföy seçiminin kaynak dağıtım problemi olduğunu belirterek yapay sinir ağları modelinin lineer olmayan büyük problemleri çözme becerisinden yararlanmak istemişlerdir. Ancak, geleneksel yapay sinir ağları modelinin çıktı katmanında yatırım ağırlıklarının %100 ünü her zaman temsil edemeyeceğini belirterek yapay sinir ağları modelini kaynak dağıtım problemine göre uyarlamışlardır.

Yu ve arkadaşları (2008) ampirik ayrışım bazlı yapay sinir ağları metodu kullanarak dünya ham petrol piyasası fiyatlarını tahmin edecek bir model üzerinde çalışmışlardır. Ham petrol fiyat serilerini yerleşik fonksiyonlara dönüştürerek üç katmanlı ileri beslemeli yapay sinir ağı modeli kullanılmış ve her bir yerleşik fonksiyon için tahminler gerçekleştirilmiştir. Sonraki aşamada ise tüm bu tahminler uyarlanabilir lineer sinir ağı içerisinde kaynaştırılarak nihai tahmin sonuçlarına ulaşılmıştır.

Kermanshahi (1998) yinelenen ve ileri beslemeli geri yayımlı olmak üzere iki yapay sinir ağı kullanarak Japon firmalarının ileriye dönük uzun vadeli iş yüklerini

tahmin etmiştir. Yinelenen sinir ağı metodu 1 yıllık, ileri beslemeli geri yayımlı sinir ağı metodu ise 5 ve 10 yıllık tahminler için kullanılmıştır. Modeller veri seti olarak geçmiş 20 yıla ait verilerle beslenmişlerdir.

Wu ve Yen (1992) marjinal maliyet ve kümülatif üretim arasındaki ilişkiyi (lineer regresyon örneği) ve buğday üretimi ile suni gübre kullanımı arasındaki ilişkiyi (lineer olmayan regresyon örneği) inceleyerek geleneksel regresyon modelleri ile yapay sinir ağlarını karşılaştırmışlardır. Her iki örnekte de yapay sinir ağların geleneksel regresyon tekniklerine göre daha iyi sonuçlar vermiştir. Chang ve arkadaşları (1991) yapay sinir ağlarını zaman serilerine uygulamışlardır. Araştırmalarında iki gizli kademeli yöntemin tek gizli kademeli yöntemle göre daha iyi sonuç verdiğini saptamışlardır.

Tang ve arkadaşları (1991) yapay sinir ağları ve yine bir tahmin modeli olan Box-Jenkins modellerini kullanarak bir çalışma gerçekleştirmişlerdir. Yaptıkları çalışma sonucunda yapay sinir ağları yapısının modelin performansını etkileyebileceğini belirtmişlerdir. Bu çalışmaların sonuçları birbiri ile çelişkili de olabilmektedirler. Örneğin Weigend ve arkadaşları (1991)'na göre yapay sinir ağları konvansiyonel metotlara göre daha iyi sonuçlar verirken Tang ve arkadaşları (1991) tersi bir sonuca vararak Box-Jenkins modelinin kısa dönemli tahminlerde yapay sinir ağları yönteminden başarılı olduğu sonucuna varmışlardır. Ancak, unutulmamalıdır ki uzun dönemli tahminlerde yapay sinir ağları yöntemi Box-Jenkins yöntemine göre daha iyi sonuçlar vermektedir (Kuo ve Xue, 1999). Kuo (2001) satış tahminlerinde yapay sinir ağları modelinin sıklıkla kullanıldığını ve iyi sonuçlar verdiğini ancak bazı özel durumlar altında, örneğin promosyonların satışlar üzerindeki ani değişirici etkisi gibi, bulanık sinir ağları yönteminin daha doğru sonuçlar verdiğini belirtmiştir.

Leung ve arkadaşları (2000) adını genel regresyon sinir ağları verdikleri spesifik bir yapay sinir ağı mimarisi ile tahmin çalışmaları yapmış ve bu yapının performansını içerisinde çok katmanlı ileri beslemeli ağ, çok değişkenli transfer fonksiyonu ve rasgele değişimli modellerini içeren farklı tahmin metotları ile karşılaştırmıştır.

### 3.2.5. Bulanık Yapay Sinir Ağları

Sinir ağlarının bir modeli de bulanık sinir ağlarıdır. Kuo ve arkadaşları (2002) bulanık sinir ağlarını aşağıdaki gibi özetlemiştir. Bulanık model ile yapay sinir ağları modelinin birlikte kullanılmasıyla oluşan bulanık sinir ağları yöntemi son zamanlarda iki ana başlıkta incelenmiştir: Kaynaştırıcı (fuse) yapay sinir ağları ve bulanık mantık, birleştirici (integrated) yapay sinir ağları ve bulanık mantık. İlk yöntemde geleneksel bulanık sistem tecrübe ve bilgiye dayandığı için objektif olmayabilmektedir. Ayrıca sağlam bilgi ve uygun deneyime sahip insan bulmak oldukça zor olabilmektedir. İkinci yöntemde ise yaratıcı bir yaklaşım geliştirilerek yapay sinir ağlarının öğrenen algoritması bulanık sisteme uygulanarak sistemin performansı artırılmaktadır. Bu yöntemde sayısal datalarda bulanık IF-THEN yöntemi kullanılmaktadır. Bulanık yapay sinir ağlarını kullanarak birçok çalışma yapılmıştır. Örneğin Takagi ve Hayashi (1991) ileri bildirimli yapay sinir ağları modelini bulanık çıkarım içerisinde uygulamıştır. Bu çalışmayı baz alarak, Kuo (1994) ve Kuo ve Cohen (1998, 1999) yine benzer şekilde yapay sinir ağları modelini kullanarak bulanık çıkarım yapmışlardır. Kuo ve arkadaşları (2002) yapay sinir ağları ile bulanık yöntemleri birleştirerek bulanık sinir ağları yöntemini kullanarak satış tahmin sistemi geliştirmişlerdir. Bu çalışmalarında Tayvan'daki perakende sektöründeki bir firmaya ait veriler kullanılmıştır. Çalışmanın sonucunda kullandıkları yöntemin konvansiyonel tahmin yöntemlerine ve hatta salt yapay sinir ağları yöntemine göre daha başarılı sonuçlar verdiğini belirtmişlerdir. Enke ve Mehdiyev (2014) yapay bulanık sinir ağları metodunu içeren hibrid bir tahmin modellemesi ile enflasyon tahmini yapmışlardır.

Huang ve Yu (2006) lineer olmayan problemlerin çözümü için kullanılan bulanık zaman serilerinin tahmini için yapay sinir ağları yöntemini kullanmışlardır ve çalışmalarında iki model önermişlerdir. İlk model tüm gözlemleri tahmin etmek için temel bir yapay sinir ağları modeli iken; ikinci model ise, bilinen şablonları tahmin etmek için yapay sinir ağları yöntemini ve bilinmeyen şablonları tahmin etmek için ise basit bir model kullanarak hibrid bir model kullanmaktadır. Bu çalışmada 1991 ve 2003 yılları arasındaki Tayvan borsası sonuçları tahmin için veritabanı oluşturmuştur. Çalışmanın sonucuna göre hibrid model temel ve konvansiyonel bulanık zaman serileri modellerinden daha iyi sonuçlar elde etmiştir.

Indro ve arkadaşları (1999)'na göre yapay sinir ağları modeli lineer olmayan yapılar için oldukça iyi sonuçlar verdiğiinden Huarng ve Yu (2006) 'nun çalışmasının temelini oluşturan lineer olmayan bulanık zaman serileri tahmininde de yapay sinir ağlarının bu becerisinden yararlanmıştıdır.

Kuo ve Xue (1999) satış tahminlerinin iş stratejilerini belirlemek adına büyük önem arzettiğini ve bu yüzden bu noktaya işaret eden birçok çalışma yapıldığını belirterek bulanık yapay sinir ağları modeli ile bir çalışma gerçekleştirmişlerdir. Satış tahmin sürecini veri toplama, genel şablon modeli, tekil şablon modeli ve birleştirilmiş karar adı altında dört bölümde incelemiş ve kullanmış oldukları bulanık sinir ağları yönteminin konvansiyonel modellere göre daha iyi sonuçlar verdiğini belirtmişlerdir.

### **3.3. Destek Vektör Regresyonu**

Destek vektör makineleri algoritması Rusya'da Vapnik ve arkadaşları tarafından geliştirilen lineer olmayan genelleştirme algoritmalarındandır. Vapnik ve arkadaşları otuz yıl boyunca bu modeli geliştirmişlerdir. Destek vektör makineleri istatistiksel öğrenme teorisi üzerine bir algoritmadır. Algoritma, lineer olmayan haritalama yöntemi kullanarak orijinal data ortamından fazla boyutlu ve özellikli bir ortama aktarmakta ve burada oluşturduğu lineer fonksiyonları orijinal data ortamındaki nonlinear fonksiyonlarla değiştirmektedir (Wang ve ark, 2012). Bu sayede destek vektör makinelerinin iyi genelleştirme yeteneğine sahip olduğu belirtilmekte ve birçok alanda kullanılmaktadır.

Oldukça basit yapısına rağmen güvenilir sonuçları, iyi genelleştirme yetenekleri ve optimum sonuçlara erişme becerisi ile destek vektör makineleri en popüler öğrenme ve tahmin etme araçlarından biridir. Bunun yanı sıra destek vektör makineleri en güçlü sınıflandırma araçlarından bir tanesidir. Bu sebeple hava şartları tahmini, elektrik piyasası tahminleri, hisse fiyatı tahmini, el yazısı tanıma, ses ve resim prosesi ve tanınması, video analizi ve tıbbi amaçlar olmak üzere çok geniş bir alanda kullanılmaktadır (Smola ve Scholkopf, 2004).

Destek vektör makineleri tahmin etme için güvenilir bir araçtır ve finansal zaman serilerini tahmin etmede başarılıdır. Trafalis ve İnce (2000) hisse fiyatı

tahmini için destek vektör makinelerinin geri yayımlı ve radyal bazlı fonksiyonlarını regresyon ile kullanarak bir çalışma gerçekleştirmiş ve destek vektör regresyonunun oldukça iyi sonuçlar verdiği belirtmişlerdir.

Destek vektör makineleri aralıklı (sparse) bir tekniktir. Parametrik olmayan modellerde olduğu gibi, bu model de öğrenme sürecinde tüm öğrenme veri setinin erişilebilir olmasına ihtiyaç duymaktadır. Bununla birlikte destek vektör makineleri model parametreleri öğrendiği zaman, tahmin yapabilmesi için sadece destek vektörleri denem öğrenme veri setinin bir alt kümesine ihtiyaç duymaktadır (Awad ve Khanna, 2015). Destek vektör makineleri matematiksel olarak destek vektörlerinin ağırlıklarının toplamıdır denilebilir.

Destek vektör makineleri Kernel tekniğidir: Destek vektör makineleri öğrenme sürecinde veriyi çoklu düzleme haritalarken kernel kullanmaktadır. Veri setleri genellikle lineer olarak ayrılabilen konumda değildirler. Bu lineer olmayan ortamda, destek vektör makineleri tanımlanmış kernel fonksiyonlarını kullanarak çok boyutlu düzlemler oluşturarak, farklı sınıflar arasını ayrıştırabilen lineer seperatörler oluşturmaktadır. Dolayısıyla kernel fonksiyonunun seçilip belirlenmesi kritik bir öneme sahiptir (Smola ve Scholkopf, 2004).

Liu ve arkadaşları (2014)'nin belirttiğine göre Vapnik ve Chervonenkis'in geliştirmiş olduğu VC istatistiksel öğrenme teorisine göre, destek vektör makineleri olması gereken datayı genelleştirme sürecinde oldukça iyi pozisyonlanmaktadır. Sınıflandırma olarak adlandırılan proseste ise destek vektör regresyonu kernel kullanımı, sparse çözümü, VC marj kontrolü ve destek vektörleri kullanmaktadır. Destek vektör regresyonu gerçek değer tahmininde destek vektör makinelerinden daha efektif sonuç verdiği birçok çalışmada kanıtlanmıştır. Destek vektör regresyonu öğrenme sürecinde hatalı yaklaşımların hem alt hem üst değerini eşit şekilde cezalandırarak simetrik bir kayıp fonksiyonu oluşturmaktadır. Vapnik'in  $\epsilon$ -intensive fonksiyonunu kullanarak, tahmin edilen fonksiyonun etrafında en düşük olası çapta esnek bir tüp (tube) oluşturarak, tüpün dışında kalan yani  $\epsilon$  olarak belirtilen tüp genişliğininin hem altında hem de üstünde olan değerler önemsenmemektedir (Smola ve Scholkopf, 2004).



Sınıflandırma problemlerini çözenin yanı sıra, destek vektör makineleri regresyon problemlerine de alternatif kayıp fonksiyonu ile uygulanabilmektedir ve bu fonksiyon mesafe ölçümünü de içermelidir. Destek vektör regresyonu ekonometrik ve istatistiksel metotlarda eksik olan, lineer olmayan regresyon fonksiyonu ile birlikte de çalışmakta ve ekonomik göstergeleri ve finansal zaman serilerini tahmin etmede başarılı bir yöntem olmaktadır (Wang ve ark, 2012).

Destek vektör regresyonu, ilk olarak Vapnik tarafından çalışılan destek vektör makineleri metodundan türetilmiştir (Awad ve Khanna, 2015). Yapısal risk minimizasyonu prensibini temel alan destek vektör makineleri algoritmasının sadece deneysel risk minimizasyonuna odaklanmamaktadır. Bu prensip, destek vektör makinelerinin iyi bir genelleştirme yapmasını mümkün kılmaktadır ve bu sebeple çok geniş bir kullanım alanı bulunmaktadır. Destek vektör makinelerinde regresyon sorunu bir sınıflandırma problemine olarak ele alınmaktadır. Kernel tekniği destek vektör makinelerinin lineer olmayan durumlar için de uygun olmasını sağlamaktadır ve bu sonuç ile, destek vektör regresyonu tahmin modelleri için sıkça kullanılmaktadır (Liu ve ark, 2014). Ekonomik ve finansal zaman serisi problemlerinde, diğer ekonometrik modellerle karşılaştırıldığında destek vektör regresyonu oldukça gerçekçi sonuçlar vermektedir.

Regresyon, sınıflandırma probleminin genelleştirilmesi olarak tanımlanabilir. Regresyon sonlu kümedeki bir çıktıyı değil, aksine sürekli değerli bir çıktıya işaret etmektedir. Diğer bir deyişle, regresyon modeli, sürekli-değerli (continuous-valued) çok değişkenli bir fonksiyonu tahmin etmektedir.

Destek vektör makineleri ikili sınıflandırma problemlerini onları konveks optimizasyon problemleri olarak ele alarak formüle etmektedir (Vapnik, 1998). Optimizasyon problemi, mümkün olduğunca çok öğrenme noktasını doğru şekilde sınıflandırırken hiper düzlemi ayıran maksimum marjın bulunmasını gerektirir. Destek vektör makineleri optimum hiperdüzlemi destek vektörleri ile temsil etmektedir. Bu ayrık çözüm ve iyi genelleştirme özelliği bu modelin regresyon problemlerinin çözümüne uyum sağlamasına yeterlidir (Awad ve Khanna, 2015). Destek vektör makinelerinin genelleştirme ile destek vektör regresyonuna dönüşmeleri tüp adı verilen ve fonksiyonun etrafında duyarsız bir bölge oluşturulması ile gerçekleştirilmektedir. Bu tüp, optimizasyon problemini yeniden

formüle ederek sürekli-değerli fonksiyona en yaklaşık değeri bulmakta ve bunu yaparken aynı zamanda karmaşıklık ve tahmin hatasını dengelemektedir (Smola ve Scholkopf, 2004).


Daha spesifik olarak bahsetmek gerekirse, destek vektör regresyonu bir optimizasyon problemini, konveks bir duyarsız kayıp fonksiyonu tanımlayarak en fazla öğrenme örneğini içeren en düz tüpü bulacak şekilde formülize etmektedir. Dolayısıyla çok hedefli fonksiyon, kayıp fonksiyonundan ve tüpün geometrik özelliklerinden oluşturulmaktadır.

Destek vektör makinelerinde destek vektör regresyonu yöntemi, regresyon problemlerini çözmeye kullanılmaktadır. Algoritmayı kurmak için, kayıp fonksiyonunun bir mesafe ölçümünü içerecek şekilde kurgulanması gerekmektedir. Yapılan çalışmalarda kayıp fonksiyon için Laplacian, Huber ya da küçük karalar hata kriteri ya da  $\varepsilon$ -intensive kullanılmıştır (Wang ve ark., 2012). Destek vektör regresyonu genellikle  $\varepsilon$ -intensive hata fonksiyonunu ( $L_\varepsilon$ ) seçmektedir (Drucker ve ark., 1995)

$$L_\varepsilon(f(x), y) = \begin{cases} |f(x) - y| - \varepsilon, & \text{if } |f(x) - y| \geq \varepsilon \\ 0, & \text{otherwise} \end{cases} \quad (4)$$

$\varepsilon$ , regresyon fonksiyonu olan  $f(x)$  ile gerçek değer olan  $y$  arasındaki mesafeyi ölçen pozitif bir rakamı temsil etmektedir.  $\varepsilon$ -intensive kayıp fonksiyonu  $f(x)$  ve  $y$  arasındaki mesafe  $\varepsilon$ 'u aşmaz ise,  $f(x)$  ve  $y$  arasında kayıp olmadığını ifade etmektedir. Böylece, bu bölgeye  $\varepsilon$ -intensive bölgesi denmekte ve bu bölgede amaç fonksiyonunun herhangi bir değerinin kayba uğramadığı anlamına gelmektedir (Wang ve ark., 2012).

Destek vektör regresyonu formülü genellikle geometrik açıdan oluşturulmaktadır. Aşağıda Şekil 3.3a'da görüldüğü üzere tek boyutlu bir lineer destek vektör regresyonu örneği yer almaktadır.



Şekil 3.3a: Tek Boyutlu Lineer Destek Vektör Regresyonu (Awad ve Khanna, 2015)

Sürekli-değerli fonksiyon aşağıdaki 5 nolu denklemde gösterilmektedir. Başka bir deyişle, destek vektör regresyonunun konseptini açıklamak için bir lineer regresyon problemi aşağıdaki şekilde formüle edilebilir. Buna göre regresyonun amacı aşağıda yer alan fonksiyonu tanımlamaktır.

$$y = f(x) = (\omega, x) + b = \sum_{j=1}^M w_j x_j + b, y, \omega \in R^M, b \in R \quad (5)$$

Çok boyutlu veride ise,  $x$ 'i bir ile artırarak ve  $w$  vektörüne  $b$  yi dahil ederek çok değişkenli regresyon elde edilmektedir. Bu fonksiyon 6 nolu denklemde gösterilmektedir.

$$f(x) = \begin{bmatrix} w \\ b \end{bmatrix}^T \begin{bmatrix} x \\ 1 \end{bmatrix} = w^T x + b \quad x, \omega \in R^M \quad (6)$$

Destek vektör regresyonu bu fonksiyonun yaklaşık problemini, tahmin hatasını (yani tahmin edilen ve istenen çıktılar arasındaki mesafeyi) en aza indirirken, yüzey etrafında merkezlenmiş en dar tüpü bulmaya çalışan bir optimizasyon problemi olarak formüle eder. Bu durum aşağıdaki denklemde (7) gösterildiği üzere nesnel bir fonksiyon üretmektedir. Burada  $w$  yaklaşılacak yüzeyin normal vektörünün büyüklüğüdür.  $W$  nin büyüklüğü düzenleyici bir görev görür ve çözümün düzlüğüne

bakarak optimizasyon probleminin kontrolünü sağlamaktadır (Awad ve Khanna, 2015).

$$\min_w \frac{1}{2} \|w\|^2 \quad (7)$$

Belirli bir girdi için fonksiyonun tahmin edilen değeri ile gerçek çıktı arasındaki hatayı asgariye indirmek temel kısıtlamadır (Smola ve Scholkopf, 2004). Destek vektör regresyonu istenen çıktıdan “ε” kadardan daha uzak tahminleri cezalandıran, ε -insensitive bir kayıp fonksiyonu oluşturur. ε'nin değeri tüpün genişliğini belirlerken, daha küçük değer hata için daha düşük toleransı ifade etmektedir. Bu durum destek vektör sayısını etkilemektedir. Eğer ε'nin değeri azalır, Şekil 3.3b'de görünen tüpün sınırları içe doğru kaymaktadır (Awad ve Khanna, 2015). Dolayısıyla sınırların etrafında daha fazla veri noktası olduğundan, daha fazla destek vektörü gerekmektedir. Benzer şekilde artan ε değeri sınırların etrafında daha az veri noktasına işaret etmektedir.

F(x)'in lineer olmadığı durumlarda ise daha doğru sonuçlara ulaşmak için veriler kernel boşluğu denilen yüksek boyutlu bir boşluğa gereksinim duymaktadır. Bu durumda aşağıdaki denklem (8) kernel boşluğu dikkate alınarak değiştirilmiş non lineer formüldür. Ayrıca bir diğer formül ise (9) dönüştürülmüş girdi açısından yeni ağırlık vektörünü tanımlamaktadır. Aşağıdaki formülde ω ağırlık vektörünü, b ise sabiti ifade etmektedir. ε-intensive kayıp fonksiyonuna göre, ağırlık vektörü ve sabit, düzenlenmiş risk fonksiyonu minimize ederek tahmin edilmektedir (Boser ve ark., 1992; Awad ve Khanna, 2015).


$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l (\zeta_i + \zeta_i^*) \quad (8)$$

$$s. t. \quad y_i - (\omega \cdot x_i) - b \leq \varepsilon + \zeta_i \quad (9)$$

$$(\omega \cdot x_i) + b - y_i \leq \varepsilon + \zeta_i^*$$

$$\zeta_i, \zeta_i^* \geq 0, \text{ for } i = 1, 2, \dots, l$$

$\frac{1}{2} \|w\|^2$  güven aralığını belirtirken,  $(\zeta_i + \zeta_i^*)$  ise artıran yapay değişkenlerdir. C ise deneysel riski ve düzenlenmiş terim arasındaki dengelemeyi belirleyen düzenlenmiş sabittir.



Şekil 3.3b: Nonlineer Destek Vektör Regresyonu (Awad ve Khanna, 2015)

### 3.4. En Küçük Kareler Destek Vektör Makineleri

En Küçük Kareler Destek Vektör Makineleri (LSSVM) Vapnik'in geliştirmiş olduğu destek vektör makineleri ve regresyonu modelini baz alarak geliştirilmiş ve Suykens ve arkadaşları (2002) tarafından önerilen bir modeldir. Böylelikle LSSVM hem sınıflandırma hem de regresyon uygulamalarına uygundur.

LSSVM modelinde regresyon aşağıdaki şekilde (10) gösterilmektedir (Xie ve ark., 2011; Samui ve Sitharam, 2009).

$$\min \frac{1}{2} w^T w + C \sum_{i=1}^l (e_i)^2 \quad (10)$$

$$s. t. \quad y_i(w^T \phi(x) + b) = 1 - e_i, \quad e_i \geq 0, i_1, \dots, l$$

Lagrange denklemi ise şu şekilde (11) oluşmaktadır (Suykens ve ark., 2002).

$$L(w, b, e; \alpha) = \frac{1}{2} w^{T+1} + C \sum_{i=1}^l (e_i)^2 - \sum_{i=1}^l \alpha_i \{y_i(w^T \phi(x) + b) - 1 + e_i\} \quad (11)$$

Bu denklemde  $\alpha_i$  Lagrangian çarpanını ifade etmektedir ( $\alpha_i \in \mathbf{R}$ ). Eğer Lagrangian denklemi  $w$ ,  $b$ ,  $\alpha_i$ , and  $e_i$  ile diferansiyele tabi tutulursa aşağıda yer alan denklemler (12) oluşmaktadır.

$$\frac{\partial L}{\partial w} = 0 \rightarrow w = \sum_{i=1}^l \alpha_i y_i \phi(x_i)$$

$$\frac{\partial L}{\partial b} = 0 \rightarrow \sum_{i=1}^l \alpha_i y_i = 0 \quad (12)$$

$$\frac{\partial L}{\partial e_i} = 0 \rightarrow \alpha = C e_i, i = 1, \dots, l$$

$$\frac{\partial L}{\partial \alpha_i} = 0 \rightarrow y_i = y_i(w^T \phi(x) + b) - 1 + e_i, i = 1, \dots, l$$

e ve w 'yi elimine ettiğimiz durumda formülün matris görünümü şu şekilde (13) olmaktadır.

$$\begin{bmatrix} 0 & 1^T \\ 1 & \phi(x_i)^T \phi(x_i) + C^{-1}I \end{bmatrix} \begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 \\ y \end{bmatrix} \quad (13)$$

Bu denklemde  $y = [y_1, \dots, y_n]$ ,  $1 = [1, \dots, 1]$ ,  $\alpha = [\alpha_1, \dots, \alpha_n]$  ifade etmektedir. Mercer şartı düşünüldüğünde kernel fonksiyonu şu şekilde (14) olmaktadır.

$$K(x_i, x_j) = \phi(x_i)^T \phi(x_j), \quad i, j = 1, 2, \dots, n \quad (14)$$

Bu formüller ışığında LSSVM modelinin formülü (15) şu şekilde gösterilmektedir (Suykens ve ark., 2002).

$$y(x) = \sum_{i=1}^n \alpha_i K(x_i, x_j) + b \quad (15)$$

Bu formülde  $\alpha_i$  ve  $b$  lineer sistem için çözümlerdir.  $K(x_i, x_j)$  kernel fonksiyonu olarak tanımlanmaktadır. Kernel fonksiyonu seçiminde ise  $K(\dots)$  birden fazla seçenek bulunmaktadır. Kernelin değeri  $x_i$  ve  $x_j$  vektörlerinin  $\phi(x_i)$  ve

$\phi(x_j)$  uzay düzlemdeki çıktılarına eşittir ve  $K(x_i, x_j) = \phi(x_i)^T \phi(x_j)$  olarak formüle edilebilir.

