

Uzmanlık Tezleri Serisi No: 180

# REKABET KURUMU

REKABET POLİTİKASI  
ÇERÇEVESİNDE GİZLİ  
ALGORİTMİK ANLAŞMALAR,  
MAKİNE ÖĞRENME VE  
YAPAY ZEKÂ

ENDER YILDIZ

**REKABET POLİTİKASI  
ÇERÇEVESİNDE GİZLİ  
ALGORİTMİK ANLAŞMALAR,  
MAKİNE ÖĞRENME VE YAPAY  
ZEKÂ**

*ENDER YILDIZ*

Ağustos 2020

©Bu eserin tüm telif hakları  
Rekabet Kurumuna aittir. 2020

Baskı, Ağustos 2020  
Rekabet Kurumu-ANKARA

Bu kitapta öne sürülen fikirler eserin yazarına aittir;  
Rekabet Kurumunun görüşlerini yansıtmaz.

Bu tez, Rekabet Kurumu Başkan Yardımcısı Abdulgani GÜNGÖRDÜ, Rekabet Kurumu Başkan Yardımcısı Kürşat ÜNLÜSOY, Bilgi Yönetimi Dairesi Başkanı Haluk Recai BOSTAN, Prof. Dr. Mahmut YAVAŞI ve Doç. Dr. Fatih Cemil ÖZBUĞDAY'dan oluşan Tez Değerlendirme Heyeti tarafından 30 Eylül 2019 tarihinde yürütülen Tez Savunma Toplantısı sonucunda yeterli ve başarılı kabul edilmiştir.

Tez yazarı Ender YILDIZ, 24.01.2020 tarihinde yapılan Yeterlik Sınavında başarılı olmuş ve Başkanlık Makamının 06.02.2020 tarih ve 2252 sayılı onayı ile Rekabet Uzmanı olarak atanmıştır.

YAYIN NO

363

## İÇİNDEKİLER

<b>KISALTMALAR</b> .....	v
<b>GİRİŞ</b> .....	1

### BÖLÜM 1 ALGORİTMALAR VE ANLAŞMALAR

1.1. ALGORİTMALAR VE PAZARLAR.....	5
1.2.1. Algoritmalar.....	6
1.2.1.1. İzleme Algoritmaları.....	7
1.2.1.2. Paralel Algoritmalar.....	8
1.2.1.3. Sinyal Algoritmaları.....	9
1.2.1.4. RL, ML ve DL Algoritmaları.....	10
1.2. ALGORİTMA, ANLAŞMA VE KÖTÜYE KULLANMA.....	12
1.2.1. Haberci Senaryosu.....	13
1.2.2. Topla ve Dağıt Senaryosu (Hub & Spoke).....	16
1.2.3. Makineden Makineye (M2M) İletişim ve ML, DL Algoritmaları ....	18
1.2.3.1. Rekabeti Sınırlayıcı Anlaşmalar Kapsamında Değerlendirilmesi.....	19
1.2.3.2. Hâkim Durumun Kötüye Kullanılması Kapsamında Değerlendirilmesi.....	20
1.2.4. Gizli Anlaşma Senaryosu.....	21
1.3. BÖLÜM DEĞERLENDİRMESİ.....	22

### BÖLÜM 2 YAPAY ZEKÂ (AI) UYGULAMALARI

2.1. AIRBNB ML FİYAT TAHMİN UYGULAMASI.....	24
2.2. PROBLEM TANIMLAMA.....	26
2.3. PROBLEM ÖZELLİKLERİ.....	27
2.3.1. Amaç.....	28
2.3.2. Değişkenler.....	28
2.3.3. Girdi ve Çıktılar.....	28

2.4. YAPI İSKELETİ SEÇİMİ.....	29
2.5. GÖRSELLEŞTİRME .....	30
2.5.1. Histogram .....	31
2.5.2. Sıcaklık Haritası .....	32
2.6. VERİ ANALİZİ .....	33
2.6.1. Veri Toplama.....	35
2.6.2. Veri Temizleme.....	35
2.6.3. Veri İşleme.....	36
2.7. ÖĞRENMEYİ GERÇEKLEŞTİRME (APPLY LEARNING).....	37
2.7.1. ML Algoritmasının Modellenmesi .....	37
2.7.1.1. Xgboost Modeli ve Eğitilmesi .....	39
2.7.1.2. Ağaçların Artırılması (Tree Boosting) .....	40
2.7.2. DL Algoritmasının Modellenmesi .....	44
2.8. MODEL BAKIMI (MODEL MAINTANCE) .....	47
2.8.1. İstatistik ve Olasılık.....	48
2.8.1.1. Normal Dağılım (Normal Distribution, Gauss Distribution). 48	
2.8.2. Model Hata Hesaplama .....	50
2.9. BÖLÜM DEĞERLENDİRMESİ.....	53
2.9.1. Airbnb Uygulama Sonuçlarının Hâkim Durumun Kötüye Kullanılması Bağlamında Değerlendirilmesi.....	54

### **BÖLÜM 3**

#### **ALGORİTMALAR VE DENEYSEL ÇALIŞMALAR**

3.1 OYUN TEORİLERİ .....	56
3.1.1. Fiyatların Kontrollü Artırılması.....	57
3.1.2. Cournot Yarışması .....	57
3.1.3. Mahkûm İkilemi .....	58
3.2. RL ALGORİTMALARI VE EKONOMİK DENEYLERDE KULLANILMASI.....	58

3.3. Q-ÖĞRENME ALGORİTMASIYLA YAPILAN DENEYLERİN ANALİZLERİ .....	60
3.4. Q-ÖĞRENME ALGORİTMALARININ GİZLİ ANLAŞMAYI SÜRDÜRME İSTEĞİNİN ANALİZİ .....	63
3.5. BÖLÜM DEĞERLENDİRMESİ.....	64

## BÖLÜM 4

### ALGORİTMİK ANLAŞMALAR VE REKABET POLİTİKALARI

4.1. ABİDA 101. VE 102. MADDELERİ KAPSAMINDA ALGORİTMİK ANLAŞMALARIN DEĞERLENDİRİLMESİ.....	69
4.1.1. Haberci Senaryosu.....	69
4.1.2. Topla ve Dağıt (Hub & Spoke).....	69
4.1.3. Gizli Anlaşma .....	70
4.2. ABD VE YASA ÇALIŞMALARI.....	70
4.3. ALGORİTMİK ANLAŞMALARIN DEĞERLENDİRİLMESİNE İLİŞKİN TÜRK REKABET KURUMUNA ÖNERİLER.....	71
SONUÇ.....	73
ABSTRACT .....	78
KAYNAKÇA .....	79

#### Şekil Dizini

Şekil 1: İzleme Algoritması.....	8
Şekil 2: Paralel Algoritma .....	9
Şekil 3: Sinyal Algoritması.....	10
Şekil 4: ML ve DL Algoritmaları .....	11
Şekil 5: Topla ve Dağıt (Hub & Spoke) Senaryosu.....	17
Şekil 6: Makineden Makineye (M2M) İletişim ve ML, DL Algoritmaları (M2M Communication and ML, DL Algorithms) .....	19
Şekil 7: Gizli Anlaşma Senaryosu (Tacit Collusion) .....	21
Şekil 8: ML İş Akışı.....	26
Şekil 9: Problem Tanımlamanın Problem Özellikleriyle İlişkisi.....	27

<b>Şekil 10:</b> Kullanılan Kütüphaneler .....	29
<b>Şekil 11:</b> Görselleştirme Metotları.....	31
<b>Şekil 12:</b> Fiyata Bağlı İlan Sayısı .....	32
<b>Şekil 13:</b> Sütunlar Arası Bağlılık.....	33
<b>Şekil 14:</b> Veri Analiz Bileşenleri .....	34
<b>Şekil 15:</b> Eksik Verilerin Sütunlardaki Oranları .....	36
<b>Şekil 16:</b> Xgboost, Regresyon Ağaç Topluluğu.....	39
<b>Şekil 17:</b> XGBoost Modeli Tarafından Belirlenen Sütunların Önem Derecesi. 42	
<b>Şekil 18:</b> Airbnb Fiyat Tahmini .....	43
<b>Şekil 19:</b> Airbnb Gerçek Fiyatlar.....	43
<b>Şekil 20:</b> Airbnb Gerçek Fiyatlar ile Tahmin Edilen Fiyatların Uygunluğu .....	44
<b>Şekil 21:</b> Bir Gizli Katmanlı Yapay Sinir Ağının Yapısı .....	45
<b>Şekil 22:</b> DL Aktivasyon Fonksiyonları (Géron, 2019, 289) .....	45
<b>Şekil 23:</b> DL Algoritmasının Eğitimi ve Elbow .....	47
<b>Şekil 24:</b> Veri İşlenmeden Önceki Normal Dağılım (Gaussian Distributions).. 49	
<b>Şekil 25:</b> Veri İşlendikten Sonraki Normal Dağılım (Gaussian Distributions) . 50	
<b>Şekil 26:</b> RL Çalışma Prensipleri.....	59
<b>Tablo Dizini</b>	
<b>Tablo 1:</b> Algoritmaların Anlaşılmalardaki Rollerinin Özeti .....	12
<b>Tablo 2:</b> DL Katman Yapısı.....	46
<b>Tablo 3:</b> ML Model RMSLE Skor .....	52
<b>Tablo 4:</b> Algoritma ve Rekabet İhlalleri.....	67

## KISALTMALAR

<b>AB</b>	: Avrupa Birliđi
<b>ABAD</b>	: Avrupa Birliđi Adalet Divanı
<b>ABD</b>	: Amerika Birleşik Devletleri
<b>ABİDA</b>	: Avrupa Birliđinin İşleyişine Dair Anlaşma
<b>AI</b>	: Artificial Intelligence (Yapay Zekâ)
<b>Bkz.</b>	: Bakınız
<b>CART</b>	: Classification and Regression Trees (Sınıflandırma ve Bağlanım Ağaçları)
<b>DL</b>	: Deep Learning (Derin Öğrenme)
<b>DOJ</b>	: Department of Justice
<b>FTC</b>	: Federal Trade Commission
<b>Kanun</b>	: 4054 Sayılı Rekabetin Korunması Hakkında Kanun
<b>Komisyon</b>	: Avrupa Birliđi Komisyonu
<b>KRR</b>	: Kernel Ridge Regression (Çekirdek Sırt Bağlanım)
<b>Kurul</b>	: Rekabet Kurulu
<b>LASSO</b>	: Least Absolute Shrinkage Selector Operator (En Az Mutlak Çekme Seçici Operatörü)
<b>M2M</b>	: Machine to Machine (Makineden Makineye)
<b>ME</b>	: Mean Error (Ortalama Hata)
<b>ML</b>	: Machine Learning (Makine Öğrenmesi)
<b>MSE</b>	: Mean Squared Error (Ortalama Kare Hata)
<b>OECD</b>	: The Organisation for Economic Co-operation and Development (Ekonomik İşbirliđi ve Kalkınma Teşkilatı)
<b>R<sup>2</sup></b>	: Coefficient of Determination (Öğrenme Katsayısı)
<b>RL</b>	: Reinforcement Learning (Pekiştirmeli Öğrenme)
<b>RHKH</b>	: Rekabetin Korunması Hakkında Kanun

<b>RMSE</b>	: Root Mean Square Error (Kök Ortalama Kare Hata)
<b>RMSLE</b>	: Root Mean Square Logarithmic Error (Kök Ortalama Kare Logaritmik Kare Hata)
<b>Vb.</b>	: Ve Benzeri
<b>Vd.</b>	: Ve Diğerleri
<b>YSA</b>	: Yapay Sinir Ağları
<b>XGBoost</b>	: Extreme Gradient Boost (Aşırı Artırılmış Eğitim)

## GİRİŞ

Son zamanlarda e-ticaret, sağlık, sinema, otel, ulaşım, reklam ve perakende sektöründe yaşanan en önemli gelişmelerden biri, insanlar tarafından belirlenen fiyatların yerine, algoritmaların başrolde etkili olduğu *Artificial Intelligence* (AI) uygulamalarının fiyatları dinamik olarak belirlemesidir. ABD ve Avrupa'nın en büyük e-ticaret sitesi olan Amazon.com, Inc (Amazon), algoritmalar aracılığıyla çok büyük miktardaki çevrimiçi işlem hacmini yönetmekte ve yüz milyonlarca üründeki fiyat değişimlerini sürekli olarak izlemektedir (Synced 2018). Bu sayede Amazon dinamik fiyatlandırma için gerekli olan verileri de kendiliğinden elde etmektedir. Algoritmik fiyatlandırmanın etkisinin daha iyi anlaşılması için yapılan bir araştırmada Amazon'dan rastgele seçilen yüz ürünün fiyatının bir yıl boyunca yüzde 260'a kadar değiştiği belirtilmektedir.<sup>1</sup> Bu kadar yüksek orandaki değişimlerin takibinin insan tarafından yapılmasının zor oluşu Amazon'daki algoritmik satıcıların zaman içerisinde avantajlarını giderek artırmış ve dolayısıyla Amazon'un en çok satanların tekliflerinin sergilendiği ürün sayfası olan *Amazon Satın Alma Kutusu*'nda daha çok algoritmik satıcıların ön plana çıkmasıyla sonuçlanmıştır. Böylelikle belirli ürün kategorilerinde *hepsini al* "winner-take-all"<sup>2</sup> senaryosu da gün yüzüne çıkmaya başlamıştır. Algoritmik fiyatlandırmanın böylesine güçlü yanlarının giderek belirginleşmesi bu yöntemin yakın gelecekte daha yaygın hale gelmesini sağlayacaktır.

---

<sup>1</sup> Bu araştırma Amazon'dan rastgele seçilen yüz ürünün fiyatının bir yıl boyunca yüzde 260'a kadar değiştiğini göstermiştir (Synced 2018).

<sup>2</sup> Hepsini al, herkese açık bir pazarda, en iyi performans gösteren oyuncuların ödülleri çok büyük bir bölümünü alabildikleri ve geri kalan rakiplerin çok az kaldığı bir pazar olarak tanımlanmaktadır (Kenton 2018).

Daha önceleri kullanılan düşük kazançlı dinamik fiyatlandırma algoritmalarının yerine günümüzde yüksek kazanç sağlayan *Reinforcement Learning* (RL<sup>3</sup>) uygulamaları daha fazla kullanılmaktadır. Bu tür uygulamalar önkçkilerine göre fiyatlandırma stratejilerine sıfırdan başlamakta ve deęişen ortam şartlarına uyum sağlamaktadır. RL algoritmaları öğrenme aşamasından başlayarak sürecin sonuna kadar dışarıdan neredeyse hiç yardım almadan algoritmik fiyatlandırma sürecini başarılı bir şekilde tamamlamaktadır. Algoritmik fiyatlandırmada sağlanan bu başarı RL algoritmalarının sürekli bir şekilde gelişmesine katkı sağlamaktadır.

RL uygulamalarının çok hızlı bir şekilde gelişiminin ardından yaygınlaşması rekabet politikası için bazı kaygılara neden olmuştur (Harrington 2017). Yapılan deneylerde<sup>4</sup> RL algoritmalarının rekabetçi bir ortamda birbirleriyle iletişim kurmadan öğrenimini tamamlamaları sağlanmıştır. Bu öğrenmenin sonucunda RL algoritmaları kendi aralarında bir gizli anlaşma oluşturabilmiştir. Söz konusu durum rekabet hukuku kapsamında çeşitli tartışmaları gündeme getirmiştir.<sup>5</sup> Bu tartışmaların odak noktasını kendi kendine öğrenen algoritmaların fiyat belirleme oligopollerinde karlarını en üst düzeye çekecek bir dengeyi en uygun yol stratejisini kullanarak çok hızlıca öğrenebilecekleri üzerine yoğunlaşmaktadır (Schwalbe 2018, 9).

AI fiyatlandırma algoritmalarının arasında oluşabilecek bir gizli anlaşmanın varlığından bahsedebilmek için rekabet hukuku bağlamındaki çalışmalar genellikle deneysel ve teorik açıdan cevaplar aranmaktadır. Deneysel olarak bu konuda cevaplar arandığında yazılım firmalarının oluşturdukları AI uygulama kodlarını paylaşmadığı ve sektörlerin pazar yapılarının anlaşılmasının zorluklarıyla

<sup>3</sup> RL, sayısal bir ödül sinyalinin en üst düzeye çıkarmak için ne yapılacağını (durumları eylemlerle nasıl eşleştireceğini) öğrenmesi olarak tanımlanmaktadır. Algoritmaya hangi eylemlerin gerçekleştirileceği bilgisi verilmemekte bunun yerine hangi eylemlerin en çok ödül ile sonuçlanacağını denemeleri sağlanmaktadır. Bu senaryoda, en ilginç ve zorlu durumlarda eylemlerin o anki alacağı ödülü değil, bir sonraki durumu ve bundan sonraki tüm ödülleri de etkileyebilmektedir. Bu iki özellik (gecikmeli ödül), RL'nin en önemli ayırt edici özelliğini oluşturmaktadır (Sutton ve Barto 2017, 1).

<sup>4</sup> Deneyler, gizli anlaşmaların oluşumuna sebebiyet veren Q-öğrenme algoritmaları üzerine yapılmaktadır.

<sup>5</sup> Ezrachi / Stucke (2015, 2016a, 2016b, 2017), Mehra (2015), Oxera (2017), Pasquale (2005, 2016), Woodcock (2017), Avrupa Komisyonu Üyesi M. Vestager'in görüşleri, Bundeskartellamt 18. Rekabet Konferansı'nda, Berlin, Mart 16, 2017 ("Algorithms and Competition") ve FTC Başkan Vekili M. Ohlhausen'in konuşması, Mali Sektör Konferansında, New York, Mayıs 23, 2017 ("Should We Fear the Things That Go Beep in the Night? Some Initial Thoughts on the Intersection of Antitrust Law and Algorithmic Pricing").

karşılaştığı anlaşılmaktadır (Decarolis ve Rovigatti 2017, 2). Teorik açıdan ele alındığında ise RL algoritmaları arasında muhtemel bir gizli anlaşmayı ortaya çıkarma çabasının çok karmaşık bir yapıda olması gerektiği anlaşılmaktadır.

Bu çalışma kapsamında yukarıda bahsi geçen durumların ne şekilde rekabet karşıtı bir ihlalin parçası olabileceği durumların anlaşılabilmesi için RL algoritmasının gelişmiş hali olan Q-öğrenme<sup>6</sup> (Q-learning) algoritmalarının kullanıldığı bir deneyden bahsedilmektedir (Calvano vd. 2019). Bu çalışma kapsamında, AI algoritmalarının yapısını bu günlere gelmesini sağlayan bütün bileşenlerinin tanımı yapılmakta ve bu bileşenler ile pazar yapısını ne şekilde analiz edildiğine dair ML algoritmalarına, veri bilimine ve olasılık konularına detaylı bir şekilde bahsedilmektedir.

Deneylerin<sup>7</sup> sonuçları basit fiyatlandırma algoritmalarının bile belirli bir mantık çerçevesinde ortak stratejiler kullanmayı öğrendiğini göstermektedir. Gerçek çevre koşulları için deneyde ayrıca ceza mekanizmaları kullanılarak fiyatlarda fiyat dengesinden sapmalar meydana getirilmektedir. Oluşan sapmaların kısa süre içerisinde algoritmaların sapma öncesi fiyatlara kademeli bir şekilde geri döndüğünü ortaya çıkarmaktadır. Bunlara ilaveten deneydeki oyuncu sayısının artırılması, asimetrik firma eklenmesi ya da olasılıklı ortamda bile algoritmaların oluşturduğu gizli anlaşmayı sürdürebildikleri görülmektedir.

Sonuç olarak algoritmik gizli anlaşmaların ispatının zorluğu, rekabet hukuku kapsamında ihlal olarak değerlendirilmeleri için gerekli ispat yükü sorununu gündeme getirmektedir. Ayrıca bu anlaşmaların yanlış doğrular (*false pozitif*) üretebilmesi ihtimalinin varlığı, ABD ve Avrupa Birliği ülkelerde hala yasa dışı sayılmamasına neden olmaktadır. Bu sebeple AI fiyatlandırmasının ihlale söz konusu olabilmesi için öncelikle daha fazla araştırma ve iktisadi analiz yapılması gerekmektedir.

Son yıllarda rekabet hukukunda yaşanan gelişmeler dikkate alınarak, bu çalışma kapsamında, algoritmik fiyatlandırmanın rekabet hukuku uygulamalarındaki rolü ve bu bağlamda ihlal oluşturabilecek durumlar

---

<sup>6</sup> Q-öğrenme, başlangıçta Markov karar süreçleriyle başa çıkmak için tasarlanmış olsa da, tekrarlanan oyunlarda da uygulanabilmektedir (Calvano vd. 2019, 5).

<sup>7</sup> Q-öğrenme ile gizli anlaşmaların ortaya çıkarılması için yürütülen çalışmalar kastedilmektedir.

değerlendirilecek; algoritmik fiyatlandırmada kullanılan AI uygulamaları incelenerek ihlale konu olabilecek durumların neler olduğu sorusuna cevap aranacaktır. Bu doğrultuda, ilk bölümde öncelikle, algoritmik fiyatlandırmalarda kullanılan senaryolar ve gizli anlaşmaların teorik çerçevesi çizilerek, algoritmik fiyatlandırma kavramı açıklanacaktır. Sonrasında algoritmik fiyatlandırmanın pazar üzerine etkileri ele alınacaktır. Çalışmanın ikinci bölümünde, AI uygulamalarının bütün bileşenleri tek tek incelenerek algoritmik fiyat tahminin nasıl yapıldığına yer verilecektir. Üçüncü bölümde ise RL algoritmalarıyla rekabet hukuku kapsamında ihlal oluşturabilecek gizli bir anlaşmanın olduğu örnek bir deney üzerinde tartışılacak ve bu kapsamda değerlendirmelerde bulunulacaktır. Son olarak, önceki bölümlerde yapılan değerlendirmeler ışığında, hızla gelişmekte olan algoritmik fiyatlandırmanın rekabet hukuku içerisindeki yeri ve alınacak önlemlerin ne olması gerektiği tartışılacaktır.