Kernel fonksiyonlarının en çok bilinen ve kullanılan tipik örnekleri şu şekildedir (Abe, 2005):

Lineer Kernel Fonksiyonu:  $K(x_i, x_j) = x_i^T x_j$

Sigmoid Kernel Fonksiyonu:  $K(x_i, x_j) = \tanh(\gamma x_i^T x_j + r)$

Polinomial Kernel Fonksiyonu:  $K(x_i, x_j) = \tanh(\gamma x_i^T x_j + r)^d, \gamma > 0$

Radial Basis Function (RBF) Kernel Fonksiyonu:

$$K(x_i, x_j) = \exp\left(-\gamma \|x_i - x_j\|^2\right), \gamma > 0 \quad (16)$$

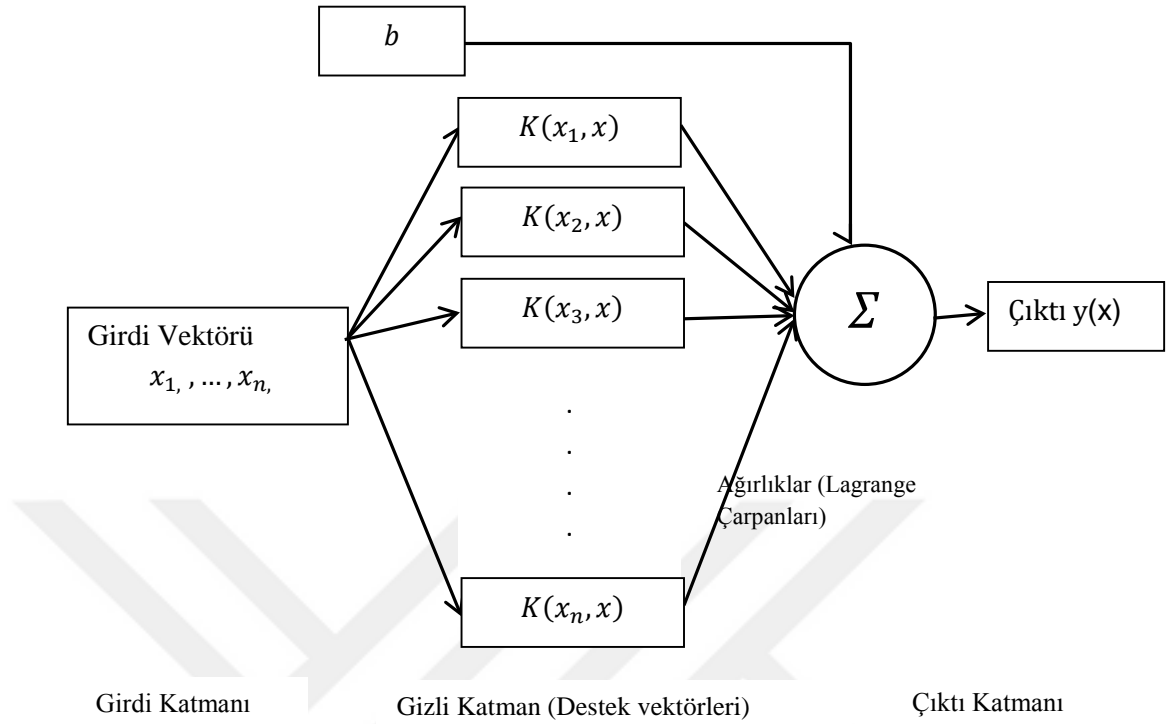
Formüllerde  $\gamma$ ,  $r$  ve  $d$  kernel parametreleridir. Gaussian RBF Kernel fonksiyonu ise (17) aşağıda gösterilmektedir.

$$K(x_i, x_j) = \exp\left\{-\frac{(x_i - x_j)(x_i - x_j)^T}{2\sigma^2}\right\}, \quad i, j = 1, 2, \dots, n \quad (17)$$

$\sigma$  Gaussian kernelin genişliğini ifade etmektedir.  $\sigma$  ve  $\gamma$  nın belirlenmesi formülün sonucunu bulmak açısından önem teşkil etmektedir. Jiang ve Zhao (2013) LSSVM'nin başarısının regüle edici parametre olan  $\gamma$  ve kernel parametresi olan  $\sigma^2$  ye oldukça bağımlı olduğunu belirtmişlerdir. Xie ve arkadaşları (2011) parametrelerin optimizasyonun destek vektör regresyonunun performansının belirlenmesinde kritik önemde olduğunu belirtmiştir.

Yapılmış çalışmalarda genellikle (Liu ve Wang, 2008; Samui, 2011; Samui ve Sitharam, 2009; Samsudin ve ark., 2011) bu parametrelerin üst limitleri trial ve error (ya da bir başka deyişle “parameter tuning”) şeklinde belirlenmektedir. Böylece uygun sonuçlara ulaşma adına farklı parametrelere üst limitler koyularak  $\gamma$  ve  $\sigma^2$  doğrulama (crossvalidation) yöntemiyle belirlenmektedir.

Aşağıda yer alan Şekil 3.6'da destek vektör makinelerinin yapısı gösterilmektedir.



Şekil 3.6: Destek Vektör Makinelerinin Mimarisi (Chen ve Yu, 2007)

### 3.5. Destek Vektör Regresyonu Literatür Taraması

Liu ve Wang (2008) LSSVM kullanarak döviz kuru tahmini üzerinde çalışmışlardır. Parametreleri belirlemek için crossvalidation yaklaşımı kullanılmıştır. 2003-2007 arasındaki verileri çalışarak yapılan çalışmalar olumlu sonuçlar vermiştir.

Wang ve arkadaşları (2012) yaptıkları çalışmada enflasyon tahmininde kullanılmak üzere finansal durum endeksi oluşturulmasını ve bunun veri madenciliği metodunun yeni bir uygulaması olmasını önermektedirler. Yazarlar geleneksel ekonometrik ve lineer varsayımlar yerine finansal indikatörler ile gelecekteki enflasyon arasında lineer olmayan karmaşık bir ilişki olduğunu öne sürmekte ve destek vektör fonksiyonunun algoritmasından yararlanarak çalışmayı gerçekleştirmektedirler. Sonuç olarak, destek vektör regresyonunun finansal göstergeleri kullanarak enflasyonu tahmin etmede güçlü bir araç olduğu sonucuna varmış ve finansal durum endeksinin ağırlığını hesaplamak için ağırlık vektörü kullanmayı ve destek vektör regresyonu ile enflasyonu tahmin etmeyi önermektedirler. Çalışmada enflasyon tahminini yapacak modeli geliştirdikten sonra



destek vektör regresyonunun ağırlık vektörlerini kullanarak finansal durum indeksinin ağırlığı hesaplanmış ve bu modelin doğruluğunu test etmek için de Çin finansal ekonomik göstergeleri kullanılmıştır.

He ve arkadaşları (2012) yaptıkları çalışmada döviz kuru tahmininde en küçük kareler destek vektör regresyon modelini belirleyen yeni bir analiz önerilmiştir. Temel trendin lineer modellemesini ve veri serisinin nonlineer modellemesini birleştirmek için Slantlet analizi kullanmanın, diğer alternatiflere karşı üstün performansa sahip bir hibrid algoritmaya yol açtığını bulduklarını belirtmişlerdir.

Liu ve arkadaşları (2014) destek vektör makineleri modeli ile yeni bir makro varlıklar fiyat endeksi oluşturmuşlardır. İstatistiksel ve ekonomik olarak makroekonomiyi temsil eden 12 değişken endeksi oluşturmak için seçilmiştir ve geleneksel ekonometrik yöntemden farklı olarak, Çin enflasyonunu tahmin etmek için destek vektör regresyon modeli kullanılmıştır. Seçilen 12 değişkene ait ağırlık vektörleri yardımı ile makro varlıklar fiyat endeksi oluşturulmuştur. Modelde destek vektör makineleri kullanılmasının sebebi her bir indikatör ile enflasyon arasındaki ilişkiyi açıkça anlamak olduğu araştırmacılar tarafından belirtilmiştir. Çalışma içerisinde indikatörlerin ağırlık vektörleri ve farklı kernel fonksiyonları kullanılarak en iyi regresyon sonucu bulunmaya çalışılmıştır. Çalışmanın sonunda bir kıyaslama yapılmakta ve destek vektör makinelerinin diğer ekonomik modellere göre enflasyonu tahmin etmede daha uygun sonuçlar verdiğini ifade edilmektedir. Ayrıca, modelin 4-6 aylık sonuçları tahmin etmede başarılı olduğu belirtildiği için kısa-orta vadeli yani çeyreklik sonuçlar gerektiren kararları almada faydalı olacağı belirtilmiştir.

Hua ve arkadaşları (2015) destek vektör makineleri modelini kullanarak Çin bazlı dinamik finansal durum endeksi oluşturmuşlardır. Çalışmada enflasyon, döviz kuru, hisse senedi fiyatları, para arzı, konut fiyatları ve faiz oranları gibi ekonomik göstergeler kullanılmıştır. Oluşturulan endeksin doğruluğunu test etmek için enflasyon ile bir karşılaştırma yapılmış ve iyi bir performans elde edilmiştir.

Xu ve arkadaşları (2016) bulanık mantık ile destek vektör regresyonunu birleştirerek (SVMRE) hibrid bir model ile turizm talep tahmini yapmıştır. Farklı

bölgelerdeki veri kümelerinden yararlanılarak yapılan çalışmalarda SVMRE geleneksel modeller ile karşılaştırılmış ve en iyi tahmin sonuçlarını vermiştir.

Samui ve Sitharam (2009) kayaç özellikleri ve sismik azalma tahmininde LSSVM'nin kullanılabilirliğini analiz etmiştir. Çalışmada LSSVM'nin istatistiksel bir öğrenme metodu olduğu ve bu regresyon tekniği ile her bir girdinin çıktı üzerindeki ağırlığının hesaplandığını ifade edilmiştir. Sismik azalmanın tahmininde bu yöntemin pratik bir araç olacağı sonucuna varmışlardır.

Samui (2011) kaynaklardaki buharlaşmanın azalmasının tahmininde LSSVM'nin kullanılabilirliğini analiz etmiştir. Girdi olarak hava sıcaklığı, rüzgar hızı, gün ışığı saati ve nem gibi parametreler kullanarak buharlaşmanın azalmasını belirlemeye çalışmıştır. Bu çalışmada her bir girdinin sonuç üzerindeki ağırlığı da ölçülmüş ve destek vektör regresyonu yönteminin sonuçları değerlendirilmiştir. Buharlaşmanın azalması tahmininde LSSVM'nin kullanılabilir bir yöntem olacağı sonucuna varılmıştır.

Samsudin ve arkadaşları (2011) en küçük kareler destek vektör regresyonu yöntemiyle zaman serileri şeklinde belirlenen veri seti üzerinde çalışarak aylık nehir debisini tahmin etmeye çalışmışlardır. Bu modelin sonuçlarını yapay sinir ağırları modeli ile de karşılaştırmışlardır. Yaptıkları çalışma sonuçlarını RMSE ve R kullanarak karşılaştırmışlar ve nehir debisi tahmin etmede önerdikleri LSSVM bazlı modelin başarılı sonuçlar verdiğini belirtmişlerdir.

Chen ve Yu (2007) sel baskını felaketlerinin önemli bir habercisi olan sel tahmin yöntemi çalışmasını destek vektör regresyonu kullanarak çalışmıştır. Çalışmada destek vektör makineleri ve yapay sinir ağırları yapısı da karşılaştırılmıştır. Yapay sinir ağırlarında yapının belirlenmesinin, örneğin gizli nöron sayısı, genellikle deneme yanılma (trial and error) yoluyla belirlendiğini belirtip, destek vektör makineleri modelindeki yapının ise destek vektör makineleri algoritması içerisinde analitik olarak belirlendiğini ve destek vektörlerinin otomatik olarak elde edildiğini ifade etmişlerdir. Bununla birlikte, Tayvan'daki bir nehir ile ilgili değişkenlerin belirlenip sel tahmini sonuçlarına destek vektör makineleri yöntemi ile ulaşmaya çalışmışlar ve yöntemin başarılı sonuç verdiğini belirtmişlerdir.

Sameni ve Chamkalani (2018) petrol endüstrisindeki sondaj verimliliği problemini çözmek için en küçük kareler destek vektör regresyonu yöntemi ile bir çalışma yapmışlardır. Belirlenen girdilerle çıktının tahmin edilmesi amaçlanmış ve sondaj mühendisliği alanında bu çalışmanın sonucunun iyi performans gösterdiğini belirtmişlerdir.



## 4. DÖVİZ KURU VE ENFLASYON TAHMİN MODELLEMESİ

Bu tez çalışmasında Türkiye’de faaliyet gösteren bir çimento firmasına ait bir yatırım projesi analiz edilmiştir. Bu bölümde tez çalışmasında yapılan araştırma ile ilgili bilgiler ve çalışmanın hazırlık aşamaları anlatılacaktır. Yatırım projesi analizinde değerlendirme metodu olarak öncelikle sektörün çoğunlukla kullandığı geleneksel DCF metodu kullanılmıştır. DCF metodu kullanılırken nakit akımları ve bunları oluşturan girdiler geleneksel yöntemler ile tahmin edilip oluşturulmuştur. Sonraki aşamada ilerleyen bölümlerde bahsedilecek en kritik değişkenlerden olan Türkiye ekonomisine ait enflasyon ve USD/TRY döviz kuru tahminleri yapay zeka tekniklerinden olan yapay sinir ağları ve destek vektör regresyonu ile tahmin edilmiş ve modele implemente edilmiştir. Yapay sinir ağları ve destek vektör regresyonu ile elde edilen tahminlerle oluşturulmuş nakit akımları yine DCF değerlendirme metoduna tabi tutulmuş ve yeni bir değerlendirme sonucu elde edilmiştir.

Firmaya ait çimento üretim hattı yatırımına ilişkin DCF metodunun projeksiyon dönemi olarak, sektörde genellikle kullanıldığı şekli ile sonsuza kadar olan dönemdeki nakit akımları dikkate alınmıştır. Yatırımın devreye girişi ile başlayan ilk 5 senelik dönem çeyreklik dönemler halinde 20 periyot olarak projekte edilmiş, 5. yıldan sonsuza kadar olan dönem artık değer (terminal value – TV) analizi ile hesaplanmıştır. Söz konusu 5 yıllık nakit akımları 2011-2015 yıllarını kapsamaktadır. Yatırım projesine ait yapılmış olan geleneksel metot ve yapay sinir ağlarının dahil edildiği metoda ait hesaplama sonuçları, 2011-2015 dönemlerinde yapay sinir ağları ile tahmin edilmiş iki girdiye ait gerçekleşmiş fiili sonuçların dikkate alınarak hesaplandığı gerçek proje yatırım değeri sonucu ile karşılaştırılmıştır. Böylece geleneksel ve tez çalışmasında önerilen metotların gerçek sonuçlarla olan ilişkisi analiz edilmiştir.

### 4.1. Serbest Nakit Akım Bileşenleri

Her sektörde olduğu gibi çimento sektöründe de bir yatırım projesine ilişkin karlılık analizi yapıp sonuca ulaşmak istenildiğinde, proje ile ilgili nakit akımlarının öngörülmesi gerekmektedir. Bu nakit akımları geleneksel ya da farklı değerlendirme

analizlerine tabi tutulabilir ve çıkan sonuç karar verme mekanizmasında önemli bir kriter olarak yer alabilir. Belirlenmiş bir döneme ait nakit akım her ne kadar tek bir değermiş gibi görünse de o sonuca erişebilmek için bir çok alt kırılım yer almaktadır. En çok kullanılan değerlendirme metodu olan DCF modeli ve bu model ile kullanılacak analizlerden olan NPV ve IRR için söz konusu nakit akımlarından yararlanılacaktır ve her bir döneme ait nakit akımlarını oluşturabilmek için birçok girdiden yararlanılacaktır. Bu girdilerin bir kısmı göreceli olarak sektör bilgisi ile zorlanılmadan tahmin ediliyor olsa da birçoğunun tahmin edilme süreci karmaşık ve zordur. Yatırım değerlendirme sonucuna erişebilmek için bu girdilerin tahmin edilip uygun bir şekilde model içerisinde kullanılması gereklidir.

Öncelikle, DCF analizinde kullanılan belirlenmiş bir döneme ait serbest nakit akımı oluşturan alt başlıklar aşağıdaki şekilde genelleştirilebilmektedir.

Serbest Nakit Akım

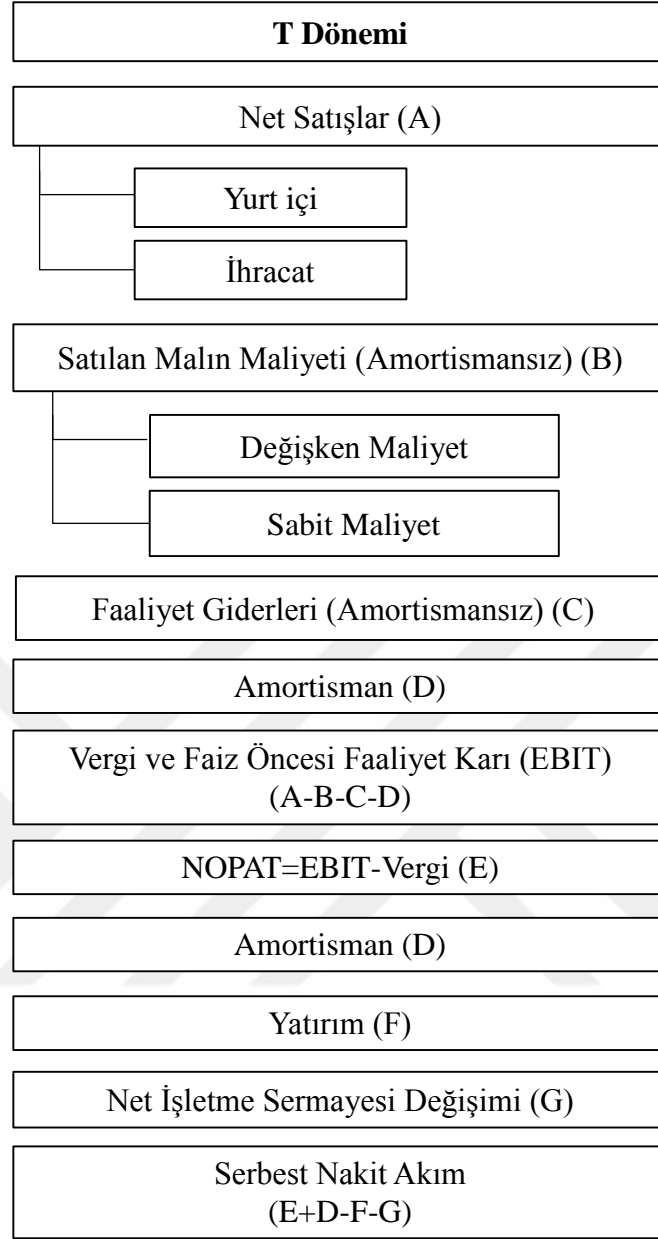
- Gelir
- Gider/Maliyetler
- Yatırım Maliyeti
- Net İşletme Sermayesi Değişimi
- Vergi

Şekil 4.1a: Serbest Nakit Akım Bileşenleri

Şekil 4.1a'da görüleceği üzere serbest nakit akımı oluşturan 5 ana kalem vardır ve bunların her biri alt başlıklardan oluşmaktadır. Gelirler firmanın yatırım projesinden elde edeceği net satışları ifade etmektedir. Net satışlar firmanın hem yurt içinden hem de yurt dışından elde edeceği gelirleri ifade etmektedir. Dolayısıyla yatırım projesinin yapısı itibarıyla birden fazla para biriminden gelir elde edilebilir. Maliyetlerin toplamı proje kapsamında katlanılacak değişken ve sabit maliyetleri, amortismanı ve faaliyet giderlerini ifade etmektedir. Yatırım maliyeti ise projeyi yapmak için gerekli olan ve gerekli ise yıllar içerisinde projeyi idame ettirmek için gerekli olan yatırım maliyetlerini ifade etmektedir. Proje ile yürütülen faaliyetleri gerçekleştirmek için ticari alacaklar, stoklar ve ticari borçlardan oluşan net işletme sermayesine ihtiyaç duyulmaktadır. Bir önceki dönemle gerçekleşen fark o dönemde

yaratılan nakti etkilediđi için net işletme sermayesi deđişimi serbest nakit akımı etkileyen bir başka alt başlıktır. Son olarak vergi, hesaplamada dikkate alınan bir diđer gider kalemidir.

DCF analizinde projenin faydalı ömrü boyunca, ya da projekte edilen ömrü boyunca veya bazı sektörlerde kullanıldığı şekli ile sonsuza kadar olan dönemde yaratacađı nakit akımlar dikkate alınmaktadır. Dolayısıyla tek bir döneme ait nakit akımın oluşturulması ve tahmin edilmesi tek başına bir anlam ifade etmemektedir. Yatırım projesine ilişkin karlılık analizinin yapılabilmesi için öngörülen ve projekte edilen tüm ömür boyunca nakit akım tahminlerinin yapılması gerekmektedir. Bu durumda dönemler arası nakit akım tahminlerinde öne çıkan faktör enflasyondur. Projenin ilerleyen dönemlerine ilişkin kesine yakın olarak bilinen girdilerin dışındaki bir girdiyi tahmin edebilmek için, örneđin ortalama satış fiyatı, genellikle enflasyon oranı kullanılmaktadır. Bir döneme ait satış fiyatı öngörüsü yapılırken, önceki döneme ait satış fiyatı enflasyon ile dikkate alınarak tahmin edilmektedir. Belli bir döneme ait serbest nakit akımı oluşturan başlıklara bir alt kırılımda bakılmak istenirse bu kısımlar Şekil 4.1b' de gösterilmektedir.



Şekil 4.1b: Serbest Nakit Akım Bileşenlerinin Detaylı Gösterimi

#### 4.1.1. Net Satışlar

Bir dönemde elde edilen gelir net satışlar kalemi olarak adlandırılmaktadır. Net satışlar, satış miktarı ve satış fiyatından elde edilir. Örneğin bir dönemde satılan 100 birim malın her birinin ortalama satış fiyatı 10 TL ise o dönemde elde edilen net satışlar toplamı 1.000 TL dir. Dolayısıyla en basit anlamda net satışları belirlemek

için satış miktarının ve satış fiyatının belirlenmesi gerekmektedir. Net satışlar ciro olarak da adlandırılmaktadır.

Satış miktarı arz talep dengesi, sektörün içinde bulunduğu ekonomik ortam, rakipler, kapasite durumu ve firmanın nasıl bir strateji izleyeceği gibi bir çok konu ile ilişkilidir. Dolayısıyla yatırım projesi sonucunda öngörülen satış miktarı sektör tecrübesi ile yakından ilişkilidir ve firmalar yatırım ile ilişkili satış miktarı tahminleri yaparken büyük ölçüde bilgi sahibidirler. T dönemi ve sonrasındaki her bir dönem için satış miktarı öngörüsü yapılırken, eğer kapasite kısıtı yok ise ve agresif bir satış stratejisi izlenmiyor ise pazar büyümesi kadar bir büyüme ile sabit pazar payı düşünülerek bir satış miktarı öngörüsü yapmaktadırlar. Tez çalışmasında öngörülen yatırım projesine ilişkin satış miktarı öngörüsü de bu şekilde yapılmış, yatırım sonrasında yaratılan ek kapasite ile üretilen çimento pazarda belli bir pazar payı alacağı varsayılmış, pazar büyümesi tahmin edilerek ve bu pazar payı sabit tutularak satış miktarı öngörüsü yapılmıştır. Türkiye çimento sektörüne has bir durum olan, eğer öngörülen yurt içi satış miktarı sonrası hala üretim kapasitesinden boşluk kalıyorsa, yani bir başka deyişle yurtiçi tüketime satılan miktar ile kapasite tam olarak kullanılamıyorsa, kalan kısım ihracata yönlendirilmektedir. Çalışmadaki modelde bu varsayım dikkate alınmış ve ihracat satışları da öngörülmüştür.

Satış fiyatı da satış miktarındaki faktörlere benzer bir şekilde arz talep dengesi, sektörün içinde bulunduğu ekonomik ortam, rakiplerin fiyatları, enflasyon ve firmanın nasıl bir fiyat stratejisi izleyeceği gibi bir çok konu ile doğrudan ilişkilidir. Firma yatırım projesi sonrası üreteceği ürünü pazarda geçerli olan ortalama fiyata göre nasıl konumlandıracağını ve nasıl bir fiyat stratejisi izleyeceğini belirledikten sonra genellikle dönemler itibarıyla fiyatı enflasyona tabi tutarak projekte etmektedir. İhracat satış fiyatları ihracatın yapılacağı ülkedeki ve global fiyatlar çerçevesinde belirlenmektedir ve para cinsi büyük çoğunlukla döviz bazlıdır. Dolayısıyla satış fiyat öngörülerinde ilk fiyat tahmin edildikten sonra projekte edilen dönemdeki fiyatı belirlemek için en önemli girdiler enflasyon ve döviz kurudur.

Sonuç olarak, satış miktarı ve satış fiyatı ile net satışlar kalemi hesaplanmaktadır ve bu hesaplamaların projekte edilen dönemler boyunca hesaplanması söz konusu olduğunda ileriye dönük tahminleri belirleyen en önemli girdiler enflasyon, döviz kuru ve pazar büyümesidir. Tez çalışmasında yatırıma ait



değerleme yapılırken önerilen modelde enflasyon ve döviz kuru tahminleri yapılmış, pazar büyümesi için ise firmanın sektör tecrübesi dolayısıyla kendi öngörülerden yararlanılmıştır.

#### **4.1.2. Satılan Malın Maliyeti**

Net satışlarda hesaplama dahil olan söz konusu satış miktarı için katlanılması gereken değişken ve sabit maliyetlere satılan malın maliyeti denmektedir. Çimento sektöründe değişken maliyetler hammadde maliyeti, enerji (elektrik) maliyeti, yakıt (petrokok, ithal kömür, yerli linyit, fuel oil, doğalgaz vb) maliyeti, işletme malzemesi ve diğer maliyetlerden oluşmaktadır. Üretilen çimentonun yapısı gereği genellikle değişken maliyetlerin %80'i enerji ve yakıt maliyetlerinden meydana gelmektedir.

Belirli bir dönemdeki değişken maliyeti oluşturan alt başlıklardaki maliyetleri belirlemek için, üretilecek ve satılacak miktara ait ne kadar kullanım gerçekleştirileceği belirlenip, satın alma fiyatları dikkate alınarak bir değişken maliyet hesabı yapılmaktadır. Tedarik edilecek ürün ve hizmetlere ait fiyatlar belirlendikten sonra her bir dönemdeki satın alınan bu ürün ve hizmetlere ait fiyatlar belirlenirken genellikle enflasyona tabi tutulmaktadır. Ayrıca maliyetlerin önemli bir kısmını oluşturan yakıt maliyeti ve bazı diğer değişken maliyet kalemleri döviz bazlı satın alımlardan oluşmaktadır. Dolayısıyla mevcut dönem maliyeti belirlendikten sonra projeksiyon dönemi boyunca değişken maliyeti belirlemek ve ileriye dönük tahmin etmek için kritik girdiler enflasyon ve döviz kurudur.

Üretim ile ilişkili sabit maliyetler ise personel maliyeti (genellikle mavi yaka), bakım ve onarım giderleri, dışarıya yaptırılan işçilikler ve diğer sabit maliyetlerden oluşmaktadır. Sabit maliyetler genellikle sektörde ve/veya yatırımı yapan şirkette daha önce yapılmış benzeri yatırım projeleri dikkate alınarak belirlenmektedir ve ileriye dönük tahminler genellikle maliyetin enflasyona tabi tutulması şeklinde yapılmaktadır. Öngörülen personel sayıları ve yatırımın gerektireceği bakım vb. giderler bu şekilde tahmin edilmektedir. Mevcut dönem maliyeti belirlendikten sonra projeksiyon dönemi boyunca sabit maliyeti hesaplarken temel girdi enflasyondur.

Sonuç olarak, satılan malın maliyetini belirlerken ve ileriye dönük tahmin ederken sektör tecrübesi ile yapılan tahminlerin haricinde en önemli iki kriter enflasyon ve döviz kurunun tahmin edilmesidir.

### **4.1.3. Faaliyet Giderleri**

Yapılan yatırımın projeksiyon sürecinde faaliyetlerini sürdürebilmesi için katlandığı ve üretim faaliyetleri dışındaki giderler faaliyet giderleri olarak adlandırılmaktadır. Satış pazarlama gideri, genel yönetim giderleri, araştırma geliştirme faaliyeti giderleri, personel (genellikle beyaz yaka) giderleri bu kapsamda değerlendirilmektedir. Bu giderler de aynen sabit maliyette olduğu gibi sektörde ve/veya yatırımı yapan şirkette daha önce yapılmış benzeri yatırım projeleri dikkate alınarak belirlenmektedir. Sektör tecrübesi ile belirlenmiş tahminlerin yanı sıra projeksiyon süresince ileriye dönük tahminlerin yapılması söz konusu olduğunda en önemli girdi yine enflasyon olmaktadır.

### **4.1.4. Amortisman**

Yapılan yatırımın faydalı ömrü boyunca yıpranma payının dikakte alınmasını esas alan bir giderdir. Faiz ve vergi öncesi kar (EBIT) hesaplanırken bu gider de gelirlerden düşülmektedir. Ancak amortisman gideri ile gerçek bir nakit çıkışı olmadığı için net nakit akım hesabı yapılırken amortisman tekrardan ilave edilmektedir. Projeksiyon dönemlerindeki tahmini için genellikle herhangi bir ilave öngörüye gereksinim duymamakta, yatırım miktarı ve faydalı ömür süresi belirlenerek yıllar boyunca sabit ilerletilmektedir.

### **4.1.5. Vergi**

Serbest nakit akım hesaplanırken faaliyet giderlerinden vergi düşülerek NOPAT yani “Vergi Sonrası Net Faaliyet Karı” (Net Operating Profit After Tax) hesaplanılmaktadır. Kullanılan değer genellikle yatırımı yapan şirketin yatırımı yaptığı ülkedeki kurumlar vergisi oranınca hesaplanan vergi gideridir. Türkiye için mevcut durumda bu oran %20 dir. Yani bu çalışmada kullanılan DCF analizinde herhangi bir dönemdeki NOPAT hesaplaması için o döneme ait EBIT değeri bulunmakta ve EBIT’in %20 si vergi gideri olarak kabul edilmektedir. Dolayısıyla NOPAT EBIT’in %80’ine denk gelmektedir.

#### **4.1.6. Yatırım Maliyeti**

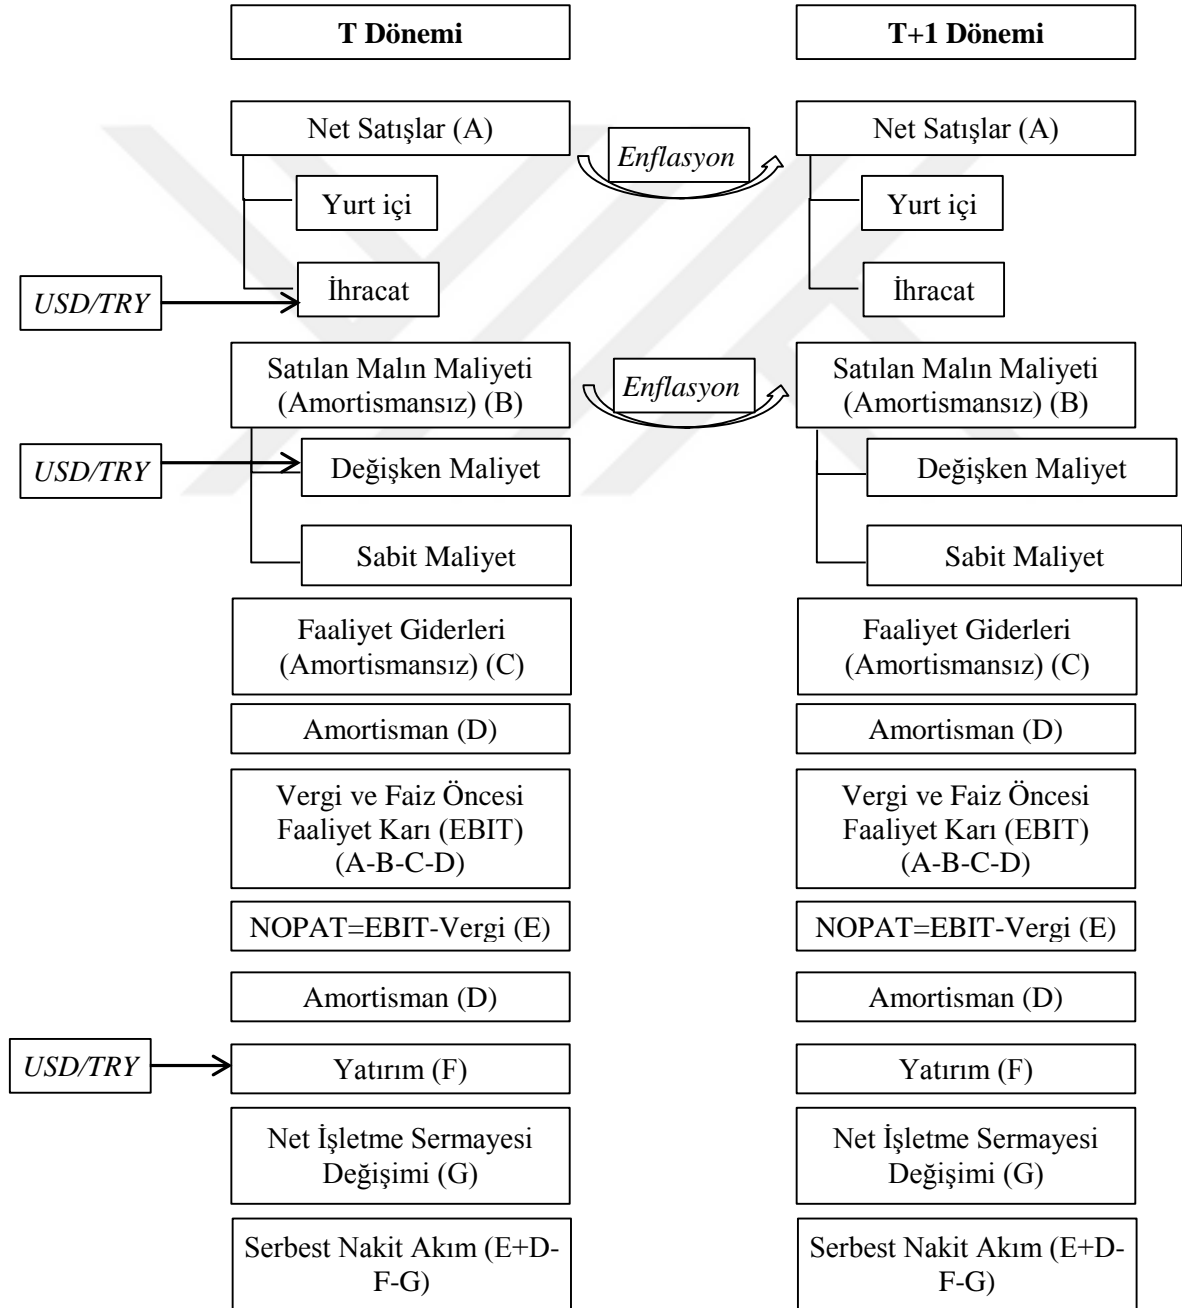
Yatırım projesine ait yatırım maliyetini ifade etmektedir. Çimento sektöründe kapasite yatırımı için katlanılacak yatırım bedeli, kurulacak klinker fırını, çimento değirmeni ve diğer benzeri ekipmanların satın alınması, bunların montajı, inşaat işleri, proje mühendislik bedeli ve alınması gereken izinlere ait giderler vb. gibi ana kalemlerden oluşmaktadır. Yatırım maliyetini oluşturan proje mühendislik bedeli, izinler ve inşaat işlerine ait giderler genellikle lokal para birimi olan Türk Lirası cinsinden olurken, yatırım maliyetinin önemli bir kısmını oluşturan ekipmanların satın alınması, bu ekipmanların yurtdışı üreticilerinden satın olunuyor olmasından dolayı döviz bazlı para cinsinden oluşmaktadır. Ayrıca projeksiyon süresi boyunca yapılmış olan yatırıma ait yıllık idame yatırımları belirlenmektedir. İdame yatırımları için kullanılacak ekipmanların yine belli bir kısmının yurt dışı menşeli olmasından dolayı sektöre ait yatırım analizlerinde genellikle yaratılan kapasiteye bağlı döviz kuru ile belirlenen sabit bir çarpan kullanılmaktadır (Örneğin, yıllık idame yatırımı gideri = çimento üretim kapasitesi (ton) x 2 \$/ton). Dolayısıyla DCF analizinin temel alt başlıklarından olan yatırım maliyetine ait ilk yatırım tutarı ve idame yatırımlarının belirlenmesindeki önemli girdilerden bir tanesi yine döviz kuru olmaktadır.

#### **4.1.7. Net İşletme Sermayesi Değişimi**

Net işletme sermayesi, işletmenin faaliyetlerine devam edebilmesi için gerekli olan ve likite çevrilmesi zor olmadığından dolayı kısa vadeli olarak belirtilen sermayedir. Net işletme sermayesi, ticari alacaklar, stoklar ve ticari borçlardan oluşmaktadır. DCF analizinde bir döneme ait serbest nakit akım bulunurken o yıl gerçekleşen net işletme sermayesi değişimi dikkate alınmaktadır. Net işletme sermayesini oluşturan alt başlıklar projeye ait net satışlar ve satılan malın maliyetine oran olarak hesaplanan gün sayılarını baz alarak bulunmaktadır. Genellikle yatırım projesi sonucunda satılacak ürüne ait sektörde var olan ticari alacak gün sayısı, stok devir gün sayısı ve ticari alacak devir gün sayıları kullanılmakta ve bu bu değerler projeksiyon süresince sabit tutularak net satışlar ve satılan malın maliyetindeki değişimlere göre şekillenmektedir. Dolayısıyla çalışmada kullanılan DCF analizinde yer alan net işletme sermayesi değişimine ilişkin projeksiyon süresince sektörel bilgi dışında direkt olarak etki eden önemli bir değişken bulunmamaktadır.

#### 4.1.8. Çalışmaya Konu Olan Değişkenler

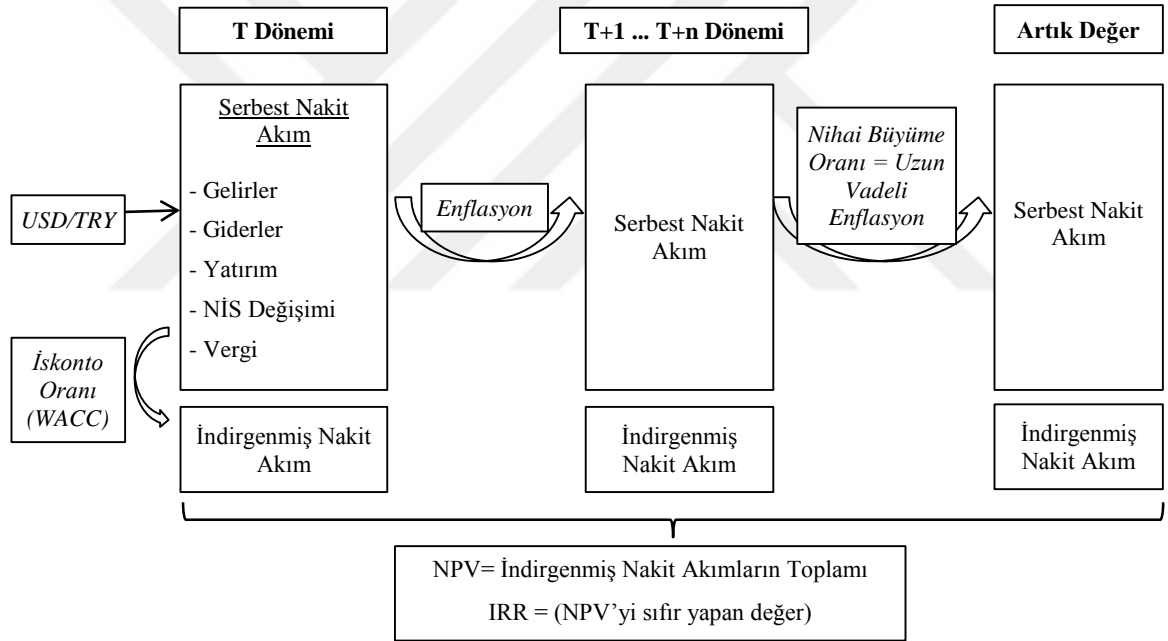
Projeksiyon süresi boyunca farklı dönemlerdeki serbest nakit akımlarını oluşturan alt başlıklara bakıldığında, sektörel bilgi ile oluşturulan tahminler haricinde en kritik değişkenlerin enflasyon ve döviz kuru olduğu görülmektedir. Dolayısıyla bu çalışmada önerilen modelde yapay zeka teknikleri tarafından da tahmin edilen değişkenler Türkiye enflasyonu ve döviz gelir ve giderlerinin hemen hemen tamamını oluşturan USD/TRY döviz kurudur. Bu değişkenlerin serbest nakit akımı oluşturan alt başlıklara nasıl etki ettiği Şekil 4.1c’de gösterilmiştir.



Şekil 4.1c: Kritik Değişkenlerin Serbest Nakit Akım Bileşenlerine Etkisi

Yukarıda da belirtildiği şekilde serbest nakit akım bu alt kalemlerin tahminleri ile oluşmakta ve projeksiyon dönemi süresince hesaplanmaktadır. 5. yılın sonunda, sonsuza kadar gerçekleşecek dönemleri içeren artık değer hesaplamasında, daha sonraki dönemler için gerçekleşecek nakit akımları terminal growth denilen nihai büyüme oranına tabi tutulmaktadır. Yatırım değerlemesi analizlerinde genellikle bu oran uzun dönemli enflasyon verisi olarak dikkate alınmaktadır.

Her bir döneme ve artık değerden elde edilen hesaplama ait serbest nakit akımları belirlenmiş olan iskonto oranı ile (WACC) indirgenerek indirgenmiş nakit akımlarını oluşturmaktadırlar. İndirgenmiş nakit akımlarının toplamı ise projenin net bugünkü değerini vermektedir. Sonuç olarak yapılan bu DCF analizi Şekil 4.1d' de gösterilen şekilde oluşmaktadır.



Şekil 4.1d: Çalışmada DCF Analizine Tabi Tutulan Nakit Akım Yapısı

## 4.2. Döviz Kuru Tahmin Modelleri

Bir ülkenin yerel para biriminin diğer ülkelere ait para birimleri karşısındaki değeri döviz kuru olarak adlandırılmaktadır. Döviz kurları sadece makroekonomik bir gösterge değil, aynı zamanda hem makro hem de mikro yatırımcıları etkileyen iktisadi bir göstergedir. Örneğin, Dünya'da en fazla kullanılan para birimi olan Amerikan Doları'nın (USD) Türk Lirası (TRY) karşısındaki değerini gösteren

USD/TRY döviz kuru büyük bir yatırıma ait ekipman alımında kullanılacak para birimi olup yatırımı etkileyen faktörlerden biri olabilirken, küçük bir yatırımcının nakdini değerlendirmek isterken direkt olarak kullanacağı bir yatırım aracı da olabilmektedir. Özellikle Türkiye gibi gelişmekte olan ekonomilerde ülke para biriminin USD karşısındaki konumu ve belirli sürelerde izlediği seyir o ülkedeki ekonomik gidişatın da göstergesi olabilmektedir. Bu gibi sebeplerden, döviz kurlarındaki hareketin tahmin edilmesi birçok çalışmanın ana konusu olmuştur.

Literatürde döviz kuru tahmini için kronolojik olarak temelde aşağıdaki 3 model geliştirilmiştir, ancak çalışmalar bu modellerle sınırlı kalmamıştır.

- Frenkel - Bilson Modeli
- Dornbusch - Frankel Modeli
- Hooper - Morton Modeli

Frenkel (1984) geliştirmiş oldukları Frenkel – Bilson modelini aşağıdaki gibi tanımlamıştır:

$$s = (m - m^*) - \phi(y - y^*) + \lambda(\pi - \pi^*) \quad (18)$$

Esnek kur modeli olarak da adlandırılan modelde  $s$ , yerel ve yabancı para birimleri arasındaki farkı logaritmik olarak ifade ederken,  $m$  yerel ve yabancı ülke para arzını,  $y$  yerel ve yabancı reel geliri,  $\pi$  ise kısa dönemli yerel ve yabancı faiz oranlarını ifade etmektedir.  $m$ ,  $y$  ve  $\pi$  değerleri logaritmandır. Ayrıca  $\phi$  gelir elastikiyetini,  $\lambda$  ise faiz oranı elastikiyetini ifade etmektedir.

Katı fiyat modeli dikkate alınarak öne sürülen Dornbush - Frenkel modelini Frenkel (1984) aşağıdaki şekilde (19) tanımlamıştır.  $\Theta$  döviz kurunun dengeye ulaşacağı hızı belirtirken,  $i$  ise uzun dönemli enflasyon değerini ifade etmektedir.

$$s = (\bar{m} - \bar{m}^*) - \phi(\bar{y} - \bar{y}^*) + \left(\lambda + \frac{1}{\theta}\right)(\bar{\pi} - \bar{\pi}^*) - \frac{1}{\theta}(i - i^*) \quad (19)$$

Hooper – Morton modelinde ise ticaret dengesinin kur üzerindeki etkisinin üzerinde durulmuş olup diğer modellere ek olarak 20 nolu eşitlikte görüleceği üzere TB olarak gösterilen dış ticaret dengesi eklenmiştir.

$$s = a_0 + a_1(m - m^*) + a_2(y - y^*) + a_3(i - i^*) + a_4(\pi - \pi^*) + a_5(TB - TB^*) + u \quad (20)$$

Literatürde ilk geliştirilen modeller bu üç model olup, çalışmalar bu modelleri baz alarak geliştirilmiştir. Meese ve Rogoff (1983) döviz kuru tahmin modellemesinde değişken olarak kısa vadeli faiz oranı, enflasyon oranı, ticaret dengesi ve para stoğunu kullanmıştır. Sarantis ve Stewart (1995) M1 para stoğu, kısa vadeli faiz oranı, enflasyon oranı, cari işlemler dengesi ve gayri safi yurt içi hasılayı ana değişkenler olarak kullanarak döviz kuru modellemesi yapmıştır. Verkooijen (1996) ve Weeren ve arkadaşları (1997) ise aşağıdaki denklemde (21) belirtilen altı değişkeni kullanarak modelleme yapmışlardır.

$$s_t = f(r_t, r_t^*, m_t, m_t^*, ip_t, ip_t^*, \pi_t, \pi_t^*, TB_t, TB_t^*) + \varepsilon_t \quad (21)$$

Modelde, s yerel para birimi ile yabancı para birimi arasındaki logaritmik değere işaret ederken, r kısa dönemli faiz oranını, m M1 para arzının logaritmik değerini, ip sanayi üretim endeksinin logaritmik değerini,  $\pi$  tüketici fiyatlarındaki enflasyon değerini ve TB ise ticaret dengesinin logaritmik değerini belirtmektedir.

Bu çalışmada (21) numaralı denklemde belirtilen Verkooijen (1996) ve Weeren ve arkadaşları (1997) tarafından kullanılan model ile elde edilecek USD/TRY döviz kuru analizleri kullanılacaktır.

### 4.3. Enflasyon Tahmin Modelleri

Enflasyon tahmini için literatürde birçok çalışma yapılmıştır. Bu çalışmaların birçoğunda aynen döviz kurunda olduğu gibi birden fazla değişken kullanılmış ve sonuç elde edilmeye çalışılmıştır. Ancak döviz kuru tahmin modellerinde olduğu şekilde enflasyon tahminlerinde, kronolojik olarak literatürde yerini alan ve herkes tarafından benimsenmiş modellerin yerine, araştırmacılar tarafından kabul görmüş bazı temel uygulamalar yer almaktadır. Dolayısıyla bu bölümde enflasyonu tahmin etme ve modelleme önerilerinde bulunan yazarlara ve çalışmalarına yer verilmiştir.

Somaratra ve arkadaşları (2010) enflasyon tahmini için değişken olarak gayri safi yurt içi hasıla, para arzı, hazine bonusu faiz oranı ve döviz kuru oranlarından yararlanmışlardır. Enke ve Mehdiyev (2014) enflasyon tahmini için yedi değişken kullanmıştır. Bunlar sanayi üretim endeksi, üretici fiyat endeksi, M1 para stoğu, M2 para stoğu, 10 yıllık hazine bonusu faiz oranı, döviz kuru ve Moody's in belirlemiş olduğu Aaa özel şirket tahvil getirisidir. Kooths ve arkadaşları (2003) petrol fiyatı değişimi, döviz kuru, enerji fiyatlarındaki değişim ve Almanya Merkez Bankası'nın enflasyon hedef tahminleri ile enflasyon tahmini modellemesi tanımlamışlardır. Dominguez ve arkadaşları (1988) ise sanayi üretim endeksi, üretici fiyat endeksi, hisse senedi endeksi, üç aylık faiz oranları ve para stoğu verilerini kullanarak enflasyon tahmini gerçekleştirmiştir. Romer (1992) Büyük Bunalım dönemini inceleyerek M1 para stoğu, gecikmeli M1 büyümesi, faiz oranları ve sanayi üretim endeksini kullanarak enflasyon tahmin modelini açıklamıştır. Cecchetti (1992) ise enflasyonu etkileyen temel değişkenlerin faiz oranları, M1 ve M2 para stoklarının büyüme oranları ve sanayi üretim endeksi olduğunu belirtmiştir.

Örnekleri verilen çalışmalarda görüldüğü üzere, üzerinde anlaşılması kabul gören bir değişken seti olmamasına rağmen hemen hemen tüm çalışmalarda kullanılan değişkenler birbirine benzerdir. Bu çalışmada birçok çalışmaya da kaynak teşkil etmiş olan Cecchetti (1992)'nin önermiş olduğu değişkenler olan faiz oranları, M1 ve M2 para stoklarının büyüme oranları ve sanayi üretim endeksi kullanılarak enflasyon tahmin modellemesi yapılacaktır.

#### **4.4. Veri Seti**

Bölüm 4.1'de belirtildiği ve Bölüm 4.2 ve 4.3'de literatürde yer alan tahmin modellerinden bahsedildiği üzere çalışmaya konu olan kritik değişkenler USD/TRY döviz kuru ve Türkiye enflasyonu olacaktır. Çalışmadaki bir diğer önemli unsur olan satış tahminleri ve diğer tahminler ise sektörel veriler kullanılarak çalışmadaki karşılaştırmaya tabi tutulacak tüm üç modelde (gerçekleşmiş, geleneksel ve yapay sinir ağları) aynı tutulacaktır.

Şekil 4.1c ve 4.1d'de gösterildiği üzere bu değişkenlerden USD/TRY döviz kuru ihracat gelirlerinden ötürü net satışları, döviz bazlı maliyetlerden ötürü toplam maliyetleri, yatırımın döviz bazlı anapara ile gerçekleşmesinden ötürü de Capex



olarak da adlandırılan yatırım tutarını etkileyecektir. Modellemesi yapılacak bir diğer değişken olan enflasyon ise birçok değişkenin yıllar arasındaki artışının temel girdisi olarak kullanılacaktır. Ayrıca modelde son yılların ortalama enflasyon verileri dikkate alınarak hesaplanan uzun vadeli enflasyon beklentisi artık değer hesaplamasının önemli bir unsuru olan nihai büyüme oranını belirleyecektir.

Bölüm 4’de bahsedildiği üzere DCF modellemesi 2011-2015 yılları arası nakit akımlarını ve sonrasını oluşturan artık değer toplamından meydana geleceği için değişkenlerin 2011-2015 yılları arasına denk gelen zaman diliminde çıktılarının DCF modeline implemente edilmesi gerekmektedir. Çalışmanın bundan sonraki kısımlarında detaylı olarak açıklanacak olan yapay sinir ağlarının ve destek vektör regresyonunun öğrenme ve test etme metodolojisine binaen modelin 2011-2015 dönemine denk gelen zaman periyodundaki çıktılarını test edebilmek için daha önceki dönemlere ait çıktılarının öğrenme işlemine dahil edilmesi gerekmektedir. Bu sebepten tahmin edilecek döviz kuru ve enflasyon için, bu iki kritik değişkenin yanı sıra, bu değişkenlerin tahmin edilmesinde kullanılan tüm diğer değişkenlerin 1999-2015 yılları arasındaki aylık gerçekleştirmeleri çalışmaya temel oluşturan veri seti olarak dikkate alınmıştır.

#### **4.5. Tahmin Modellemesi ve Çalışmaya Entegrasyonu**

Bu çalışmada nakit akımların tahmini için yeni bir yaklaşım önerilmektedir. Bu yaklaşım yapay sinir ağları ve destek vektör regresyonu ile tahmin edilen enflasyon ve döviz kurunun yatırım değerlemesinde kullanılan DCF modelini oluşturan nakit akımlarını oluştururken sürece dahil edilmesini ve bu kritik girdilerle şekillenen nakit akımların yatırım değerlemesi modelinde kullanılmasını belirtmektedir.

Yapay sinir ağları ile yapılan uygulama birkaç adımdan oluşmaktadır:

- 1- Kritik değişkenleri tahmin etmek için bu değişkenlerin çıktı olarak belirlenmesi
- 2- Bu çıktılarının tahmin edilebilmesi için girdi değişkenlerinin belirlenmesi
- 3- Sinir ağının yapısının kurulması
- 4- Öğrenme sürecinin oluşturulabilmesi için ağın eğitilmesi

5- Tahminin doğruluğunun ölçülebilmesi için gerçekleştiren data ile kıyaslama yapılması

Birinci adımda kritik değişkenler USD/TRY döviz kuru ve Türkiye ekonomisi enflasyonu olarak belirlenmiştir. Bu iki değişken modellemelerde çıktı olarak kullanılacaktır. İkinci adımda bahsedilen değişkenler Bölüm 4.2 ve 4.3’de belirtilen değişkenlerdir.

USD/TRY döviz kuru için yerel ekonomi Türkiye, yabancı ekonomi Amerika Birleşik Devletleri olmak üzere girdi değişkenleri aşağıdaki şekilde belirlenmiştir.

- kısa dönemli faiz oranı
- M1 para arzı
- sanayi üretim endeksi
- tüketici fiyatlarındaki enflasyon değeri
- ticaret dengesi

Türkiye ekonomisi enflasyonu tahmini için ise aşağıdaki değişkenler girdi değişkenleri olarak belirlenmiştir.

- kısa dönemli faiz oranı
- M1 para stoklarının büyüme oranı
- M2 para stoklarının büyüme oranı
- sanayi üretim endeksi

Üçüncü adımda belirtilen ağı oluşturulması için öncelikle tüm değişkenlerin hangi zaman dilimini içereceği belirlenmelidir. Daha sonra bu zaman serisinin belli dönemleri yapay sınır ağının yapısı olan öğrenme (training), doğrulama (validation) ve test etme (testing) aşamaları olarak belirlenmesi gerekmektedir. Literatür çalışmalarında data setinin genellikle %60-80 kadarı öğrenme periyodu olarak kullanılmaktadır. Bu çalışmada data setinin %60’ı öğrenme, %10’u doğrulama, %30’u da test etme aşamalarında kullanılmıştır. Bu oranlar çıktı dönemi olarak

kullanılacak 2011-2015 periyodu dikkate alınarak belirlenmiştir. Değişken olarak kullanılacak tüm parametrelere ait veriler aylık olarak kullanılmıştır. 2011-2015 dönemini kapsayacak 60 aylık gerçekleşme için, 60 verinin data setinin en fazla %30'unu oluşturabilmesi için data serinin sıralı olarak en az 200 veriden oluşması belirlenmiştir. Dolayısıyla 204 aylık süreden oluşan 1999-2015 veri seti kullanılmış, bu verilerin 123 tanesi (%60) öğrenme, 20 tanesi (%10) doğrulama ve kalan 61 tanesi (%30) test aşaması için kullanılmıştır. Söz konusu değişkenlerin bu dönemdeki gerçekleştirmeleri Türkiye İstatistik Kurumu (TÜİK) ve ABD Ekonomik Analiz Bürosu (BEA) veritabanlarından elde edilmiştir.