## BÖLÜM 1

### ALGORİTMALAR VE ANLAŞMALAR

Fiyatlandırma algoritmaları hakkında rekabet hukuku bağlamında iki önemli konu üzerinde tartışmalar yoğunlaşmaktadır (Schwalbe 2018, 3). Bunlardan ilki tüketici tercihleri, satın alma alışkanlıkları ve arama geçmişleri vb. bilgilerinin tutulduğu büyük verinin (*big data*) algoritmalar aracılığıyla tüketicilerin ödeme yapma isteklerini artırmak için kullanılması olarak tanımlanmaktadır. Ayrıca bu durum teşebbüslerin kârlarını daha da artırmasını sağlayacak kişiselleştirilmiş fiyat<sup>8</sup> için de gerekli ortamı sağlamaktadır. İkinci olarak ise algoritmaların rakip algoritmalar ile rekabet etmek yerine pazarda ortak ve eşgüdümlü davranışlar sergilemesi şeklinde belirlenmektedir. Bu bilgiler ışığında tez, algoritmik gizli anlaşmaları odak noktasına alarak algoritmaların davranışları sonucunda oluşan rekabet sorunlarını derinlemesine incelemektedir.

#### 1.1. ALGORİTMALAR VE PAZARLAR

Algoritmalar, pazarda ortak bir davranış üzerinde genellikle iki farklı şekilde etki oluşturmaktadır. Bu davranışlardan ilki piyasa koşullarını olası bir anlaşmanın oluşmasını kolaylaştıracak yönünde etkilemesidir. Algoritmalar bu kolaylaştırma işlevini yerine getirirken öncelikle rakip teşebbüslerin fiyatlarını piyasadan toplayarak ve analiz ederek işe başlamaktadır. Bu sürecin sonucunda algoritmalar piyasanın şeffaflaşmasını artırıcı bir etkide bulunmakta ve ortak fiyattan ayrılmaları hızlı ve kolayca tespit edebilmektedir (Oxera 2017, 17). Ayrıca algoritmalar, ani fiyat değişikliklerine hızlıca tepki verebildikleri için ortak fiyatta oluşabilecek sapmaları çok hızlı bir şekilde belirleyebilmektedir. Bu durum örneğin kartel fiyatının tespitini ve kartel denetimini kolaylaştırmakta; kartelden ayrılmayı (*cheating*) ise zorlaştırmaktadır.

<sup>8</sup> Kişiselleştirilmiş fiyatlandırma, teşebbüslerin fiyatları bireyler hakkında gözlemlenen ve elde edilen bilgilere dayanarak uyarladıklarında ortaya çıkmaktadır (OECD 2018, 3).

İkinci etkisi ise ağ etkileri<sup>9</sup> ve ölçek ekonomileri ile karakterize edilen birçok çevrimiçi platform teşebbüslerinin fiyatlandırma algoritmalarını kullanmasından kaynaklanmaktadır (Schwalbe 2018, 4). Bu tür teşebbüsler fiyatlandırma algoritmaları sayesinde toplanan verinin hacmini ve hızını artırmasıyla yeni gelenlerin pazara girmesini “*veri giriş engeli*” (data barrier to entry<sup>10</sup>) yaratarak zorlaştırmaktadır.

Algoritmalar, pazar üzerinde olumsuz etkilerinin yanı sıra olumlu etkilerde de bulunabilmektedir. Bunların başında fiyatlandırma işlemini yaparken insan faktörünü ortadan kaldırıp fiyatların daha kolay bir şekilde hesaplanması ve fiyatların değişen talep koşullarına daha kolay uyulanabilmesi gelmektedir. Bu sayede arz ve talep koşullarındaki anlık değişiklikleri yansıtarak piyasa etkinliğine olumlu katkı sağlamaktadır. Bir diğer olumlu katkısı ise piyasanın şeffaflığı artıkça, tüketiciler için de gerçek fiyatlar hakkında kolay erişim imkânı sunulması gelmektedir. Dolayısıyla, fiyat karşılaştırma siteleri tüketicilere neredeyse gerçek zamanlı fiyatlar ve satıcılar hakkında bilgiler sunabilmektedir (Gal ve Elkin-Koren 2016, 6). Bu da bir piyasa aksaklığı niteliğindeki asimetrik enformasyon sorununa önemli bir çözüm olarak ortaya çıkmaktadır. Ayrıca, pazarları izlemek ve olağandışı fiyatlama davranışını tespit etmek için rekabet otoriteleri tarafından da izleme algoritmaları da kullanılmakta; böylece alışılmadık fiyatlama davranışları ve anormallikleri tespit edilmekte ve rekabetçi sorunlar, örneğin kartel veya ortak davranışlar taranabilmektedir. Bu konu hakkında daha detaylı bilgilere dördüncü bölümde ayrıca yer verilmektedir.

### 1.2.1. Algoritmalar

Dijital ekonomide yaşanan son gelişmelerin fiyat algoritmalarının<sup>11</sup> yeteneklerine olan katkıları göz önüne alındığında, pazarların rekabet otoriteleri

---

<sup>9</sup> Ağ etkisi, bir ürün veya hizmetin, kullanıcı sayısı artıkça daha değerli hale gelmesini ya da kullanıcı sayısının iyi bir şekilde artması, ağın değerini artıran tamamlayıcı ürün veya hizmetlere yol açmasını ifade etmektedir (Graef 2016, 44).

<sup>10</sup> Veri giriş engeli, mevcut büyük veri sağlayıcıların karşısında piyasaya yeni girenlerin verilere erişimde ciddi bir dezavantajda buldukları durumu ifade etmektedir (Tuck ve Wellford 2014, 1).

<sup>11</sup> Bir algoritma, girdi olarak bazı değerleri veya değer kümesini alan ve çıktı olarak değer veya bazı değerler üreten, iyi tanımlanmış herhangi bir hesaplama prosedürü olarak belirtilmektedir. Bir algoritma bu nedenle girdiyi çıktıya dönüştüren bir dizi işlemsel adımdan oluşmaktadır (Cormen vd. 2001, 5).

tarafından sürekli olarak izlenmesi ve oluşabilecek herhangi bir gizli anlaşmanın varlığının tespit edilmesine yönelik ihtiyaç artmaktadır. Fiyatlandırma algoritmalarının açık piyasalarda sürekli kullanımının artmasıyla beraber piyasa şeffaflığının da artması söz konusu olmakta bu durum ise teşebbüslere fiyatlandırma stratejilerinde ortaklaşa hareket etme ve kârlarını artırma imkânı sağlamaktadır.

Algoritmaların piyasa şartlarını değiştirmesinin yanı sıra bir diğer olası rekabet kaygısı ise tespiti kolay olan açık anlaşmalar ile tespiti daha zor olan gizli anlaşmalar arasındaki gri alanı giderek genişletmesi oluşturmaktadır. Bu durum, teşebbüslerin aralarında anlaşma yapma veya rekabet etmelerine gerek kalmadan kârlarını artırma fırsatı sağlamaktadır. Bir başka deyişle sadece açık iletişim üzerinden kurulan algoritmik bir anlaşma aracılığıyla öğrenilen ortak fiyatlama politikası, ileride oluşabilecek gizli bir anlaşmanın temellerini oluşturabilmektedir. Dolayısıyla teşebbüsler fiyatlar üzerindeki insan etkileşimini ortadan kaldırmakta ve fiyat davranışlarının izlenmesi için yeni otonom sistemlerinin kurulmasına olanak sağlamaktadır. Sonuç olarak teşebbüsler, aralarındaki açık iletişimi zamanla gizli anlaşmalara dönüştürme kapasitesine sahip olmaktadır.

İlerleyen bölümlerde, kullanılan çeşitli algoritma türleri ve bu algoritmalar aracılığıyla yapılan anlaşmalar, akış diyagramları eşliğinde gösterilerek daha detaylı açıklanacaktır.

### **1.2.1.1. İzleme Algoritmaları**

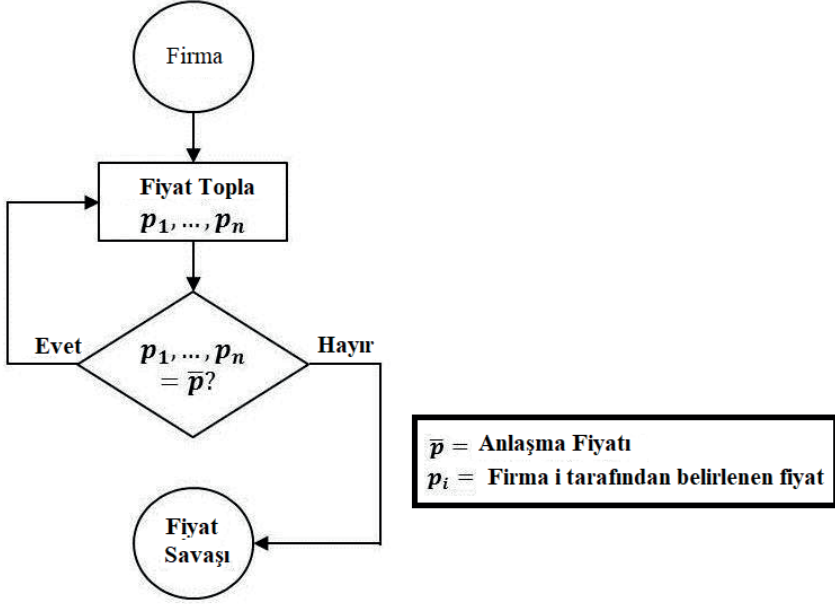
İzleme algoritmaları, piyasadan veri toplamının zorluklarını aşarak sürece başlamaktadır (OECD 2017, 27). Veri toplama işlemi web ortamında fiyat karşılaştırma işlemi yapan internet siteleri ya da yazılımlar<sup>12</sup> aracılığıyla yapılmaktadır. Veri toplama işleminin ardından anlaşma fiyatı belirlenmektedir. Böylece anlaşma sürecine fiilen geçilmektedir. Anlaşma süreci boyunca piyasadan veri toplama işleminin devam etmesi ve bu sürecin algoritmalar tarafından sürekli izlenmesi sebebiyle algoritmalar tarafından sapmalar çok hızlı bir şekilde belirlenebilmektedir. Şekil 1’de de görüleceği üzere piyasadan veriler toplandıktan sonra fiyat karşılaştırılması yapılmakta bir sapma olduğu tespiti yapıldığı takdirde

---

<sup>12</sup> İnternet üzerinden otomatik işlem yapan yazılımlara web bot denilmektedir (Technopedia 2019).

ise fiyat savaşı başlamaktadır. Böyle bir durumun varlığı ise anlaşmadan çıkma ihtimalini düşürmektedir. İzleme algoritmalarının kullanıldığı durumlarda fiyat savaşları uygulanmakta olan algoritmalarda meydana gelen arızalar sonucunda oluşabilmektedir.

**Şekil 1: İzleme Algoritması**



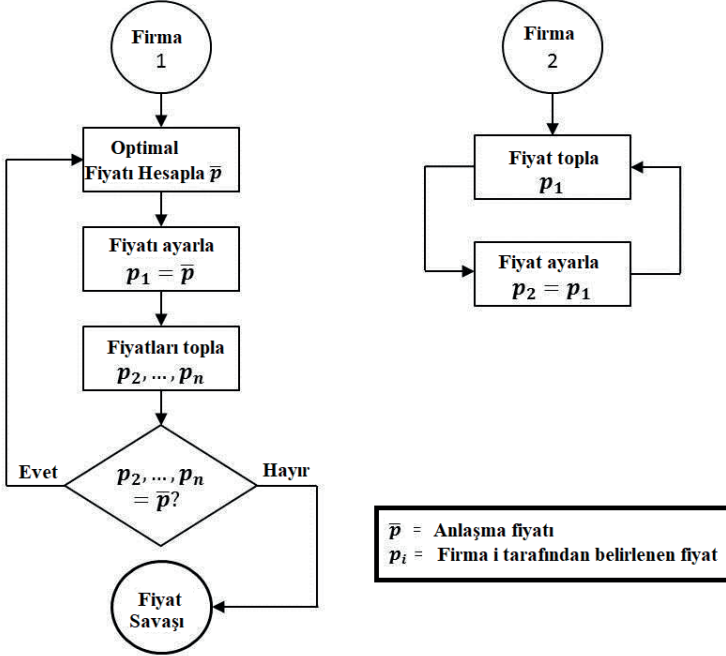
**Kaynak:** OECD (2017, 27), Algorithms and Collusion: Competition Policy in the Digital Age <http://www.oecd.org/competition/algorithms-collusion-competition-policy-in-the-digital-age.htm>, Erişim Tarihi: 10.06.2019.

### 1.2.1.2. Paralel Algoritmalar

Paralel algoritmalar başlangıçta firmalar üzerinde oluşan yoğun iş yükü sebebiyle karar alma süreçlerinin birçoğunda karar destek sistemleri kullanması sebebiyle ortaya çıkmaktadır (OECD 2017, 27). Otomatikleştirilen karar süreçlerinin çalışma prensipleri aynı şekilde olduğu için piyasada fiyatlarının aynı anda değişmesine yol açmakta böylece bilinçli paralellik sürecini de başlatmaktadır. Bu süreçte, firmaların fiyatlandırma algoritmalarını birbirleriyle paylaşması rekabet ihlali doğuracağı için bunun yerine teşebbüsler aynı bilişim firmasından danışmanlık alarak bu problemin üstesinden gelebilmektedir.

Danışmanlık alınan bilişim firması aracılığıyla aynı fiyatlandırma algoritmasının kullanımı mümkün hale gelmekte ve Şekil 2’de gösterilen lider Firma 1, Firma 2 tarafından paralel algoritma aracılığıyla sürekli bir şekilde takip edilmektedir.

**Şekil 2: Paralel Algoritma**

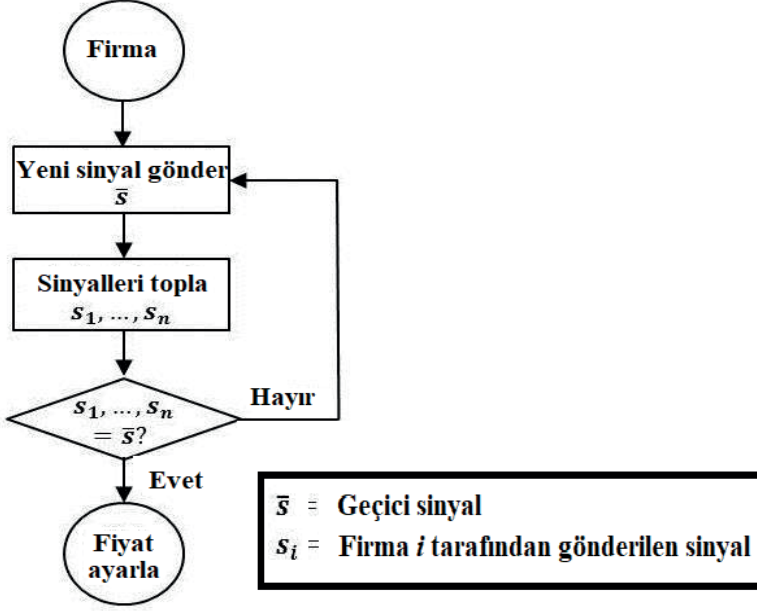


**Kaynak:** OECD (2017, 29), Algorithms and Collusion: Competition Policy in the Digital Age <http://www.oecd.org/competition/algorithms-collusion-competition-policy-in-the-digital-age.htm>, Erişim Tarihi: 10.06.2019.

### 1.2.1.3. Sinyal Algoritmaları

Sinyal algoritmaları genel olarak firmalar tarafından gönderilen sinyallerin değerlendirilmesiyle oluşmaktadır (OECD 2017, 29). Firmalar birbirlerine fiyatların yükseltileceğine dair sinyal göndermeye başladıktan sonra fiyatlarda artışlar yaşanmaktadır. Bu durum sinyallerin eşit bir değere gelmesiyle sonlanmakta ve bu fiyatta anlaşmaya varılmaktadır. Şekil 3’teki akış diyagramında gösterildiği üzere sinyaller firmalardan toplanarak değerlendirilmekte ve daha sonra eşit sinyal geldiğinde ise fiyat anlaşmasına varılmaktadır.

Şekil 3: Sinyal Algoritması



**Kaynak:** OECD (2017, 31), Algorithms and Collusion: Competition Policy in the Digital Age <http://www.oecd.org/competition/algorithms-collusion-competition-policy-in-the-digital-age.htm>, Erişim Tarihi: 10.06.2019.

#### 1.2.1.4. RL, ML ve DL Algoritmaları

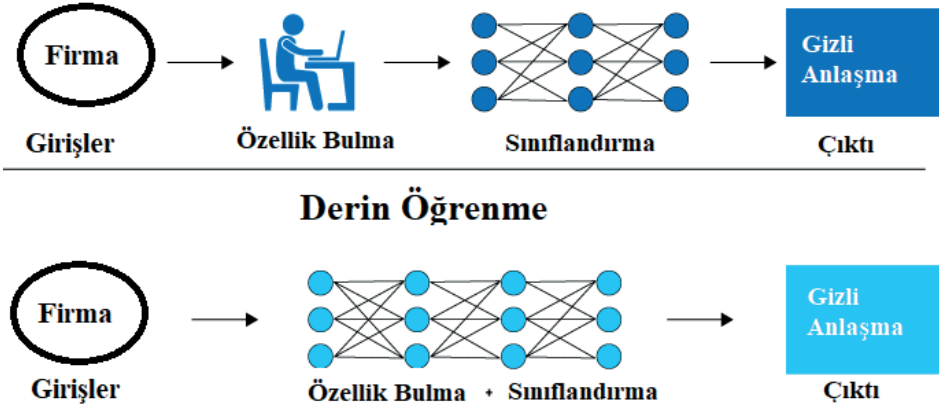
Algoritmalar arasındaki fiyat anlaşmasının en karmaşık olanları RL, ML<sup>13</sup> ve DL<sup>14</sup> algoritmaları aracılığıyla yapılmaktadır. Bu algoritmalar aralarında açık bir

<sup>13</sup> ML, bilgisayarların öngörülebilir bulunma veya robot kullanma gibi eylemlerini değiştirebilmesi veya uyarlayabilmesi olarak tanımlanmaktadır. ML, eylemlerin uyarlanması veya değiştirilmesi işlemi doğru bir şekilde sonuçlandırabilmek için ise seçilen eylemleri doğru eylemler ile karşılaştırarak sürekli bir şekilde doğruluk oranlarını ölçerek düzeltmeler yapmaktadır. Örneğin, bir bilgisayara karşı Scrabble oynanan bir senaryoda oyunun başlangıcında bilgisayar insana karşı birçok kez yenilmektedir. Ancak bu durum bilgisayarın oyunun kurallarını öğrenmesinden sonra bilgisayarın rakibini sürekli yenmesine dönüşmekte en sonunda ise bilgisayara karşı asla kazanılamayacak duruma gelmektedir. Bu durum, ya bilgisayarın rakibi daha kötüye gitmiş ya da bilgisayar Scrabble’da sürekli kazanmayı öğrenmiştir. Bilgisayarın edindiği bu tecrübeyi devam ettirebileceği ve daha sonra başka oyunculara karşı aynı stratejileri kullanabileceği ve böylece her yeni oyuncuyla sıfırdan başlamasına ihtiyaç duyulmaması ML’nin bilgisayarlara kazandırmış olduğu bir başka özelliği de oluşturmaktadır (Marsland 2015, 4).

<sup>14</sup> DL, yakın geçmişte popülerlik kazanmış yeni bir ML alanı olarak belirtilmektedir. DL, çoklu soyutlama seviyelerinde farklı özellikleri öğrenmek için çoklu gizli katmanları (derin ağlar) içeren mimarileri kullanmaktadır. DL algoritmaları aslında düşük seviyeli özellikler açısından tanımlanmış daha yüksek seviyeli öğrenilmiş özelliklerle, çoğu zaman çoklu seviyelerde iyi temsiller keşfetmek

iletişim kurmaksızın gizli anlaşma varmış gibi davranarak karlarını en üst düzeye çekebilmektedirler. Bu tür algoritmalar piyasadan edindikleri bilgileri sürekli işleyerek piyasa koşullarının ne şekilde oluştuğunu öğrenmekte, ileriye dönük gerçeğe yakın tahminlerde bulunmakta ve aralarında tıpkı bir anlaşma varmış gibi davranabilmektedir. Bunun sonucunda ise piyasada bir tekel oluşmaktadır (OECD 2017, 31). Veri setlerinde kullanılacak olan özelliklerin hangilerinin algoritmalar tarafından kullanılacağına programcılar karar veriyorsa ML algoritmaları, şayet makineler belirliyorsa DL algoritmaları kullanılmaktadır (Bkz. Şekil 4). ML ve DL algoritmaları için ikinci bölümde, RL algoritmaları için ise üçüncü bölümde detaylı bilgiler verilecektir.

Şekil 4: ML ve DL Algoritmaları



Bu bölümde yer verilen bilgiler doğrultusunda kısacası algoritmaların ne şekilde rekabet ihalelerine yol açtığı anlatılmıştır. Tablo 1’de ise algoritma türleri ve davranış özellikleri açıklanmıştır. Bundan sonraki bölümde ise fiyatlandırma algoritmalarının hangi senaryolarda kullanıldığında ne tür rekabet ihlali oluşturdukları incelenecektir.

çin girdi dağılımındaki bilinmeyen yapıdan yararlanmaya olanak sağlamaktadır (Wani vd. 2019, 2).

**Tablo 1:** Algoritmaların Anlaşmalardaki Rollerinin Özeti

Algoritma Türleri	Anlaşmalara rollerin uygulanışı
İzleme Algoritmaları	Rakip firmalardan veri toplama işlemiyle beraber analiz yapılmakta sapmalar olduğunda ise cezalandırma mekanizmaları kullanılmaktadır.
Paralel Algoritmalar	Paralel davranış kontrolü yapma, lider firmayı takip için fiyat programlama, fiyat algoritmaları paylaşma ve üçüncü taraf algoritmaları kullanma gibi adımlar kullanılmaktadır.
Sinyal Algoritmaları	Ortak politikaları toplama ve müzakere etme niyetiyle bilgileri açıklama ve dağıtma gibi adımlar kullanılmaktadır.
RL, ML ve DL Algoritmaları	Karşılıklı bağımlılığı tanıma ve diğer piyasa oyuncularının yapmış olduğu eylemlere karşılık olarak davranışını yeniden düzenleme ve kârı maksimize etme gibi adım kullanılmaktadır.

**Kaynak:** OECD (2017, 32), Algorithms and Collusion: Competition Policy in the Digital Age <http://www.oecd.org/competition/algorithms-collusion-competition-policy-in-the-digital-age.htm>, Erişim Tarihi: 10.06.2019.

## 1.2. ALGORİTMA, ANLAŞMA VE KÖTÜYE KULLANMA

Algoritmaların rakiplerin algoritmalarıyla iletişim kurması ve bilgi alışverişinde bulunması için programlanması, insan iradesinin bir uzantısı olarak görülmektedir (Ezrachi vd. 2016, 44). Algoritmalar aracılığıyla yapılan fiyat anlaşması makine düzeyinde gerçekleşse de, bunların insanlar tarafından yapılan herhangi bir kartelden farklı olmadığını ABD Adalet Bakanlığında 2015 yılında görev yapmış Bill Baer şu şekilde ifade etmektedir:

Dumanla doldurulmuş bir odada veya İnternet üzerinden karmaşık fiyatlandırma algoritmaları kullanarak gerçekleşmesi halinde rekabet karşıtı davranışa müsamaha göstermeyeceğiz. ABD’li tüketiciler, hem çevrimiçi hem de fiziki pazarlarda serbest ve adil bir pazar yeri edinme hakkına sahiptir (DOJ 2015).

Bill Bear tarafından vurgulanan karmaşık fiyatlandırma algoritmaları, *açık kartel (hard core cartel)*<sup>15</sup> yapabildiğinin yanı sıra günümüz yasalarının

<sup>15</sup> OECD, açık karteli anti-rekabetçi bir anlaşma, uyumlu bir eylem veya rakiplerin fiyatları sabitlemesi, çıktılarını sınırlandırması, teklifleri (toplu ihaleler) veya pazarları bölmek için düzenlemesi şeklinde tanımlamaktadır (OECD 2004, 9).

ulaşamayacağı gizli anlaşmaları da yapabilecek seviyeye gelmiştir. Bu karmaşık fiyatlandırma algoritmaları, *Büyük Veri* (Big Data) ve *Büyük Analitik*<sup>16</sup> (Big Analytics)'i kullanarak fiyat değişikliklerindeki izleme hızını artırabilmekte, fiyat anlaşmasında herhangi bir aldatma veya sapmayı tespit edebilmekte ve bu sapmaların cezalandırılmasında gizli anlaşmanın artması için yeni ve gelişmiş araçlar sağlayabilmektedir. Bundan sonraki bölümlerde bu araçlar sayesinde yapılan algoritmik anlaşmalar dört senaryoda tek tek detaylı bir şekilde açıklanmaktadır.

### 1.2.1. Haberci Senaryosu

Bu senaryoda, algoritmalar açık bir anlaşma yöntemi kullandığı için rekabet ihlali oluşturmaktadır. Bu, dumanla doldurulmuş bir odada insanlar tarafında yapılan bir anlaşmanın dijital karşılığıdır ve algoritmaları bilinçli bir şekilde kartelleri uygulamak ve izlemek için kullanılmaktadırlar (DOJ 2015).

Klasik bir kartelde, rakip teşebbüsten yöneticiler gizlice bir araya gelerek fiyatları değiştirmeyi, teklifleri tahsis etmeyi ve üretim miktarını düşürmeyi kabul ederler (Ezrachi ve Stucke, 2016, 39). Bu senaryoda ise yöneticiler gizlice toplandıktan sonra, yasadışı anlaşmayı izlemek ve uygulamak için algoritmaları haberci olarak kullanılmaktadırlar.

Bu senaryoya uygun David Topkins'in *Poster Kartel* kararı<sup>17</sup> ABD Adalet Bakanlığı tarafından rekabet yasa kapsamında değerlendirilmiştir. Bu kararda David Topkins'in, Amazon pazarındaki afişlerin satış fiyatlarını koordine etmek amacıyla rakip firma bilgilerini toplayan fiyatlandırma algoritması kullandığı tespit edilmiştir.

Bir başka örnek karar ise ABD'deki büyük finans firmalarının referans faiz oranlarını manipüle etmesidir.<sup>18</sup> DOJ tarafından beş bankanın (Citicorp,

---

<sup>16</sup> Büyük Veri analizi, kalıpları ve diğer faydalı bilgileri keşfetmek için büyük veri kümelerini toplama, düzenleme ve analiz etme işlemidir (Beal 2019).

<sup>17</sup> United States of America v. David Topkins, Case3:15-cr-00201 (United States District Court, Northern District Of California, San Francisco Division, 2015)

<sup>18</sup> United States of America v. Barclays Plc, Violation: 15 U.S.C. § 1 (United States District Court, District Of Connecticut, 2015)

JPMorgan Chase & Co., Barclays PLC, İskoçya Kraliyet Bankası PLC ve UBS AG) döviz kuru spot piyasasında ABD Doları ve Avro için döviz fiyatlarını manipüle ettikleri tespit edilmiştir. Citicorp, JPMorgan, Barclays ve RBS'deki aracılardan (trader<sup>19</sup>) beş yıl boyunca referans döviz kurlarını manipüle etmek için özel bir elektronik sohbet odasını ve kodlanmış bir dili nasıl kullandığı ortaya çıkarılmıştır. Bu vaka incelendiğinde ise aracılardan arasında iletişim için elektronik sohbet odalarının kullanıldığı ancak döviz kurlarının manipüle işlemine hala kendilerinin karar verdiği anlaşılmaktadır. Ancak burada edilen bilgiler sektördeki teşebbüslerce ilerleyen süreçte daha hızlı ve doğru alınabilmesi için insan kısmının yerine algoritmaların kullanılma ihtimalini artırmaktadır.

Ayrıca, Yunanistan rekabeti otoritesi rekabet karşıtı uygulamaları kolaylaştırmak için bilişim alt yapısının kullanımı ile ilgili karar vermiştir.<sup>20</sup> Yunanistan Rekabet Komisyonu, Carrefour Marinopoulos'a yeniden satış fiyatının belirlenmesi (RPM) dâhil olmak üzere birçok ihlal için 12.5 milyon Euro para cezası vermiştir. Bu cezada, Carrefour'un franchise ağı ABİDA'nın 101. maddesini ihlal ettiği tespit edilmiştir. Komisyon, kararında Carrefour'un ortak bilişim altyapısının ihlali kolaylaştırmakta oynadığı rolü de vurgulanmıştır. Franchise ağının ayrılmaz bir parçasını oluşturduğu sistem, franchise<sup>21</sup> verenin franchise alanına tavsiye ettiği yeniden satış fiyatlarının ağı toplam fiyat politikasıyla ilgili olarak perakende satış fiyatlarının uygunluğunu değerlendirmek ve sapmalarını izlemek amacıyla kullanılmıştır. Ayrıca, Komisyon söz konusu bilişim alt yapısının franchise alanlar tarafından uygulanacak fiyatları uygulamada zor ve zaman alıcı hale getirdiğini

---

United States of America v. Jpmorgan Chase & Co., Violation: 15 U.S.C. § 1 (United States District Court, District Of Connecticut, 2015)

United States of America v. The Royal Bank Of Scotland Plc, Violation: 15 U.S.C. § 1 (United States District Court, District Of Connecticut, 2015)

United States of America v. Ubs Ag, Violation: 18 u.s.c. §§ 1343 &2 (United States District Court, District Of Connecticut, 2015)

<sup>19</sup> Bir aracı (trader), kendisi veya başka bir kişi veya kurum adına, herhangi bir finansal piyasada finansal varlık alım ve satımı yapan kişi olarak tanımlanmaktadır. <https://www.investopedia.com/terms/t/trader.asp>, Erişim Tarihi:26.05.2019

<sup>20</sup> Decision No. 495/VI/2010, Greece Competition Commission v. Carrefour's Greek business (Carrefour Marinopoulos S.A.),[ 2010]

<sup>21</sup> Franchise, bir girişimcinin başka bir işletmenin ürünlerini, markasını, özel bilgilerini ve ticari sırlarını kullanmak için bir lisans satın aldığı bir anlaşma olarak tanımlanmaktadır. Bu, girişimcinin kendi markasını veya ürünlerini oluşturmadan bir işe başlamasını sağlamaktadır. <https://financial-dictionary.thefreedictionary.com/Franchise+system>, Erişim Tarihi: 26.05.2019

ve yeniden satış fiyatının belirli bir fiyatta kalmasına neden olduğunu da tespit etmiştir.

Algoritmaların kullanımına dair bir diğer örnek olan DOJ'un *Sivil Havayolu Tarifesi Yayıncılık* kararı incelendiğinde ise havayolları tarafından bilgisayarlı ücret dağıtım hizmetlerini başlangıçta çoklu pazarlarda kendi aralarında rekabet edebilen ücretleri serbestçe pazarlık etmek için kullandıkları iddia edilmiştir<sup>22</sup>. ABD'de, birçok kişi tarafından havayolu firmasının bilgisayarlı ücret keşif sistemini, seyahat acentelerine belirli rotalar için havayolu ücretleri hakkında temel bilgi sağlamada rekabetçi bir amaç için kullanıldığı düşünülmüştür. Ancak daha sonra havayolları bu sistemi tüketiciler için sınırlı ya da hiç kullanımına açık olmayan, diğer rekabetçi havayolları ile iletişim ve ücret konusunda anlaşarak birbirleri için önemli olan bilgi alışverişinde bir aracı olarak kullanmaya başlamıştır. Dolayısıyla bu hizmet ilerleyen süreçte rekabet karşıtı risklere neden olmuştur.

DOJ, bu havayollarının ücretleri yükseltmek için yapılan girişimlerdeki uyumsuzlukları ilk ve son bilet tarihleri üzerinden indirimli ücretleri elemek için birbirlerine sinyal gönderdiklerini tespit etmiştir. Temel olarak, havayolları bilgisayarlı ücret keşif sistemi sayesinde ilk ve son bilet tarihlerini kullanarak ücretleri değiştirmek için kendi aralarında anlaşmalar yapmıştır. Tüm bu ücret bilgilerini işlemek için karmaşık bilgisayar programları kullanan bahse konu havayolu firmaları, rakiplerinin belirli rotalardaki mevcut ve gelecekteki ücretlerine verdiği yanıtları izlemiş ve analiz etmiştir. Bu sistem üzerinden yapılan haberleşmeler sayesinde farklı rotalardaki ücret değişiklikleri birbirine bağımlı hale getirilmiştir. Tüm havayolları ilk bilet tarihi ile birlikte ücretleri birkaç hafta boyunca aynı oranda artırarak fiyatlama sistemine bağlılıklarını göstermiştir. Benzer şekilde, havayolları tüketicilere sunulan indirimli fiyatları ortadan kaldırmak için bu sistemde son bilet tarihlerini kullanmıştır. Bu bilgisayarlı ücret yayma sistemi, havayollarına daha yüksek ücretler için pazarlık yapmalarını sağlamakla kalmamış, aynı zamanda bu ücretlerin yapılacağını doğrulamış ve belirli yollar için belirli ücretlerle birlikte hareket etmeyen herhangi bir havayoluna karşı gerekli önlemler almalarını da sağlamıştır.

<sup>22</sup> United States of America Plaintiff v. Airline Tariff Publishing Company,, Civil Action No.: 92 2854 (United States District Court, District Of Columbia, 1993)

Bu kararlara rekabet hukuku açısından bakıldığında, kartelin görevini doğrudan yerine getiren algoritmaların kullanımı insanlar tarafından yürütülen bir kartel ile aynı etkiye neden olmaktadır. İnsanlar tarafından yapılan açık anlaşmalarda algoritmalar sadece insanların başka türlü yapacağı işleri kolaylaştırmaktadır. Vestager<sup>23</sup> “teşebbüsler bir bilgisayar programının arkasına saklanarak sorumluluktan kaçamazlar.” söylemiyle bu durumdan teşebbüslerin sorumlu olacağını belirtmiştir.

Sonuç olarak bu senaryoda kullanılan algoritmalar yeni veya özel bir durum oluşturmadığı için rekabet yasalarının kapsamı bakımından değişiklik yapılmasına gerek görülmemektedir. Bir karteli uygulamak için kullanılan teknoloji farklı olabilir, ancak bu durum, rekabet mevzuatının değiştirilmesi gerektiği anlamına gelmemektedir (Bartłomiejczyk 2018, 22).

### **1.2.2. Topla ve Dağıt Senaryosu (Hub & Spoke)**

Bu senaryo, çevrimiçi perakendecilerin üçüncü taraf sağlayıcıların algoritmalarını kullandığı durumlarda ortaya çıkmaktadır. Bu algoritmalar bir kartel oluşumunda kullanıldığında çevrimiçi perakendeciler de kartel iddialarıyla karşı karşıya kalabilmektedir. Bu durum sektör oyuncuları (spoke) tarafından ürün fiyatını belirleme ve ürün fiyat değişikliklerine tepki vermek için aynı üçüncü taraf sağlayıcının (hub) fiyatlandırma algoritmalarını kullanmasıyla başlamaktadır. Bu süreçte aynı bilişim firması tarafından bir birinin aynısı olacak şekilde geliştirilen algoritmaların, kendi aralarında iletişim kurmaksızın fiyatlandırma yöntemi olarak kullanması sonucunda fiyatların sabitlendiği tespit edilmiştir.

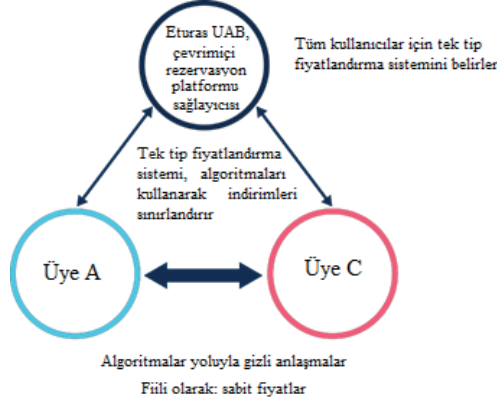
*Eturas*<sup>24</sup> kararı incelendiğinde ise Topla ve Dağıt (Hub & Spoke) senaryosunun çevrimiçi pazarlarda kullanıldığı anlaşılmaktadır (Bkz. Şekil 5). Bu karar kapsamında Litvanyalı çevrimiçi seyahat acente yöneticisi tarafından diğer seyahat acentelerine elektronik ortamda bir not gönderilerek, indirim oranlarının sınırlanmasında yeni teknik bir kısıtlamanın olduğu bildirilmiştir. Bu bildirimden haberdar olan ya da olmayan bütün acentelerin bildirim amacından uzaklaşmadığı sürece sorumlu oldukları ve bir karteğe katılmış gibi değerlendirileceği ABAD tarafından belirtilmiştir (Bartłomiejczyk 2018, 28). Ayrıca mahkeme, sistem

<sup>23</sup> (Komisyon 2017)

<sup>24</sup> Case C-74/14, *Eturas v Others* [2016], OJ C 24

yöneticisi tarafından gönderilen bildirim kartel olarak değerlendirilen fiili bir bilgi olduğunu ve bu bilginin objektif ve tutarlı işaret olduğunu vurgulanmıştır.

### Şekil 5: Topla ve Dağıt (Hub & Spoke) Senaryosu



**Kaynak:** FRESHFIELDS BRUCKHAUS DERINGER LLP. (2017, 2), Pricing algorithms: the digital collusion scenarios, <https://www.freshfields.com/globalassets/our-thinking/campaigns/digital/mediainternet/pdf/freshfields-digital---pricing-algorithms---the-digital-collusion-scenarios.pdf>, Erişim Tarihi: 10.06.2019.

Bu senaryoda pazar oyuncuları kendi iradeleriyle bir platform algoritmasını kullanmayı kabul ettikleri zaman diğer rakip oyuncularında aynı algoritmayı kullanma ihtimalinin bulunduğunu ve platform algoritmalarının ise fiyatları belirli bir seviyede sabitlenmek için kullanılabileceğini bilmeleri gerekmektedir. Bu durum klasik Topla ve Dağıt (Hub & Spoke) olarak değerlendirilerek bütün oyuncuların kartel anlaşması içerisinde buldukları kabul edilmektedir.

Uber dünya üzerinde mobil uygulama aracılığıyla taşımacılık hizmeti sunmaktadır (Nowag 2016, 1). Uber, Uber uygulamasını kullanan müşteriler ile sürüş hizmeti veren sürücüyü bir araya getirerek bu durumu sağlamaktadır. Mobil uygulama aracılığıyla müşteriye sabit bir fiyatla A noktasından B noktasına bir yolculuk teklif edilmektedir. Uber, fiyat algoritmaları kullanarak fiyatları belirlemekte ve müşteriler yolculuk için Uber'e mobil uygulama üzerinden ödeme yapmaktadırlar. Uber, kendisiyle sürücü arasındaki ücret ödeme şeklini tek bir şekilde yapmakta ve bunu belli bir yüzde tutarını kendisine aldıktan sonra

sürücüye aktarmaktadır. Uber, sürücülere mobil uygulaması hariç başka herhangi bir yöntemle bir ödeme talep etmelerine veya almalarına izin vermemektedir.

Bu bilgiler çerçevesinde Uber'in algoritması, gerçek piyasa fiyatı yerine algılanan rekabetçi bir fiyatı taklit edebildiği için algoritmik tekel olarak adlandırılmaktadır (Ezrachi ve Stucke 2016, 51). Uber, müşterilerden sürücü bahşışı alınmaması yönünde bir politika benimsemekte ve fiyatların sadece algoritmalar tarafından belirlenmesini sağlamaktadır. Belirlenen fiyatlar üzerinden %20 ile %25 arasında Uber kendisi için kesinti yapmakta geri kalan miktarı ise sürücüye aktarmaktadır. Uber, algoritmaları fiyat belirlemede tek başına yetkili kılmakta ve müşterilerin belirli bir bölgede artan sürücü talebine fiyatlarda orantılı bir artış ile karşılık vermektedir. Yapılan bu artışlar bazı durumlar karşısında algoritmik tekelin fiyatlar üzerindeki etkisini net bir şekilde göstermektedir. Örneğin New York'ta kar fırtınasının olduğu bir bölgede sürücü isteği zamanla artmış bu da fiyatların 8.5 kat artmasına neden olmuştur (Chew 2016).

FTC Komisyon Üyesi Ohlhausen, algoritmaların anlaşma için Topla ve Dağıt (Hub & Spoke) ile beraber kullanımını açıklığa kavuşturmak için bu durumu şu şekilde ifade etmiştir: "Algoritma" kelimesi yerine "Bob adında bir adam" ifadesi kullanılırsa, algoritmalar geleneksel bir Topla ve Dağıt (Hub and Spoke) kartel gibi ele alınabilir (Ohlhausen 2017, 10).

Bu senaryoda anlatılanların ışığında ortak kullanılan bir algoritmanın her şeyin fiyatını belirlemeye başladığı durumlarda kartel olarak değerlendirilmesi gerektiği belirtilmiştir. Yukarıda yer verilen ifade de, örneklerin klasik Topla ve Dağıt (Hub & Spoke) kartelinden farklı olmadığı sadece bu işlevi yerine getiren algoritmalar olduğu anlatılmaktadır.

### **1.2.3. Makineden Makineye (M2M) İletişim ve ML, DL Algoritmaları**

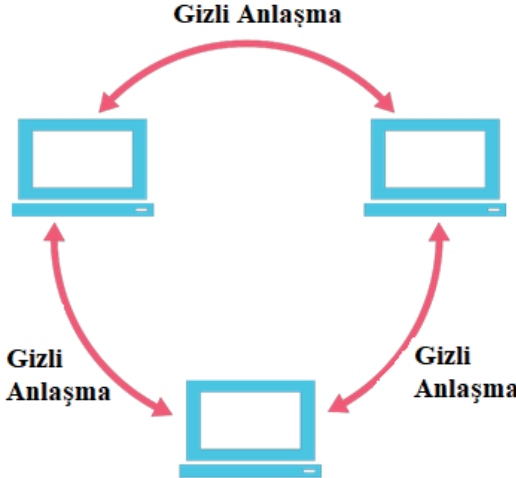
Bu senaryoda AI algoritması, insandan bağımsız bir şekilde karar almakta ve bu süreçte deneyimlerle öğrenme yeteneğini artırması sonucunda oluşan rekabet karşıtı durumları insan etkisinden uzak bir şekilde gerçekleştirmektedir. Ayrıca bu duruma ilaveten sektör oyuncuları dışında fiyatlandırma algoritmaları için kullanılan algoritmaları kodlayan programcılarının, algoritmaların birbirleriyle iletişime geçip rekabet karşıtı bir davranıştan kaçınmasını göz ardı ettiği durumlarda

meydana gelebilmektedir. Ancak bu durumu rekabet hukuku bağlamında Komisyon üyesi Vestager, “işletmelerin şu an yaptıkları ve yapacakları şeyler için rekabet uyumluluğunu gözetmeleri gerekmektedir.” şeklinde değerlendirmiştir (Komisyon 2017).

### 1.2.3.1. Rekabeti Sınırlayıcı Anlaşmalar Kapsamında Değerlendirilmesi

Bu senaryoda AI fiyat algoritmaları, kârı optimize etmeyi sektörden topladığı bilgilerle sıfırdan öğrenerek ve pazardaki diğer algoritmalar ile bu durumu koordine ederek gizli bir anlaşma oluşturmaktadır (Bkz. Şekil 6). ABİDA’ya göre genel ilke, teşebbüslerin böylesi rekabet karşıtı bir ortamın oluşmaması için teknolojik güncel bütün önlemleri almalarına rağmen kullanıldıkları fiyat algoritmasının gizli anlaşma oluşmasına neden olması halinde bundan sorumlu tutulacaklarını göstermektedir. Bu durumu Komisyon üyesi Vestager şu şekilde ifade etmektedir: “...bir teşebbüsün fiyat belirlemek için algoritmalar kullandığı durumda ortaya çıkan rekabet risklerinden sorumlu tutulacaktır.” (Komisyon 2017)

Şekil 6: Makineden Makineye (M2M) İletişim ve ML, DL Algoritmaları (M2M Communication and ML, DL Algorithms)



**Kaynak:** FRESHFIELDS BRUCKHAUS DERINGER LLP. (2017, 3), Pricing algorithms: the digital collusion scenarios, <https://www.freshfields.com/globalassets/our-thinking/campaigns/digital/mediainternet/pdf/freshfields-digital---pricing-algorithms---the-digital-collusion-scenarios.pdf>, Erişim Tarihi: 10.06.2019.