Üçüncü adımın, yani ağı yapısının oluşturulması için gerekli en önemli aşamalardan birisi de yapay sinir ağı modeli ve gizli nöron sayısının seçilmesidir. Model olarak bu çalışmada ileri beslemeli ve geri bildirimli yapay sinir ağı seçilmiştir. Gizli nöron sayısı için ise birçok çalışmada olduğu gibi (Palmer ve ark., 2006; Zhang, 2001) deneme yanılma (trial-and-error) yöntemi seçilerek 1 gizli nöronla başlayarak 10 gizli nörona kadar katman belirlenmiş ve en iyi sonucu veren gizli nöron çalışmaya baz alınmıştır.

Dördüncü adımda belirtilen ağı eğitilmesi aşaması USD/TRY döviz kuru ve enflasyon tahmin modelinde değişkenlerin her birinin 204 adet gerçekleşmesinden oluşan data setinin %60'ı öğrenme işlemine tabi tutulmuştur. Bu aşamada Matlab programınının Yapay Sinir Ağları eklentisinden yararlanılmıştır.

Beşinci adım olarak belirtilen tahminin doğruluğunun ölçülebilmesi için gerçekleştirilmiş data ile kıyaslama yapılmasında ise her bir gizli nöron ile yapılan tahmin sonucunun doğrulama kısmına denk gelen çıktılarının o döneme ait gerçekleştirilmiş veriler ile ortalama karekök hata (RMSE) ve korelasyon katsayısı (R) yöntemleri ile kıyaslaması yapılmıştır.

Root mean square error olarak adlandırılan 22 nolu RMSE formülünde  $y_i$  i dönemine ait gerçekleştirilmiş veriyi ifade ederken,  $\hat{y}_i$  i dönemi için elde edilen tahmin sonucunu göstermektedir.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (22)$$

RMSE, gerçek değerler ile tahmin edilen değerlerin karelerinin toplamının ortalamasının kareköküne eşittir. Her bir gizli nöron için bulunan sonuçlar arasında en düşük RMSE'ye sahip olan data seti en başarılı tahmine işaret etmektedir.

Korelasyon katsayısının (R) formülü ise aşağıda 23 nolu denklemde gösterilmiştir.

$$R = \frac{\sum_{i=1}^n (y_i - \bar{y})(\hat{y}_i - \bar{\hat{y}})}{\sqrt{\sum_{i=1}^n (y_i - \bar{y})^2 \sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})^2}} \quad (23)$$

Formülde, her bir çıktıya ait gerçek değer ve tahmin edilen değerlerin ortalamalarından, farklarının çarpımlarının toplamı payı oluştururken, payda her bir çıktıya ait gerçek değer ve tahmin edilen değerlerin ortalamalardan farkının karelerinin toplamının çarpımlarının karekökünden meydana gelmektedir. Her bir gizli nöron için bulunan sonuçlar arasında en yüksek R'ye sahip olan data seti en başarılı tahmine işaret etmektedir.

Destek vektör regresyonu ile yapılan tahmin çalışmasında ise yukarıda belirtilen 5 adımlı yöntem şu şekilde oluşmaktadır.

- 1- Kritik değişkenleri tahmin etmek için bu değişkenlerin çıktı olarak belirlenmesi
- 2- Bu çıktıların tahmin edilebilmesi için girdi değişkenlerin belirlenmesi
- 3- Destek vektör regresyonu yapısının kurulması ve kritik parametrelerin belirlenmesi
- 4- Öğrenme sürecinin oluşturulabilmesi için yapının eğitilmesi
- 5- Tahminin doğruluğunun ölçülebilmesi için gerçekleştiren data ile kıyaslama yapılması

Çalışmada birinci ve ikinci adım aynen yapay sinir ağları modelinde olduğu şekliyle kullanılmaktadır. Üçüncü adımda ise tahmin çalışmasını şekillendirebilmek için ve destek vektör regresyonu çalışmasını yapmak için yapının kurulması gerekmektedir.

Destek vektör regresyonunda çoklu girdili bir veri seti kullanılacağından en küçük kareler destek vektör regresyonu ve bu modelin de kullandığı radial basis function (RBF) yapısı seçilmiştir. RBF, yapılan çalışmalarda çoğunlukla kullanılan kernel yöntemidir çünkü lineer olmayan haritalamalarda, RBF çok boyutlu ortamda lineer kernelin aksine uygun modeldir.

Seçilen kernel modeli ile birlikte parametrelerin belirlenmesi gerekmektedir. Veri setinin tahmini için kullanılacak en uygun  $\sigma$  ve  $\gamma$  parametrelerini bulmak için genellikle kullanılan yöntem olan crossvalidation kullanılmıştır (Liu ve Wang, 2008; Samui, 2011; Samui ve Sitharam, 2009; Samsudin ve ark., 2011). Bu yöntemi yapmadan direkt olarak belirlenmiş  $\sigma$  ve  $\gamma$  ile başlamak uygun değildir. Test datasını iyi tahmin edebilmek için öğrenme sürecinde en optimum ( $\sigma$ ,  $\gamma$ ) ikilisinin belirlenmesi modelin en kritik adımlarından bir tanesidir (Jiang ve Zhao, 2013; Xie ve ark., 2011). Bu aşamada en optimum değerleri bulmak için  $\sigma$  ve  $\gamma$  üst değerleri değiştirilerek model bir çok kere çalıştırılmaya hazır hale getirilmiştir.

Yine bu adımda yapay sinir ağı modeli olduğu gibi veri setinin öğrenme, doğrulama ve test aşamalarına uygun şekilde hazırlanması gerekmektedir. Destek vektör regresyonunun uygulanması sürecindeki önemli parametrelerden  $\sigma$  ve  $\gamma$  bulunabilmesini sağlamak için veri setinin şu şekilde dizaynı esas alınmıştır. Öncelikle tüm değişkenlerin hangi zaman dilimini içereceği belirlenmeli ve daha sonra bu zaman serisinin belli dönemleri yapay sinir ağının yapısı olan öğrenme (training), doğrulama (validation) ve test etme (testing) aşamaları olarak belirlenmesi gerekmektedir. Literatür çalışmalarında data setinin genellikle %60-80 kadarı öğrenme periyodu olarak kullanılmaktadır. Bu çalışmada data setinin %60'ı öğrenme, %10'u doğrulama, %30'u da test etme aşamalarında kullanılmıştır. Bu oranlar çıktı dönemi olarak kullanılacak 2011-2015 periyodu dikkate alınarak belirlenmiştir. Değişken olarak kullanılacak tüm parametrelere ait veriler aylık olarak kullanılmıştır. 2011-2015 dönemini kapsayacak 60 aylık gerçekleşme için, 60 verinin data setinin en fazla %30'unu oluşturabilmesi için data serinin sıralı olarak en az 200 veriden oluşması belirlenmiştir. Dolayısıyla 204 aylık süreden oluşan 1999-2015 veri seti kullanılmış, bu verilerin 123 tanesi (%60) öğrenme, 20 tanesi (%10) doğrulama ve kalan 61 tanesi (%30) test aşaması için kullanılmıştır. Söz konusu değişkenlerin

bu dönemdeki gerçekleřmeleri Türkiye İstatistik Kurumu (TÜİK) ve ABD Ekonomik Analiz Bürosu (BEA) veribankalarından elde edilmiştir.

Dördüncü adımda belirtilen yapının eğitilmesi aşamasında USD/TRY döviz kuru ve enflasyon tahmin modelinde deęişkenlerin her birinin 204 adet gerçekleřmesinden oluřan data setinin %60'ı öğrenme işlemine tabi tutulmuřtur. Bu aşamada Matlab programı için dizayn edilmiş LSSVMLab toolbox'ı kullanılmıştır. Bu öğrenme ve crossvalidation işleminde üçüncü adımda da belirtildięi gibi  $\sigma$  ve  $\gamma$  parametrelerinin aralıkları ve üst limitleri deęiřtirilerek her bir aralık öncelikle uygun  $\sigma$  ve  $\gamma$  deęerleri bulunmuř ve bu deęerlerle veri setine yapılan öğrenme işlemi tekrarlanmıştır.

Beřinci adım olarak belirtilen tahminin doęruluęunun ölçülebilmesi için gerçeklemiş data ile kıyaslama yapılmasında ise her bir aralık ile yapılan tahmin sonucunun doęrulama kısmına denk gelen çıktıların o döneme ait gerçeklemiş veriler ile karesel ortalama hata (RMSE) ve korelasyon katsayısı (R) yöntemleri ile kıyaslaması yapılmıştır.

#### **4.6. Yapay Sinir Ağları ile USD/TRY Döviz Kuru Tahmini**

Yapay sinir ağları kullanılarak USD/TRY döviz kuru tahmini yapılmıştır. Tahmin çalışmasında doęal olarak çıktı olarak USD/TRY döviz kuru dikkate alınırken yerel ekonomi Türkiye, yabancı ekonomi Amerika Birleřik Devletleri olmuřtur. Girdi deęişkenleri Verkooijen (1996) ve Weeren ve arkadaşları (1997)'nin çalışmalarında kullandığı üzere ařağıdaki řekilde belirlenmiştir.

- kısa dönemli faiz oranı
- M1 para arzı
- sanayi üretim endeksi
- tüketici fiyatlarındaki enflasyon deęeri
- ticaret dengesi

Araştırmaya konu olan yatırım projesine ait 2011-2015 yılı arasındaki nakit akımları hesaplanacağından bu zaman periyodu çıktı dönemi olarak belirlenmiştir. Çalışmadaki data setine yapay sinir ağı tahmin sürecinde öğrenme, doğrulama ve test etme aşamalarının uygulanması gerekmektedir. 2011-2015 arasındaki döneme ait çıktıların yapay sinir ağı tarafından öğrenilmiş ağın test etme aşamasına denk gelen kısımları kullanılacaktır. Test etme periyodu literatür göz önünde bulundurularak tüm data setininin %30'u olarak belirlenmiştir. Dolayısıyla tüm data setinin bu oranı karşılayabilmesi için 1999 yılından başlaması gerektiği belirlenmiştir. Bu sebepten 1999-2015 yılları arasındaki 17 yıla ait ay bazındaki veriler her bir değişken için sıralı 204 veriden oluşmaktadır. Bu 204 verinin %60'ı öğrenme, %10'u doğrulama, %30'u da test etme aşamalarında kullanılmıştır. Dolayısıyla bu verilerin 123 tanesi (%60) öğrenme, 20 tanesi (%10) doğrulama ve kalan 61 tanesi (%30) test aşaması için kullanılmıştır. Söz konusu değişkenlerin bu dönemdeki gerçekleştirmeleri Türkiye İstatistik Kurumu (TÜİK) ve ABD Ekonomik Analiz Bürosu (BEA) veritabanlarından elde edilmiştir.

Hazırlanan bu veri seti 5 değişkene ait 204 adet sıralı veriden oluşan 204x5 lik bir matris yapıyı oluşturmaktadır. Aynı şekilde çıktı değişkene ait 204x1 lik bir değişken seti de ağın output kısmını oluşturmaktadır. Bu veri seti Matlab programının yapay sinir ağı eklentisi yardımıyla yapay sinir ağları modellemesine tabi tutulmuştur. Ağ yapısının oluşturulmasındaki en kritik aşamalardan biri gizli nöron sayısının seçilmesidir. Gizli nöron sayısı için ise birçok çalışmada olduğu gibi (Palmer ve ark., 2006; Zhang, 2001) deneme yanılma (trial-and-error) yöntemi seçilerek 1 gizli nöronla başlayarak 10 gizli nörona kadar katman belirlenmiş ve en iyi sonucu veren gizli nöron çalışmaya baz alınmıştır.

USD/TRY döviz kuru tahmininin çıktı kısmı için yerel ekonomi Türkiye, yabancı ekonomi Amerika Birleşik Devletleri alındığı için USD/TRY döviz kurunun seçilen dönemdeki her bir verisine ait logaritmik değer alınarak 204x1 lik fiili çıktı seti oluşturulmuştur. Yani, örneğin 204 verinin zaman açısından ilk verisi olan 1999 yılı Ocak ayı USD/TRY döviz kuru fiili verisi 0,33148 olduğu için bu verinin logaritmik değeri olan  $\ln(0,33148) = -1,1042$  çıktı veri setinin ilk değeri olmuştur.

Çıktı matrisinin ardından girdilerden oluşturulan 204x5 lik yapı şu şekilde oluşturulmuştur. İlk olarak, kısa dönemli faiz oranı için Türkiye aylık Libor faiz

oranı ile ABD aylık Libor faiz oranları kullanılmış, yerel ekonomi Türkiye, yabancı ekonomi Amerika Birleşik Devletleri alındığı için Türkiye kısa dönemli faiz oranı ile ABD kısa dönemli faiz oranının her bir dönem için farkı bulunarak veri seti oluşturulmuştur. Örneğin, veri setinin ilk dönemi olan 1999 yılı Ocak ayı Türkiye aylık Libor faiz oranı %72,0 iken ABD aylık Libor faiz oranı %4,979 olarak gerçekleştiği için bu oranlar arasındaki fark girdi veri setini oluşturan ilk değer olmuştur.

İkinci değişken olarak M1 para arzı kullanılmıştır. Türkiye M1 para arzı miktarı ile ABD M1 para arzı miktarlarının logaritmik değerleri bulunmuş ve bu logaritmik değerler arasındaki fark girdi veri setini oluşturan değer olmuştur. Örneğin, veri setinin ilk dönemi olan 1999 yılı Ocak ayı Türkiye M1 para arzı miktarı parasal büyüklük olarak 2,38586 milyar dolar ABD M1 Para arzı 1.103,9 milyar dolar olarak gerçekleşmiştir. Öncelikle bu her iki miktarın logaritmik değerleri bulunmuş ve bulunan logaritmik değerlerin farkı alınırken yerel ekonomi Türkiye, yabancı ekonomi Amerika Birleşik Devletleri alındığı için Türkiye M1 değerinden ABD M1 değeri çıkarılmıştır. Bulunan değer girdi veri setinin M1 kısmını oluşturan ilk değer olmuştur.

Üçüncü değişken olarak sanayi üretim endeksi kullanılmıştır. Türkiye sanayi üretim endeksi değeri ile ABD sanayi üretim endeksi değerinin logaritmik değerleri bulunmuş ve bu logaritmik değerler arasındaki fark girdi veri setini oluşturan değer olmuştur. Örneğin, veri setinin ilk dönemi olan 1999 yılı Ocak ayı Türkiye sanayi üretim endeksi değeri 51,2378, ABD sanayi üretim endeksi değeri 90,3455 olarak gerçekleşmiştir. Öncelikle bu her iki rakamın logaritmik değerleri bulunmuş ve bulunan logaritmik değerlerin farkı alınırken yerel ekonomi Türkiye, yabancı ekonomi Amerika Birleşik Devletleri alındığı için Türkiye sanayi üretim endeksi değerinden ABD sanayi üretim endeksi değeri çıkarılmıştır. Bulunan değer girdi veri setinin sanayi üretim endeksi kısmını oluşturan ilk değer olmuştur.

Dördüncü değişken olarak tüketici fiyat endeksi (TÜFE) kullanılmıştır. Türkiye TÜFE değeri ile ABD TÜFE değerinin farkı girdi veri setini oluşturan değer olmuştur. Örneğin, veri setinin ilk dönemi olan 1999 yılı Ocak ayı Türkiye TÜFE değeri %65,90 iken ABD TÜFE'si %1,7 olarak gerçekleşmiştir. Bu değerlerin farkı alınırken yerel ekonomi Türkiye, yabancı ekonomi Amerika Birleşik Devletleri



alındığı için Türkiye TÜFE değerinden ABD TÜFE değeri çıkarılmıştır. Bulunan değer girdi veri setinin enflasyon kısmını oluşturan ilk değer olmuştur.

Beşinci değişken olarak ticaret dengesi (trade balance) kullanılmıştır. Türkiye ticaret dengesi miktarı ile ABD ticaret dengesi miktarının logaritmik değerleri bulunmuş ve bu logaritmik değerler arasındaki fark girdi veri setini oluşturan değer olmuştur. Örneğin, veri setinin ilk dönemi olan 1999 yılı Ocak ayı Türkiye ticaret dengesi 343,195 milyon dolar iken, ABD ticaret dengesi 15.946 milyon dolar olarak gerçekleşmiştir. Öncelikle bu her iki miktarın logaritmik değerleri bulunmuş ve bulunan logaritmik değerlerin farkı alınırken yerel ekonomi Türkiye, yabancı ekonomi Amerika Birleşik Devletleri alındığı için Türkiye ticaret dengesi değerinden ABD ticaret dengesi değeri çıkarılmıştır. Bulunan değer girdi veri setinin ticaret dengesi kısmını oluşturan ilk değer olmuştur.

Her bir değişkene bu işlem uygulandıktan sonra 204 aylık dönem sonucunda 204x5 lik bir matris elde edilmiştir. Oluşturulan 204x5 lik girdi matrisi ile 204x1 lik çıktı matrisi ile ağ yapısı oluşturulmuş, Matlab programı yapay sinir ağları eklentisi yardımıyla yapay sinir ağı modeline tabi tutulmuştur. Yapı oluşturulurken gizli nöron sayısının da belirlenmesi gerekmektedir. Bu çalışmada bölüm başında belirtildiği üzere deneme yanılma yöntemi dikkate alınmış 1 gizli nöronun 10 gizli nörona kadar 10 değişik yapı kullanılmıştır. Yine bölüm başında da belirtildiği üzere değişkenlerin ilk 123 tanesi (%60) öğrenme, 20 tanesi (%10) doğrulama ve kalan 61 tanesi (%30) test aşaması için kullanılmıştır. Ağın eğitilmesi esnasında her bir gizli nöron sayısından oluşan yapının ilk 123 verisi öğrenme aşamasında kullanılmıştır. Öğrenme aşamasından sonra 124-143. sıradaki değişkenler doğrulama aşaması için kullanılmıştır. Her bir yapıda bu kısma denk gelen model çıktısı fiili çıktı ile karşılaştırılmış ve çıktının tahmin performansının ölçülmesi için karesel ortalama hata (RMSE) ve korelasyon katsayısı (R) yöntemleri ile kıyaslaması yapılmıştır. Örneğin anlatılan bu çalışma 1 gizli nöron ile yapılan modeldeki sonuçlar üzerinden şu şekilde özetlenebilir.

1 gizli nöron ile yapılmış çalışmada doğrulama periyoduna denk gelen veri setinin 124-143. verileri için gerçek USD/TRY döviz kuru değeri ile modelin sonucunu belirten model çıktı USD/TRY döviz kuru sonucu tahminin performansını

ölçmek için karşılaştırılmaktadır. Bu iki veri setinin karşılaştırması ile RMSE 0,0446, R ise 0,63 çıkmaktadır.

Nöron sayısı 1 den 10'a değiştirildiğinde her bir ağ yapısı için aynı yöntemler uygulanmış ve işlem sonucunda Tablo 4.6j' de yer alan sonuçlara ulaşılmıştır.


Tablo 4.6a: USD/TRY Döviz Kuru Tahmin Modellemesi - Farklı Gizli Nöronlara Ait Sonuç Tablosu

Gizli Nöron Sayısı	RMSE	R
1	0,0446	0,63
2	0,0437	0,63
3	0,0437	0,48
4	0,0411	0,56
5	0,0500	0,47
6	0,0407	0,63
7	0,0416	0,52
8	0,0533	0,61
9	0,0434	0,65
10	0,0653	0,08

Bu sonuçlara göre en düşük RMSE ve en yüksek R değerini veren yapay sinir ağı yapısı 6 gizli nöron ile oluşturulmuş yapı çıkmaktadır. 6 nöron ile oluşan sonuçlar Tablo 4.6b. ve Şekil 4.6' da gösterilmiştir.

Tablo 4.6b: USD/TRY Döviz Kuru Tahmin Modellemesi - 6 Gizli Nörona Ait Fiili ve Model Çıktı Karşılaştırma Tablosu

Dönem	USD/TRY (fiili)	USD/TRY (model)
124	1,60448	1,62510
125	1,56972	1,61000
126	1,53757	1,56830
127	1,48409	1,54620
128	1,49720	1,50330
129	1,48914	1,51360
130	1,48944	1,51500
131	1,48974	1,50600
132	1,51301	1,49520
133	1,49227	1,51260
134	1,54744	1,50590
135	1,52883	1,56180
136	1,48750	1,52900
137	1,55893	1,49640
138	1,58233	1,58220
139	1,51044	1,59250
140	1,52409	1,51660
141	1,45820	1,53870
142	1,43706	1,46720
143	1,49347	1,45660
<b>RMSE</b>	<b>0,0407</b>	
<b>R</b>	<b>0,63</b>	



Şekil 4.6: USD/TRY Döviz Kuru Tahmin Modellemesi - 6 Gizli Nörona Ait Fiili ve Model Çıktılarının Grafikselsel Gösterimi

6 gizli nöronlu yapay sinir ağı yapısı ile oluşmuş modelin denenen tüm yapılar içerisinde tahmin performansının en iyi olduğu bulunduktan sonra bu yapının test etme periyodu dönemindeki çıktıları ise çalışmada kullanılan DCF modelinin içerisine 2011-2015 yılı verileri olarak yerleştirilmiştir. Bu konu ile ilgili detay bölüm 4.8’de verilecektir.

## 4.7. Yapay Sinir Ağları ile Türkiye Enflasyonu Tahmini

Çalışmada USD/TRY döviz kuru tahmininin haricinde yapay sinir ağları kullanılarak Türkiye enflasyonu (TÜFE) tahmini de yapılmıştır. Tahmin çalışmasında çıktı değişkeni olarak Türkiye enflasyon oranı dikkate alınırken girdi değişkenleri Cecchetti (1992)’nin çalışmasında belirttiği şekilde kullanılmıştır:

- kısa dönemli faiz oranı
- M1 para stoklarının büyüme oranı
- M2 para stoklarının büyüme oranı
- sanayi üretim endeksi

Araştırmaya konu olan yatırım projesine ait 2011-2015 yılı arasındaki nakit akımları hesaplanacağından bu zaman periyodu çıktı dönemi olarak belirlenmiştir. Çalışmadaki data setine yapay sinir ağı tahmin sürecinde öğrenme, doğrulama ve test etme aşamalarının uygulanması gerekmektedir. 2011-2015 arasındaki döneme ait çıktıların yapay sinir ağı tarafından öğrenilmiş ağın test etme aşamasına denk gelen kısımları kullanılacaktır. Test etme periyodu literatür göz önünde bulundurularak tüm data setininin %30’u olarak belirlenmiştir. Dolayısıyla tüm data setinin bu oranı karşılayabilmesi için 1999 yılından başlaması gerektiği belirlenmiştir. Bu sebepten 1999-2015 yılları arasındaki 17 yıla ait ay bazındaki veriler her bir değişken için sıralı 204 veriden oluşmaktadır. Bu 204 verinin %60’ı öğrenme, %10’u doğrulama, %30’u da test etme aşamalarında kullanılmıştır. Dolayısıyla bu verilerin 123 tanesi (%60) öğrenme, 20 tanesi (%10) doğrulama ve kalan 61 tanesi (%30) test aşaması için kullanılmıştır. Söz konusu değişkenlerin bu dönemdeki gerçekleştirmeleri Türkiye İstatistik Kurumu (TÜİK) ve ABD Ekonomik Analiz Bürosu (BEA) veritabanlarından elde edilmiştir.

Hazırlanan bu veri seti 4 deęişkene ait 204 adet sıralı veriden oluşan 204x4 lik bir matris yapıyı oluşturmaktadır. Aynı şekilde çıktı deęişkene ait 204X1 lik bir deęişken seti de aęın output kısmını oluşturmaktadır. Bu veri seti Matlab programının yapay sinir aęı eklentisi yardımıyla yapay sinir aęları modellemesine tabi tutulmuştur. Aę yapısının oluşturulmasındaki en kritik aşamalardan biri gizli nöron sayısının seçilmesidir. Gizli nöron sayısı için ise birçok çalışmada olduęu gibi (Palmer ve ark., 2006; Zhang, 2001) deneme yanılma (trial-and-error) yöntemi seçilerek 1 gizli nöronla başlayarak 10 gizli nörona kadar katman belirlenmiş ve en iyi sonucu veren gizli nöron çalışmaya baz alınmıştır.

Enflasyon oranı tahmininin çıktı kısmı için Türkiye enflasyon oranı (TÜFE) dikkate alınarak 204x1 lik fiili çıktı seti oluşturulmuştur. Aylık veriler kullanıldığı için her dönem için önceki yılın aynı ayına göre olan deęişim kullanılmıştır. Örneğin 204 verinin zaman açısından ilk verisi olan 1999 yılı Ocak ayı enflasyon fiili verisi %65,90 yani 0,6590 çıktı veri setinin ilk verisine denk gelmektedir.

Çıktı matrisinin ardından girdilerden oluşturulan 204x4 lük yapı şu şekilde oluşturulmuştur. İlk olarak, kısa dönemli faiz oranı için Türkiye aylık Libor faiz oranı kullanılmıştır. Örneğin, veri setinin ilk dönemi olan 1999 yılı Ocak ayı Türkiye aylık Libor faiz oranı %72,0 olduęu için girdi veri setini oluşturan ilk deęer olmuştur.

İkinci deęişken olarak M1 para stoklarının büyüme oranı kullanılmıştır. Türkiye M1 para stoęu büyüme oranı girdi veri setini oluşturan deęer olmuştur. Örneğin, veri setinin ilk dönemi olan 1999 yılı Ocak ayı Türkiye M1 para stoęu büyüme oranı %-6,89 olarak gerçekleşmiştir. Bu deęer girdi veri setinin M1 para stoęu büyüme oranı kısmını oluşturan ilk deęer olmuştur.

Üçüncü deęişken olarak M2 para stoklarının büyüme oranı kullanılmıştır. Türkiye M2 para stoęu büyüme oranı girdi veri setini oluşturan deęer olmuştur. Örneğin, veri setinin ilk dönemi olan 1999 yılı Ocak ayı Türkiye M2 para stoęu büyüme oranı %2,59 olarak gerçekleşmiştir. Bu deęer girdi veri setinin M2 para stoęu büyüme oranı kısmını oluşturan ilk deęer olmuştur.

Dördüncü değişken olarak sanayi üretim endeksi kullanılmıştır. Türkiye sanayi üretim endeksi değerinin logaritmik değeri bulunmuş ve bu logaritmik değer girdi veri setini oluşturan değer olmuştur. Örneğin, veri setinin ilk dönemi olan 1999 yılı Ocak ayı Türkiye sanayi üretim endeksi değeri 51,2378 olarak gerçekleşmiştir. Bu verinin logaritmik değeri olan 3,9365 girdi veri setinin sanayi üretim endeksi kısmını oluşturan ilk değer olmuştur.