### **1.2.3.2. Hâkim Durumun Kötüye Kullanılması Kapsamında Değerlendirilmesi**

Bu senaryoda yatay anlaşmalar dışında bir de hâkim durumu kötüye kullanarak oluşabilecek algoritmik eylemler de bulunmaktadır. Şayet teşebbüslerin sayısı birden fazla ise bu durum kolektif egemenliğin kötüye kullanımı olarak da adlandırılmaktadır.

ABAD, *Bertelsmann AG / Sony v. Impala* davasında kolektif baskınlık bulmuş ve olay taraflar arasında var olan karşılıklı bağımlılığın sıkı bir oligopolle ilişkili olması sebebiyle meydana geldiği tespit edilmiştir. Ayrıca kolektif baskınlık diğer korelasyon faktörlerine dayanabileceği de vurgulanmıştır (Bartłomiejczyk 2018, 39). Bu davaya göre Savcı Kokott, kolektif pazar egemenliğinin oligopolün tüm üyelerinin piyasa davranışlarının zımnı koordinasyonundan kaynaklanabileceğini açıkça belirtmiştir. Bu dava kapsamında algoritmanın nerede ve ne şekilde kullanılacağı olası rekabet ihlalinin türünü de değiştirmektedir.

### **1.2.4. Gizli Anlaşma Senaryosu**

Bu senaryo, fiyatlandırma algoritmalarının pazarın artan şekilde şeffaflaşması sonucunda bir gizli anlaşma oluşturma varsayımına dayanmaktadır. Bu olasılıkları artırıcı durumları Ezrachi ve Stucke şu ifadelerle belirtmektedir:


Pazarın daha geniş ve daha ayrıntılı bir görünümü, rekabetçi girişimlere cevap olarak daha hızlı tepki verilmesini sağlamakta ve ayrıca yaparak öğrenme<sup>25</sup> (learning by doing) ile elde edilen dinamik stratejiler ile mümkün kılan teknolojiler sayesinde oligopolistik pazarlarda gizli anlaşmalar daha da etkili hale gelebilmektedir (2016, 71).

Dünya üzerindeki rekabet otoriteleri tarafından incelenmekte olan bu senaryo şu an için bir rekabet ihlali olarak değerlendirilmemektedir. Ancak bahsedilen bu varsayımın gerçekleşmesi durumunda rekabet otoritelerinin almaları gereken düzenleyici önlemler ve teşebbüslerin ise alacağı tedbirlere ilişkin tartışmalar dünya genelinde yapılmaktadır.

---

<sup>25</sup> Yeterli hesaplama kaynaklarına sahip bir algoritmanın, gerçek dünya verileri üzerinde oynama yapılmadan, eğitim örnekleri sunularak kendine ait öğrenme kalıpları çıkartarak performansını iyileştirmesine “yaparak öğrenme” denilmektedir.

### Şekil 7: Gizli Anlaşma Senaryosu (Tacit Collusion)



**Kaynak:** FRESHFIELDS BRUCKHAUS DERINGER LLP. (2017, 4), Pricing algorithms: the digital collusion scenarios, <https://www.freshfields.com/globalassets/our-thinking/campaigns/digital/mediainternet/pdf/freshfields-digital--pricing-algorithms--the-digital-collusion-scenarios.pdf>, Erişim Tarihi: 10.06.2019.

Pazar şeffaflığı her geçen gün dinamik fiyatlandırma algoritmalarını kullanan ve mevcut fiyatlarını yayımlayan teşebbüs sayısı ile doğru orantılı olacak şekilde artmaktadır. Sektördeki teşebbüslerin her birinin kendi fiyatlandırma algoritmalarını kullandığı ve rakipleriyle gerçek zamanlı fiyatlarını paylaştığı bir durumda gizli anlaşma için en uygun durum oluşmaktadır. Böyle bir durumda bir teşebbüs fiyat artışı gerçekleştirdiğinde rakip teşebbüs de anlık artış yapmaktadır. Aynı teşebbüs fiyatını düşürdüğünde ise yine rakip teşebbüsler fiyatlarını aynı seviyeye çekerek cevap vermektedir (Bkz. Şekil 7). Bu yaşanan fiyat değişiklikleri çok hızlı bir şekilde gerçekleştiği için de müşterilere indirim teklifi yapılamamaktadır. Ayrıca algoritmaların yapmış olduğu bu tür gizli anlaşmaların sonucunda piyasa, dengeye gelmesi gereken fiyattan daha yukarıda bir noktada dengeye gelmektedir.<sup>26</sup>

Bu senaryoda ilk belirtilmesi gereken hususun rakip teşebbüslerin kullanmış olduğu algoritmaların birbirlerinin fiyatlarını izleyerek yapmış oldukları paralel hareketlerin şu an için rekabet hukuku kapsamında hali hazırda cezalandırmaya

<sup>26</sup> Süper rekabetçi fiyatlandırma (supracompetitive), rekabetçi bir pazarda sürdürülebilecek olanın üzerinde fiyatlandırma olarak tanımlanmaktadır (Freshfields Bruckhaus Deringer LLP 2017, 5).

konu olmadığıdır. Bu durumun temelinde ise algoritmalar arasında herhangi bir açık anlaşmanın olduğuna dair bir kanıtın olmayışı ve şeffaf bir pazar yapısının olması yatmaktadır. Hâkim görüş bu tür davranışların soruşturulmasının zor olduğu ve pazar şeffaflığının ise tüketicilere fayda sağladığı yönündedir. Bunun aksini iddia edenler ise aşırı piyasa şeffaflığının algoritmalar tarafından kötüye kullanılabilceğini (Freshfields Bruckhaus Deringer LLP 2017, 4) ve bu sebeple kanunların değiştirilmesi gerektiğini ifade etmektedirler. Bu durumda oluşabilecek rekabet karşıtı eylemler için ise yetkili makamların rekabet yasalarını değiştirerek aşırı şeffaf bir pazarın oluşturulmasını önlemesi gerektiğini belirtmektedirler.

### **1.3. BÖLÜM DEĞERLENDİRMESİ**

Algoritmaların fiyat tespiti için birbirleriyle olan ilişkilerinin rekabet hukuku bağlamında bazı sorunlara sebebiyet verdiği bu bölüm kapsamında vurgulanmıştır. Dolayısıyla algoritmalar tarafından yapılan davranışların, rekabet hukuku kapsamında bir ihlal oluşturup oluşturmadığının değerlendirilmesi gerektiğini söylemek de yanlış olmayacaktır.

Fiyatlama için algoritma kullanımının teşebbüsler açısından fiyatlama stratejisi üzerine olumlu etkiler sağladığı yadsınamaz bir gerçektir. Sektör oyuncuları tarafından kendi algoritmalarını yazmaları ve mevcut fiyatlarını paylaşmaları pazar şeffaflığını artırıcı bir özellik kazandırarak algoritmik fiyatlama derhal dönüşleri ve ceza mekanizmalarını oluşturma imkânı sağlamıştır. Ayrıca algoritmik fiyatlandırma teşebbüsler için açık bir şekilde verimliliğini artırma ve maliyetleri düşürücü etkide bulunarak gelir artışına da imkân vermektedir (Oxera 2018, 4). Algoritmaların faydalarının bu denli fazla olmasının yanında rekabet karşıtı etkileri de karşımıza çıkmaktadır. ABD'deki havayolu teşebbüslerinin bilet fiyatları için ilk ve son bilet fiyatları üzerinden haber göndermeleri, Uber gibi devasa teşebbüslerin fiyatlama için sadece algoritmaları kullanmaları ve algoritmik tekel durumunun oluşumu ve son olarak e-ticaret firmalarının büyük çoğunluğunun bu algoritmalarından yararlanması rekabet karşıtı davranışlara neden olmaktadır. Bu algoritmalar, oluşum yapıları incelendiğinde ise İzleme, Paralel, Sinyal ve AI algoritmaları olarak dört sınıfa ayrılmaktadır. Bu yapılar ile yapılabilecek senaryolar incelendiğinde ise Haberci, Topla ve Dağıt, M2M ve

Gizli Anlaşma senaryoları karşımıza çıkmaktadır.

Görüldüğü üzere, sektör oyuncuları tarafından fiyat belirlemek için algoritmaların kullanımı artıkça, AI algoritmalarının rekabet hukuku uygulamalarındaki rolü daha da artacak ve kullanımı gittikçe yaygınlaşacaktır. Bununla birlikte, gizli anlaşma (tacit collusion) senaryosunun gerçekten bu tür ortak sonuçlara yol açıp açmayacağı net değildir. Bu algoritmaların neler yapabileceği, davranışlarını gerçekten koordine edip etmeyecekleri ve hatta birbirleriyle iletişim kurmayı öğrenebileceği gibi durumları incelenmesi gerekmektedir. Bu soruları daha ayrıntılı bir şekilde araştırmak için öncelikle izleyen bölümde ML ve DL algoritmaları daha sonrada üçüncü bölümde RL algoritmaları konusunda detaylı açıklamalar yapılacaktır.

## BÖLÜM 2

### YAPAY ZEKÂ (AI) UYGULAMALARI

#### 2.1. AIRBNB ML FİYAT TAHMİN UYGULAMASI<sup>27</sup>

Rekabet iktisadında, neyin gerçekleştiği kadar, bunun neden ve nasıl gerçekleştiğini ortaya koymaya çalışan analizler de yer almaktadır (Arslan 2015, 22). Bunun için sadece piyasadaki oyuncuların insani uygulamalarının sonuçlarına değil, AI algoritmalarının neden olmuş olabileceği durumlar da değerlendirmektedirler. Bu bakış açısı doğrultusunda, tüketicileri, rakipleri ya da piyasadaki diğer oyuncuları etkileyen ve piyasalardaki rekabet koşullarını ortadan kaldıran AI uygulamaları anlaşılmaya çalışılmaktadır.

AI uygulamaları; fiyatlandırma, üretim kapasitesini belirleme, işe alınacak personel seçme ve lojistik süreçlerini yönetme gibi daha birçok alanda kullanılmaktadır. Bu alanlarda yaygın bir şekilde algoritmaların kullanımının artmasıyla beraber algoritmalar giderek daha etkin hale gelmektedir. Bu nedenle algoritmalar basit sonlu otomatlar gibi basit sezgisel kurallar karşısında kullanılabileceği gibi birden fazla değişkene bağlı olarak sürekli olarak değişen sistemleri fiyatlandırmada veya üretim miktarının belirlenmesi karşısında da kullanılmaktadır.

Bir teşebbüsün kullanmış olduğu algoritmanın fiyat tahmini yapabilmesi için birden fazla değişkeni analiz etmesi, değişkenler arasındaki ilişkileri tespit etmesi ve bu bilgileri kullanarak sonuçlar çıkarması gerekmektedir. Bu süreçleri tamamlayabilmek için ise ileri düzey ML, DL ve RL algoritmalarının kullanımı söz konusu olmaktadır. Mitchell tarafından ML'nin akademik tanımı şu şekilde yapılmıştır:

---

<sup>27</sup> Airbnb uygulaması Kaggle platformunda bulunan ML uygulamalarından esinlenerek yazılmıştır.

Bir bilgisayar programının bir T görevini yerine getirdiğini varsayalım. Program bu T görevini yerine getirirken zaman geçtikçe E tecrübesini kazansın. P ise programın bu T görevini yerine getirirken ki performans ölçütü olsun. Eğer bu P performans ölçütü E tecrübesi ile geliyorsa o zaman bu programın öğrendiğini söyleyebiliriz (1997, 2).

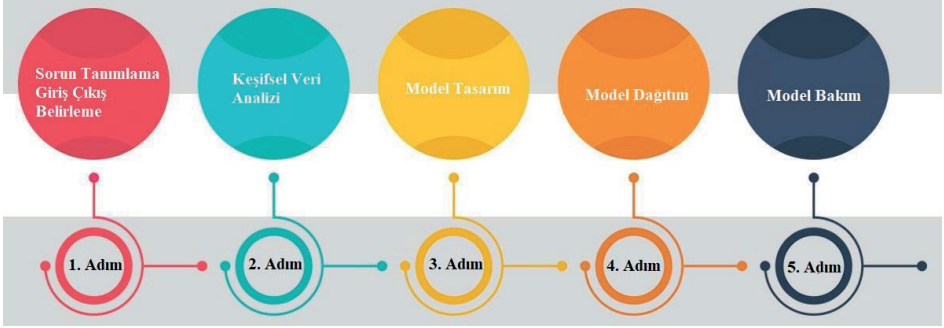
Burada bahsedilen tanıma göre bu algoritmalar aldıkları girdilere bağlı olarak zaman içinde kendilerini sürece uygun şekilde çalışabilecek şekle getirebilmekte ve bu durum ise algoritmanın öğrenme yeteneğini sürekli bir şekilde gelişmesine olanak sağlamaktadır. Bununla beraber algoritmaların daha doğru sonuçlara ulaşma isteği ise ister istemez rekabet karşıtı durumların da oluşmasına neden olabilmektedir. Bu durumu netleştirmek açısından Python koduyla hazırlanmış Airbnb'deki ilan fiyatlarını tahmin eden ve müşterilerin daha düşük fiyattan ev kiralamalarının önüne geçen ML ve DL uygulamalarının tahmin işlemini nasıl gerçekleştirdiği tek tek açıklanmaktadır. Airbnb fiyat tahmin uygulamasının sonuçları ise grafikler üzerinden incelenerek ne şekilde rekabet karşıtı bir etki doğurabileceği anlatılmaktadır.

Airbnb fiyat tahmin uygulamasının anlatımında kullanılacak ML ve DL uygulamaları için genel kabul görmüş belli başlı aşamalar bulunmaktadır. Bu aşamalar Google tarafından desteklenen Kaggle platformunu kullanan Mkariithi (2018) tarafından şu başlıklar altında toplanmaktadır:

- Sorunu Tanımla
- Giriş ve Çıktıları Belirleme
- Keşifsel Veri Analizi
  - Veri Koleksiyonu
  - Veri Ön İşleme
  - Veri Temizleme
  - Görüntüleme
- Model Tasarımı
- Model Dağıtımı
- Model Bakım

Bu aşamalar, Airbnb fiyatlandırma algoritmasının çalışma prensibine benzer şekilde uyarlanmış ML ve DL uygulamalarıyla<sup>28</sup> beraber anlatılmaktadır (Bkz. Şekil 8).

**Şekil 8: ML İş Akışı**

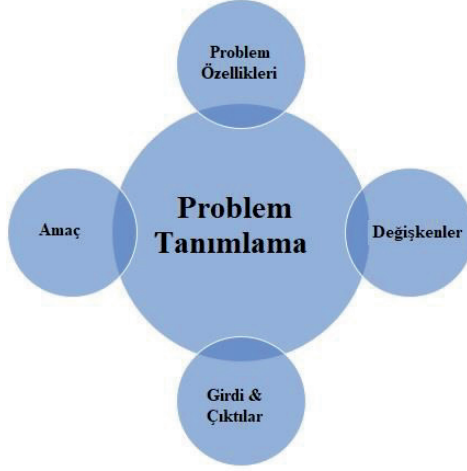


## 2.2. PROBLEM TANIMLAMA

Dünya üzerinde seyahat edenler için akla gelen en tipik problemlerden bir tanesini konaklanacak yerin ayarlanması oluşturmaktadır. Gelişen teknolojiyle beraber eskiden telefon görüşmeleri ile yapılan bu rezervasyonların yerini Airbnb gibi uygulamalar aracılığıyla yapılan rezervasyonlar almaktadır. Bu uygulamalar üzerinden yapılacak rezervasyonlar için ise en önemli değişkeni rezervasyon fiyatını hesaplamak oluşturmaktadır (Bkz. Şekil 9). Airbnb gibi yazılım üzerinden fiyatlama algoritmaları kullanan teşebbüslerin fiyatlara etki edebilecek ana faktörlerin neler olduğunu bulabilmek için turistlerin en çok ne zaman geldikleri, fiyatların en çok ne zaman değiştiği, konaklanacak yerin seçiminde en önemli özelliğin neler olduğu gibi soruların cevabını ararken fiyatlama algoritmalarına başvurmaktadırlar.

<sup>28</sup> Airbnb uygulaması içerisinde kullanılan kodları Kaggle üzerinden alınarak geliştirilmiştir. ML kodu (Deis 2019), DL kodu (Cybulski 2019) ve Veri seti (Seattle Airbnb Open Data 2018)

## Şekil 9: Problem Tanımlamanın Problem Özellikleriyle İlişkisi



**Kaynak:** MKARIITHI (2018). “Real Estate Sales Price Prediction”, <https://www.kaggle.com/mkariithi/real-estate-sales-price-prediction>, Erişim Tarihi:13.06.2019.

Airbnb, uygun yer kiralamak isteyenleri yerel ev sahipleriyle bir araya getiren bir pazar olarak tanımlanmaktadır (Yee ve Ifrach 2015). Airbnb üzerinden ilan sahipleri fiyatları serbestçe belirleyebilmektedir ancak Airbnb ev sahiplerine ML içeren bir algoritmaya göre fiyatları tavsiye etmektedir. Fiyat önerileri yer ve büyüklük, mülkün doluluk oranı, rezervasyon süresi, sezon, rakiplerin fiyatları ve bulunabilirliği gibi sürekli algoritmalar tarafından belirlenen değişkenlere göre ayarlanmaktadır. Fiyat ipuçları, örneğin yerel olayları dikkate almak üzere zaman içinde değişiklik gösterebilmekte ve düzenli olarak algoritma öğrendiği bilgiler ile kendisini güncellemektedir.

### 2.3. PROBLEM ÖZELLİKLERİ

Problem, Airbnb verileri üzerinden bir fiyat tavsiye uygulaması geliştirebilmek olarak belirlendikten sonra problem özelliklerini belirleme aşamasına geçilmesi gerekmektedir. Bu aşamada Airbnb üzerinden rezervasyon fiyatının hangi değişkenlere bağlı olduğu bilgisine ve gelecekteki çıktılar için bazı yararlı verilere Airbnb'nin internet sitesinden ulaşılabilir. Airbnb internet sitesinde belirtildiğine göre rezervasyon fiyatı şu başlıklardan oluşmaktadır:

- Ev sahibi tarafından belirlenen maliyetler,
- Gecelik ücret, ev sahibi tarafından karar verilen ücret,
- Temizlik ücreti, bazı ev sahipleri tarafından kendi alanını temizleme maliyetini karşılamak için alınan bir kerelik ücret,
- Ekstra misafir ücreti, bazı ev sahipleri tarafından kullanım alanlarıyla ilgili diğer masrafları karşılamak için bir kerelik ücret,
- Airbnb tarafından belirlenen maliyetler, Airbnb servis ücreti,
- Dâhil edilebilecek diğer maliyetler: döviz kuru ücretleri, KDV, diğer yerel vergiler vs.

Problemi özelliklerini daha da detaylandırılacak olursa, üç kısma ayırmak gerekmektedir: amaç, değişkenler ve girdi ve çıktılar.

### 2.3.1. Amaç

Her bir ilanın fiyatını tahmin etmek uygulamanın amacını oluşturmaktadır. İlerleyen bölümlerde bahsedilecek olan test veri setindeki her bir Id (ilan numarası) için rezervasyon fiyat değişkeninin değeri tahmin edilecektir.

### 2.3.2. Değişkenler

Uygulama fiyat hesaplarırken ev sahibi tarafından belirlenen gecelik fiyatı etkileyen değişkenleri odak noktasına alacaktır. Diğer bir yandan Airbnb'nin kullanmış olduğu algoritma incelendiğinde rezervasyonun yapıldığı tarih, Wi-Fi ve TV gibi sunulan imkânlar, mahalle bilgisini kullanmak veya tam koordinatlar kullanmak daha iyi sonuçlar vermektedir (Vrmintel 2015). Bunun sebebi ise bazen yakın yerlerin farklı mahallelerde oluşu veya nehrin farklı taraflarında yer alıyor oluşu liste fiyatlarında büyük farklılıklar göstermesine neden olabilmektedir.

### 2.3.3. Girdi ve Çıktılar

Uygulamamız da kullanmış olduğu veri seti, ana organizatörünün Google olduğu Kaggle'dan alınmıştır (Seattle Airbnb Open Data 2018). Alınan bu veriler uygulamamızda girdi olarak kullanılmaktadır. Bu veriler ile eğitilen ML ve DL algoritmaları ise çıktılar üretmektedir.

#### *Girdiler*

- **listings.csv:** Airbnb ilan hakkında özet bilgiler bulunmaktadır. Örneğin konum, ana bilgisayar bilgileri, temizlik ve misafir ücretleri, olanaklar vb.

- **calendar.csv:** Airbnb ilan takvim verileri bulunmaktadır. Örneğin uygunluk tarihleri, her bir tarih için fiyat.


### **Çıktılar**

- **dfy\_test\_tahmin:** İçerisinde test veri setinde alınan her bir ilan numarasının tahmini fiyat bilgisi listelenmektedir.

## **2.4. YAPI İSKELETİ SEÇİMİ**

ML uygulamaları kodlanırken programcılar tarafından genel olarak Python programlama dili seçilmektedir (Patel 2018). Bunun başlıca sebepleri ise dilin okunabilirliği ve daha az karmaşık oluşudur. Bu gerçekten yola çıkacak olursak önceden yazılmış bir Python kodu kolayca anlaşılabilir. Dolayısıyla da başka bir programcıya kodun ne şekilde çalıştığı çok hızlı bir şekilde anlatımı sağlanabilmektedir. ML ve DL uygulaması için kullanılan yapı iskeletlerinin tamamı aşağıda açıklanmaktadır (Bkz. Şekil 10).

### **Şekil 10: Kullanılan Kütüphaneler**



**Kaynak:** MKARIITHI (2018). “Real Estate Sales Price Prediction”, <https://www.kaggle.com/mkariithi/real-estate-sales-price-prediction>, Erişim Tarihi:13.06.2019.

- **Numpy (Numerical Python Package):** *NumPy*, sadece dizi nesneleri kullanmakla kalmayıp aynı zamanda hesaplamalar için rahatlıkla kullanılabilen lineer cebirsel fonksiyonlardan da yararlanmaktadır (Raman 2015). Dizilerin ve ilişkili dizi işlevlerinin hızlı bir şekilde uygulanmasının sağlanmasının yanı sıra bir dizi nesnesini kullanarak matris çarpımı, vektörlerin ve matrislerin transpozisyonu, denklem sistemlerinin çözümünü, vektör çarpımı ve normalizasyonu vb. işlemlerini de yapılabilmektedir.
- **Pandas:** Karmaşık veri kümelerini saklamak ve işlemek için kullanılmaktadır (Raman 2015).
- **Matplotlib:** Programcılar tarafından rahat bir şekilde kaliteli grafikler oluşturma için kullanılmaktadır (Raman 2015).
- **Seaborn:** İstatiksel verilerin gösterimi için kullanılmaktadır (Seaborn 2018).
- **Sklearn:** *Python* için bir makine öğrenme kütüphanesi olarak tanımlanmaktadır (Pal 2015). Destek vektör makinesi (*support vector machine*), rastgele ormanlar (*random forests*) ve k-en-yakın-komşuları (*k-neighbours*) gibi çeşitli algoritmaları bünyesinde barındırmakta ve ayrıca *NumPy* ve *SciPy* gibi *Python* sayısal ve bilimsel kütüphanelerini de desteklemektedir.
- **Xgboost:** Baskın rekabetçi makine öğrenmesi olan hız ve performans için tasarlanmış gradyanlı yükseltilmiş karar ağaçlarının bir uygulaması olarak tanımlanmaktadır (Brownlee 2016).

## 2.5. GÖRSELLEŞTİRME

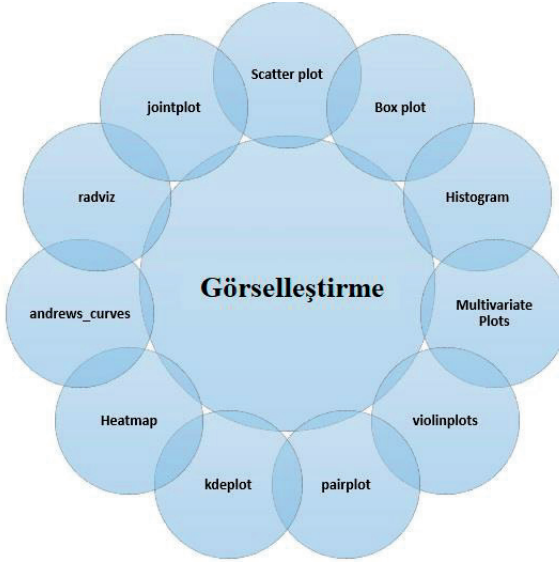
İyi bir görselleştirme, kullanıcıların verileri keşfetmesine ve anlamasına, değer ve derin görüşler sağlanmasına yardımcı olmakta (Raman 2015) ve verinin ölçeklenebilmesini sağlamaktadır. Görselleştirmenin faydalarından bir diğeri ise veri içerisinde belli kalıpları ve eğilimleri ortaya çıkararak veriyle ilgili soruların cevapların bulunmasına katkı sağlayan bir araç olarak kullanılması gelmektedir. Görselleştirmenin etkinliğini artırmak için ise yapılması gereken problemin ana

noktasını tanımlamak, bu grafikleri kullanacak son kullanıcıların seviyesini ve bakış açılarını belirlemek, verileri doğru şekilde temsil etmek ve daha sonra mesajı son kullanıcıya ileten açık bir sunum oluşturmaktan geçmektedir.

Görselleştirme için *Python*'da kullanılan grafik türleri (Bkz. Şekil 11) bir birinden farklı amaçlar için kullanılmaktadır. Bu grafik türlerinden Airbnb fiyat tahmin uygulamasının ana noktalarının belirlenmesi için fiyatların ilan sayısı ve tablolardaki sütunların birbirleriyle ilişkilerinin tespiti için *histogram* ve *heatmap*'ten yararlanılmaktadır.

### Şekil 11: Görselleştirme Metotları


**Kaynak:** MKARIITHI (2018). “Real Estate Sales Price Prediction”, <https://www.kaggle.com/mkariithi/real-estate-sales-price-prediction>, Erişim Tarihi:13.06.2019.



#### 2.5.1. Histogram

Geliştirilmiş olan uygulama Airbnb veri setinde bulunan 3818 tane ilanın ortalama fiyatlarının dağılımını gösterilmektedir. Grafik incelendiğinde girişlerin büyük çoğunluğunun 50 - 150 dolar civarında yoğunlaştığı görülmektedir. Böyle bir durumda çıkarılacak ilk sonucun ilanların genelde 50 ile 150 dolar civarında fiyatlandırıldığıdır (Bkz. Şekil 12).

## Şekil 12: Fiyata Bağlı İlan Sayısı




**Kaynak:** Tez kapsamında geliştirilen Airbnb uygulaması üzerinde yer alan bilgilerden elde edilmiştir.

### 2.5.2. Sıcaklık Haritası

Sıcaklık haritası<sup>29</sup>, son kullanıcı tarafından incelendiğinde kullanmış olduğu veri setindeki sütunların birbirleriyle olan korelasyon oranlarını göstermektedir. Bu oranlar Airbnb uygulamasının fiyat tahmini yaparken hangi sütunlardaki değerleri birbirleriyle ilişkili olduklarını göstermeleri bakımında önemli olduğu kadar diğer yandan veri temizleme işlemi yapılırken hangi sütundaki verilerin eksikliklerinin giderilmesi gerektiği ve hangi verilerin ise veri setinden atılması gerektiği konusunda yol göstermektedir. Isı haritasının incelemesine bakıldığında, fiyatın konaklama, banyo, yatak odası ve yatak sayısı ile ilişkili olduğu oranların yüksek oluşundan anlaşılmaktadır (Bkz. Şekil 13).

<sup>29</sup> Isı haritası, bir matristeki bireysel değerlerin renk olarak temsil edildiği verilerin grafiksel bir gösterimi olarak tanımlanmaktadır.

Şekil 13:Sütunlar Arası Bağlılık

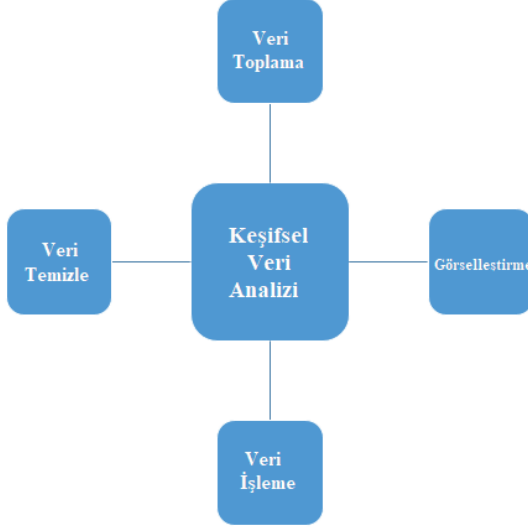


**Kaynak:** Tez kapsamında geliştirilen Airbnb uygulaması üzerinde yer alan bilgilerden elde edilmiştir.

## 2.6. VERİ ANALİZİ

Veriler, içeriğe ve önemine bağlı olarak çeşitli şekillerde toplanmakta ve saklanmaktadır (Raman 2015). Airbnb fiyat tahmini için toplanan veriler üç farklı veri setinden oluşmaktadır. Bunlar ilanlar, rezervasyonlar ve müşteri yorumlarıdır. Ancak alınan bu verilerin bir kısmı eksik verilerden ve başka bir kısmı ise tek sütunda liste verilerinden oluşmaktadır. Bu veriden bilgiye dönüşüm, aşağıdaki diyagramda gösterildiği gibi verilerin toplanmasını, işlenmesini ve düzenlenmesini (eksik veri) içermektedir (Bkz. Şekil 14).

### Şekil 14: Veri Analiz Bileşenleri



**Kaynak:** MKARIITHI (2018). “Real Estate Sales Price Prediction”, <https://www.kaggle.com/mkariithi/real-estate-sales-price-prediction>, Erişim Tarihi:13.06.2019.

Eldeki verilerden bilgiye dönüşüm, aynı zamanda istatistiksel modelleme veya hesaplama algoritması gibi daha karmaşık adımları içermektedir. Burada gerçekten önemli olan verilerin sorgulanmasını, erişilmesini ve manipüle edilmesini sağlamaktır. İncelenmekte olan Airbnb uygulamasında, çok büyük ve farklı miktarda veri bulunmasından dolayı, dönüşüm filtreleme, toplama, korelasyon uygulama, ölçeklendirme ve normalleştirme ve sınıflandırma gibi işleme yöntemlerini içermektedir. Airbnb uygulaması için uygulanan veri analiz adımları sırasıyla şu şekildedir:

- “*listings.csv*” ve “*calendar.csv*” dosyalarındaki veri setlerini birleştirme
- “*date*” sütun verisinden gün, ay ve yıl tam sayılarını elde edilme
- Veri setindeki tekil değerleri bulma
- İçerisinde liste barından sütunların değerlerini ayırma işlemi
- Kullanılmayacak sütunların çıkarılması işlemi
- Rezervasyon veri setinden alınan tarih sütunu değerini ay ve yıl olarak ayrıştırılması işlemi

- Fiyat sütununu sayısallaştırma işlemi
- “*host\_since*” tarih alanındaki veriyi sayısallaştırma ve boş verileri kaldırma
- “*host\_response\_rate*” sütunundaki verileri sayısallaştırma ve boş verileri kaldırma
- “*host\_listings\_count*” sütunundaki boş verileri var olan değerlerin ortalaması alınarak bu değerler ile doldurma
- “*host\_verifications*” kukla sütununa taşıma ve gerçek değerleri kaldırma
- “*bathrooms*”, “*bedrooms*” ve “*beds*” sütunların *mode*<sup>30</sup> alınarak boş değerleri doldurma
- “*amenities*” birden fazla sütuna bölünerek orijinal verileri yeni sütunlara taşıma (Liste barındırdıkları için sütunlara bölme işlemi yapılmakta)
- Fazladan kişi olması durumunda sonucu bir, olmaması durumunda sonucu sıfır olarak ayarlama
- Kullanıcı görüş skor sütunundaki eksik verilerinin değerini sıfıra atama

### 2.6.1. Veri Toplama


Airbnb, Amazon, Google ve Facebook gibi internet sitelerindeki verilerin tamamını sürekli olarak depolamaktadır. Airbnb örneğine dönülecek olursa rezervasyon gibi işlemler uygulama üzerinden gerçekleştirildiği için yapılan bütün işlemler kayıt altına alınmaktadır. Bu tür kayıtlar daha sonra müşteri memnuniyeti veya fiyat tahmin hesaplama gibi işlemlerden geçirilmektedir.

### 2.6.2. Veri Temizleme

Veri temizleme süreci bir kaynaktan gerekli bilgiler toplandıktan sonra girdi verileri üzerinde başlamaktadır. Veri eksikliklerini gidermek için toplanan bilgilerin görselleştirilmesi eldeki verinin ne kadarı ile işlem yapılabileceği konusunda daha iyi fikir vermektedir (Bkz. Şekil 15). Aşağıdaki grafik incelendiğinde lisans verisinin tamamı girilmemiş olduğundan uygulanacak ML ve DL algoritmalarında kullanılmaması gerekmektedir.

<sup>30</sup> <http://pandas.pydata.org/pandas-docs/version/0.17/generated/pandas.DataFrame.mode.html>, Erişim Tarihi: 06.06.2019.

Şekil 15: Eksik Verilerin Sütunlardaki Oranları



**Kaynak:** Tez kapsamında geliştirilen Airbnb uygulaması üzerinde yer alan bilgilerden elde edilmiştir.

### 2.6.3. Veri İşleme

Veri dönüşüm sürecinin en önemli adımı olan veri işleme safhasında işlemlerin odağını veri kalitesi oluşturmaktadır. Bu noktadan hareketle Airbnb uygulamasında kullanılan verilerin analizlerini yapmak ve anlamak için veri hazırlamaya yardımcı iki tür olan bağımlılık modelleme ve kümeleme yöntemleri kullanılmaktadır.

Bağımlılık modellemesi<sup>31</sup>, veri elemanları arasındaki ilişkileri arar; örneğin, Airbnb, müşterilerinin konaklama alışkanlıkları hakkında veri toplayabilir. Bu işlem, Airbnb için müşterilerin yılın hangi aylarında nerede daha çok konaklamayı tercih ettiklerini öğrenmelerine yardımcı olmaktadır.

<sup>31</sup> Bağımlılık modellemesi, sunum doğasını ve yapısını açıklamak için veri modellemesinin temel prensibi olarak tanımlanmaktadır.

Kümeleme<sup>32</sup>, veride bilinen yapıları kullanmadan yani benzer bir yapıya sahip verideki grupları kendiliğinden belirlemektedir. Bu yöntemin Airbnb uygulamasında kullanılması tercih edilmemiştir.

## 2.7. ÖĞRENMEYİ GERÇEKLEŞTİRME (APPLY LEARNING)

Öğrenmeyi gerçekleştirme işlemleri veri setinin eğitim ve test olarak bölünmesiyle başlamaktadır. Elde bulunan veri seti birden fazla durum karşısında farklı sonuçlar alabilmek ve gerçeğe yakın testler yapabilmek için farklı durumlarda denenmiştir. İlk durumda, veri setinde bulunan verinin yüzde yetmiş eğitim, yüzde otuzu ise test veri setini oluşturacak şekilde belirlenmiş ve Xgboost modeli kullanılarak fiyat tahmin işlemi yapılmıştır. Ancak veri seti boyutu bir milyondan fazla olması ve içerisinde sayısal olmayan değerlerin fazlalığı sebebiyle “*10-fold crossvalidation*” özelliği kullanılamamıştır. Ancak yine de model eğitim sonucunda fiyat tahmini yüksek bir başarı ile gerçekleştirilmiştir. Son aşamada ise yine aynı veri seti kullanılarak eğitim ve test verileri DL algoritması için yeniden oluşturulmuş ve Airbnb uygulaması için yeniden eğitilmiştir. DL algoritması eğitim sonunda hangi özelliklerin fiyat tahmini için kullanılması gerektiğini kendisi belirleyerek ve yüksek doğruluk tahmini ile başarılı bir şekilde öğrenme sürecini tamamlamıştır. Ayrıca ML ve DL algoritmaları fiyat tahminini ne kadar doğru oranda gerçekleştirebildiklerini görebilmek amacıyla birbiriyle de karşılaştırılmıştır.

### 2.7.1. ML Algoritmasının Modellenmesi

Airbnb uygulaması, fiyat tahmin için belirlenen XGBoost optimize edilmiş bir Gradient Boost uygulaması kullanılmaktadır (Géron 2019, 210). Bu model ilk olarak Tianqi Chen tarafından dile getirilmiştir. Bu model son derece hızlı, ölçeklenebilir ve taşınabilir olmak için tasarlanmış ve ML algoritmalarının önemli bir parçasını oluşturmuştur. XGBoost modeli kullanılırken bazı parametrelere ihtiyaç duymaktadır bu parametrelerin açıklaması aşağıdaki gibidir:

- **Öğrenme Oranı (**learning\_rate**):** Gradient Descent algoritmalarında adım boyutu küçülmesinin ne kadar olacağını belirleyen değişken olarak

---

<sup>32</sup> Kümeleme, veride bilinen yapıları kullanmadan, bir şekilde veya başka bir şekilde “benzer bir yapıya” sahip verideki grupları keşfetme görevi olarak tanımlanmaktadır.

tanımlanmaktadır (Hearty 2016, 212). Gradient Descent algoritması genel olarak ileri geri zikzak yapma eğilimde olduğu için bu iniş güncelleme parametresi çok yaygın bir şekilde kullanılmaktadır. Bu değişken ne kadar küçük tutulur ise algoritmanın öğrenmesini daha keskin hale getirmektedir ancak bu parametre aşırı küçültüldüğünde sonuç alma süresi aşırı şekilde uzayarak algoritmanın maliyetini artırmaktadır. Uygulamada ise bu oran testler sonucunda 0,04'e kadar indirilmiştir. Genel uygulamalarda bu oran 0,3 olarak belirlenmektedir (Sciencedirect 2019).

- **En Fazla Derinlik (max\_depth):** Herhangi bir ağacın en fazla derinliğinin ne olacağını belirlediği değişken olarak tanımlanmaktadır. Airbnb uygulamasında bu sayı yedi olarak belirlenmiştir.
- **Tahminleyici (n\_estimators):** Uyarlanacak ağaç sayısı olarak tanımlanmaktadır. Airbnb uygulamasında beş yüz olarak belirlenmiştir.
- **Gamma (gamma):** Ağacın yaprak düğümünde başka bir bölüm yapmak için gereken minimum kayıp azaltması olarak tanımlanmaktadır. Gama artırılırsa algoritma toleransında azalma meydana gelmektedir.
- **Alt Örnekler (subsample):** Eğitim örneklerinin oranı olarak tanımlanmaktadır. 0,5 değeri atandığı takdirde, XGBoost'un ağaçların büyümesinden önce eğitim verilerinin yarısını rastgele örnekleyeceği ve bu durumun modelin daha kısa sürede sonuçlanacağı anlamına gelmektedir. Her bir yineleme işleminde alt örnekleme bir kez gerçekleştirilmektedir.
- **Sütun Alt Örnek (colsample\_bytree):** Her ağaç oluşturulduğu esnada sütunların alt örnek oranı bu değişkene göre ayarlanmaktadır. Her bir yineleme işleminde alt örnekleme bir kez gerçekleştirilmektedir.

Yukarıda açıklanan bütün değişkenlerin gerçek bir uygulamada ne şekilde kullanıldığının örnek kodu<sup>33</sup> şu şekildedir:

```
xgb = xgboost.XGBRegressor(n_estimators=500, learning_rate=0.04, gamma=0,
subsample = 0.75, colsample_bytree=1, max_depth=7)

xgb.fit(X_egitim,y_egitim)
```

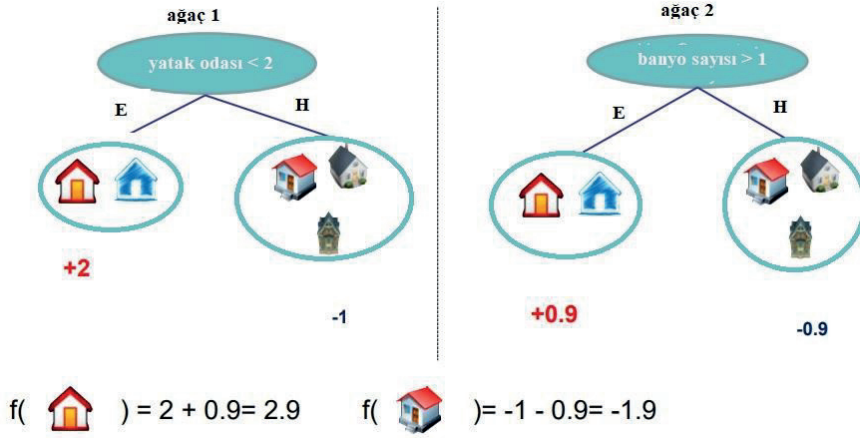
---

<sup>33</sup> Tez kapsamında hazırlanan Airbnb uygulamasından alınmıştır.

### 2.7.1.1. Xgboost Modeli ve Eğitilmesi

Xgboost modeli regresyon ağacı yapısında oluşturulmuş ve karar ağaçlarındaki (Decision Tree) kuralları ile benzer prensiplere göre tasarlanmıştır. Airbnb uygulaması üzerinden bir örnek verilecek olursa, verilen her bir ilan için konaklama fiyatını her ağaç tarafından tahmin edilen puanların toplamını alınarak hesaplamaktadır (Bkz. Şekil 16).

Şekil 16: Xgboost, Regresyon Ağaç Topluluğu



**Kaynak:** XGBOOST, (2019). “Introduction to Boosted Trees”, <https://xgboost.readthedocs.io/en/latest/tutorials/model.html>, Erişim Tarihi:13.06.2019.

### Modelin Formüle Dönüştürülmesi<sup>34</sup>

Matematiksel olarak modeli başlangıç formülü şu şekilde gösterilmektedir:

$$\hat{y} = \sum_{k=1}^K f_k(x_i), f_k \in F$$

K ağaç sayısı, f bir fonksiyon F, ise regresyon ağacındaki (CART) bütün olasılıklar olarak tanımlanmaktadır. Fonksiyon bu değişkenler ışığında mode göre optimize edildiğinde, denklem aşağıdaki hali almaktadır:

<sup>34</sup> XGBOOST, (2019). “Introduction to Boosted Trees”, <https://xgboost.readthedocs.io/en/latest/tutorials/model.html>, Erişim Tarihi:13.06.2019.

$$\text{obj}(\boldsymbol{\theta}) = \sum_i^n l(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k)$$

Bu formülün ilk kısmı eğitim kaybını hesaplarken ikinci kısmı ise ağaçların karmaşıklığını hesaplamaktadır. Bu iki kısmın toplamı ise modelin amacını vermektedir.