Her bir değişkene bu işlem uygulandıktan sonra 204 aylık dönem sonucunda 204x4 lük bir matris elde edilmiştir. Oluşturulan 204x4'lük girdi matrisi ile 204x1'lik çıktı matrisi ile ağ yapısı oluşturulmuş, Matlab programı yapay sinir ağları eklentisi yardımıyla yapay sinir ağı modeline tabi tutulmuştur. Yapı oluşturulurken gizli nöron sayısının da belirlenmesi gerekmektedir. Bu çalışmada bölüm başında belirtildiği üzere deneme yanılma yöntemi dikkate alınmış, 1 gizli nöronun 10 gizli nörona kadar 10 değişik yapı kullanılmıştır. Yine bölüm başında da belirtildiği üzere değişkenlerin ilk 123 tanesi (%60) öğrenme, 20 tanesi (%10) doğrulama ve kalan 61 tanesi (%30) test aşaması için kullanılmıştır. Ağın eğitilmesi esnasında her bir gizli nöron sayısından oluşan yapının ilk 123 verisi öğrenme aşamasında kullanılmıştır. Öğrenme aşamasından sonra 124-143. sıradaki değişkenler doğrulama aşaması için kullanılmıştır. Her bir yapıda bu kısma denk gelen model çıktısı fiili çıktı ile karşılaştırılmış ve çıktının tahmin performansının ölçülmesi için karesel ortalama hata (RMSE) ve korelasyon katsayısı (R) yöntemleri ile kıyaslaması yapılmıştır. Örneğin anlatılan bu çalışma, 1 gizli nöron ile yapılan modeldeki sonuçlar üzerinden şu şekilde özetlenebilir.

1 gizli nöron ile yapılmış çalışmada doğrulama periyoduna denk gelen veri setinin 124-143. verileri için gerçek Türkiye enflasyon değeri ile modelin sonucunu belirten model çıktısı Türkiye enflasyon değeri sonucu tahminin performansını ölçmek için karşılaştırılmaktadır. Bu iki veri setinin karşılaştırması ile RMSE 0,0090, R ise 0,86 çıkmaktadır.

Nöron sayısı 1 den 10'a değiştirildiğinde her bir ağ yapısı için aynı yöntemler uygulanmış ve işlem sonucunda Tablo 4.7a'da yer alan sonuçlara ulaşılmıştır.

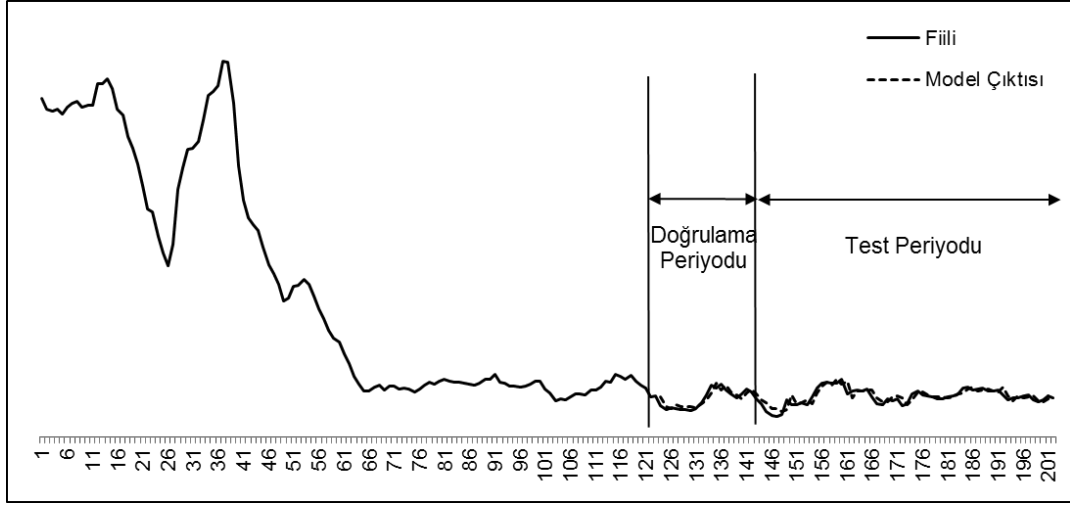
Tablo 4.7a: Türkiye Enflasyonu Tahmin Modellemesi - Farklı Gizli Nöronlara Ait Sonuç Tablosu

Gizli Nöron Sayısı	RMSE	R
1	0,0090	0,86
2	0,0086	0,87
3	0,0213	0,89
4	0,0099	0,83
5	0,0085	0,88
6	0,0111	0,85
7	0,0097	0,87
8	0,0097	0,85
9	0,0111	0,82
10	0,0145	0,89

Bu sonuçlara göre en düşük RMSE ve en yüksek R değerini veren yapay sinir ağı yapısı 5 gizli nöron ile oluşturulmuş yapı çıkmaktadır. 5 nöron ile oluşan sonuçlar Tablo 4.7b ve Şekil 4.7’de gösterilmiştir.

Tablo 4.7b: Türkiye Enflasyonu Tahmin Modellemesi – 5 Gizli Nörona Ait Fiili ve Model Çıktı Karşılaştırma Tablosu

Dönem	TR Enflasyon (fiili)	TR Enflasyon (model)
124	0,06130	0,07690
125	0,05240	0,05850
126	0,05730	0,05440
127	0,05390	0,06280
128	0,05330	0,05880
129	0,05270	0,05940
130	0,05080	0,05850
131	0,05530	0,05710
132	0,06530	0,06330
133	0,08190	0,07240
134	0,10130	0,08600
135	0,09560	0,10460
136	0,10190	0,09010
137	0,09100	0,09960
138	0,08370	0,08730
139	0,07580	0,08150
140	0,08330	0,07430
141	0,09240	0,08600
142	0,08620	0,09250
143	0,07290	0,08290
<b>RMSE</b>	<b>0,0085</b>	
<b>R</b>	<b>0,88</b>	



Şekil 4.7: Türkiye Enflasyonu Tahmin Modellemesi - 5 Gizli Nörona Ait Fiili ve Model Çıktılarının Grafikselsel Gösterimi

5 gizli nöronlu yapay sinir ağı yapısı ile oluşmuş modelin denenen tüm yapılar içerisinde tahmin performansının en iyi olduğu bulunduğundan sonra bu yapının test etme periyodu dönemindeki çıktıları ise çalışmada kullanılan DCF modelinin içerisine 2011-2015 yılı verileri olarak yerleştirilmiştir. Bu konu ile ilgili detay bölüm 4.8'de verilecektir.

#### 4.8. Yapay Sinir Ağları ile Bulunan Sonuçların DCF Modeline Aktarılması

Çalışma yöntemi Bölüm 2.3.1'de anlatılan ve Bölüm 4'de de araştırmaya konu olan şekilde hangi alt kırılımlardan oluştuğu ve bu alt kırılımlara ait verilerin nasıl oluştuğu üzerinde durulan DCF modeline, Bölüm 4.6 ve 4.7'de yapay sinir ağları tahmin modellemesi ile sonuçları paylaşılan USD/TRY döviz kuru ve Türkiye enflasyonu verileri eklenmiştir. DCF modelinde her bir döneme ait nakit akımı hesaplaması yapılırken o dönem içerisinde yurtdışına gerçekleştirilen satışlardan elde edilen döviz bazlı gelirler ile, çimento üretmek için gerekli olan hammadde, yakıt ve işletme malzemelerinin döviz bazlı satın alım fiyatlarından oluşan maliyetler ilgili para birimi cinsinden, yani USD/TRY döviz kuru ile Türk Lirası cinsinden hesaplanmıştır. Ayrıca Capex olarak adlandırılan yatırım maliyeti ve her dönem



gerçekleştirilmesi planlanan idame yatırımlarına ilişkin döviz bazlı giderler yine USD/TRY döviz kuru ile Türk Lirası cinsinden belirlenmiştir.

İlk döneme ait nakit akımı bulunduktan sonra her bir döneme ait nakit akımlarını hesaplarken aynı bazda hesaplamalar yapılmış, ancak hem gelirlerin hem maliyetlerin zaman içerisinde temel etkilendiği girdi olan enflasyon etkisi de eklenmiştir. Dolayısıyla nakit akımlarının projeksiyon döneminde oluşturulması esnasında, tüm diğer gerekli değişken ve varsayımlarla birlikte USD/TRY döviz kuru ve Türkiye enflasyonu kullanılmıştır.

Yapay sinir ağı yöntemi ile bulunan USD/TRY döviz kuru ve Türkiye enflasyonuna ait veriler Bölüm 4.6 ve 4.7’de aktarıldığı üzere 2011-2015 yıllarını kapsayan döneme ait aylık verilerdir. DCF modelinde ise bu zaman periyodu 20 çeyreklik dönem olarak değerlendirilmiştir. Dolayısıyla bulunan aylık veriler çeyreklik verilere dönüştürülmüştür. Örneğin USD/TRY döviz kuru verisine ait 2011 yılı Ocak, Şubat ve Mart ayına ait aylık ortalama verilerin ortalaması alınarak 2011 yılının ilk çeyreğine ait ortalama USD/TRY döviz kuru bulunmuştur. Zaten DCF modellemesine konu olan gelirler ve maliyetler gibi kalemlerin dönemin tek bir gününde değil, dönemin tamamında süregelen nakit akımları olduğunu düşündüğümüzde o dönemin ortalama verilerine ihtiyaç duyulmaktadır. Dolayısıyla aylık verilerin bu şekilde dönemlik ortalama verileri dönüştürülmesi tamamen nakit akım mantığı ile uyumaktadır.

Aynı şekildeki bir yöntem enflasyon verisi için de uygulanmıştır. Yapay sinir ağı yöntemi ile enflasyon tahmini yaparken kullanılan enflasyon serisi, bir önceki yılın aynı dönemine göre enflasyon değişimi verileridir. Bulunan her bir aya ait veri bir önceki yılın aynı ayına göre olan değişimi gösterdiğinden enflasyon endeksi oluşturulmuş ve bu endeks sayesinde kolaylıkla üç aylık dönemlere ait, yani DCF modelinde kullanılan çeyreklik dönemlere ait enflasyon değişimleri bulunmuştur. Bu şekilde bir önceki döneme göre enflasyon değişimi hesaplanmış ve modelde kullanılmıştır.

Bu yöntemlerle elde edilen veriler, 2011-2015 yılına ait 20 çeyrek dönemlik projeksiyon süresi ve artık değeri oluşturan nakit akımlarının oluşması için DCF modeline implemente edilmiştir. Oluşan nakit akım serisinin net bugünkü değerini

bulabilmek için ise şirket ekonomistleri tarafından kullanılan WACC değeri kullanılmış ve nakit akımları iskonto edilmiştir. Türkiye’de faaliyet gösteren ve borsaya açık olan çimento şirketlerine ait beta değerleri bulunarak bir sektör betası tespit edilmiş ve şirketin borçlanma maliyeti, borç/özkaynak oranı ve piyasa risk primi gibi verilerle WACC belirlenmiştir. Bu WACC değeri %13,5 tur.

WACC dışında model sonucunu etkileyen bir diğer girdi de nihai büyüme oranıdır. Bu oran artık değer hesaplamasında kullanılmaktadır. Artık değeri oluşturan dönem, bu çalışmaya söz konusu olan yatırım için 5. yıldan sonrası, nakit akımların artık stabil olduğu bir periyoda işaret ettiğinden genellikle kullanılan nihai büyüme oranı uzun vadeli enflasyon beklentisine eşittir. Modelde de tahmin edilen son yıl olan 5.yıla ait enflasyon beklentisi uzun vadeli enflasyon oranı olarak kabul edilmiş ve bu değer nihai büyüme oranı olarak dikkate alınmıştır. Yapay sinir ağı modeli sonucunda elde edilen çıktılar ile yapılan analizin sonucu olarak bu değer %8,6 olarak belirlenmiştir.

Yapay sinir ağı modeliyle tahmin edilen değişkenlerin DCF modeli içerisinde yer alması ile elde edilen nakit akımları, belirlenmiş olan WACC ile 2011 yılının başına iskonto edilmiştir. Ayrıca nihai büyüme oranı ve WACC ile artık değer bulunmuştur. Bu işlem sonucunda yatırımın net bugünkü değeri 434 milyon TL olarak hesaplanmıştır. Bu değer 1 Ocak 2011 yılının fiili USD/TRY döviz kuru olan 1,55 ile bölüldüğünde projenin net bugünkü değerinin ABD doları bazında değeri 279 milyon USD olmaktadır.

DCF analizi yapılırken ortaya çıkan nihai net bugünkü değer tek bir parasal büyüklükten oluşsa da analizin daha güvenilir sonuç vermesi adına duyarlılık analizinin modele eklenmesi ekonomik bir kabuldür. Çalışmada yapılan duyarlılık analizinde WACC +/- 0,25% ve nihai büyüme oranı +/- 0,2% oranında değiştirilmiş ve her biri için bir net bugünkü değer hesaplanmıştır. Duyarlılık analizi sonuçları aşağıda yer alan Tablo 4.8a’da gösterilmektedir.

Tablo 4.8a: Yapay Sınır Ağları Modeli ile Elde Edilen DCF'e Ait Duyarlılık Analizi Sonuçları

		WACC		
		13,25%	13,5%	13,75%
Nihai Büyüme Oranı	<i>mUSD</i>			
	8,8%	<b>298</b>	294	290
	8,6%	283	<b>279</b>	275
	8,4%	270	266	<b>262</b>

Elde edilen bu sonuçlara göre yatırıma ait net bugünkü değeri, orta değeri 279 milyon USD olmak üzere 262-298 milyon USD aralığındadır.

Yatırıma ait elde edilen nakit akımlarını analiz ederek hesaplanan IRR ise %24,4 olarak bulunmuştur.

Tablo 4.8b: Yapay Sınır Ağları Modeli ile Elde Edilen DCF'e Ait Değerleme Sonucu

Model	Net Bugünkü Değer		
	Orta Değer (mUSD)	Değer Aralığı (mUSD)	IRR
Yapay Sınır Ağları ile DCF	279	262-298	24,4%

## 4.9. Destek Vektör Regresyonu ile USD/TRY Döviz Kuru Tahmini

Destek vektör regresyonu kullanılarak USD/TRY döviz kuru tahmini yapılmıştır. Tahmin çalışmasında çıktı olarak USD/TRY döviz kuru dikkate alınırken doğal olarak yerel ekonomi Türkiye, yabancı ekonomi Amerika Birleşik Devletleri olmuştur. Girdi değişkenleri Verkooijen (1996) ve Weeren ve arkadaşları (1997)'nin çalışmalarında kullandığı üzere aşağıdaki şekilde belirlenmiştir.

- kısa dönemli faiz oranı
- M1 para arzı
- sanayi üretim endeksi

- tüketici fiyatlarındaki enflasyon değeri
- ticaret dengesi

Araştırmaya konu olan yatırım projesine ait 2011-2015 yılı arasındaki nakit akımları hesaplanacağından bu zaman periyodu çıktı dönemi olarak belirlenmiştir. Çalışmadaki data setine destek vektör regresyonu tahmin sürecinde öğrenme, doğrulama ve test etme aşamalarının uygulanması gerekmektedir. 2011-2015 arasındaki döneme ait çıktıların destek vektör regresyonu tarafından öğrenilmiş yapının test etme aşamasına denk gelen kısımları kullanılacaktır. Test etme periyodu literatür göz önünde bulundurularak tüm data setininin %30'u olarak belirlenmiştir. Dolayısıyla tüm data setinin bu oranı karşılayabilmesi için 1999 yılından başlaması gerektiği belirlenmiştir. Bu sebepten 1999-2015 yılları arasındaki 17 yıla ait ay bazındaki veriler her bir değişken için sıralı 204 veriden oluşmaktadır. Bu 204 verinin %60'ı öğrenme, %10'u doğrulama, %30'u da test etme aşamalarında kullanılmıştır. Dolayısıyla bu verilerin 123 tanesi (%60) öğrenme, 20 tanesi (%10) doğrulama ve kalan 61 tanesi (%30) test aşaması için kullanılmıştır. Söz konusu değişkenlerin bu dönemdeki gerçekleştirmeleri Türkiye İstatistik Kurumu (TÜİK) ve ABD Ekonomik Analiz Bürosu (BEA) veritabanlarından elde edilmiştir.

Hazırlanan bu veri seti 5 değişkene ait 204 adet sıralı veriden oluşan 204x5'lik bir matris yapıyı oluşturmaktadır. Aynı şekilde çıktı değişkene ait 204x1'lik bir değişken seti de veri setinin output kısmını oluşturmaktadır. Girdi veri setinin 123x5'lik ilk kısmı öğrenme setini oluştururken doğrulama ve test periyodunu içeren 81x5'lik bir ikinci veri seti oluşturulmuştur. Aynı şekilde bu zaman dilimlerine denk gelecek şekilde çıktı verileri de 123x1 ve 81x1'lik iki kümeye bölünmüştür. Bu veri seti Matlab programı için oluşturulmuş LSSVMLab Toolbox'ı yardımıyla destek vektör regresyonu modellemesine tabi tutulmuştur.

Modelleme için uygun yapının oluşturulmasındaki en kritik aşamalardan biri  $\sigma$  ve  $\gamma$  parametrelerinin belirlenmesidir. İncelenen çalışmaların tamamına yakınında bu parametreler crossvalidation yöntemi ile (Liu ve Wang, 2008; Samui, 2011; Samui ve Sitharam, 2009; Samsudin ve ark, 2011) bulunmaktadır. Yani  $\sigma$  ve  $\gamma$  için üst aralık limiti belirlenmekte ve LSSVMLab toolbox yardımıyla optimum  $\sigma$  ve  $\gamma$  değeri bulunmaktadır. Buna ek olarak yine üst limitlerin belirlenmesi esnasında birden fazla

çalışmada kullanılan trial and error yaklaşımı uygulanmış ve aralıkların limitleri değiştirilerek model çalıştırılmıştır.

İlk olarak  $\gamma$  için 1 ve 10.000 aralığı belirlenmiş  $\sigma^2$  için ise 0,01 alt aralığı belirlenmiş, üst aralık ise 1 den 100 e artırılarak her bir değer için optimum  $\sigma$  ve  $\gamma$  değerleri bulunmuştur. Daha sonra benzer şekilde  $\gamma$  için üst aralık 1.000 ile 10.000 arasında değiştirilmiştir. Son olarak alt limitler  $\gamma$  ve  $\sigma^2$  için 0,1 ve 0,001 olarak değiştirilerek hesaplama yapılmıştır.

Modele esas oluşturacak girdi ve çıktı setinin oluşturulması aşamasında Bölüm 4.6 ve 4.7 de anlatılan yapay sinir ağı modeli ile yapılan hesaplamalarda olduğu gibi aynı uygulama yapılmıştır. Hatırlatmak gerekirse, USD/TRY döviz kuru tahmininin çıktı kısmı için yerel ekonomi Türkiye, yabancı ekonomi Amerika Birleşik Devletleri alındığı için USD/TRY döviz kurunun seçilen dönemdeki her bir verisine ait logaritmik değer alınarak 204x1 lik fiili çıktı seti oluşturulmuştur. Yani, örneğin 204 verinin zaman açısından ilk verisi olan 1999 yılı Ocak ayı USD/TRY döviz kuru fiili verisi 0,33148 olduğu için bu verinin logaritmik değeri olan  $\ln(0,33148) = -1,1042$  çıktı veri setinin ilk değeri olmuştur.

Çıktı matrisinin ardından girdilerden oluşturulan 204x5 lik yapı şu şekilde oluşturulmuştur. İlk olarak, kısa dönemli faiz oranı için Türkiye aylık Libor faiz oranı ile ABD aylık Libor faiz oranları kullanılmış, yerel ekonomi Türkiye, yabancı ekonomi Amerika Birleşik Devletleri alındığı için Türkiye kısa dönemli faiz oranı ile ABD kısa dönemli faiz oranının her bir dönem için farkı bulunarak veri seti oluşturulmuştur. Örneğin, veri setinin ilk dönemi olan 1999 yılı Ocak ayı Türkiye aylık Libor faiz oranı %72,0 iken ABD aylık Libor faiz oranı %4,979 olarak gerçekleştiği için bu oranlar arasındaki fark girdi veri setini oluşturan ilk değer olmuştur.

İkinci değişken olarak M1 para arzı kullanılmıştır. Türkiye M1 para arzı miktarı ile ABD M1 para arzı miktarlarının logaritmik değerleri bulunmuş ve bu logaritmik değerler arasındaki fark girdi veri setini oluşturan değer olmuştur. Örneğin, veri setinin ilk dönemi olan 1999 yılı Ocak ayı Türkiye M1 para arzı miktarı parasal büyüklük olarak 2,38586 milyar dolar ABD M1 Para arzı 1.103,9 milyar dolar olarak gerçekleşmiştir. Öncelikle bu her iki miktarın logaritmik

değerleri bulunmuş ve bulunan logaritmik değerlerin farkı alınırken yerel ekonomi Türkiye, yabancı ekonomi Amerika Birleşik Devletleri alındığı için Türkiye M1 değerinden ABD M1 değeri çıkarılmıştır. Bulunan değer girdi veri setinin M1 kısmını oluşturan ilk değer olmuştur.

Üçüncü değişken olarak sanayi üretim endeksi kullanılmıştır. Türkiye sanayi üretim endeksi değeri ile ABD sanayi üretim endeksi değerinin logaritmik değerleri bulunmuş ve bu logaritmik değerler arasındaki fark girdi veri setini oluşturan değer olmuştur. Örneğin, veri setinin ilk dönemi olan 1999 yılı Ocak ayı Türkiye sanayi üretim endeksi değeri 51,2378, ABD sanayi üretim endeksi değeri 90,3455 olarak gerçekleşmiştir. Öncelikle bu her iki rakamın logaritmik değerleri bulunmuş ve bulunan logaritmik değerlerin farkı alınırken yerel ekonomi Türkiye, yabancı ekonomi Amerika Birleşik Devletleri alındığı için Türkiye sanayi üretim endeksi değerinden ABD sanayi üretim endeksi değeri çıkarılmıştır. Bulunan değer girdi veri setinin sanayi üretim endeksi kısmını oluşturan ilk değer olmuştur.

Dördüncü değişken olarak tüketici fiyatlarındaki enflasyon değeri (TÜFE) kullanılmıştır. Türkiye TÜFE değeri ile ABD TÜFE değerinin farkı girdi veri setini oluşturan değer olmuştur. Örneğin, veri setinin ilk dönemi olan 1999 yılı Ocak ayı Türkiye TÜFE değeri %65,90 iken ABD TÜFE'si %1,7 olarak gerçekleşmiştir. Bu değerlerin farkı alınırken yerel ekonomi Türkiye, yabancı ekonomi Amerika Birleşik Devletleri alındığı için Türkiye TÜFE değerinden ABD TÜFE değeri çıkarılmıştır. Bulunan değer girdi veri setinin enflasyon kısmını oluşturan ilk değer olmuştur.

Beşinci değişken olarak ticaret dengesi (trade balance) kullanılmıştır. Türkiye ticaret dengesi miktarı ile ABD ticaret dengesi miktarının logaritmik değerleri bulunmuş ve bu logaritmik değerler arasındaki fark girdi veri setini oluşturan değer olmuştur. Örneğin, veri setinin ilk dönemi olan 1999 yılı Ocak ayı Türkiye ticaret dengesi 343,195 milyon dolar iken, ABD ticaret dengesi 15.946 milyon dolar olarak gerçekleşmiştir. Öncelikle bu her iki miktarın logaritmik değerleri bulunmuş ve bulunan logaritmik değerlerin farkı alınırken yerel ekonomi Türkiye, yabancı ekonomi Amerika Birleşik Devletleri alındığı için Türkiye ticaret dengesi değerinden ABD ticaret dengesi değeri çıkarılmıştır. Bulunan değer girdi veri setinin ticaret dengesi kısmını oluşturan ilk değer olmuştur.

Her bir deęişkene bu işlem uygulandıktan sonra 204 aylık dönem sonucunda 204x5 lik bir matris elde edilmiştir. Oluşturulan 204x5'lik girdi matrisi ile 204x1'lik çıktı matrisi ile model yapısı oluşturulmuş, Matlab programı için uyarlanan LSSVMLab Toolbox eklentisi yardımıyla destek vektör regresyonuna tabi tutulmuştur. Yapı oluşturulurken bölüm başında belirtildiği üzere parametrelerin üst limitleri için deneme yanılma yöntemi dikkate alınmış, bulunan optimum  $\gamma$  ve  $\sigma^2$  lar ile 50 deęişik yapı kullanılmıştır. Yine bölüm başında da belirtildiği üzere deęişkenlerin ilk 123 tanesi (%60) öğrenme, 20 tanesi (%10) doğrulama ve kalan 61 tanesi (%30) test aşaması için kullanılmıştır. Yapının eğitilmesi esnasında her bir  $\gamma$  ve  $\sigma^2$  aralığı ve bulunan optimum  $\gamma$  ve  $\sigma^2$  lar ile ilk 123 veri, öğrenme aşamasında kullanılmıştır. Öğrenme aşamasından sonra 124-143. sıradaki deęişkenler doğrulama aşaması için kullanılmıştır. Her bir yapıda bu kısma denk gelen model çıktısı fiili çıktı ile karşılaştırılmış ve çıktının tahmin performansının ölçülmesi için karesel ortalama hata (RMSE) ve korelasyon katsayısı (R) yöntemleri ile kıyaslaması yapılmıştır.

1. denemede  $\gamma$  ve  $\sigma^2$  için belirlenmiş aralıklar ile bulunan optimum  $\gamma$  ve  $\sigma^2$  ile yapılan çalışmada doğrulama periyoduna denk gelen veri setinin 124-143. verileri için gerçek USD/TRY döviz kuru deęeri ile modelin sonucunu belirten model çıktı USD/TRY döviz kuru sonucu tahminin performansını ölçmek için karşılaştırılmaktadır. Bu çalışmanın 1.denemesinde kullanılan  $\gamma = [1,10.000]$  ve  $\sigma^2 = [0,01, 5]$  aralığında bulunan optimum  $\gamma = 213,62$  ve  $\sigma^2 = 10,22$  deęerleri ile yapılan çalışma sonucunda çıkan deęerler ile fiili veri setinin karşılaştırılması belirtilmiştir. Bu iki veri setinin karşılaştırması ile RMSE 0,3928, R ise 0,41 çıkmaktadır.

$\gamma$  ve  $\sigma^2$  aralıkları deęiştirildiğinde ve bulunan optimum  $\gamma$  ve  $\sigma^2$  deęerleri ile her bir yapı için aynı yöntemler uygulanmış ve işlem sonucunda Tablo 4.9a'da yer alan sonuçlara ulaşılmıştır.