### 2.7.1.2. Ağaçların Artırılması (Tree Boosting)

Model, öğrenmesi gereken her ağaç yapısındaki ve her yapraktaki puanları içeren bir  $f_i$  fonksiyonunu bulmaktadır. Model için ağaç yapısını öğrenmek, basit gradyanda yapıldığı gibi geleneksel en uygun şekilde sokma probleminin çözümü gibi yapılsaydı öğrenme süreci imkânsızlaşacaktı yani tüm ağaçları bir kerede öğrenmeyi başaramayacaktı. Ancak bunun yerine, öğrenileni düzelterip her seferinde yeni bir ağaç ekleyerek  $t$  adımıdaki öngörü değerini  $\hat{y}_i^{(t)}$ 'ye yazılmaktadır. Bu durum aşağıdaki gibi formüle edilebilmekte:

$$\begin{aligned} \hat{y}_i^{(0)} &= 0 \\ \hat{y}_i^{(1)} &= f_1(x_i) = \hat{y}_i^{(0)} + f_1(x_i) \\ \hat{y}_i^{(2)} &= f_1(x_i) + f_2(x_i) = \hat{y}_i^{(1)} + f_2(x_i) \\ &\dots \\ \hat{y}_i^{(t)} &= \sum_k^t f_k(x_i) = \hat{y}_i^{(t-1)} + f_t(x_i) \end{aligned}$$

$\hat{y}_i^{(t)}$   $t$ . adımda modelin öğrenmesi,  $\hat{y}_i^{(t-1)}$  yani  $(t - 1)$ . anıdaki öğrenme ile yeni gelen ağaç ve yaprak puanı olan  $f_t(x_i)$  fonksiyonu ile toplanması ile elde edilmektedir. Sonuç olarak tüm sabitleri kaldırdıktan sonra,  $t$  adımıdaki formülün son hali aşağıdaki gibi olmaktadır:

$$\begin{aligned} \text{obj}^t &= \sum_{i=1}^n l(y_i, \hat{y}_i^{(t)}) + \sum_{i=1}^t \Omega(f_i) \\ &= \sum_{i=1}^n l(y_i, \hat{y}_i^{(t-1)} + f_t(x_i)) + \Omega(f_t) + \text{sabit} \end{aligned}$$

Öğrenme sürecinde yaşanmış olan hatalı tespitler için ortalama kare hatası (MSE) kullanıldığı takdirde formül aşağıdaki şekli almaktadır:

$$\begin{aligned} \text{obj}^t &= \sum_{i=1}^n (y_i - (\hat{y}_i^{(t-1)} + f_t(x_i)))^2 + \sum_{i=1}^t \Omega(f_i) \\ &= \sum_{i=1}^n [2(\hat{y}_i^{(t-1)} - y_i)f_t(x_i) + f_t(x_i)^2] + \Omega(f_t) + \text{sabit} \end{aligned}$$

MSE formu, birinci dereceden bir terim(artık) ve ikinci dereceden terimler ile daha iyi uygunluk göstermektedir. Aşağıdaki formül  $g_i$  ve  $h_i$  değerleri yazılacak olursa daha anlaşılır bir formül elde edilmiş olacaktır.

$$\text{obj}^t = \sum_{i=1}^n [l(y_i, \hat{y}_i^{(t-1)}) + g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i)] + \Omega(f_t) + \text{sabit}$$

$g_i$  ve  $h_i$ 'nin tam karşılıkları şu şekildedir:

$$g_i = \partial_{\hat{y}_i^{(t-1)}} l(y_i, \hat{y}_i^{(t-1)})$$

$$h_i = \partial_{\hat{y}_i^{(t-1)}}^2 l(y_i, \hat{y}_i^{(t-1)})$$

Tüm sabitleri kaldırdıktan ve  $g_i$  ile  $h_i$  yerine yazıldıktan sonra  $t$  adımındaki formül son şeklini almıştır (Chen 2014, 23):

$$\sum_{i=1}^n \left[ g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i) \right] + \Omega(f_t)$$


Sonuç olarak artık algoritmayı hedefe götürecek olan formül elde edilmiştir. Buradaki formülün önemli kazanımı da nesnel fonksiyonun değerinin yalnızca  $g_i$  ve  $h_i$  değişkenlerine bağlı halde getirilmesidir. Böylelikle kullanılan XGBoost özel kayıp fonksiyonlarını da destekleyecek şekilde getirilmiştir.

Bu bilgiler ışığında model, Airbnb uygulamasında fiyat tahmini yaptıktan sonra MSE eğitim değerini 509,979 ve test değerini de 519,532 olarak bulmuştur.

Daha sonra  $R^2$  hesaplandığında ise eğitim 0,954 ve test: 0,952 ile bire çok yakın bir değer ile sonuçlandığı bu durumda fiyat tahminlerinin gerçeklerine çok yakın bir şekilde elde edildiği ve eğitimin başarılı bir şekilde sonuçlandığı anlaşılmıştır.

XGBoost modeli ile elde edilen bir diğer sonuç ise veri setinde bulunan sütunların fiyat tahmini için en çok etki edenlerin hangileri olduğunu göstermesidir (Bkz. Şekil 17).


**Şekil 17: XGBoost Modeli Tarafından Belirlenen Sütunların Önem Derecesi**



**Kaynak:** Tez kapsamında geliştirilen Airbnb uygulaması üzerinde yer alan bilgilerden elde edilmiştir.

Airbnb konaklama fiyatlarının tahmini için ML algoritmalarıyla geliştirilmiş uygulama sonuçlarında yaklaşık iki yüz seksen bin konaklama fiyat tahmini yapılmıştır (Bkz. Şekil 18).


Şekil 18: Airbnb Fiyat Tahmini



**Kaynak:** Tez kapsamında geliştirilen Airbnb uygulaması üzerinde yer alan bilgilerden elde edilmiştir.

Fiyat tahmin çıktısı alındıktan sonra ikinci aşamaya geçilmiş ve tahmin için kullanılan fiyatların asıl değerlerinin de çıktısı alınmıştır (Bkz. Şekil 19). Bu iki farklı grafikte ilk dikkat çekici özellik hemen hemen bir birinin aynısı olması olmuştur.


Şekil 19: Airbnb Gerçek Fiyatlar



**Kaynak:** Tez kapsamında geliştirilen Airbnb uygulaması üzerinde yer alan bilgilerden elde edilmiştir.

Son olarak gerçek fiyatlar ile tahmin fiyatları ayrı ayrı gösteren grafikler tekilleştirildiğinde tahmin edilen fiyatların gerçek fiyatlara çok yakın bir değerde olduğu ortaya çıkmıştır. Bunun daha önceden bahsedilen  $R^2$  sonucu ile uygunluk gösterdiği anlaşılmıştır (Bkz. Şekil 20).

**Şekil 20: Airbnb Gerçek Fiyatlar ile Tahmin Edilen Fiyatların Uygunluğu**



**Kaynak:** Tez kapsamında geliştirilen Airbnb uygulaması üzerinde yer alan bilgilerden elde edilmiştir.

### 2.7.2. DL Algoritmasının Modellenmesi


DL algoritmaları geliştirilmiş ML algoritmalarına YSA'ların uyarlanmasıyla ortaya çıkmaktadır. Bu algoritmaların en temel özelliği ise veri setindeki özellikleri yani sütunlardaki değerlerin sonuca etkisinin ne kadar olacağını öğrenmesi olarak ifade edilmektedir.

Bir DL algoritması bir gizli katman, bir giriş katmanı ve bir de sonuç katmanı olarak tasarlandığında üç katmanlı bir yapı oluşmaktadır (Bkz. Şekil 21). Gizli katmanların her biri giriş ve çıkış değişkenlerinden oluşmakta ve bu değişkenler kendinden bir önceki katmandan aldığı veriyi işledikten sonra kendinden sonraki katmana iletmektedir.<sup>35</sup> Katmanlar arası değerlerin iletimleri esnasında sonuç değerleri için birer aktivasyon fonksiyonu bulunmaktadır (Bkz. Şekil 22). Bu

<sup>35</sup> Bütün girişleri ve bütün çıkışları birbirine bağlı ve her birinin ayrı bir ağırlığı bulunan ve ağırlık sadece bu tip katmanlardan oluşturulmuş ise bu tip bir ağ mimarisine çok katmanlı algılayıcı olarak adlandırılmaktadır.

aktivasyon fonksiyonları ise katmanların doğrusal olmamasını sağlamaktadır. Aktivasyon fonksiyonlarının seçimine gelince DL algoritma geliştiricileri biyolojik açıdan benzerliği nedeniyle yıllarca sigmoid fonksiyonunu kullanmışlardır. Ancak, ReLU'nun YSA'larda genellikle daha iyi sonuçlar vermesiyle biyolojik analojinin<sup>36</sup> yanlıtıcı olduğunu ortaya çıkarmıştır (Géron 2019, 289).


### Şekil 21: Bir Gizli Katmanlı Yapay Sinir Ağının Yapısı



**Kaynak:** SCHWALBE (2017, 10). “Algorithms, Machine Learning, and Collusion”, [https://papers.ssrn.com/sol3/papers.cfm?abstract\\_id=3232631](https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3232631), Erişim Tarihi:13.06.2019.

DL algoritmanın modeline gelince Airbnb fiyat tahmin uygulaması için Tensorflow'u arka alanda kullanan Keras seçilmiştir. Keras seçmenin en önemli yanları her tür sinir ağını kolayca oluşturmaya, eğitmeye, değerlendirmeye ve yürütmeye olanak sağlaması olarak ifade edilmektedir (Géron 2019, 292).

### Şekil 22: DL Aktivasyon Fonksiyonları



**Kaynak:** GÉRON A. (2019, 289) Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow, Fifth Release, USA

<sup>36</sup> Biyolojik analogi, insan bedenine benzer bir şekilde çalışmayı ifade eder.

DL algoritmasıyla geliştirilen Airbnb uygulaması ML algoritmasıyla geliştirilen Airbnb uygulamasıyla kıyas yapılabilmesi için aynı örneklem üzerinden veriler kullanılmış ve beş katmandan oluşan bir YSA yapısı oluşturulmuştur. Bu yapının ilk katmanında aktivasyon fonksiyonu olarak *tanjat* fonksiyonu seçilmiş sonraki üç katmanda ise *RELU* kullanılmıştır. Son katmanda ise herhangi bir aktivasyon fonksiyonu kullanılmamıştır. YSA yapısının tamamı Tablo 2’de gösterilmiştir. Bu YSA yapısı incelendiğinde ise toplam 15961 değişkenin kullanıldığı ve bu değişkenlerin tamamının eğitim sürecinde eğitildiği gözlemlenmiştir.

**Tablo 2:** DL Katman Yapısı

Katman	Çıkış	Aktivasyon Fonksiyonu	Değişken
Katman 1	80	Tanjat	3600
Katman 2	120	Relu	9720
Katman 3	20	Relu	2420
Katman 4	10	Relu	210
Katman 5	1	-	11

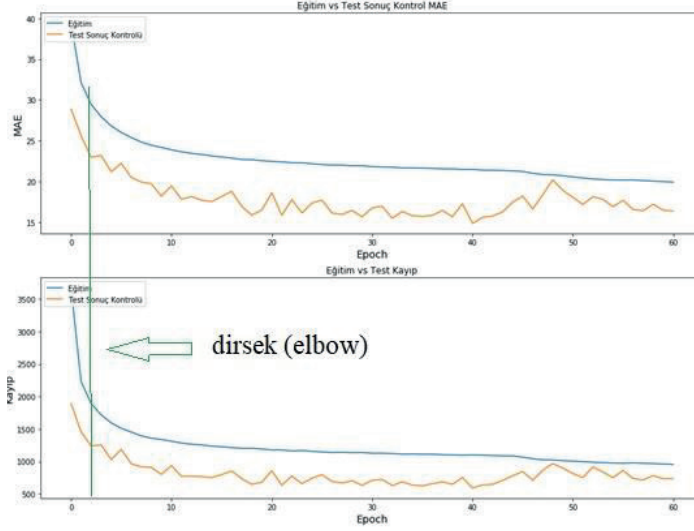
**Kaynak:** Tez kapsamında geliştirilen Airbnb uygulaması üzerinde yer alan bilgilerden derlenmiştir.<sup>37</sup>

DL algoritmasının Keras ile eğitimini tamamlandıktan sonra yine gerçek değerler ile tahmini değerler arasındaki farkın ne şekilde değiştiğinin analizi yapılmıştır (Bkz. Şekild 23). Bu analiz sonucunda tahmin değerlerinin gerçek değerlere yine başarılı bir şekilde yaklaştığı gözlenmiş ve DL algoritmalarının sonuçlarında gözlenen dirsek grafiği<sup>38</sup> başarılı bir şekilde gerçekleştirilmiştir. Bu dirsek şeklinin olduğu yer ise kullanılan verinin kaç sınıfa ayrılması gerektiğini bizlere ipucu olarak vermektedir.

<sup>37</sup> Tez için yazılan Airbnb DL uygulamasından alınmıştır. Kullanılan epoch sayısı 500’dür ve her bir örneklem setinin 500 kez tekrarlandığı anlamına gelmektedir.

<sup>38</sup> Dirsek (elbow), grafiğimizdeki eğri, bir dirsek sergiler (aşağıdaki şekilde) ve bu dirsek küme sayısını belirlemek için kullanılmaktadır.

### Şekil 23: DL Algoritmasının Eğitimi ve Elbow



**Kaynak:** Tez kapsamında geliştirilen Airbnb uygulaması üzerinde yer alan bilgilerden elde edilmiştir.

## 2.8. MODEL BAKIMI (MODEL MAINTANCE)

Airbnb uygulaması hem ML hem de DL algoritmalarına uyarlanmıştır. Deneyin gerçek durumlara ne kadar yaklaştığının anlaşılabilmesi için ML algoritmalarında çok yoğun kullanılan modeller altında birkaç teste tabi tutulmuştur. Bu testler Airbnb uygulaması için hangi ML modelin daha olumlu sonuç vereceğini belirlemek amacıyla yapılmıştır. Dolayısıyla bu testlerin başarılı bir şekilde yapılabilmesi için öncelikle veri setinin uyarlanması gerekmiş ve bu uyarlama işlemi için İstatistik ve Olasılık'tan yararlanılmıştır.

Bu kısımda öncelikle fiyat değişkeni Normal dağılıma göre bir logaritmik değişkenden geçirildikten sonra ML algoritma modellerinde testlere tabi tutulmuştur. Her bir test kendi içerisinde skorlar üretmiş ve daha sonra bu modellerin karşımı bir model uygulandığında ne tür bir skor üreteceği araştırılmıştır.

### 2.8.1. İstatistik ve Olasılık

Geçmişten günümüze eldeki veri setlerinden çıkarım yapabilmek için İstatistik ve Olasılık bilimine başvurulmaktadır. Günümüzde ise artık bu durum ML algoritmalarının modelleri içerisinde karşımıza çıkmaktadır. Sonuç olarak tahmin algoritmalarının özünü yine matematiksel yasalar belirlemektedir.

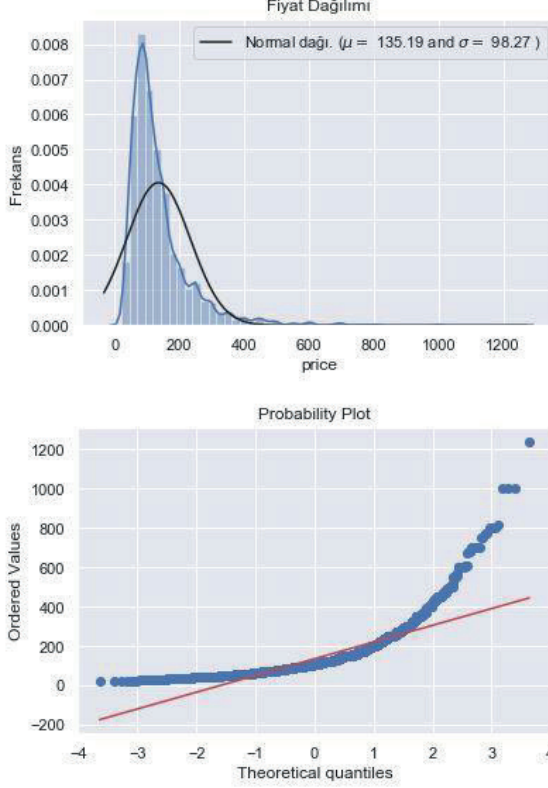
Bu bilgiler ışığında yapılan Airbnb konuklama fiyatlarının tahmin işlemi öncesi ML algoritmaların daha doğru bir şekilde fiyatlamayı öğrenebilmesi için veri setindeki fiyatların ne şekilde dağıldıkları ve bu dağılımın neye benzediği incelenmiş ve bu dağılımın bir çan eğrisi şeklinde olduğu tespit edilmiştir (Bkz. Şekil 24 ve Şekil 25). Doğadaki birçok rastsal gözlem yaklaşık olarak (Bkz. Şekil 15), çan eğrisi biçiminde dağılmakta ve birçok gözlem bir ideal değer çevresinde küçük oynamalar ile farklılaşmaktadır (Alpaydın 2017, 448).

#### 2.8.1.1. Normal Dağılım (Normal Distribution, Gauss Distribution)

Normal Dağılım grafiklerinin çizimi için kullanılan değişkenler, beklenen değeri  $\mu$  ve varyans  $\sigma^2$  olan normal ya da Gauss dağılım  $X$  rastsal değişkeni  $\mathcal{N}(\mu, \sigma^2)$  olarak ifade edilmekte sonuçların hesaplanması için ise aşağıdaki formül kullanılmaktadır.

$$p(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left[-\frac{(x - \mu)^2}{2\sigma^2}\right], -\infty < x < \infty$$

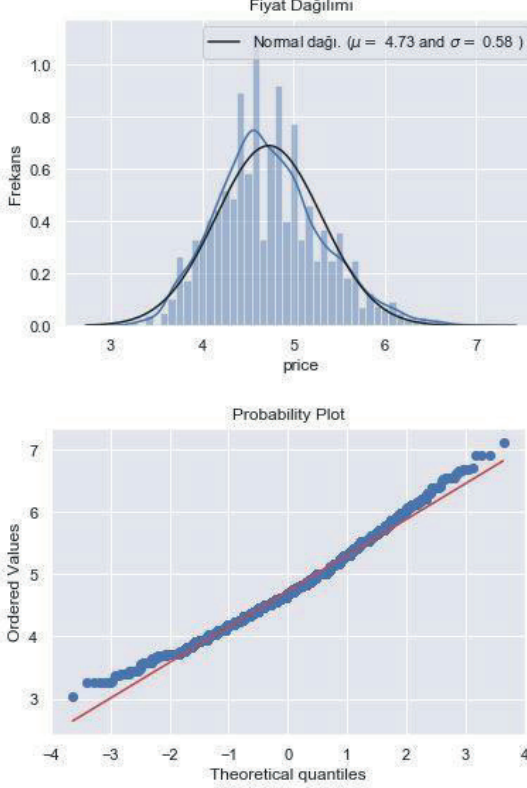
### Şekil 24: Veri İşlenmeden Önceki Normal Dağılım (Gaussian Distributions)



**Kaynak:** Tez kapsamında geliştirilen Airbnb uygulaması üzerinde yer alan bilgilerden elde edilmiştir.

Bu formül kullanarak analiz edilen Airbnb uygulamasına uyarlanırsa  $\mu$  ideal değeri,  $\sigma$  da örneklerin bu ideal değer çevresinde ne kadar oynayabildiğini göstermektedir. Fiyat-Frekans dağılımının gösterildiği grafikte  $\mu$  yaklaşık 135,19 ve  $\sigma$  ise 98,27 olarak hesaplanmıştır. Bu veriler ışığında olasılık grafiği incelendiğinde ise iki farklı değer bir birleriyle uyuşmadığı gözlemlenmiştir. Hedef değişkenin sağa doğru eğik olduğu modelin ise normal olarak dağılmış olan verileri sevdiği göz önünde bulundurulduğunda fiyat verimizi daha normal dağılıma dönüştürmemiz gerekmiştir.

**Şekil 25: Veri İşlendikten Sonraki Normal Dağılım (Gaussian Distributions)**



**Kaynak:** Tez kapsamında geliştirilen Airbnb uygulaması üzerinde yer alan bilgilerden elde edilmiştir.

Bu uygunsuz durumun düzeltilmesi için giriş değerleri olan fiyatlar logaritmik<sup>39</sup> bir şekilde iletilerek gerekli uygunluk yakalanmış ve veriler normal dağılım gösterebilmiştir (Bkz. Şekil 25).

### 2.8.2. Model Hata Hesaplama

Airbnb uygulaması veri işleme sürecinden geçirildikten sonra ML modellerinde sırasıyla denenmiştir. Sırasıyla kullanılan modelleri şu şekildedir:

<sup>39</sup> Gerçek değerli girdi veri türleri için log1p her zaman gerçek çıktı döndürmektedir. Gerçek sayı veya sonsuz olarak ifade edilemeyen her değer için, nan vermekte ve geçersiz kayan nokta hata bayrağını ayarlamaktadır.

- **Lasso:** Doğrusal uyumlama(Linear Regression) modelleri için büzülme ve değişken seçim yönetimi olarak tanımlanmaktadır. Lasso'nun amacı Coursera çevrimiçi eğitim sitesinde şu şekilde açıklanmaktadır:

... niceleyici bir yanıt değişkeni için öngörme hatasını en aza indiren öngörücü alt kümesi elde etmektir. Bunu, bazı değişkenlerin sıfıra doğru daralmasına neden olan uyumlama katsayılarının neden olduğu model değişkenlerine bir sınırlama getirerek yapmaktadır (2019).

- **KRR:** KRR, Ridge Regression ile çekirdek numarasını birleştirme yönetimi kullan bir model türü olarak tanımlanmaktadır. Bu işlem sonucunda ilgili çekirdeğin ve verinin indüklediği uzayda doğrusal bir fonksiyon tanımlanmaktadır.
- **ElasticNet:** LASSO ve Ridge Regresyonunun, L1 ve L2 cezalarını doğrusal olarak birleşimi sonucu oluşturulmuş bir uyumlama olarak tanımlanmaktadır.
- **GradientBoost:** Öğrenme sürecinde sabit büyüklükteki karar ağaçları özellikle CART ağaçları ile birlikte kullanılması modeline verilen isimlendirmedir.
- **XGBoost:** Baskın rekabetçi ML olan hız ve performans için tasarlanmış gradyanlı yükseltilmiş karar ağaçlarının bir uygulaması olarak ifade edilmektedir.
- **LightGBM:** Sıralama, sınıflandırma ve diğer birçok ML görevinde kullanılan karar ağacı algoritmasına dayalı, hızlı, dağıtılmış, yüksek performanslı bir gradyanı artırıcı bir yapı olarak tanımlanmaktadır.

Kök Ortalama Karesi Hatası (RMSE) ve Kök Ortalama Kare Logaritmik Hatası (RMSLE), ML modeli tarafından tahmin değerler ile gerçek değerler arasındaki farkı bulma teknikleri olarak kullanılmaktadır. Bu iki teknik kullanılması sonucunda modellerin hangisinin ya da hangilerinin daha iyi sonuçlar verdiklerine bakılmaktadır.

Bu kavramları ve farklılıklarını anlamak için, Ortalama Karesel Hata'nın (MSE) ne anlama geldiğini incelemek gerekmektedir. MSE, hataların karelerinin ortalamasını, RMSE ise MSE'nin karekökünün alınması ile hesaplanmaktadır.

RMSLE, tahmin ve gerçek değerler üzerinden hesaplanmaktadır. Tahmin edilen ve gerçek değerler arasındaki fark çok fazla olduğu zaman genelde RMSLE kullanılmaktadır. Tahmin ve gerçek değerler arasındaki ilişkiye göre RMSE ve RMSLE kullanımı Bhatia (2017) tarafından şu şekilde açıklanmıştır:

- Hem tahmin hem de gerçek değerler küçükse RMSE, RMSLE aynı sonuç vermektedir.
- Tahmin ya da gerçek değer büyükse RMSE, RMSLE değerinden fazla çıkmaktadır.

Yapılan tahmin hatalarının ne şekilde ele alındığı ve bulunan sonuçların ne şekilde değerlendirilmesi gerektiğine dair yöntemler belirlendikten sonra Airbnb uygulaması üzerinden değerlendirilme yapılmıştır. Bu bilgiler ışığında her bir model için alınan RMSLE skorları Tablo 3'teki gibi gösterilmektedir. Bu tablodaki veriler ışığında en düşük değerlerin yani doğruluk oranlarının en yüksek olduğu iki model ortaya çıkmaktadır. Bunların Gradient Boosting ve Xgboost olduğu anlaşılmaktadır. Ancak sadece bu modellerin kendi başlarına kullanıldığı testlerin dışında bir de modellerin bir araya getirilerek elde edilen testlerin sonuçlarına bakılmıştır. Bu sonuçların tek bir model kullanmak yerine birden fazla modelin yeterli bilgisayar kaynağı ile beraber kullanıldığında daha iyi sonuç verdiği ortaya çıkmıştır.

**Tablo 3:** ML Model RMSLE Skor

Model Türü	Rmsle Skor (Mean/Std)
Lasso	0,3866 (0,0022)
ElasticNet	0,3866 (0,0022)
Kernel Ridge	0,3359 (0,0022)
Gradient Boosting	0,2322 (0,0038)
Xgboost	0,2572 (0,0020)
LGBM	0,3163 (0,0023)

**Kaynak:** Tez kapsamında geliştirilen Airbnb uygulaması üzerinde yer alan bilgilerden derlenmiştir.

ElasticNet, Gradient Boosting, KRR ve Lasso modellerinin ortalama hata payı (mean/std) 0,3197/0,0024 olarak hesaplandıktan sonra bu değer üzerinden

RMSLE hatası hesaplanmış ve değeri 0,2261/0,0040 olarak bulunmuştur. Tablo 3'te de anlaşılacağı üzere her bir modelin ortalama hata payı hesaplanmış ve böylelikle birleştirilecek modelde, içerisinde doğruluk payı yüksek olanların daha fazla etkilemesi sağlanmıştır.

Son aşamada birleştirilen dört model stacking esemble metodu ile yapılmıştır. Stacking modeli daha önceden yapılan tahminler üzerinden bir kez daha eğitilerek yeni tahmin değerleri üretmiştir. Bu aşamadan sonra Xgboost ve LGBM üzerinden tekrar bir tahmin işlemi gerçekleştirilerek oluşan üç farklı tahmin veri setinin yüzde yetmişini dört modelin oluşturduğu stacking tahmin veri setinden, yüzde on beşerlerini de Xgboost ve LGBM alındıktan sonra birleştirdiğinde ortaya çıkan hata payının RMSE hata değeri 0,21348957174720665 olarak gerçekleşmektedir. Sonuç olarak elde edilen veri setindeki tahminlerin değerlerinin hata payları daha da düşük bir değere çekilerek tahminlerin doğruluk oranları artırılmıştır.

## 2.9. BÖLÜM DEĞERLENDİRMESİ

Bu bölümün tamamında ML ve DL algoritmaları ile yapılan fiyat tahmin işlemleri her bir aşaması tek tek ele alınarak gerçek değerlere yaklaşmak için neler yapılması gerektiği sorusunun cevabı aranmıştır. Bu arayış içerisinde yapılan model bakımları ya da kullanılan tekniğin değiştirilmesi (DL Algoritmaları gibi) tahmin edilecek olan değişkenin gerçek değere yaklaşım oranını çok yakın değerlere taşıyabilmiştir. Bu testlerin e-ticarette devleşen her bir teşebbüs tarafından da yapıldığı ve bu alanda gelişim için yatırım olanaklarının sürekli bir şekilde artırıldığı sektörde genel kabul haline geldiği düşünülmektedir. Bu kabulün oluşmasında en büyük etkinin temelinde fiyatlama algoritmaları ile teşebbüslerin kârlarını artırabilmesi yatmakta ve kâr oranının ise sürekli artırılmak istenmektedir. Bu istek sonucunda fiyatlandırma algoritmaları kullanan AI uygulamalarının yaygınlaşması giderek artmaktadır. Bu bölümde yoğun teknik bir analizin yapılmasındaki amaçlarından bir tanesi algoritmik fiyatlamanın başarı oranının artırılması için algoritmik karmaşıklığının da artırılması gerektiğini ortaya çıkarmaktır. Artan bu karmaşıklık sonucunda ise Airbnb uygulama örneğindeki gibi yüksek tahmin oranı yakalanması ve bu durumun Airbnb'nin lehine konaklama sahipleri üzerindeki komisyon paylarını artırıcı bir ekti oluşturarak rekabet karşıtı durumların oluşmasına neden olabilmektedir.

### **2.9.1. Airbnb Uygulama Sonuçlarının Hâkim Durumun Kötüye Kullanılması Bağlamında Değerlendirilmesi**

Airbnb'deki ML algoritmalarının çalışma mantığına benzer bir biçimde oluşturulan Airbnb uygulamasında gerçek fiyatlara çok yakın ve başarılı bir şekilde fiyat tahmini gerçekleştirilmiştir. Bu bilgiler ışığında Airbnb'deki çoğu ev sahibi Airbnb fiyatlama uygulamasını kullanarak daha hızlı, daha doğru ve zahmetsizce fiyatlarını hesaplayabildiğini düşünmektedirler. Öte yandan ev sahiplerinin, ev fiyatlarını deneme yanılma yoluyla bulmaları vakit kaybına neden olduğundan Airbnb fiyat tahmin uygulamasının kullanılması söz konusu olmaktadır (Oxera 2018, 4). Ancak Airbnb fiyat tahmini uygulamasının (Airbnb 2019) giderek yaygınlaşmasıyla birlikte ev sahiplerinden alınan komisyon oranları da artmıştır<sup>40</sup>. Bu durumu daha da detaylandıracak olursak Airbnb fiyat tahmini önererek platformdaki genel fiyat seviyesini artırma konusunda teşvik edici olmaktadır (Oxera 2018, 4).

Airbnb ML fiyat tahmin uygulamasının kullanımı arttıkça konak evlerin fiyatlarının artışı sürekli bir hale dönüşebilmektedir. Bu fiyat artışları incelendiğinde hâkim durumda olduğu düşünülen Airbnb'nin<sup>41</sup>, aşırı fiyat uygulayarak kârlarını en üst düzeye çekebilecek pazar gücünü elde edebilmektedir. Bu bağlamda sektörde dijital veri giriş engellerinin bulunması ve ağ etkisinin pazara yeni girişleri engellemesi tüketici refahının da azalacağını sonucunu ortaya çıkarmaktadır.

Bu bölümde, algoritmik fiyat tahmininin rekabet üzerine etkileri detaylı bir şekilde analiz edilmiştir. Bundan sonraki bölümde ise oyun teorileri üzerinden RL algoritmaların fiyat rekabetinin olduğu bir sanal ortamda ne şekilde davranacakları ve hangi şekilde rekabet karşıtı durumların oluşacağı değerlendirilmektedir.

---

<sup>40</sup> Airbnb (2017), 'New Study: Airbnb Community Generates £502 Million in Economic Activity in the UK'. <https://www.airbnb.co.uk/press/news/new-study-airbnb-community-generates-502-million-in-economic-activity-in-the-uk>, Erişim Tarihi: 13.06.2019.

<sup>41</sup> Airbnb by the Numbers: Usage, Demographics, and Revenue Growth, <https://muchneeded.com/airbnb-statistics/>, Erişim Tarihi: 13.06.2019.

## BÖLÜM 3

### ALGORİTMALAR VE DENEYSEL ÇALIŞMALAR

RL algoritmaları geçmişten edindikleri deneyimleri hafızalarına alarak hataları daha az sıklıkla yaparak başarılı eylemlere dönüştürmektedirler. Bu durum ise RL algoritmalarının dünya üzerindeki popülaritesini daha da artırıcı bir etki yapmaktadır. Hal böyle olunca RL algoritmalarının rekabet karşıtı eylemlere neden olup olmayacağı tartışılmaya başlanmıştır. Bu tartışmaların odak noktasında ise teşebbüslerin yeni bir pazarda zaman geçirdikçe uygun bir stratejiyle edindiği tecrübeler sayesinde fiyat birlikteliği yapabilecek bir gizli anlaşmanın parçası olabileceği gerçeği yer almaktadır.

RL algoritmaları hakkında oluşmaya başlayan bir başka endişe ise bu tür yazılımları geliştiren firmalar hakkında yeterince bilgi sahibi olunamamasıdır. Bu durumda kullanılan RL algoritmalarının rekabet karşıtı bir eylemde bulunup bulunmadığının kontrolü yapılamamaktadır (Calvano vd. 2019, 2). Burada rekabet karşıtı eylemleri oluşturabilecek RL algoritmaları şu şekilde tespit edilebilmektedir. Eğer bir RL algoritması hafıza taşıyorsa bu geçmiş deneyimlerinden besleneceği ve rakip firmaları takip edebileceği anlamına geldiği için bu tür algoritmalar üzerinde odaklanılması gerekmektedir. Diğer türlü hafıza taşımayan algoritmalar genelde ezberci ajanlardan oluşmakta ve bunlar rakip firmaların yapmış oldukları hareketleri cezalandıramadıkları gibi yapmış oldukları eylemleri gizleyemedikleri için bu deneylerin kapsamındaki algoritmalarından sayılmamaktadır.

RL algoritmaları kendi içerisinde çok farklı türlere ayrılmaktadır. Ancak ekonomik analiz yapılabilecek bir yapıya uygun ve yapmış olduğu eylemleri hafızasında tutabilen ve eylemlerin sonuçlarında ödül ya da ceza durumları karşısında tepki verebilecek bir yapıda olması gerekmektedir. Bütün bu özelliklerin hepsinin bir arada bulundurulması sebebiyle rekabet karşıtı deneylerin analizinde

genelde Q-öğrenme (Q-learning) seçilmektedir. Q-öğrenmenin bir diğer özelliği ise ekonomik faktörlerin deneye kolay bir şekilde uyarlanabilecek bir yapıda oluşudur.

Bu tür deneyler sonucunda yapılan analizlerde AI uygulamalarının daha da gelişmesiyle gizli anlaşma oluşma ihtimalinin artacağı öngörülmektedir. Doğası gereği bu tür algoritmaların kârlarını artırma isteği gizli anlaşmaları daha da makul hale getirmektedir. Ancak bu tür anlaşmaların hala ispatlanmasında ve değerlendirilmesinde istenilen noktaya gelinememiştir.

Bu nedenle bu bölümde AI uygulamaların değerlendirilmesi ve bu tür algoritmalara karşı bir bakış açısının oluşması açısından öncelikle ekonomik çevrelerce tartışılan oyun teoremlerinden bahsedilecek, daha sonra oligopol bir pazarda Q-öğrenmesinin deneysel sonuçları tartışılacak ve son olarak bu tür algoritmaların rekabet ortamlarındaki davranışları değerlendirilerek son bölüme geçilecektir.

### 3.1 OYUN TEORİLERİ

Ekonomi dünyasında algoritmik fiyatlama için en çok şu üç tür oyun teorisi üzerinde durulmaktadır. Bu teoriler Fiyatların Kontrollü Artırılması, Cournot Yarışması ve Tekrarlanan Mahkûm İkilemi olarak ifade edilmektedir. Algoritmaların fiyatlamalar üzerindeki etkinliğini net bir şekilde ortaya koymak için bu oyun teorilerinde oligopol pazar yapısı tercih edilmektedir. Çünkü oligopol pazar yapısının bulunduğu bir pazarda oyuncular arasında etkileşim tekrarlı bir şekilde meydana gelmektedir. Bir başka ifadeyle bahsetmek gerekirse Nash<sup>42</sup> dengesinin sınırsız bir şekilde oluşabileceği anlamına gelmektedir. Bu nedenle Nash dengesinin belirlenmesi oyuncular arasındaki etkileşimin koordinasyon mu yoksa olası bir davranış türü mü olduğunu net bir şekilde ortaya çıkarmak için önemli bir eşik haline gelmektedir.

Oyun teorilerinde Nash dengesinin sınırsız sayıda oluşma ihtimalinin etkisini ortadan kaldırmak için gerçek oyunculara bulunan aşırı gerçekçi davranışların

---

<sup>42</sup> Her oyuncu, oyun içinde elinde olan eylemlerden birini seçmiş olduğu ve diğer tüm oyuncuların böyle bir seçim yaptığı varsayımı altında bir oyuncu için seçilmiş eylem, diğer oyuncuların seçtikleri eylem gözetildiğinde oynanabilecek en iyi eylem ise ve bu özellik tüm oyuncular için sağlanıyorsa, bu eylemler bir Nash Dengesine ulaştıkları anlaşılmaktadır.

biraz daha hafifletilerek teorilere uyarlanması sağlanmaktadır. Böylelikle Nash dengesi belirli bir noktada oluşmakta ve oyuncular arasındaki davranışlar rasyonel bir şekilde analiz edilebilmektedir.

### 3.1.1. Fiyatların Kontrollü Artırılması

Teşebbüslerin fiyatlarını kontrollü bir şekilde artırabildiği bir pazar yapısı genelde duopol<sup>43</sup> model olarak karşımıza çıkmaktadır. Böyle bir pazar yapısında teşebbüslerce verilen taahhütlerin uygulanmasının tespitinin daha rahat olması sebebiyle oyun teorilerinde analiz için daha sık kullanılmaktadır. Ayrıca teşebbüsler böyle bir pazar yapısında kârlarını belirlerken de şu anki indirimli değerini maksimum değere çekerek yapmak istemektedir (Maskin vd. 1988, 572). Başka bir ifadeyle teşebbüsler fiyatlarını sadece geçmişte yapmış oldukları eylemleri temel alarak değil aynı zamanda şu anki rakip teşebbüsün fiyatına bakarak da belirleyebilmektedirler.

Bu oyun modelinde bir gizli anlaşmaya yol açabilecek en uygun oyun stratejisini belirleme üzerine Klein (2018) tarafından yapılan deneylerde Q-öğrenme algoritmasının bunu başarabileceği ortaya konulmuştur. Bu deneyde piyasa özellikleri ürünlerin homojen olduğu ve taleplerin ise doğrusal bir şekilde olduğu üzerine yapılmaktadır (Maskin vd.1988). Deneyde iki Q-öğrenme algoritmasının sabit bir fiyata ya da Edgeworth<sup>44</sup> döngüsüne benzeyen bir şekilde yakınsadığı ortaya konulmuştur.

Sonuç olarak bu oyun modelinde Q-öğrenme algoritması kullanılarak bir deney yapılmak istendiğinde kullanılması gereken en önemli faktör rakip teşebbüslerin yapmış oldukları fiyat artışları ya da indirimleri olarak belirlenmiştir.

### 3.1.2. Cournot Yarışması

Cournot Oligopol; teşebbüs sayısının sabit olduğu, teşebbüslerin birbirlerini mükemmel ikame ettiği, talep fonksiyonunun doğrusal olduğu (Waltman ve Kaymak 2008, 6), teşebbüslerin aynı maliyet fonksiyonlarına sahip ve marjinal maliyetin sabit olduğu bir model olarak tanımlanmaktadır. Bu tanım kapsamında Waltman

---

<sup>43</sup> Bir malın yalnızca iki satıcısının bulunduğu piyasa yapısı olarak tanımlanmaktadır.

<sup>44</sup> Edgeworth Fiyat Çevrimleri, belirli basit varsayımlar altında rakip oligopolistler arasında dinamik bir fiyat dengesi tarafından üretilen asimetrik bir fiyat modelini ifade etmektedir (Noel 2011, 1).

ve Kaymak (2008) tarafından Cournot modeli ile bir deney gerçekleştirilmiştir. Deneyde tüm oyuncuların aynı anda hareket etmesi sağlanarak sonuçları üzerinde incelemelerde bulunulmuştur. Sonuç olarak tamamen rekabetçi olmaktan uzak durumların ortaya çıktığı gözlemlenmiştir. Ayrıca yapılan deneylerde oyuncuların kâr oranları çok fazla bir oranda meydana geldiği gözlemlenmiştir.

Ancak Waltman ve Kaymak tarafından yapılan deneyler teşebbüslerin geçmiş fiyat bilgileri üzerinden gerçekleştirilmesi sebebiyle teşebbüsler arasında oluşan denge davranışını açıklamakta yetersiz kalmaktadır. Bunun sebebinin ise teşebbüslerin ileriye dönük fiyatlamalarda miyopik<sup>45</sup> davranmaları ve bununla birlikte geçmiş fiyatlar kullanıldığı için ise rekabetçi olmayan durumları ortaya koyması oluşturmaktadır. Bu ise çalışmanın konusu olan RL algoritmasıyla yapılan gizli anlaşmalardan uzak bir noktayı işaret etmektedir.

### **3.1.3. Mahkûm İkilemi**

Oyun teorilerindeki oyuncuların yapabilecekleri eylemleri iki tür ile sınırlandırıldığında oyun teorileri mahkûm ikilemine dönüşmektedir. Bu oyun teorisine uyarlanan Q-öğrenme algoritmaları aralarında gizli bir anlaşma varmış gibi sonuçlanmaktadır. Ancak bu durum, üst düzey rekabetin olduğu ve oyuncuların açık iletişimde bulunmadığı durumlarda gizli bir anlaşmanın koordine edilmesinin zor olacağı ve gerçeğe uyarlanmasının ise mümkün olmadığını iddia etmektedir. Bu durumda Q-öğrenme algoritmalarıyla elde edilecek bir delilin gizli bir anlaşmanın varlığına kesin bir şekilde ispat olmayacağı da belirtilmektedir.

Oyun teorilerinden üç tanesi incelenerek bundan sonraki süreçte bahse konu oyun teorilerindeki bilgiler ışığında RL algoritmasının çalışma prensibi ve ekonomi deneylerinde ne şekilde kullanıldıkları açıklanmaktadır.

## **3.2. RL ALGORİTMALARI VE EKONOMİK DENEYLERDE KULLANILMASI**

RL algoritmaları ekonomi çevresine ilk olarak Arthur tarafından 1991 yılında tanıtılmıştır. Daha sonra RL algoritmalarının oyun teorilerinde kullanılmaya başlanıldığı zamana bakıldığında, 1995 yılında Roth ve Erev tarafından yazılan bir makalede karşımıza çıkmaktadır. Bu makale kapsamında RL algoritması

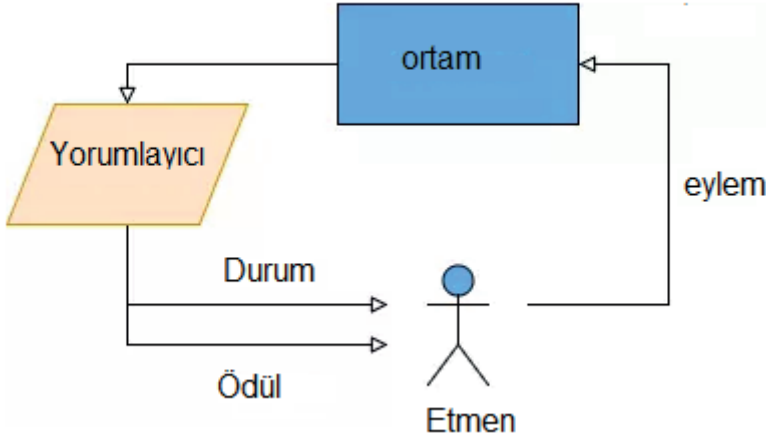
<sup>45</sup> Çok ilerisi için fiyatlama stratejisinde bulunmamaktır.

üzerinden deneyler yapılmış ve bu deneyler sonucunda RL algoritmalarının gözlemlenen seçimleri takip yeteneğinin olduğu (Roth ve Erev 1995) açıklığa kavuşturulmuştur. Ardından RL algoritmalarının daha da geliştirilmiş hali olan Q-öğrenme 2006 yılında Bergemann ve Vallimaki tarafından kullanılmıştır. Bu algoritmanın öğrenme olarak keşif yöntemini kullanması ve bu sayede algoritma performansına olumlu katkısı incelenmiştir (Bergemann ve Valimaki 2006).

Bu gelişim sürecinden sonra akademik çevrede yapılan araştırmalar artmaya ve RL algoritmaları kullanılarak yapılan deney sayılarında artışlar meydana gelmeye başlamıştır. Bu kapsamda yapılan deneylerin daha iyi anlaşılabilmesi için RL algoritmaların çalışma mantığı bu kısımda anlatılmaktadır.

RL algoritmalarında, bir ortamda eylemleri gerçekleştiren bir veya birden fazla etmen (ajan) öğrenme sürecini gerçekleştirmektedir. Öğrenme sürecinde bu etmenler ortamda gerçekleştirdikleri eylemler sonucunda hangi durumda olduğuna bağlı olarak ödüllendirilmektedir. Böylelikle RL algoritması bir oyunu öğrenmek için araştırmaya başlamakta ve bu oyunda kazancını en üst düzeye çıkarmak için sürekli kendisini eğitmektedir (Bkz. Şekil 25).