Tablo 4.9a: USD/TRY Döviz Kuru Tahmin Modellemesi - Farklı  $\gamma$  ve  $\sigma^2$  Aralıkları İçin Bulunan Optimum  $\gamma$  ve  $\sigma^2$ ler ile Yapılmış Çalışmaya Ait Sonuç Tablosu

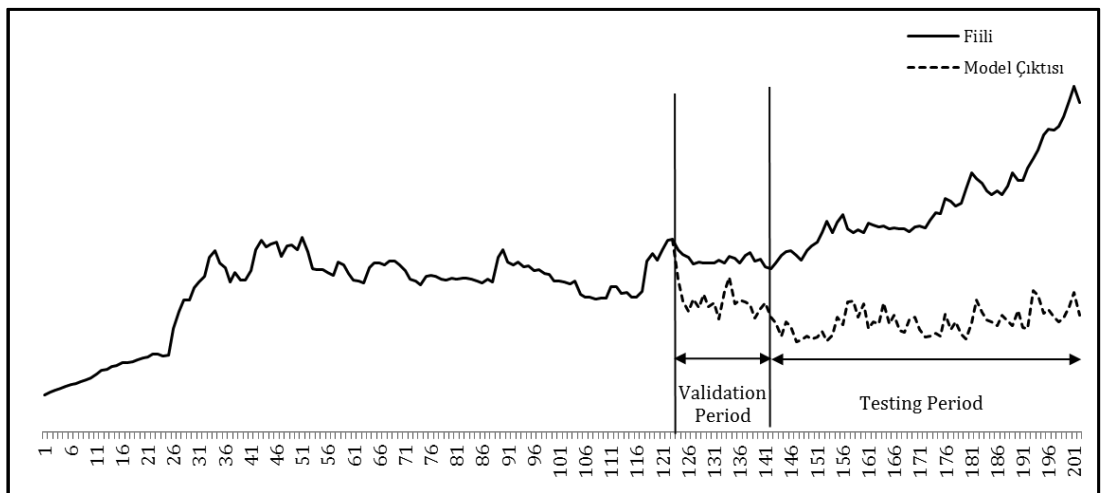
Deneme	RMSE	R	Deneme	RMSE	R
1	0,3928	0,406	26	0,3985	0,409
2	0,3969	0,409	27	0,4028	0,411
3	0,3995	0,409	28	0,4003	0,410
4	0,4001	0,410	29	0,3969	0,409
5	0,3986	0,410	30	0,4162	0,404
6	0,3963	0,409	31	0,3973	0,412
7	0,3922	0,406	32	0,4004	0,410
8	0,3970	0,409	33	0,3957	0,407
9	0,3919	0,407	34	0,3939	0,407
10	0,3952	0,409	35	0,3982	0,409
11	0,3990	0,410	36	0,3932	0,406
12	0,3951	0,407	37	0,3982	0,410
13	0,3957	0,409	38	0,3947	0,408
14	0,3952	0,408	39	0,4016	0,411
15	0,3966	0,408	40	0,3991	0,410
16	0,3952	0,407	41	0,3940	0,411
17	0,3990	0,410	42	0,3998	0,430
18	0,4012	0,410	43	0,4035	0,412
19	0,4033	0,411	44	0,4048	0,418
20	0,3936	0,407	45	0,3966	0,418
21	0,3957	0,408	46	0,3939	0,433
22	0,3957	0,409	47	0,3978	0,402
23	0,3923	0,406	48	0,4001	0,410
24	0,4000	0,409	49	0,3908	0,404
25	0,3946	0,408	50	0,4107	0,407

Bu sonuçlara göre en düşük RMSE ve en yüksek R değerini veren yapıda  $\gamma$  ve  $\sigma^2$  değerleri 154,97 ve 8,60'dır ve bu yapı modellenmiş olan 9. denemeye denk gelmektedir. Bu çalışmaya ait sonuçlar Tablo 4.9b ve Şekil 4.9'da gösterilmiştir.



Tablo 4.9b: USD/TRY Döviz Kuru Tahmin Modellemesi –  $\gamma = 154,97$  ve  $\sigma^2 = 8,60$  Ait Fiili ve Model Çıktı Karşılaştırma Tablosu

Dönem	USD/TRY (fiili)	USD/TRY (model)
124	1,60448	1,34953
125	1,56972	1,15297
126	1,53757	1,06353
127	1,48409	1,17689
128	1,49720	1,10174
129	1,48914	1,21759
130	1,48944	1,11015
131	1,48974	1,13706
132	1,51301	0,99782
133	1,49227	1,23576
134	1,54744	1,36097
135	1,52883	1,12932
136	1,48750	1,16108
137	1,55893	1,14929
138	1,58233	1,12513
139	1,51044	1,00902
140	1,52409	1,08749
141	1,45820	1,13957
142	1,43706	1,01306
143	1,49347	0,96154
<b>RMSE</b>	<b>0,3919</b>	
<b>R</b>	<b>0,41</b>	



Şekil 4.9: USD/TRY Döviz Kuru Tahmin Modellemesi –  $\gamma = 154,97$  ve  $\sigma^2 = 8,60$  Ait Fiili ve Model Çıktılarının Grafikselsel Gösterimi

Ancak sonuçlardan ve grafikten de görüleceği üzere ilerleyen dönemler için elde edilen çıktılar uygun sonuç vermemiştir. Doğrulama periyodundaki RMSE ve R değerleri de başarılı sonuç veren modellerden oldukça uzak sonuçlar vermiştir. Ancak yine de karşılaştırma için bu değerler ile bulunmuş yapının test etme periyodu dönemindeki çıktıları çalışmada kullanılan DCF modelinin içerisine 2011-2015 yılı verileri olarak yerleştirilmiştir. Bu konu ile ilgili detay bölüm 4.11’de verilecektir.

## **4.10. Destek Vektör Regresyonu ile Türkiye Enflasyonu Tahmini**

Çalışmada USD/TRY döviz kuru kuru tahmininin yanı sıra destek vektör regresyonu kullanılarak Türkiye enflasyonu (TÜFE) yapılmıştır. Tahmin çalışmasında çıktı değişkeni olarak Türkiye enflasyon oranı dikkate alınırken girdi değişkenleri Cecchetti (1992)’nin çalışmasında belirttiği şekilde kullanılmıştır:

- kısa dönemli faiz oranı
- M1 para stoklarının büyüme oranı
- M2 para stoklarının büyüme oranı
- sanayi üretim endeksi

Araştırmaya konu olan yatırım projesine ait 2011-2015 yılı arasındaki nakit akımları hesaplanacağından bu zaman periyodu çıktı dönemi olarak belirlenmiştir. Çalışmadaki data setine destek vektör regresyonu tahmin sürecinde öğrenme, doğrulama ve test etme aşamalarının uygulanması gerekmektedir. 2011-2015 arasındaki döneme ait çıktıların destek vektör regresyonu modeli tarafından öğrenilmiş yapının test etme aşamasına denk gelen kısımları kullanılacaktır. Test etme periyodu literatür göz önünde bulundurularak tüm data setininin %30’u olarak belirlenmiştir. Dolayısıyla tüm data setinin bu oranı karşılayabilmesi için 1999 yılından başlaması gerektiği belirlenmiştir. Bu sebepten 1999-2015 yılları arasındaki 17 yıla ait ay bazındaki veriler her bir değişken için sıralı 204 veriden oluşmaktadır. Bu 204 verinin %60’ı öğrenme, %10’u doğrulama, %30’u da test etme aşamalarında kullanılmıştır. Dolayısıyla bu verilerin 123 tanesi (%60) öğrenme, 20 tanesi (%10) doğrulama ve kalan 61 tanesi (%30) test aşaması için kullanılmıştır. Söz konusu

değişkenlerin bu dönemdeki gerçekleştirmeleri Türkiye İstatistik Kurumu (TÜİK) ve ABD Ekonomik Analiz Bürosu (BEA) veritabanlarından elde edilmiştir.

Hazırlanan bu veri seti 4 değişkene ait 204 adet sıralı veriden oluşan 204x4'lük bir matris yapıyı oluşturmaktadır. Aynı şekilde çıktı değişkene ait 204x1'lik bir değişken seti de veri setinin output kısmını oluşturmaktadır. Girdi veri setinin 123x4'lük ilk kısmı öğrenme setini oluştururken doğrulama ve test periyodunu içeren 81x4'lük bir ikinci veri seti oluşturulmuştur. Aynı şekilde bu zaman dilimlerine denk gelecek şekilde çıktı verileri de 123x1 ve 81x1'lik iki kümeye bölünmüştür. Bu veri seti Matlab programı için oluşturulmuş LSSVMLab Toolbox'ı yardımıyla destek vektör regresyonu modellenmesine tabi tutulmuştur.

Modelleme için uygun yapının oluşturulmasındaki en kritik aşamalardan biri  $\sigma$  ve  $\gamma$  parametrelerinin belirlenmesidir. İncelenen çalışmaların tamamına yakınında bu parametreler crossvalidation yöntemi ile bulunmaktadır (Liu ve Wang, 2008; Samui, 2011; Samui ve Sitharam, 2009; Samsudin ve ark, 2011). Yani  $\sigma$  ve  $\gamma$  için üst aralık limiti belirlenmekte ve LSSVMLab toolbox yardımıyla optimum  $\sigma$  ve  $\gamma$  değeri bulunmaktadır. Buna ek olarak yine üst limitlerin belirlenmesi esnasında birden fazla çalışmada kullanılan trial and error yaklaşımı uygulanmış ve aralıkların limitleri değiştirilerek model çalıştırılmıştır.

İlk olarak  $\gamma$  için 1 ve 10.000 aralığı belirlenmiş  $\sigma^2$  için ise 0,01 alt aralığı belirlenmiş, üst aralık ise 1 den 100 e artırılarak her bir değer için optimum  $\sigma$  ve  $\gamma$  değerleri bulunmuştur. Daha sonra benzer şekilde  $\gamma$  için üst aralık 1 ile 10.000 arasında değiştirilmiştir. Son olarak alt limitler  $\gamma$  ve  $\sigma^2$  için 0,1 ve 0,001 olarak değiştirilmiş  $\gamma$  için üst aralık 1 ile 100,  $\sigma^2$  için ise 0,1 ve 10 olarak belirlenerek hesaplamalar yapılmıştır.

Modele esas oluşturacak girdi ve çıktı setinin oluşturulması aşamasında Bölüm 4.6 ve 4.7'de anlatılan yapay sinir ağı modeli ile yapılan hesaplamalarda olduğu gibi aynı uygulama yapılmıştır. Hatırlatmak gerekirse, enflasyon oranı tahmininin çıktı kısmı için Türkiye enflasyon oranı (TÜFE) dikkate alınarak 204x1'lik fiili çıktı seti oluşturulmuştur. Aylık veriler kullanıldığı için her dönem için önceki yılın aynı ayına göre olan değişim kullanılmıştır. Örneğin 204 verinin

zaman açısından ilk verisi olan 1999 yılı Ocak ayı enflasyon verisi %65,90 olduğu için girdi veri setini oluşturan ilk değer olmuştur.

Çıktı matrisinin ardından girdilerden oluşturulan 204x4'lük yapı şu şekilde oluşturulmuştur. İlk olarak, kısa dönemli faiz oranı için Türkiye aylık Libor faiz oranı kullanılmıştır. Örneğin, veri setinin ilk dönemi olan 1999 yılı Ocak ayı Türkiye aylık Libor faiz oranı %72,0 olduğu için girdi veri setini oluşturan ilk değer olmuştur.

İkinci değişken olarak M1 para stoklarının büyüme oranı kullanılmıştır. Türkiye M1 para stoğu büyüme oranı girdi veri setini oluşturan değer olmuştur. Örneğin, veri setinin ilk dönemi olan 1999 yılı Ocak ayı Türkiye M1 para stoğu büyüme oranı %-6,89 olarak gerçekleşmiştir. Bu değer girdi veri setinin M1 para stoğu büyüme oranı kısmını oluşturan ilk değer olmuştur.

Üçüncü değişken olarak M2 para stoklarının büyüme oranı kullanılmıştır. Türkiye M2 para stoğu büyüme oranı girdi veri setini oluşturan değer olmuştur. Örneğin, veri setinin ilk dönemi olan 1999 yılı Ocak ayı Türkiye M2 para stoğu büyüme oranı %2,59 olarak gerçekleşmiştir. Bu değer girdi veri setinin M2 para stoğu büyüme oranı kısmını oluşturan ilk değer olmuştur.

Dördüncü değişken olarak sanayi üretim endeksi kullanılmıştır. Türkiye sanayi üretim endeksi değerinin logaritmik değeri bulunmuş ve bu logaritmik değer girdi veri setini oluşturan değer olmuştur. Örneğin, veri setinin ilk dönemi olan 1999 yılı Ocak ayı Türkiye sanayi üretim endeksi değeri 51,2378 olarak gerçekleşmiştir. Bu verinin logaritmik değeri olan 3,9365 girdi veri setinin sanayi üretim endeksi kısmını oluşturan ilk değer olmuştur.

Her bir değişkene bu işlem uygulandıktan sonra 204 aylık dönem sonucunda 204x4'lük bir matris elde edilmiştir. Oluşturulan 204x4'lük girdi matrisi ile 204x1'lik çıktı matrisi ile model yapısı oluşturulmuş, Matlab programı için uyarlanan LSSVMLab Toolbox eklentisi yardımıyla destek vektör regresyonuna tabi tutulmuştur. Yapı oluşturulurken bölüm başında belirtildiği üzere parametrelerin üst limitleri için deneme yanılma yöntemi dikkate alınmış, bulunan optimum  $\gamma$  ve  $\sigma^2$  lar ile 51 değişik yapı kullanılmıştır. Yine bölüm başında da belirtildiği üzere değişkenlerin ilk 123 tanesi (%60) öğrenme, 20 tanesi (%10) doğrulama ve kalan 61

tanesi (%30) test aşaması için kullanılmıştır. Yapının eğitilmesi esnasında her bir  $\gamma$  ve  $\sigma^2$  aralığı ve bulunan optimum  $\gamma$  ve  $\sigma^2$  lar ile ilk 123 veri, öğrenme aşamasında kullanılmıştır. Öğrenme aşamasından sonra 124-143. sıradaki değişkenler doğrulama aşaması için kullanılmıştır. Her bir yapıda bu kısma denk gelen model çıktısı fiili çıktı ile karşılaştırılmış ve çıktının tahmin performansının ölçülmesi için karesel ortalama hata (RMSE) ve korelasyon katsayısı (R) yöntemleri ile kıyaslaması yapılmıştır.

$\gamma$  ve  $\sigma^2$  için belirlenmiş aralıklar ile bulunan optimum  $\gamma$  ve  $\sigma^2$  ile yapılan çalışmada doğrulama periyoduna denk gelen veri setinin 124-143. verileri için gerçek Türkiye enflasyonu değeri ile modelin sonucunu belirten model çıktı Türkiye enflasyonu sonucu tahminin performansını ölçmek için karşılaştırılmaktadır. Örnek olarak, çalışmanın 1.denemesinde kullanılan  $\gamma = [1,10.000]$  ve  $\sigma^2 = [0,01, 5]$  aralığında bulunan optimum  $\gamma = 3,28$  ve  $\sigma^2 = 2,26$  değerleri ile yapılan çalışma sonucunda çıkan değerler ile fiili veri setinin karşılaştırılması belirtilmiştir. Bu iki veri setinin karşılaştırması ile RMSE 0,045, R ise 0,39 çıkmaktadır.

$\gamma$  ve  $\sigma^2$  aralıkları değiştirildiğinde ve bulunan optimum  $\gamma$  ve  $\sigma^2$  değerleri ile her bir yapı için aynı yöntemler uygulanmış ve işlem sonucunda Tablo 4.10a'de yer alan sonuçlara ulaşılmıştır.

Tablo 4.10a: Türkiye Enflasyonu Tahmin Modellemesi – Farklı  $\gamma$  ve  $\sigma^2$  Aralıkları İçin Bulunan Optimum  $\gamma$  ve  $\sigma^2$ ler ile Yapılmış Çalışmaya Ait Sonuç Tablosu


Deneme	RMSE	R	Deneme	RMSE	R
1	0,0448	0,392	26	0,0469	0,416
2	0,0453	0,399	27	0,0443	0,375
3	0,0477	0,415	28	0,0445	0,381
4	0,0434	0,389	29	0,0472	0,416
5	0,0445	0,401	30	0,0474	0,382
6	0,0473	0,408	31	0,0455	0,402
7	0,0441	0,385	32	0,0456	0,399
8	0,0469	0,415	33	0,0437	0,389
9	0,0457	0,385	34	0,0427	0,388
10	0,0481	0,418	35	0,0458	0,400
11	0,0464	0,409	36	0,0455	0,394
12	0,0445	0,401	37	0,0472	0,409
13	0,0483	0,417	38	0,0474	0,407
14	0,0479	0,414	39	0,0462	0,400
15	0,0458	0,404	40	0,0437	0,390
16	0,0447	0,397	41	0,1902	0,294
17	0,0440	0,395	42	0,0753	0,321
18	0,0430	0,391	43	0,0510	0,432
19	0,0474	0,417	44	0,0446	0,399
20	0,0466	0,413	45	0,0457	0,401
21	0,0466	0,413	46	0,0439	0,389
22	0,0466	0,414	47	0,0439	0,387
23	0,0466	0,414	48	0,0448	0,396
24	0,0468	0,414	49	0,0437	0,388
25	0,0468	0,415	50	0,0431	0,379
			51	0,0448	0,398

Bu sonuçlara göre en düşük RMSE ve en yüksek R değerini veren yapıda  $\gamma$  ve  $\sigma^2$  değerleri 2,90 ve 2,45'dir ve bu yapı modellenmiş olan 34. denemeye denk gelmektedir. Bu çalışmaya ait sonuçlar Tablo 4.10b ve Şekil 4.10'da gösterilmiştir.

Tablo 4.10b: Türkiye Enflasyonu Tahmin Modellemesi –  $\gamma = 2,90$  ve  $\sigma^2 = 2,45$

Ait Fiili ve Model Çıktı Karşılaştırma Tablosu

Dönem	Türkiye Enflasyonu (fiili)	Türkiye Enflasyonu (model)
124	0,06130	0,11421
125	0,05240	0,08374
126	0,05730	0,09508
127	0,05390	0,10169
128	0,05330	0,09145
129	0,05270	0,08673
130	0,05080	0,12794
131	0,05530	0,09642
132	0,06530	0,12173
133	0,08190	0,10558
134	0,10130	0,08367
135	0,09560	0,12047
136	0,10190	0,12006
137	0,09100	0,12445
138	0,08370	0,13035
139	0,07580	0,13274
140	0,08330	0,12187
141	0,09240	0,11226
142	0,08620	0,13997
143	0,07290	0,12222
<b>RMSE</b>	<b>0,0427</b>	
<b>R</b>	<b>0,39</b>	



Şekil 4.10: Türkiye Enflasyonu Tahmin Modellemesi –  $\gamma = 2,90$  ve  $\sigma^2 = 2,45$

Ait Fiili ve Model Çıktılarının Grafikselsel Gösterimi

Ancak sonuçlardan ve grafikten de görüleceği üzere ilerleyen dönemler için elde edilen çıktılar uygun sonuç vermemiştir. Doğrulama periyodundaki RMSE ve R değerleri de başarılı sonuç veren modellerden oldukça uzak sonuçlar vermiştir. Ancak yine de karşılaştırma için bu değerler ile bulunmuş yapının test etme periyodu dönemindeki çıktıları çalışmada kullanılan DCF modelinin içerisine 2011-2015 yılı verileri olarak yerleştirilmiştir. Bu konu ile ilgili detay bölüm 4.11’de verilecektir.

#### **4.11. Destek Vektör Regresyonu ile Bulunan Sonuçların DCF Modeline Aktarılması**

Çalışma yöntemi Bölüm 2.3.1’de anlatılan ve Bölüm 4’de de araştırmaya konu olan şekliyle hangi alt kısıtlımlardan oluştuğu ve bu alt kısıtlımlara ait verilerin nasıl oluştuğu üzerinde durulan DCF modeline Bölüm 4.9 ve 4.10’da destek vektör regresyonu tahmin modellemesi ile sonuçları paylaşılan USD/TRY döviz kuru ve Türkiye enflasyonu verileri eklenmiştir. DCF modelinde her bir döneme ait nakit akımı hesaplaması yapılırken o dönem içerisinde yurtdışına gerçekleştirilen satışlardan elde edilen döviz bazlı gelirler ile, çimento üretmek için gerekli olan hammadde, yakıt ve işletme malzemelerinin döviz bazlı satın alım fiyatlarından oluşan maliyetler ilgili para birimi cinsinden, yani USD/TRY döviz kuru ile Türk Lirası cinsinden hesaplanmıştır. Ayrıca Capex olarak adlandırılan yatırım maliyeti ve her dönem gerçekleştirilmesi planlanan idame yatırımlarına ilişkin döviz bazlı giderler yine USD/TRY döviz kuru ile Türk Lirası cinsinden belirlenmiştir.

İlk döneme ait nakit akımı bulunduktan sonra her bir döneme ait nakit akımlarını hesaplarken aynı bazda hesaplamalar yapılmış, ancak hem gelirlerin hem maliyetlerin zaman içerisinde temel etkilendiği girdi olan enflasyon etkisi de eklenmiştir. Dolayısıyla nakit akımlarının projeksiyon döneminde oluşturulması esnasında, tüm diğer gerekli değişken ve varsayımlarla birlikte USD/TRY döviz kuru ve Türkiye enflasyonu kullanılmıştır.

Destek vektör regresyonu yöntemi ile bulunan USD/TRY döviz kuru ve Türkiye enflasyonuna ait veriler Bölüm 4.9 ve 4.10’da aktarıldığı üzere 2011-2015 yıllarını kapsayan döneme ait aylık verilerdir. DCF modelinde ise bu zaman periyodu 20 çeyreklik dönem olarak değerlendirilmiştir. Dolayısıyla bulunan aylık veriler çeyreklik verilere dönüştürülmüştür. Örneğin USD/TRY döviz kuru verisine ait 2011



yılı Ocak, Şubat ve Mart ayına ait aylık ortalama verilerin ortalaması alınarak 2011 yılının ilk çeyreğine ait ortalama USD/TRY döviz kuru bulunmuştur. Zaten DCF modellemesine konu olan gelirler ve maliyetler gibi kalemlerin dönemin tek bir gününde değil, dönemin tamamında süregelen nakit akımları olduğunu düşündüğümüzde o dönemin ortalama verilerine ihtiyaç duyulmaktadır. Dolayısıyla aylık verilerin bu şekilde dönemlik ortalama verileri dönüştürülmesi tamamen nakit akım mantığı ile uyusmaktadır.

Aynı şekildeki bir yöntem enflasyon verisi için de uygulanmıştır. Destek vektör regresyonu yöntemi ile enflasyon tahmini yaparken kullanılan enflasyon serisi, bir önceki yılın aynı dönemine göre enflasyon değişimi verileridir. Bulunan her bir aya ait veri bir önceki yılın aynı ayına göre olan değişimi gösterdiğinden enflasyon endeksi oluşturulmuş ve bu endeks sayesinde kolaylıkla üç aylık dönemlere ait, yani DCF modelinde kullanılan çeyreklik dönemlere ait enflasyon değişimleri bulunmuştur. Bu şekilde bir önceki döneme göre enflasyon değişimi hesaplanmış ve modelde kullanılmıştır.

Bu yöntemlerle elde edilen veriler, 2011-2015 yılına ait 20 çeyrek dönemlik projeksiyon süresi ve artık değeri oluşturan nakit akımlarının oluşması için DCF modeline implemente edilmiştir. Oluşan nakit akım serisinin net bugünkü değerini bulabilmek için ise şirket ekonomistleri tarafından kullanılan WACC değeri kullanılmış ve nakit akımları iskonto edilmiştir. Türkiye’de faaliyet gösteren ve borsaya açık olan çimento şirketlerine ait beta değerleri bulunarak bir sektör betası tespit edilmiş ve şirketin borçlanma maliyeti, borç/özkaynak oranı ve piyasa risk primi gibi verilerle WACC belirlenmiştir. Bu WACC değeri %13,5 tur.

WACC dışında model sonucunu etkileyen bir diğer girdi de nihai büyüme oranıdır. Bu oran artık değer hesaplamasında kullanılmaktadır. Artık değeri oluşturan dönem, bu çalışmaya söz konusu olan yatırım için 5. yıldan sonrası, nakit akımların artık stabil olduğu bir periyoda işaret ettiğinden genellikle kullanılan nihai büyüme oranı uzun vadeli enflasyon beklentisine eşittir. Modelde de tahmin edilen son yıl olan 5.yıla ait enflasyon beklentisi uzun vadeli enflasyon oranı olarak kabul edilmiş ve bu değer nihai büyüme oranı olarak dikkate alınmıştır. Destek vektör regresyonu modeli sonucunda elde edilen çıktılar ile yapılan analizin sonucu olarak bu değer %22,2 olarak belirlenmiştir.

Destek vektör regresyonu metoduyla tahmin edilen değişkenlerin DCF modeli içerisinde yer alması ile elde edilen nakit akımları, belirlenmiş olan WACC ile 2011 yılının başına iskonto edilmiştir. Ayrıca nihai büyüme oranı ve WACC ile artık değer bulunmuştur. Bu işlem sonucunda yatırımın net bugünkü değeri anlamsız bir sonuç olan pozitif sonsuz ( $+\infty$ ) olarak hesaplanmıştır. Çünkü nihai büyüme oranı WACC değerinden büyük olduğu için yıllar ilerledikçe iskonto edilen her yıllık değer bir önceki yıla göre pozitif olarak artarak devam etmektedir.

WACC değeri belirlenirken şirketin yatırım için borçlanma maliyeti ve sermaye maliyeti de dikkate alınmaktadır. Sermaye maliyeti belirlenirken risksiz oran (risk free rate) kullanılmakta ve bunun için genellikle 10 ya da 30 yıllık devlet tahvili getiri oranı kullanılmaktadır. Dolayısıyla, eğer enflasyon beklentisi o yıla ait mevcut enflasyon değerinin oldukça üzerinde ise WACC hesabının içerisine girecek borçlanma faizi ve risksiz oranı da aynı ölçüde yükseltip yeni bir WACC hesaplanabilirdi. Örnek olarak, şirket geleneksel yöntemlerle tahmin ettiği %7 enflasyon oranını, destek vektör regresyonu ile belirlenen sonuç olan %22,2 olarak tahmin ediyor olsaydı WACC değeri %13,5 değil tahmini olarak %25-30 arası bir değer olarak belirlenecekti. Ancak bu yorum hem test edilemeyen bir makroekonomik ortamı ifade ettiğinden, hem de çalışmanın karşılaştırma koşullarına uymadığından bu değerlerle yeni bir analiz yapılmamıştır.

Normal koşullar altında DCF analizi yapılırken ortaya çıkan nihai net bugünkü değer tek bir parasal büyüklükten oluşsa da analizin daha güvenilir sonuç vermesi adına duyarlılık analizinin modele eklenmesi ekonomik bir kabuldür. Çalışmada yapılan duyarlılık analizinde WACC +/- 0,25% ve nihai büyüme oranı +/- 0,2% oranında değiştirilmiş ve her biri için bir net bugünkü değer hesaplanmıştır. Ancak çıkan net bugünkü değer anlamsız çıktığı için bu analiz yapılamamaktadır.

Yatırıma ait elde edilen nakit akımlarını analiz ederek hesaplanan IRR ise %37,3 olarak bulunmuştur.

Tablo 4.11a: Destek Vektör Regresyonu Modeli ile Elde Edilen DCF'e Ait Değerleme Sonucu

Model	Net Bugünkü Değer		
	Orta Değer (mUSD)	Değer Aralığı (mUSD)	IRR
Destek Vektör Regresyonu ile DCF	+∞	+∞	37,3%

## 4.12. Geleneksel Yöntem ile Yapılan DCF Modelinin Sonucu

Çalışmada yapay sinir ağları ve destek vektör regresyonu ile elde edilen DCF'in yanı sıra hemen hemen tüm çalışmalarda kullanıldığı şekli ile geleneksel yöntem ve varsayımlar ile yapılan DCF çalışmasına da yer verilmiştir. Şirketler yatırım değerlemesi için DCF modelini kullanacakları zaman, modelin önemli girdilerinden olan makroekonomik varsayımlar için genellikle kabul görmüş iktisadi kuruluşlara ait varsayımları dikkate almaktadırlar. Tahmin kaynağı olarak kullanılan bu veriler bazen ülkelerin merkez bankalarının ya da ekonomi bakanlıklarının yayınlamış olduğu orta-uzun vadeli ekonomik tahminleri baz alırken çoğu zaman da Dünya Bankası, IMF gibi global anlamda makroekonomik tahmin yapan ve yılda birden fazla defa bu tahminlerini güncelleyen kuruluşlardan elde edilen tahminleri baz almaktadır. Dolayısıyla alışlagelmiş yöntemlerle hesaplanan DCF modellerinde, IMF'in ülkeler için yaptığı makroekonomik tahminler bu modellerdeki girdilere kaynak teşkil eden en önemli verilerdir.

Çalışmada geleneksel yöntemle elde edilen DCF sonucuna ulaşmak adına yatırım için belirlenmiş makroekonomik veri seti kullanılmıştır. Bu veri seti geleneksel yollarla belirlenmiş olan bir veri setidir ve hem IMF'in 2010 yılı sonunda Türkiye ekonomisi için tahmin ettiği 2011-2015 yılını kapsayan USD/TRY döviz kuru ve Türkiye enflasyonu verilerini hem de Türkiye ekonomisi için o dönemde yapılan ekonomik değerlendirmeleri kapsayan yaklaşımların vermiş olduğu analiz sonuçlarını kullanmaktadır.

Bölüm 4.8’ de detayları bahsedilen yapay sinir ağları ile elde edilen DCF sonuçları ile anlamlı karşılaştırma yapmak için modelde sadece USD/TRY döviz kuru ve Türkiye enflasyon oranının etkileri belirlenmek istenmiştir. Dolayısıyla tüm diğer varsayım ve değişkenler yapay sinir ağları ile elde edilen DCF modeli ile aynı alınmış, ancak USD/TRY döviz kuru ve Türkiye enflasyon oranı için alışlagelmiş metot olan geleneksel yöntemlerle elde edilmiş makroekonomik veri seti kullanılmıştır.

Bu yöntem sonucunda elde edilen nakit akımları belirlenmiş olan %13,5 WACC oranı ile 2011 yılının başına iskonto edilmiştir. Ayrıca veri setinde uzun vadeli enflasyon tahmini olan %7,0 olarak belirtilmiş nihai büyüme oranı ve WACC ile hesaplanan artık değer de iskonto edilmesi ile DCF sonucu 297 milyon TL olarak bulunmuştur. Bu değer 1 Ocak 2011 yılının fiili USD/TRY döviz kuru olan 1,55 ile bölüldüğünde projenin net bugünkü değerinin ABD doları bazında değeri 191 milyon USD olmaktadır.

Çalışmada yapılan duyarlılık analizinde WACC +/- 0,25% ve nihai büyüme oranı +/- 0,2% oranında değiştirilmiş ve her biri için bir net bugünkü değer hesaplanmıştır. Duyarlılık analizi sonuçları aşağıda yer alan Tablo 4.12a’da gösterilmektedir.

Tablo 4.12a: Geleneksel Yaklaşım ile Elde Edilen DCF’e Ait Duyarlılık Analizi Sonuçları

		WACC		
		13,25%	13,5%	13,75%
Nihai Büyüme Oranı	<i>mUSD</i> 7,2%	<b>202</b>	199	196
	7,0%	194	<b>191</b>	188
	6,8%	186	183	<b>180</b>

Elde edilen bu sonuçlara göre yatırıma ait net bugünkü değeri, orta değeri 191 milyon USD olmak üzere 180-202 milyon USD aralığındadır.

Yatırıma ait elde edilen nakit akımlarını analiz ederek hesaplanan IRR ise %23,2 olarak bulunmuştur.

Tablo 4.12b: Geleneksel Yaklaşım ile Elde Edilen DCF'e Ait Değerleme Sonucu

Model	Net Bugünkü Değer		
	Orta Değer (mUSD)	Değer Aralığı (mUSD)	IRR
Geleneksel Yöntem ile DCF	191	180-202	23,2%

#### 4.13. Fiili Veriler ile Yapılan DCF Modelinin Sonucu

Çalışmada yapay sinir ağları ve destek vektör regresyonu ile elde edilen DCF sonucu ile geleneksel yöntem ve varsayımlar ile yapılan DCF sonucunun performansını karşılaştırabilmek amacıyla gerçekleşmiş fiili veriler ile hesaplanmış DCF analizi de yapılmıştır.

Bu modelde makroekonomik varsayım olarak 2011-2015 yılını kapsayan dönemdeki gerçekleşmiş fiili USD/TRY döviz kuru ve Türkiye enflasyonu verileri kullanılmıştır. Bu modelin sonucunu Bölüm 4.8' de detayları bahsedilen yapay sinir ağları ile elde edilen DCF sonucu ve Bölüm 4.12'de detayları bahsedilen geleneksel yöntem ile elde edilen DCF sonucu ile anlamlı karşılaştırma yapmak için modelde sadece USD/TRY döviz kuru ve Türkiye enflasyon oranının etkileri belirlenmek istenmiştir. Dolayısıyla tüm diğer varsayım ve değişkenler bu iki modeldeki ile aynı alınmış ancak USD/TRY döviz kuru ve Türkiye enflasyon oranı için fiili verilerden oluşmuş veri seti kullanılmıştır.

Bu yöntem sonucunda elde edilen nakit akımları belirlenmiş olan %13,5 WACC oranı ile 2011 yılının başına iskonto edilmiştir. Ayrıca veri setinde uzun vadeli enflasyon tahmini olarak belirtilen %8,8 nihai büyüme oranıyla ve WACC ile hesaplanan artık değer de iskonto edilmesi ile DCF sonucu 460 milyon TL olarak bulunmuştur. Bu değer 1 Ocak 2011 yılının fiili USD/TRY döviz kuru olan 1,55 ile bölüldüğünde projenin net bugünkü değerinin ABD doları bazında değeri 296 milyon USD olmaktadır.

Çalışmada yapılan duyarlılık analizinde WACC +/- 0,25% ve nihai büyüme oranı +/- 0,2% oranında değiştirilmiş ve her biri için bir net bugünkü değer

hesaplanmıştır. Duyarlılık analizi sonuçları aşağıda yer alan Tablo 4.13a'da gösterilmektedir.

Tablo 4.13a: Fiili Veriler ile Elde Edilen DCF'e Ait Duyarlılık Analizi Sonuçları

		WACC		
		13,25%	13,5%	13,75%
Nihai Büyüme Oranı	<i>mUSD</i>			
	9,0%	<b>316</b>	312	307
	8,8%	300	<b>296</b>	292
	8,6%	286	281	<b>277</b>

Elde edilen bu sonuçlara göre yatırıma ait net bugünkü değeri, orta değeri 296 milyon USD olmak üzere 277-316 milyon USD aralığındadır.

Yatırıma ait elde edilen nakit akımlarını analiz ederek hesaplanan IRR ise %24,6 olarak bulunmuştur.

Tablo 4.13b: Fiili Verileri Elde Edilen DCF'e Ait Değerleme Sonucu

Model	Net Bugünkü Değer		
	Orta Değer (mUSD)	Değer Aralığı (mUSD)	IRR
Fiili Veriler ile DCF	296	277-316	24,6%

#### 4.14. DCF Sonuçlarının Karşılaştırılması

Çalışmada yeni yaklaşım olarak önerilen modelin performansını ölçmek için, sonuçları hem geleneksel yöntem ile hem de fiili veriler ile yapılan modellerin sonuçları ile karşılaştırmak gerekmektedir. Ayrıca Bölüm 1.1 de bahsedilen araştırmanın amacına yönelik soruları da dikkate alarak bu sorular eşliğinde bir değerlendirme yapılması mümkün olacaktır.

Karşılaştırmaya başlarken her dört modelin de ana çerçevesini alt alta koymak gerekmektedir. Aşağıda yer alan Şekil 4.14 her dört modelin yapısını özetlemektedir.

<b>Fiili Veriler</b>	<b>Geleneksel Yöntem</b>	<b>Yapay Sinir Ağları</b>	<b>Destek Vektör Regresyonu</b>
Gelirler, maliyetler, yatırım maliyeti gibi girdiler için fiili 2011-2015 dönemi USD/TRY döviz kuru ve Türkiye enflasyonu kullanılmıştır.	2011-2015 dönemi USD/TRY döviz kuru ve Türkiye enflasyonu verileri için, 2010 yılı sonunda IMF'nin yapmış olduğu makroekonomik verilerden yararlanarak oluşturulan veri seti kullanılmıştır.	2011-2015 dönemi USD/TRY döviz kuru ve Türkiye enflasyonu verileri için yapay sinir ağları tahmin modelinin çıktıları kullanılmıştır.	2011-2015 dönemi USD/TRY döviz kuru ve Türkiye enflasyonu verileri için destek vektör regresyonu tahmin modelinin çıktıları kullanılmıştır.
Satış miktarı, sektörel veriler, yatırım miktarı, kapasite vb. gibi tüm diğer veriler (USD/TRY döviz kuru ve Türkiye enflasyonu dışındaki veriler) her üç modelde de aynı varsayılmıştır.			

Şekil 4.14: Çalışmada Kullanılan Modellere Ait Yapı ve Farklılıklar

Şekil 4.14'de görüleceği üzere modellere ait performans karşılaştırmasını doğru yapabilmek adına modellerde tek değişen varsayımın USD/TRY döviz kuru ve Türkiye enflasyonu olduğunu bir kez daha belirtmek gerekir. Karşılaştırmaya baz teşkil edecek model, fiili veriler kullanılarak yapılan DCF çalışmasıdır. Çünkü yatırım değerlemesi yapılmasının amacı o yatırıma ve projeye ait oluşacak nakit akımların bugünkü değerini hesaplamaya yöneliktir. Performansa tabi tutulan iki değişken haricindeki tüm diğer verilerin gerçekleştiğini varsaydığımızda ve USD/TRY döviz kuru ve Türkiye enflasyonuna ait fiili verileri bu denkleme eklediğimizde elde edilecek sonuç gerçek net bugünkü değere işaret etmektedir.

Firmaların DCF analizi yaptığı dönemde, ileriki zamanlara ait belirsizlikler altında gelecekte oluşacak nakit akımlarını en doğru şekilde tahmin edip net bugünkü değeri bulmak istemeleri DCF analizinin yapılmasının en temel sebebidir. Bu sonucu veren fiili verilerle yapılmış analiz bu sebepten bu belirsizliklerin elimine edildiği analizin sonucudur. Çalışmada yapılan her dört analizin DCF çıktıları aşağıda yer alan Tablo 4.14'de gösterilmiştir.

Tablo 4.14: Çalışmada Kullanılan Modellere Ait Değerleme Sonuçları

Model	Net Bugünkü Değer		
	Orta Değer (mUSD)	Değer Aralığı (mUSD)	IRR
Fiili Veriler ile DCF	296	277-316	24,6%
Geleneksel Yöntem ile DCF	191	180-202	23,2%
Yapay Sinir Ağları ile DCF	279	262-298	24,4%
Destek Vektör Regresyonu ile DCF	-	-	37,3%

Tablo 4.14’de görüleceği üzere fiili veriler ile yapılmış DCF analizin sonucu ile yapay sinir ağları ile yapılmış analizin sonuçları birbirine yakın iken, geleneksel yöntem ile yapılmış analizin sonuçları fiili veriler ile yapılan analizden oldukça farklıdır. Destek vektör regresyonu ile yapılmış analiz ise anlamlı sonuçlar vermemektedir.

Bu sonuçlar altında, geleneksel yöntem ile analizi yapan bir yatırımcı için yatırım projesinin değerini 191 milyon \$USD olarak bulunacaktı. Duyarlılık analizi ile de yaklaşık 200 milyon USD’lik bir değer düşünülüyor olacaktı ve belki de eğer masada birden fazla yatırım varsa bu değer yatırımcıya yeterli gelmeyip yatırım yapılmayacaktı. Aynı şekilde bu DCF analizi bir kapasite yatırımı için değil de benzeri bir tesisin satın alımı için yapılıyor olsa ve bu analiz sonucunda tesisi satan tarafa 200 milyon USD satın alma bedeli teklif edildiğinde, satıcı taraf belki de bu değeri az bulacak ve bu işlem gerçekleşmeyecekti.

Bu çalışmada kullanılan örnekte geleneksel yöntem ile o günün koşullarında bulunan değerlendirme sonucu fiili verilere göre yapılmış değerlendirme sonucundan oldukça düşük çıkmıştır. Ancak, ekonomik olarak daha riskli bir dönemde ya da belirsizlikler dolayısıyla makroekonomik tahminlerin çok daha marjlı tahmin edildiği dönemlerde, değerlendirme sonucu gereğinden yüksek de çıkabilmektedir. Yapılan çalışmada geleneksel yöntemle yapılan değerlendirme sonucunun fiili verilerle yapılan değerlendirme sonucundan bu kadar sapsmasının sebebi şu şekilde açıklanabilir. IMF’nin



2010 yılı sonunda Türkiye ekonomisi için belirlemiş olduğu uzun vadeli enflasyon oranı %7,0 iken, fiili enflasyon verisi %6 ile %10 arasında gerçekleşmiş, 2015 yılı enflasyon oranı ise %8,8 olarak gerçekleşmiştir. Aynı şekilde IMF'in ve diğer makroekonomik tahmin yapan kaynakların o dönemde yapmış olduğu makroekonomik tahminlerde 2015 yılsonu için öngördükleri USD/TRY döviz kuru 2,0-2,1 arasında değişmekte iken gerçekleşen fiili USD/TRY döviz kuru 2,7 civarında gerçekleşmiştir. Bu iki temel farklılık doğrultusunda net bugünkü değer analizinde elde edilen sonuçlarda %35 civarında bir sapma gerçekleşmiştir. Takdir edileceği üzere bu denli bir sapma hangi tür analiz olursa olsun kabul edilemez nitelikte büyük bir sapmadır.

Yapay sinir ağları ile yapılan değerlendirme analizi sonucunda elde edilen net bugünkü değer fiili veriler ile elde edilen değerden yaklaşık %5,7 oranında bir sapma göstermiştir. %95'e yakın doğrulukla analiz sonucuna ulaşılan bu yöntem bariz bir şekilde geleneksel yöntemle göre daha iyi sonuç vermiş, sapmanın az olması sebebi ile de gerçekçi bir sonuç elde edilmiştir. Bu sonuçlar yapay sinir ağlarının DCF modeline girdi tahmini aşamasında dahil edilmesinin sonuçların doğruluğu açısından büyük bir fayda sağlayacağını göstermektedir.

Destek vektör regresyonu ile yapılan değerlendirme analizi sonucunda anlamsız bir sonuç elde edilmiştir. Çünkü hem USD/TRY döviz kuru, hem de Türkiye enflasyonu için tahmin edilen değerler fiili verilerden oldukça sapmaktadır. Bu sonuçlar ile destek vektör regresyonu modelinin DCF modeline girdi tahmini aşamasında dahil edilmesinin sonuçların doğruluğu açısından uygun olmayacağı sonucu çıkmaktadır.

Araştırmaya konu olan ve yanıt aranan sorular bu bölümde bahsedilen karşılaştırma sonuçları sonrasında netliğe kavuşmuştur ve bununla alakalı yorum ve analize tez çalışmasının son bölümü olan Bölüm 5'de sonuçlar kısmında değinilecektir.

## 5. SONUÇ

Şirketler sürdürülebilir ve karlı büyüme hedefleri için mevcut işlerini en verimli devam ettirmelerinin yanı sıra yatırım yaparak büyümeyi ve yenilenmeyi hedeflemektedirler. Birçok opsiyon arasından verimli, doğru, fayda sağlayan ve en önemlisi karlı yatırımı seçebilmek şirketler ve karar vericiler açısından önemli zorluklardan biridir. Karar vericiler bu yatırımları değerlemek için stratejik kararları, şirket için en doğru alternatifleri, sinerjileri ve sektörün, rakiplerin ve kendi şirketlerinin durumunu gözden geçirmekte bunlarla birlikte yatırım opsiyonlarının değerlendirmek için çeşitli finansal modeller kullanmaktadırlar. En eski ve geleneksel metotlardan biri olmasına rağmen DCF en çok kullanılan yatırım değerlendirme aracıdır. DCF indirgenmiş nakit akımlarını hesaplamak için kullanılırken, DCF ile birlikte değerlemeye ışık tutan, en çok kullanılan değerlendirme araçları net bugünkü değer ve iç verim oranıdır.

Unutmamak gerekir ki DCF analizi gelecekte beklenen nakit akımlarının tahmin edilmesine dayalı bir metottur ve bu nakit akımlarını belirlemek için detaylı bir gelir ve gider analizinin yapılması gerekmektedir. Bu girdileri belirlerken şirketler sektörel ekspertiz gerektiren verileri ve varsayımları belirledikten sonra modele makroekonomik verileri de dahil ederek nakit akımları hesaplamaya çalışmaktadırlar. Ancak şirketlerin, ve hatta bu çalışmaya konu olan çimento sektöründeki şirketin, ana işi makroekonomik tahminler yapmak olmadığından bu veriler için en güvenilir ve kabul görmüş kurum ve kuruluşların yapmış olduğu tahminleri kullanmaktadırlar. Bu kurum ve kuruluşlardan en bilinenleri IMF ve Dünya Bankası gibi global finansal kuruluşlar iken, aynı zamanda yine bu finansal kuruluşların verilerini baz alan ülke merkez bankaları ve ekonomi bakanlıklarının yapmış olduğu tahminler de güvenilir kaynak olarak kabul görmektedir. Özellikle bir firma kendi ülkesi dışında, ya da kendi ana işi dışında bir yatırım yapmayı hedefliyorsa, bu dış ülkeye ait makroekonomik veriler için bu bahsedilen kaynaklar en çok tercih edilen kaynaklardır.

Bu çalışmada Türkiye’de faaliyet gösteren şirketlerin yatırım değerlendirme analizi yaparken en çok kullandığı iki temel makroekonomik değişken olan USD/TRY döviz kuru ile Türkiye enflasyonu ve bunların tahmin edilmesi ele

alınmıştır. Bu iki deęişken sadece imento sektr yatırımları iin deęil, hemen hemen her sektre ait yatırım deęerlemesi analizinde kullanılan girdilerdendir. alıřmada bu deęişkenler yapay sinir aęları metodu ve destek vektr regresyonu ile tahmin edilmiř ve DCF'in ierisinde dahil edilerek NPV ve IRR gibi deęerleme aralarının sonuları oluřturmasında etkin rol oynamıřtır. Bu iřlemin yapılmasının ve nerilmesinin temel sebebi literatrde de belirtildięi řekilde geleneksel yntemler ile yapılan DCF modellemesinin rijit yapısının esnetilmesine olanak saęlamak ve belirsizlik altında DCF modelinin daha doęru sonu vermesini saęlamaktır. Bu yntemin geleneksel metotlara bir alternatif yaklařım oluřturması hedeflenmiřtir.

alıřmada USD/TRY dviz kurunun ve Trkiye enflasyonunun yapay sinir aęları metodu ve destek vektr regresyonu ile tahmin edilerek DCF modelinin ierisine dahil edilmesi ile ortaya ıkan deęerleme sonucunun performansı llmřtr. Bu performans deęerlendirmesi, alıřmaya rnek teřkil eden yatırıma ait deęerleme sonucunun hem yapay zeka tekniklerinden olan yapay sinir aęları ve destek vektr regresyonu modelleri ile hem de geleneksel yntemler ile yapılmasını baz almakta ve her  modeli, bir drdnc model olan ve en gereki sonucu veren, fiili veriler ile yapılan DCF sonucu ile karřılařtırmaktadır. Bu karřılařtırmanın sonucu Blm 4.14'de ele alınmıř ve yapay sinir aęları ile yapılan DCF modeli ile elde edilen yatırım deęerinin fiili sonulara yaklařıklıęının kabul edilebilir seviyede olduęu gsterilirken geleneksel yaklařım ile yapılan deęerleme sonucunun kabul edilemez seviyede saptıęını ortaya koymuřtur. Aynı řekilde destek vektr regresyonu ile elde edilen sonuların da anlamsız sonular verdięi iin uygun olmadıęı ortaya ıkmıřtır. Bu karřılařtırma sonrasında Blm 1.1'de de bahsedilen ve arařtırmada yanıt aranan soruların cevaplar elde edilmiřtir. Bu sorular ařaęıda listelenmiřtir.

- 1- Geleneksel yntemlerle yapılan yatırım deęerlemesi modellerinin sonuları hangi lde gerekidir?
- 2- Yatırım deęerlemesi alıřmalarına yeni bir bakıř aısı getirilebilir mi?
- 3- Yapay zeka tekniklerinin kanıtlanmış tahmin becerileri, yatırım deęerlemesinde kullanılan girdilerin tahmininde kullanılabilir mi?
- 4- Yapay zeka teknikleri ile tahmin edilen girdiler DCF modeli ile nasıl birleřtirilebilir?

5- Yapay zeka teknikleri ve DCF'in birlikte kullanılması ile önerilen hibrid model ile geleneksel yöntemlerle yapılan yatırım değerlemesi analizleri, gerçek çıktılar ile yapılan sonuçlar ile kıyaslandığında nasıl bir performans sergilemektedir?

6- Önerilen hibrid model iş dünyasında kullanılabilir mi?

Birinci soruda geleneksel yöntemler ile yapılan yatırım değerlemesinin sonuçlarının geçerliliği sorgulanmaktadır. Çalışmaya konu olan örnekte yatırım değerlemesi sonuçlarına bakıldığında geleneksel yöntemler ile yapılan değerlendirme filli veriler ile yapılan değerlemeden büyük ölçüde sapmıştır ve gerçekliği tartışma konusu olmaya açıktır. Ancak yapılan makroekonomik tahminler ülkenin ve global ekonominin içinde bulunduğu durumla yakından alakalıdır. Örneğin ekonomik kriz dönemlerinde ileriye dönük tahminlerde ekonomik göstergelerin olumsuz beklenmesi olası bir durumdur ve böyle bir dönemde yapılan tahminlerde ülke para biriminin Amerikan Doları karşısında hızla değer kaybedeceği veya ülke enflasyon değerinin yıllar itibarıyla yüksek seyredeceği beklenebilir. Aynı şekilde ekonominin yıllar boyunca iyi yönetildiği ve beklentilerin de olumlu olduğu dönemlerde tam tersi manada olumlu tahminler de yapılabilir. Ancak gerçekleştirmelerin bu tahminlerden ne kadar uzak olacağı ülkenin makroekonomik, sosyal, politik ve tüm diğer süreçlerinin nasıl işlediği ile yakından alakalıdır. Bu sebeple makroekonomik tahminler ileriye dönük ekonomik gösterge araçları olarak nitelendirilebilir. Sonuç olarak, bu tahminler kullanılarak yapılan geleneksel yöntemli değerlendirme sonuçları belirsizliğin az olduğu ve daha stabil ekonomilerde daha gerçekçi sonuçlar verebilirken, tam tersi durumda oldukça farklı sonuçlar verebilmektedir. Bu açıdan yaklaşıldığında, geleneksel yöntemler ile yapılan DCF sonuçlarının gerçekliği tartışma konusu olmaya açıktır. Literatürde de benzeri yaklaşımlar mevcuttur.

Bu durum ikinci soruyu doğuran sebeplerden bir tanesidir. Yatırım değerlemelerine yeni bir yaklaşım getirme çabaları bir çok araştırmaya konu olmuş, bir çok hibrid ve yeni modeller önerilmiştir. Gerçek opsiyonlar yaklaşımı, bulanık mantık bazlı modellemeler bunlardan bazılarıdır. Aynı şekilde bu çalışmada önerildiği üzere yapay sinir ağları kullanılarak kritik girdiler tahmin edilebilmekte ve DCF modelinin içerisine yerleştirilebilmektedir. Bu durum aynı zamanda üçüncü soruya cevap olmaktadır.

Dördüncü sorunun cevabı Bölüm 4'de detaylarıyla anlatılmış ve cevaplanmıştır. Beşinci soruda ise bu çalışmada önerilen hibrid modelin performansı irdelenmektedir. Bölüm 4.14'de çalışmada önerilen modelin değerlendirme sonuçları paylaşılmakta ve bu değerlerin fiili verilerle yapılmış değerlendirme çalışmasından kabul edilebilir seviyede sapma göstererek oldukça başarılı sonuç verdiği belirtilmiştir.

Son olarak bu modelin iş dünyasında kullanılabilirliğine yanıt aranmıştır. Şirketler makroekonomik tahminleri elde ederken kullandığı verileri genel kabul görmüş ve en güvenilir kuruluşlardan almayı tercih etmektedir. Ama bu çalışmada sonuçlarının paylaşıldığı ölçüde belirtilebilir ki, geleneksel yöntemlerle elde edilen sonuçlar şirketleri yanıltabilir ve yanlış yatırım kararları almalarına sebebiyet verebilir. Şirketler daha doğru ve gerçekçi sonuçlar elde edebileceği modelleri kullanmayı tercih ettikleri ölçüde bu çalışmada önerilen hibrid model rahatlıkla iş dünyasında kullanılabilir seviyededir ve önerilmektedir.

Çalışmanın sonucu olarak, şirketlerin yatırım kararları alırken kullandığı temel değerlendirme araçlarından DCF modelinin daha gerçekçi sonuçlar verebilmesi adına hibrid bir model önerilmektedir. Bu model, yapay sinir ağları metodunun güçlü yönü olan tahmin yapabilme becerisini, nakit akımlarını oluşturan kritik girdilerin tahmin edilmesinde kullanarak DCF modelinin içerisine yerleştirmeyi esas almaktadır. Modelin elde ettiği sonuçlar oldukça çarpıcıdır ve iş dünyasında kullanılması durumunda şirketlere yatırımlar anlamında doğru karar vermesine yardımcı olacaktır.

## KAYNAKLAR

- Abe S. (2005). *Support Vector Machines for Pattern Classification*. New York: Springer
- Amram, M., Kulatilaka, N. (1999). Uncertainty: The new rules for strategy. *The Journal of Business Strategy*, 20, 3
- Angelini, E., Roli, A., Tollo, G. (2008). A neural network approach for credit risk evaluation. *The Quarterly Review of Economics and Finance*, 48, 733–755.
- Awad, M., Khanna, R. (2015). *Efficient Learning Machines: Theories, Concepts, and Applications for Engineers and System Designers*. New York: Apress Media.
- Babusiaux, D., Pierru, A. (2009). Investment project valuation: A new equity perspective. *Engineering Economist*, 54 (2), 101-108.
- Bailey, D.L., Thompson, D.M. (1990). Developing neural-network applications. *AI Expert*, 5, 34-41
- Bennouna, K., Meredith, G.G., Marchant, T. (2010). Improved capital budgeting decision making: evidence from Canada. *Management Decision*, 48, 225-247.
- Black, F, Scholes, M. (1973). The pricing of options and corporate liabilities. *Journal of Political Economy*, 81, 637-654.
- Boser, B.E., Guyon, I, Vapnik, V.N. (1992) A training algorithm for optimal margin classifiers. *Proceedings of the Fifth Annual Workshop on Computational Learning Theory*, 144-152.
- Bowe, M., Lee, D.L. (2007). Project evaluation in the presence of multiple embedded real options: Evidence from the Taiwan High-Speed Rail Project. *Journal of Asian Economics*, 15 , 71-98.
- Brach, M. A. (2003). *Real Options in Practice*. USA: John Wiley & Sons.
- Brealey, R.A., Myers, S.C. (2000). *Principles of Corporate Finance* (6th ed.). London: McGraw-Hill.
- Brennan, M., Schwartz, E. (1985). Evaluating natural resource investment. *Journal of Business*, 58, 135-157.

- Brigham, E.F., Ehrhardt, M.C. (2002). *Financial Management: Theory and Practice*. (10th ed.) Ohio: South-Western, Mason
- Brigham E.F. & Houston, J.F. (2004). *Fundamentals of financial management*: 10th ed. Ohio, Thomson South-Western Publications
- Buckley, J.J. (1987). The fuzzy mathematics of finance. *Fuzzy Sets and Systems*, 21, 257-273.
- Carlsson, C., Fuller, R. (2003). A fuzzy approach to real option valuation. *Fuzzy Sets and Systems*, 139, 297–312.
- Carlsson, C., Fuller, R., Heikkila, M., Majlender, P. (2007). A fuzzy approach to R&D project portfolio selection. *International Journal of Approximate Reasoning*, 44, 93–105.
- Cecchetti, S. (1992). Prices during the great depression: Was the deflation of 1930-1932 really unanticipated? *American Economic Review*, 82, 141-156
- Chang, I., Rapiiraju, S., Whiteside, M., Hwang, G., (1991). A neural network to time series forecasting. *Proceedings of the National Meeting of the Decision Sciences Institute*, 1716-1718.
- Chen, A.S., Leung, M.T. (2004). Regression neural network for error correction in foreign exchange forecasting and trading. *Computers and Operations Research*, 31, 1049–1068.
- Chen, J.H. (2012). A hybrid knowledge-sharing model for corporate foreign investment in China's construction market. *Expert Systems with Applications*, 39, 7585–7590.
- Chen, S.T., Yu, P.S. (2007). Support vector networks pruning on flood forecasting and data mining. *Journal of Hydrology*, 347, 67-78.
- Chen, T., Zhang, J., Lai, K.K. (2009). An integrated real options evaluating model for information technology projects under multiple risks. *International Journal of Project Management*, 27, 776–786.
- Chen, Y., Liang, X., Xiao, J., Zhang, H. (2009). Improving option price forecasts with neural networks and support vector regressions. *Neurocomputing*, 72, 3055–3065.

- Chi, L.C., Tang, T.C. (2005). Artificial neural networks in reorganization outcome and investment of distressed firms: The Taiwanese case. *Expert Systems with Applications*, 29, 641–652.
- Chiu, C.Y., Park, C.S. (1994). Fuzzy cash flow analysis using present worth criterion. *The Engineering Economist*, 39 (2), 113-138.
- Copeland, T., Antikarov, V. (2003). *Real options: A practitioner's guide*. New York: Cengage Learning
- Cox, J., Ross, S., Rubinstein, M. (1979). Option pricing: A simplified approach. *Journal of Financial Economics*, 7, 229–263.
- Davis, G.A., Owens, B. (2003). Optimizing the level of renewable electric R&D expenditures using real options analysis. *Energy Policy*, 31 (15), 1589-1608.
- Deng, S.J., Oren, S.S. (2003). Incorporating operational characteristics and start-up costs in option-based valuation of power generation capacity. *Probability in the Engineering and Informational Sciences*, 17 (2), 155-181.
- Dixit, A.K., Pindyck, R.S. (1994). *Investment under uncertainty*. New Jersey: Princeton University Press
- Dixit, A.K., Pindyck, R.S. (1995). The options approach to capital investment. *Harvard Business Review*, 73 (3), 105–115.
- Dominguez, K.M., Fair, R.C., Shapiro, M.D. (1988). Forecasting the depression: Harvard versus Yale. *American Economic Review*, 78, 595-612
- Drucker, H., Burges, C.J.C., Kaufman, L., Smola, A.J., Vapnik, V. (1996). NIPS'96 Proceedings of the 9th International Conference on: *Neural Information Processing Systems*, 155-161
- Efendigil, T., Kahraman, C., Önüt, S. (2009). A decision support system for demand forecasting with artificial neural networks and neuro-fuzzy models: A comparative analysis. *Expert Systems with Applications*, 36, 6697–6707.
- Enke, D., Mehdiyev, N. (2014). A hybrid neuro-fuzzy model to forecast inflation. *Procedia Computer Science*. 36, 254-260



- Fernandes, B., Cunha, J., Ferreira, P. (2011). The use of real options approach in energy sector investments. *Renewable and Sustainable Energy Reviews*, 15 (9), 4491-4497.
- Fioretti, G. (2006). Recognising investment opportunities at the onset of recoveries. *Research in Economics*, 60, 69–84.
- Frenkel, J.A. (1984). Tests of Monetary and Portfolio Balance Models of Exchange Rate Determination, *Exchange Rate Theory and Practice*, içinde (239-260)
- Garcia, F.A.A. (2004). Fuzzy real option valuation in a power station reengineering project, in *Soft Computing with Industrial Applications – Proceedings of the Sixth Biannual World Automation Congress*, Spain: 281-287.
- Garvin, M.J., Cheah, C.Y.J. (2004). Valuation techniques for infrastructure investment decisions. *Construction Management & Economics*, 22 (4), 373-383.
- Garvin, D., Hayes, R.H. (1982). Managing as if tomorrow mattered. *Harvard Business Review*, 60 (3), 70-79.
- Graham, J.R., Harvey, C.R. (2002). How do CFOs make capital budgeting and capital structure decisions? *The Journal of Applied Corporate Finance*, 15, 187-243.
- Hahn, W.J., Dyer, J.S. (2008). Discrete time modeling of mean-reverting stochastic processes for real option valuation. *European Journal of Operational Research*, 184, 534-548.
- Hamzaçebi, C., Akay, D., Kutay, F. (2009). Comparison of direct and iterative artificial neural network forecast approaches in multi-periodic time series forecasting. *Expert Systems with Applications*, 36, 3839–3844.
- He, K., Lai, K.K., Yen, J. (2012). Hybrid slantlet denoising least squares support vector regression model for exchange rate prediction. *Procedia Computer Science*, 1, 2397-2405
- Herath, H.S.B., Park, C.S. (1999). Economic analysis of R&D projects: an options approach. *Engineering Economist*, 44 (1), 1-35.
- Hill, T., O'Connor, M., Remus, W. (1996). Neural network models for time series forecasts. *Management Science*, 42(7), 1082–1092.

- Ho, S.H., Liao, S.H. (2011). A fuzzy real option approach for investment project valuation. *Expert Systems with Applications*, 38 (12), 15296-15302.
- Hu, M.J.C. (1964). Application of the adaline system to weather forecasting. *Yüksek Lisans Tezi*. Stanford Electronic Laboratories, Stanford.
- Hu, M.H., Tsoukalas, C. (1999). Combining conditional volatility forecasts using neural networks: an application to the EMS exchange rates. *Journal of International Financial Markets, Institutions and Money*, 9, 407–422.
- Hua, X., Yang, Z., Ye, Y., Shao, Y. (2015). A Novel Dynamic Financial Conditions Index Approach Based on Accurate Online Support Vector Regression. *Procedia Computer Science*, 55, 944 – 952
- Huang, K., Yu, T.H.K. (2006). The application of neural networks to forecast fuzzy time series. *Physica A*, 363, 81–491.
- Indro, D.C., Jiang, C.X., Patuwo, B.E., Zhang, G.P. (1999). Predicting mutual fund performance using artificial neural networks. *Omega International Journal of Management Science*, 27, 373–380.
- Jasemi, M., Kimiagari, A.M., Memariani, A. (2011). A modern neural network model to do stock market timing on the basis of the ancient investment technique of Japanese Candlestick. *Expert Systems with Applications*, 38, 3884–3890.
- Jiang, B.T., Zhao, F.Y. (2013). Particle Swarm Optimization-based Least Squares Support Vector Regression for Critical Heat Flux Prediction. *Annals of Nuclear Energy*, 53, 69-81.
- Jiménez, L.G., Pascual, L.B. (2008). Multicriteria cash-flow modeling and project value-multiples for two-stage project valuation. *International Journal of Project Management*, 26 (2), 185-194.
- Kallio, M., Kuula, M., Oinonen, S. (2012). Real options valuation of forest plantation investments in Brazil. *European Journal of Operational Research*, 217 (2), 428-438.
- Karsak, E.E., Tolga, E. (2001). Fuzzy multi-criteria decision-making procedure for evaluating advanced manufacturing system investments. *International Journal of Production Economics*, 69 (1), 49-64.

- Katz, J.O. (1992). Developing neural network forecasters for trading. *Technical Analysis of Stocks and Commodities*, 10, 160–168
- Kermanshahi, B. (1998). Recurrent neural network for forecasting next 10 years loads of nine Japanese utilities. *Neurocomputing*, 23, 125-133.
- Khashei, M., Bijari, M. (2010). An artificial neural network (p,d,q) model for timeseries forecasting. *Expert Systems with Applications*, 37, 479–489.
- Khashman, A. (2010). Neural networks for credit risk evaluation: Investigation of different neural models and learning schemes. *Expert Systems with Applications*, 37, 6233–6239.
- Kjærland, F. (2007). A real option analysis of investments in hydropower – the case of Norway. *Energy Policy*, 35 (11), 5901-5908.
- Kleczyk, E. (2008). Risk management in the development of new products in the pharmaceutical industry. *African Journal of Business Management*, 2 (10), 186-194.
- Ko, P.C., Lin, P.C. (2008). Resource allocation neural network in portfolio selection. *Expert Systems with Applications*, 35, 330–337.
- Kogut, B., Kulatilaka, N. (2001). Capabilities as real options. *Organization Science*, 12, 744-758.
- Kooths, S., Mitze, T., Ringhut, E. (2003). Inflation forecasting - a comparison between econometric methods and a computational approach based on genetic-neural fuzzy rule-bases. *Computational Intelligence for Financial Engineering*, 1, 183-190.
- Kuchta, D. (2001). A fuzzy mode for R&D project selection with benefit: outcome and resource. *The Engineering Economist*, 46 (3): 164-180
- Kulatilaka, N., Perotti, E.C. (1998). Strategic growth options. *Management Science*, 44, 1021-1031.
- Kulatilaka, N., Trigeorgis, L. (1994). The general flexibility to switch: real options revisited. *International Journal of Finance*, 6, 778-798
- Kumar, K.V., Carr, M., Kiran, N.R., Ravi, V. (2008). Software development cost estimation using wavelet neural networks. *The Journal of Systems and Software*, 81, 1853–1867.

- Kumbaroglu, G., Madlener, R., Demirel, M.A. (2008). Real options evaluation model for the diffusion prospects of new renewable power generation technologies. *Energy Economics*, 30 (4), 1882-1908.
- Kuo, R. J. (1994). Multi-sensor integration for manufacturing process control through artificial neural networks and fuzzy modelling. *Doktora Tezi*. The Pennsylvania State University, ABD
- Kuo, R.J. (2001). A sales forecasting system based on fuzzy neural network with initial weights generated by genetic algorithm. *European Journal of Operational Research*, 129, 496-517
- Kuo, R.J., Cohen, P.H. (1998). Manufacturing process control through integration of neural networks and fuzzy model. *Fuzzy Sets and Systems*, 1, 15–31.
- Kuo, R.J., Cohen, P.H. (1999). Integration of RBF network and fuzzy neural network for tool wear estimation. *Neural Networks*, 12(2), 355–370.
- Kuo, R.J., Wang, C.P., Wu, P. (2002) An intelligent sales forecasting system through integration of artificial neural networks and fuzzy neural networks with fuzzy weight elimination. *Neural Networks*, 15, 909–925.
- Kuo, R.J., Xue, K.C. (1999). Fuzzy neural networks with application to sales forecasting. *Fuzzy Sets and Systems*, 108, 123- 143.
- Lau, S.C., Ariaratnam, S.T., Lu, M. (2010). Applying radial basis function neural networks to estimate next-cycle production rates in tunnelling construction. *Tunnelling and Underground Space Technology*, 25, 357–365.
- Lee, A., Balakrishnan, J., Cheng, C.H. (1998). Software development cost estimation: Integrating neural network with cluster analysis. *Information and Management*, 34,1-9.
- Lee, Y.C., Lee, S.S. (2011). The valuation of RFID investment using fuzzy real option. *Expert Systems with Applications*, 10, 12195–12201.
- Lee, K.J., Shyu, D.S., Dai M.L. (2009). The Valuation of Information Technology Investments by Real Options Analysis. *Review of Pacific Basin Financial Markets & Policies*, 12(4), 611-628.

- Lee, S.C. (2011). Using real option analysis for highly uncertain technology investments: The case of wind energy technology. *Renewable and Sustainable Energy Reviews*, 15 (9), 4443-4450.
- Lee, S.C., Shih, L.H. (2011). Enhancing renewable and sustainable energy development based on an options-based policy evaluation framework: Case study of wind energy technology in Taiwan. *Renewable and Sustainable Energy Reviews*, 15, 2185–2198.
- Leslie, K. J., Michaels, M.P. (1997). The real power of real options. *The McKinsey Quarterly*, 3, 5-22.
- Leung, M.T., Chen, A. & Daouk, H. (2000). Forecasting exchange rates using general regression neural networks. *Computers & Operations Research*, 27, 1093-1110
- LeVee, G. S. (1993). The key to understanding the forecasting process. *Journal of Business Forecasting*, 11(4), 12–16.
- Liao, S.H., Ho, S.H. (2010). Investment project valuation based on a fuzzy binomial approach. *Information Sciences*, 180 (11), 2124-2133.
- Lin, T.T., Huang, S.L. (2010). An entry and exit model on the energy-saving investment strategy with real options. *Energy Policy*, 38 (2), 794-802.
- Liu, P., Sun, J., Han,L., Wang, B. (2014), Research on the construction of macro assets price index based on support vector machine, *Procedia Computer Science*, 29, 1801–1815
- Liu, L., Wang, W. (2008). Exchange Rates Forecasting with Least Squares Support Vector Machine, in *Proceedings of the International Conference on Computer Science and Software Engineering*, 1017-1019.
- Lubecke, T.H., Kwok, C.C.Y., Markland, R.E., Nam, K.D. (1998). Combining foreign exchange rate forecasts using neural networks. *Global Finance Journal*, 9 (1), 5-27.
- Luehrman, T. (1997). What's it worth? A general managers guide to valuation. *Harvard Business Review*, 75 (3), 132-142.
- Luehrman, T. (1998). Investment Opportunities As Real Options: Getting Started On The Numbers. *Harvard Business Review*,
- Majd, S., Pindyck, R.S. (1987). Time to build, option value, and investment decisions. *Journal of Financial Economics*, 18, 7-27.

- Majlender, P. (2008). Soft decision support systems for evaluating real and financial investments. Kahraman, C. (Ed.). *Fuzzy Engineering Economics with Applications Studies in Fuzziness and Soft Computing*, Springer Verlag, 233, içinde (307-338).
- Mandal, P., Senyju, T., Toshihisa, F. (2006). Neural networks approach to forecast several hour ahead electricity prices and loads in deregulated market. *Energy Conversion and Management*, 47, 2128–2142.
- Marcellino, M. (2004). Forecasting EMU macroeconomic variables. *International Journal of Forecasting*, 20, 359– 372
- Marreco, J.M., Carpio, L.G.T. (2006). Flexibility valuation in the Brazilian power system: a real options approach. *Energy Policy*, 34, 3749-3756.
- Marvuglia, A., Messineo, A. (2012). Using Recurrent Artificial Neural Networks to Forecast Household Electricity Consumption. *Energy Procedia*, 14, 45-55.
- McGuire, T., (1997). Artificial Neural Networks. *Computer Audit Update*, July, 25-29.
- Meese R., Rogoff, K. (1983). Exchange rate models of the seventies: do they fit out of sample. *Journal of International Economics*.14, 3-24.
- Moghaddam, M.P., Shafiekhah, M., Sheikh-El-Eslami, M.K. (2011). Price forecasting of day-ahead electricity markets using a hybrid forecast method. *Energy Conversion and Management*, 52, 2165–2169.
- Mohamed, S., McCowan, A.K. (2001). Modelling project investment decisions under uncertainty using possibility theory. *International Journal of Project Management*, 19 (4), 231-241.
- Mukherjee, A., Biswas, S.N. (1997). Artificial neural networks in prediction of mechanical behavior of concrete at high temperature. *Nuclear Engineering and Design*, 178, 1–11.
- Mun, J. (2002). *Real Option Analysis Tools and Techniques for Valuing Strategic Investments and Decisions*. USA: John Wiley & Sons.
- Myers, S.C. (1974). Interactions of corporate financing and investment decisions – implications for capital budgeting. *The Journal of Finance*, 29, 1-25.

- Myers, S.C. (1977). Determinants of corporate borrowing. *Journal of Financial Economics*, 5 (2), 147-175
- Myers, S.C. (1984). Finance theory and financial strategy. *Interfaces*, 14 (1), 126-137.
- Myers, S.C., Majd, S. (1990). Abandonment value and project life. *Advances in Futures and Options Research*, 4, 1-21.
- Özoğul, C.O., Karsak, E.E., Tolga, E. (2009). A real options approach for evaluation and justification of a hospital information system. *Journal of Systems and Software*, 82 (12), 2091-2102.
- Palmer, A., Montano, J.J. & Sese, A. (2006). Designing an artificial neural network for forecasting tourism time series. *Tourism Management*, 27, 781-790
- Panda, C., Narasimhan, V. (2007). Forecasting exchange rate better with artificial neural network, *Journal of Policy Modeling*, 29, 227–236.
- Perego, A.A., Rangone, A. (1998). Reference framework for the application of MADM fuzzy techniques to selecting AMTS. *International Journal of Production Research*, 36 (2), 437-458.
- Pierru, A., Babusiaux, D. (2008). Valuation of investment projects by an international oil company: a new proof of a straightforward, rigorous method, *OPEC Energy Review*, 32 (3), 197-214.
- Reyck, B.D., Degraeve, Z., Vandendorre, R. (2008). Project options valuation with net present value and decision tree analysis. *European Journal of Operational Research*, 184, 341–355.
- Rocha, K., Salles, L., Garcia, F.A.A., Sardinha, J.A., Teixeira, J.P. (2007). Real estate and real options – a case study, *Emerging Markets Review*, 8 (1), 67-79
- Romer, C. (1992). What ended the great depression. *Journal of Economic History*, 52, 757-784
- Sameni, A., Chamkalani, A. (2018). Application of least square support vector machine as a mathematical algorithm for diagnosing drilling effectivity in shaly formations. *Journal of Petroleum Science and Technology*, 8(1), 3-16.

- Samui, P. (2011). Application of least square support vector machine (LSSVM) for determination of evaporation losses in reservoirs. *Engineering*, 3, 431-434.
- Samui, P., Sitharam, T.G. (2009). Application of least squares support vector machine in seismic attenuation prediction. *Journal of Earthquake Technology*, 46, 147-155.
- Samsudin, R., Saad, R., Shabri, A. (2011). River flow time series using least squares support vector machines. *Hydrology and Earth System Sciences*, 15, 1835-1852.
- Sarantis N., Stewart C. (1995). Monetary and asset market models for sterling exchange rates: a cointegration approach. *Journal of Economic Integration*. 10, 335-371.
- Sariaslan, H. (2010). *Yatırım Projelerinin Hazırlanması ve Değerlendirilmesi*. Ankara: Turhan Kitabevi.
- Sermpinis, G., Dunis, C., Laws, J., Georgios Sermpinis, Stasinakis, C. (2012). Forecasting and trading the EUR/USD exchange rate with stochastic Neural Network combination and time-varying leverage. *Decision Support Systems*
- Siddiqui, A.S., Marnay, C., Wiser, R.H. (2007). Real options valuation of US federal renewable energy research, development, demonstration, and deployment. *Energy Policy*, 35 (1), 265-279.
- Singhal, D., Swarup, K.S. (2011). Electricity price forecasting using artificial neural networks . *Electrical Power and Energy Systems*, 33, 550–555.
- Smit, H.T.J., Trigeorgis, L. (2006) Real Options and Games: Competition, Alliances and other Applications of Valuation and Strategy. *Review of Financial Economics*, 15(2), 95-112.
- Smit, H.T.J., Trigeorgis, L. (2007) Strategic Options and Games in Analyzing Dynamic Technology Investments. *Long Range Planning*, 40, 84-114.
- Smith, J.E., McCardle, K.F., (1999). Options in the real world: Lessons learned in evaluating oil and gas investments. *Operations Research*, 47 (1).
- Smith, J.E., Nau, R.F. (1995). Valuing risky projects: option pricing theory and decision analysis. *Management Science*, 41 (5), 795-816.
- Smola, A.J., Scholkopf, B. (2004). A tutorial on support vector regression, *Statistics and Computing* 14, 199–222



- Somarathna, P.E., Arunatilaka, S. Premarathna, L. (2010). Which is better for inflation forecasting. *Neural Networks or Data Mining, 1*, 116-121.
- Suykens, J.A.K., De Brabanter, J., Lukas, L., Vandewalle, J. (2002). Weighted Least Squares Support Vector Machines: Robustness and Sparse Approximation. *Neurocomputing, 48*, 85–105.
- Takagi, T., Hayashi, I. (1991). NN-driven fuzzy reasoning. *International Journal of Approximate Reasoning, 5*, 191–212.
- Tan, K.H., Koay, H.S., Lim, C.P., Platts, K. (2006). An intelligent decision support system for manufacturing technology investments. *International Journal of Production Economics, 104*, 179–190.
- Tang, Z., Almeida, C., Fishwick, P.A. (1991). Times series forecasting using neural networks vs. Box-Jenkins methodology. *Simulations, 57*(5), 303 -310.
- Tao, C., Jinlong, Z., Shan, L., Benhai, Y. (2007). Fuzzy real option analysis for IT investment in nuclear power station. *Lecture Notes in Computer Science, ICCS, Springer, 4489*, 953-959.
- Taşkın, A., Güneri, A.F. (2006). Economic analysis of risky projects by ANNs. *Applied Mathematics and Computation, 175*, 171–181
- Trafalis, T.B, Ince, H. (2000). Support Vector Machine for Regression and Applications to Financial Forecasting. In: *IJCNN 2000: Proceedings of the IEEE-INNS-ENNS International Joint Conference on Neural Networks: Volume 6 edited by Shun-Ichi Amari, et al., içinde 6348, IEEE Computer Society.*
- Tseng, C.L., Barz, G. (2002). Short-term generation asset valuation: a real options approach. *Operations Research, 50* (2), 297-310.
- Trigeorgis, L., (1996). *Real Options: Managerial Flexibility and Strategy in Resource Allocation*. London: The MIT Press
- Trigeorgis, L. (2000) Real options: a primer. Alleman, J., Noam, E. (Eds.). *The new investment theory of real options and its implication for telecommunications economics. Springer US içinde (3-33).*
- Uçal, İ., Kahraman, C. (2009). Fuzzy Real Options Valuation For Oil Investments. *Technological & Economic Development of Economy, 15* (4), 646-669.

- Vapnik, V. N. (1998). *Statistical Learning Theory*. New York: Wiley.
- Verkooijen, W. (1996). A neural network approach to long-run exchange rate prediction. *Computational Economics*, 9, 51-65
- Wang, J., Hwang, W.L. (2007). A fuzzy set approach for R&D portfolio selection using a real options valuation model. *Omega*, 35, 247–257.
- Wang, M.J., Liang, G.S. (1995). Benefit/cost analysis using fuzzy concept. *The Engineering Economist*, 40 (4), 359-376.
- Wang, C.H., Min, K.J. (2006). Electric power generation planning for interrelated projects: a real options approach. *IEEE Transactions on Engineering Management*, 53 (2), 312-322.
- Wang, Y., Wang, B., Zhang, X. (2012). A new application of the support vector regression on the construction of financial conditions index to CPI prediction, *Procedia Computer Science*, 9, 1263 – 1272
- Ward, T.L. (1989). Fuzzy discounted cash flow analysis. Evans, G.W., Karwowski W., Wilhelm, M.R. (Eds.), *Applications of Fuzzy Set Methodologies in Industrial Engineering*, içinde (91-102).
- Weeren, A.J.T.M., Dumortier, F., Plasmans, J.E.J (1997). Exchange rate modeling by multivariate nonlinear cointegration analysis using artificial neural networks. *SESO Working Papers*, University of Antwerp, Applied Economy of Sciences
- Wei, C.H., Lee, Y. (2007). Sequential forecast of incident duration using Artificial Neural Network models. *Accident Analysis and Prevention*, 39, 944–954.
- Weigend, A.S., Huberman, B.A., Rumelhart, D.E. (1991). Generalization by weight-elimination with application to forecasting. *Advances in Neural Information Processing Systems*, 3, 875 - 882.
- Won, C. (2009). Valuation of investments in natural resources using contingent-claim framework with application to bituminous coal developments in Korea. *Energy*, 34 (9), 1215-1224.
- Wu, L.C., Ong, C.S., Hsu, Y.W. (2008). Active ERP implementation management: A real options perspective. *Journal of Systems and Software*, 81, 1039–1050.

- Wu, M.C., Tseng, C.Y. (2006). Valuation of patent: a real options perspective. *Applied Economics Letter*, 13 (5), 313-318.
- Wu, F.Y., Yen, K.K. (1992). Applications of neural network in regression analysis. *Computers and Industrial Engineering*, 23, 93-95.
- Xu, X., Law, R., Chen, W., Tang, L. (2016). Forecasting tourism demand by extracting fuzzy TakagieSugeno rules from trained SVMs. *CAAI Transactions on Intelligence Technology*, 1, 30-42
- Xie, C., Shao, C., Zhao, D. (2011). Parameters optimization of least squares support vector machines and its application. *Journal of Computers*, 6, 1935-1941
- Yamin, H.Y., Li, Z., Shahidehpour, S.M. (2004). Adaptive short-term electricity price forecasting using artificial neural networks in the restructured power markets. *Electrical Power Energy Systems*, 26, 571–581.
- You, C.J., Lee, C.K.M., Chen, S.L., Jiao, R.J. (2012). A real option theoretic fuzzy evaluation model for enterprise resource planning investment. *Journal of Engineering and Technology Management*, 29, 47-61.
- Yu, L., Lai, K.K., Wang, S. (2008). Forecasting crude oil price with an EMD-based neural network ensemble learning paradigm. *Energy Economics*, 30, 2623–2635.
- Zadeh, L. A. (1999). Fuzzy sets as a basis for a theory of possibility. *Fuzzy Sets and Systems*, 100, 9–34.
- Zadeh, L.A. (2005). Toward a generalized theory of uncertainty (GTU) – an outline. *Information Sciences*, 172, 1–40.
- Zadeh, L.A. (2008). Is there a need for fuzzy logic? *Information Sciences*, 178, 2751–2779.
- Zapata, J.C., Reklaitis, G.V. (2010). Valuation of project portfolios: An endogenously discounted method, *European Journal of Operational Research*, 206 (3), 653-666.
- Zeng, M., Wang, H., Zhang, T., Li, B., Huang, S. (2007). Research and application of power network investment decision-making model based on fuzzy real options, in *Service Systems and Service Management, International Conference on 9–11 June*, 1-5.
- Zhang, G.P. (2001). An investigation of neural networks for linear time-series forecasting. *Computers & Operations Research*, 28, 1183-1202

- Zhang, G.P. (2004). Business Forecasting with Artificial Neural Networks: An Overview, in: G. Peter Zhang (Ed.). *Neural Networks in Business Forecasting*, içinde (1-22)
- Zhang, G., Hu, M.Y., Patuwo, B.E. (1998). Forecasting with artificial neural networks: The state of the art. *International Journal of Forecasting*, 14, 35–62.
- Zhang, L., Luo, J., Yang, S. (2009). Forecasting box office revenue of movies with BP neural network. *Expert Systems with Applications*, 36, 6580–6587.