**Şekil 26: RL Çalışma Prensibi**



**Kaynak:** <https://adventuresinmachinelearning.com/reinforcement-learning-tutorial-python-keras/>, Erişim Tarihi: 09.06.2019.

RL algoritmalarının bu eğitimi tamamlayabilmesi için etmenin sürekli olarak ortamda eylem gerçekleştirmesi sağlanmaktadır. Etmen, eylem gerçekleştirdiğinde, yapmış olduğu bu eylemin sonuçları yorumlayıcı tarafından toplanmaktadır. Etmen her bir eylem gerçekleştirdiğinde ortamda tanımadığı kısımları keşfetmeye devam etmektedir. Bu keşif sürecinde durumunu güncelleyen etmen yapmış olduğu eylemin karşılığında bir ödül almaktadır. Bu ödül pozitif, negatif ya da sıfır olabilmektedir. Aldığı bu ödülleri en üst seviyeye çıkarmak için etmen eylemini buna göre günceller ve öğrenme sürecindeki başarısını artırmayı amaçlar. Daha sonra keşif sürecinin sona ermesiyle RL algoritması öğrenme sürecini başarılı bir şekilde tamamlamış olmaktadır.

Bu kısımda RL algoritmasının çalışma prensibi üzerinde incelemeler yapılmıştır. Bir sonraki süreçte bu çalışma prensibinin daha da geliştirilmiş hali olan Q-öğrenme anlatılmakta ve çeşitli testlerdeki sonuçları üzerine değerlendirilmelerde bulunmaktadır.

### 3.3. Q-ÖĞRENME ALGORİTMASIYLA YAPILAN DENEYLERİN ANALİZLERİ

Oyun teorilerine uyarlanan Q-öğrenme algoritmalarının deneysel çalışmalarda kullanılması sebebiyle öğrenmiş olduğu bilgileri fiyatların belirlenme aşamasında karar verici olarak da kullanabilmektedir. Böyle bir durumda insanlar tarafından gerçekleştirilemeyen bir anlaşmanın algoritmalar tarafından yapılabileceği gerçeği ilerleyen bölümlerde ele alınmaktadır.

Böyle bir gizli anlaşmanın Q-öğrenme algoritmasıyla oluşturulabilmesi için rakip oyuncuların birbirlerinden habersiz bir şekilde değişen çevre ortamları nedeniyle durumlarını değiştirebiliyorlarsa gerçekleşme ihtimali oluşmaktadır.

Bir gizli anlaşmanın parçası olabilecek ardışık bağımsız Q-öğrenme *sahte kodu* (pseudocode) Kelin (2018, 8) tarafından şu şekilde belirtilmiştir:

- Talep fonksiyonu, öğrenme ve keşif değişkenlerini ayarla  $\alpha, \delta, \epsilon_0, \theta$
- $Q^1$  ve  $Q^2$  yi başlat
- $p_t^i$  için  $t = \{1,2\}$  ve  $i = \{1,2\}$  t ve i değerlerini rastgele seç

- $t = 3, i = 1$  ve  $j = 2$  ata
- Döngüyü başlat
  - $p_t^j = p_{t-1}^j$  ata
  - Fiyat  $p_t^i$ 'yi (3) göre ayarla
  - $Q^j(p_{t-1}^j, p_{t-1}^i)$ (2) göre güncelle
  - $t \leftarrow t + 1$  ve ( $i \leftarrow j, j \leftarrow i$ )
- Döngüyü  $t = T$  olana kadar devam

Bu kısımdan sonraki aşamada Q-öğrenme algoritmasının üzerinde yapılan deneylerin bağlı olduğu değişkenler ve sonuçlar incelenmektedir.

- **Çevre:** Deneyler tüketicinin ürün satın alma kararlarının o malın fiyatına ve özelliklerine bağlı olduğu *logit tale* sistemi ile beraber marjinal maliyetlerin sabit tutulduğu bir ortamda gerçekleştirilmektedir. Bu çevre koşulları ürün farklılaşması veya talep seviyesi gibi değişkenleri analiz etmek için değiştirilebilecek birkaç parametreye sahip olması nedeniyle seçilmektedir (Calvano vd. 2019,16).
- **Başlangıç:** Deneyde algoritma için gerekli olan değişkenler için herhangi bir başlangıç değerine sahip olma zorunluluğu bulunmamaktadır. Q-öğrenme algoritmalarına başlangıçta bir değer atanmadığı durumlarda bu deneyin sonuçlanma süresine etki ekmekte olup keşif süreci için herhangi bir engel teşkil etmemektedir.
- **Bellek:** Yapılan deneylerin durum alanlarının sonlu bir alanda gerçekleştirilmesi sebebiyle hafızasının da sınırlı bir şekilde ayarlanması gerekmektedir. Q-öğrenmesi algoritmasını öğrenmiş olduğu deneyimleri bir sonraki fiyat tespitinde kullanabilmesi için belli başlı durumları hafızasında tutması zorunluluğu oluşmaktadır.
- **Keşif:** Q-öğrenme algoritmalarının ortamı keşifte bulunabilmesi için deneylerde belli başlı değişkenler kullanılmaktadır. Bu değişkenlerin büyüklükleri öğrenme süresini ve öğrenmedeki başarı oranı üzerinde etkili olmaktadır. Q-öğrenme algoritmaları genelde bu değişkenler için

açgözlü bir şekilde öğrenmesini sağlayacak büyüklükte ayarlanmaktadır. (Calvano vd. 2019,18)

- **Tutarlılık:** Öğrenme sürecinde Q-öğrenme algoritmasının tutarlı bir şekilde çalışmasının kontrolü için deneylerde algoritmanın aldığı başarı ödülleri bakılmaktadır. Bir Q-öğrenme algoritması ne kadar başarılı olursa almış olduğu ödül miktarı da o kadar yüksek çıkmaktadır. Bu test işlemi deneylerde kullanılan değişkenlerin değerleri ya da rakip teşebbüsler arasındaki fiyat farkı artırılarak ya da azaltılarak gerçekleştirilse bile kullanılan Q-öğrenme algoritmaları tarafından birbirlerine benzer şekillerde tepkiler vererek sonuçlanmıştır. Böyle bir durum karşısında Q-öğrenme algoritmalarının öğrenme sürecini tutarlı bir şekilde tamamlayabildikleri gerçeğini ortaya çıkarmaktadır.
- **Denge:** Q-öğrenme algoritmalarında denge durumları incelenirken bu durumun kendiliğinden mi sağlandığı yoksa belirli bir en uygun strateji etrafında öğrenmesini tamamlamış algoritmalar tarafından mı sağlandığının bilinmesi önemlidir. Deneylerde algoritmaların fiyat dengesine belirli bir en uygun strateji ile gelmeleri durumunda Nash dengesini bulmaları söz konusu olmaktadır. Bu bilgiler ışığında denge durumunun nasıl oluştuğuna dair *ex ante*<sup>46</sup> analizinde net bir sonuç ortaya konulmasa da, *ex post*<sup>47</sup> analizinde net bir sonuç ortaya konulabilmektedir. (Calvano vd. 2019, 23).

Ancak bazı deney sonuçlarında Nash dengesi herhangi bir şekilde sağlanamamaktadır. Bu durum olduğu takdirde algoritmaların Q-matrixleri kıyaslanmaktadır. Bu kıyaslama algoritmaların en iyi tepkiye olan uzaklığını ölçmek için kullanılmaktadır. Böyle bir durumda yapılan kıyaslama sonucunda Nash dengesinin değiştiği de hesaplanabilmektedir.

Q-öğrenme algoritmalarıyla yapılan deneylerde Nash dengesinin bulunması önem arz etmektedir. Bu tür algoritmaları Nash dengesine daha çok yakınsamak isteniyorsa öğrenme ve keşif değişkenlerinin iyi ayarlanması gerekmektedir. Bu ise ancak deneyin kapsamlı olması halinde söz konusu olmaktadır.

---

<sup>46</sup> Deney öncesini ifade etmektedir.

<sup>47</sup> Deney sonrasında ifade etmektedir.

Q-öğrenme ile yapılan deneylerin analiz sonuçlarında önemli bir çıkarım ise rakiplerini diğer teşebbüs algoritmalarını sömürmede başarılı olamayacaklarıdır (Calvano vd. 2019, 24).

### **Yakınsama**

Q-öğrenme ile yapılan deneyler algoritmaların büyük çoğunluğunun biri birlerine yakınsadığını göstermiştir. Ancak bu yakınsamanın gerçekleşebilmesi için rakip teşebbüslerin algoritmalarıyla yapmış oldukları deneylerin sonuçlanması gerekmektedir.

Q-öğrenme deneyi başarılı bir şekilde gerçekleştirildikten sonra bir sonraki aşamada bu tür algoritmaların rekabet ortamlarında ne şekilde davrandıkları ve bunun sonucunda oluşan durumlar incelenmektedir.

### **3.4. Q-ÖĞRENME ALGORİTMALARININ GİZLİ ANLAŞMAYI SÜRDÜRME İSTEĞİNİN ANALİZİ**

Q-öğrenme algoritmaları ile bir gizli anlaşma sağlandıktan sonra algoritmaların ne şekilde davranacaklarının doğru bir şekilde analizinin yapılabilmesi için öncelikle gizli anlaşma kavramının üzerinde durulması gerekmektedir. Bu kavram Harrington tarafından şu şekilde ifade edilmiştir:

Gizli anlaşma, rekabet ortamının olduğu bir pazarda teşebbüsler tarafından fiyatların yukarıda kalması için diğer teşebbüsleri ödüllendirmeyi veya aksi durumda davrananları ise cezalandırılması için bir strateji kullanmayı ifade etmektedir (2017, 2).

Bu tanımdan hareketle Q-öğrenme algoritmaları deneylerde gelmiş oldukları denge noktasında kâr kazançlarının bununla beraber arttığını öğrenmişlerdir. Deneylere devam edilerek bilinçli bir şekilde dengeyi bozacak dışardan bir etki uygulandığında bozulan dengenin tekrardan kurulması için Q-algoritmalarının en iyi strateji izlenerek tekrardan bu noktaya gelmeye çalıştıkları gözlemlenmiştir. Böyle bir sonucun elde edilmesi algoritmalar arasında gizli bir anlaşmanın olduğunun en net durumu olarak ifade edilmektedir (Calvano vd. 2019, 27).

Ekonomik literatürde pazardaki oyuncu sayısı artırıldığında teşebbüsler arasında bir anlaşmanın oluşmasının giderek daha zor bir hal alması gerektiği vurgulanmaktadır. Ancak bu durum Q-öğrenme algoritmalarının kullanıldığı

deneylerde daha farklı sonuçların ortaya çıktığını göstermiştir. Bu tür algoritmaların kullanıldığı deneylerde kâr kazancının düştüğü ancak aralarındaki korelasyonun yine de devam ettiği yönünde olmuştur.

Asimetrik teşebbüsün Q-öğrenme algoritmasının deney ortamına eklendiği durum simule edildiğinde ise gizli anlaşmanın bozulmadığı ancak algoritmaların kâr oranını en üst seviyeye çıkaramadıkları tespit edilmiştir.

Q-öğrenme algoritmalarının beraber buldukları deney ortamına bozucu etkenlerin sırasıyla uygulanması (örneğin talep üzerindeki bağımlılığının artırılması, pazara yeni teşebbüslerin girdirilmesi veya çıkarılması ve en son olarak bütün ürünlerin ikame hale getirilmesi) bile algoritmalar arasındaki korelasyonu bozmada başarılı olmadıkları ancak kâr paylarında bir miktar gerilemeye neden oldukları tespit edilmiştir.

### **3.5. BÖLÜM DEĞERLENDİRMESİ**

Q-öğrenme algoritmaları kullanılarak yapılan deneyler sonucunda gelinen noktada bu tür algoritmaların önceden bilgi vermeden pazar koşullarını öğrenerek kârlarını en üst seviyeye çıkarma eğiliminde oldukları ortaya çıkmıştır. Bu tür eylemlerde bulunurken rakip teşebbüs algoritmalarıyla hiçbir şekilde direk iletişime geçmelerine gerek olmadığı tespit edilmiştir. Bu durumun yani aralarında oluşan gizli anlaşmaları bozucu etkenler ile test edildiğinde bile bir süre sonra tekrar kâr miktarlarının en üst düzey geri getirdikleri gözlemlenmiştir.

Ancak Q-öğrenme algoritmalarının bu deneylerin yapıldığı ortamların dış etkilerin uzağında oluşu ve gerçek dünya ekonomisinin daha çok karmaşık olduğu durumlarda hızlı sonuç verme konusunda tereddütler bulunmaktadır. Bu durumun ise DL algoritmalarının Q-öğrenme algoritmalarına uyarlanmasıyla aşılacağı öngörülmektedir. Bu kısımda bir diğer problem ise rakip teşebbüslerin kullanmış oldukları algoritmaların aynı olmaması halinde ortaya çıkmaktadır. Yapılan deneylerin tamamı homojen algoritmalar ile yapılmakta ancak rakip firmaların farklı algoritmaları kullanması durumunda oluşabilecek bir anlaşmanın ne şekilde gerçekleşeceği analiz edilmektedir. Bu sebeple yapılacak deneylerin bundan sonraki kısımlarında farklı tür algoritmaların beraber kullanıldığı ortamların test edilmesi gerekmektedir.

Yukarıda bahsedilen deneylerin sonuçları ve gelecekte yapılacak olan iyileştirmeler bu tür algoritmaların kullanım oranlarının artırımını öngörmektedir. Ayrıca Q-öğrenme algoritmalarının şu an için bile yapmış oldukları anlaşmalarda rakipleriyle herhangi bir iz bırakmamaları rekabet politikaları kapsamında bu durumların farklı değerlendirilmesi gerekliliğini ortaya çıkarmaktadır. Şayet bu durumlar karşısında her hangi bir önlem alınmaz ise çok fazla suiistimal edilebilecek bir noktaya gelinebilecektir.

## BÖLÜM 4

# ALGORİTMİK ANLAŞMALAR VE REKABET POLİTİKALARI

Bu bölümde diğer bölümlerde yapılan değerlendirmelere de dayanılarak belirlenen rekabet senaryoları içerisinde ABİDA'nın hükümleri ve bu hükümlerin bu senaryolara nasıl hitap ettiği konusu incelenmiştir. İlk kısımda ABİDA kapsamında senaryoların ne tür ihlal oluşturabilecekleri anlatılmakta, ikinci kısımda ise ABD'de bu tür anlaşmaların oluşmasının engellemek için nasıl bir yasa hazırlığında olduğu anlatılmaktadır. Bir sonraki kısımda ise mevcut RKHK'nin oluşabilecek bir algoritmik anlaşmayı önleme konusunda yeterli olup olmadığı sorusuna cevaplar aranarak olası eksikler karşısında neler yapılması gerektiği tartışılmaktadır.

Algoritmaların oluşturduğu rekabet ihlallerinden bahsedebilmek için öncelikle iki durumun açıklanması gerekmektedir. Bunlardan ilki rekabet uygulamasının tipik olarak, rakipler arasındaki olası ihlalle ilgili anlaşmalara, rekabete aykırı dikey kısıtlamalara (yeniden satış fiyatının tespiti gibi), pazar gücünün kötüye kullanılmasına ve rekabeti büyük ölçüde azaltabilecek birleşmelere odaklanması gerekmektedir (FTC).<sup>48</sup> İkinci olarak ise teşebbüslerin kullanmış olduğu algoritmaların yasalarda mevcut bulunan rekabet karşıtı insan davranışlarına benzer bir etki yapıyor olması gerekmektedir (Ezrachi 2017, 7).

Ancak gelişen AI algoritmaları karşısında açıklanan durumlardan ilkinde bahsedilen ihlal türlerinin insanlar tarafından yapılmasına gerek kalmamaktadır. Teşebbüsler gelişen AI algoritmalarıyla daha hızlı fiyat belirleyebilmekte ve bu durumda rekabet ihlalleri oluşmaktadır. Ancak bu durum teşebbüsler tarafından

---

<sup>48</sup> FTC, "The Antitrust Laws", <https://www.ftc.gov/tips-advice/competition-guidance/guide-anti-trust-laws/antitrust-laws>, Erişim Tarihi:13.06.2019.

uygulanan her AI algoritmasında mutlaka rekabet ihlali oluşturacağı anlamına da gelmemektedir. AI algoritmaları tarafından yapılan anlaşmalar, açık ve gizli olmak üzere iki türde oluşabilmektedir. Açık bir şekilde yapılan anlaşmaların tıpkı insanlar tarafından yapıldığı değerlendirilmekte olup bunların tespiti kolaylıkla yapılabilmektedir. (Örneğin Haberci ve Topla ve Dağıt senaryolarında olduğu gibi.) Ancak burada kritik noktayı AI algoritmalarının rekabeti yalnızca açık anlaşma ya da uyumlu eylem şeklinde değil daha karmaşık yollardan kısıtlayabildiği durumlar oluşturmaktadır. Bu sebeple rekabet otoritelerinin AI algoritmaları tarafından oluşturulan uygulamaları incelerken ilk olarak niyet kanıtını ve yatay anlaşmanın varlığını ve ayrıca potansiyel sorumluluk olarak iki yasal kavramı göz önünde bulundurmalıdır (Ezrachi 2017, 8). Bu bilgiler ışığında Tablo 4’te bütün senaryolar ve rekabet ihlalleri gösterilmektedir.

**Tablo 4:** Algoritma ve Rekabet İhlalleri

	Anlaşma	Niyet	Yükümlülük
<b>Haberci</b>	Güçlü Delil	Sınırlı Rol	Per Se
<b>Topla ve Dağıt (Hub &amp; Spoke)</b>	Karışık Delil	Amacı ve olası etkiyi açıklığa kavuşturmak için deliller kullanılmaktadır.	Per Se / Rule of Reason
<b>Makineden makineye İletişim/ Tahminleyici Ajan</b>	Delil Yok	Gizli anlaşmaların oluşumunda kolaylaştırıcı etkisi bulunan deliller kullanılmaktadır.	FTC Act § 5 ya da ABİDA’nın 101. ya da 102. madde ihlalleri
<b>Gizli Anlaşma/ Dijital Göz<sup>49</sup></b>	Delil Yok	Delil Yok	Belirsiz

**Kaynak:** Ezrachi ve Stucke (2017, 20)’da yer alan bilgilerden derlenmiştir.

Tablo 4’teki ilk kategori Haberci senaryosudur. Bu senaryoda rekabeti sınırlamak için insanlar tarafından bilgisayarlar kullanılmaktadır.<sup>50</sup> Böylelikle piyasadan gerekli fiyat bilgileri toplanıp kartelin uygulanması ve izlenmesi için kontrol mekanizması sağlanmış olmaktadır. Rekabet otoriteleri perspektifinden bakıldığında, yasal anlaşma kavramı doğrudan uygulanabileceği ve yeterli kanıtlar ile gerekli cezai işlemlerin yapılabilmesi en net senaryoyu oluşturmaktadır. Ayrıca bu senaryoda niyet kanıtı daha az rol oynamaktadır.

<sup>49</sup> Gizli Anlaşma veya Dijital Göz her iki isimlendirmede aynı senaryo için kullanılmaktadır.

<sup>50</sup> Yazılı Mesajlaşma Antitröst Davası, 630 F.3d 622, 628–29 (2010).

İkinci kategori Topla ve Dağıt (Hub & Spoke), acentelerin (spoke) fiyatlandırma için sağlayıcısı (hub) tarafından kullanılan algoritmayı tercih etmesinden kaynaklanmaktadır. Ancak bu senaryoda tek bir dikey anlaşma başlı başına bir rekabet karşıtı etkiyi oluşturmada yeterli gelmemektedir. Başka bir ifadeyle birden fazla sağlayıcının ve bu sağlayıcıya bağlı acentelerin aynı algoritmayı fiyatlandırma için kullanmaları gerekmektedir. Bu nedenle belli sektörlerde birbirine rakip sağlayıcıların (hub) dikey anlaşmalar yaparak bir grup olarak fiyatlarını artırdıklarında rekabet karşıtı bir etki oluşabilmektedir.<sup>51</sup> Böyle bir rekabet karşıtı durumda niyet kanıtına bakılarak anlaşmanın amacının ve olası rekabet etkilerinin değerlendirilmesi gerekmektedir.

Üçüncü kategoride programcılar tarafından tek taraflı algoritmalara fiyat tahmini yaptırabilmek için değişen piyasa koşullarını takip etmesi öğretilerek edildiği bilgilerle tahminlerini güncellemesi sağlanmaktadır. Böyle bir durumda rakip teşebbüslerin de piyasa koşullarını diğer teşebbüslerin yaptığı gibi tahmin edebilmesi ve algoritmasını değiştirebilmesi gerekmektedir. Sonuç olarak benzer algoritmaların kullanımının yaygınlaşması rekabet karşıtı durumların ortaya çıkmasına neden olabilmekte fakat böylesi rekabet karşıtı durumlar için herhangi bir delil oluşmamaktadır. Öte yandan teşebbüslerin yapmış oldukları fiyat tahminlerinin doğruluk oranlarını artırabilmek için pazar koşullarını değiştirerek daha şeffaf bir ortam oluşturulmaktadır. Böylelikle fiyat tespitinde kullanılan algoritmaların doğruluk oranları artırılmış ve bunun sonucu olarak pazardaki oyuncuların fiyatlarını yükseltmesi neticesinde bilinçli bir paralellik oluşmuştur. Bu bilgiler çerçevesinde oluşan anlaşmanın açık bir şekilde gerçekleşmediği aksine gizli bir anlaşmanın sonuçlarının ortaya çıktığı bir yapıda meydana geldiği söz konusu olmaktadır. Ancak böyle bir anlaşma oluşmasına karşın bu durum karşısında rekabet otoritelerinin müdahalesi konusunda bir netlik bulunmamaktadır. Fakat teşebbüslerin piyasa dinamiklerini değiştirmek istemeleri niyetin kanıtı olarak yeterli geleceği düşünülmektedir.

Son senaryoda ise teşebbüsler tarafından tek taraflı olarak kârını en üst düzeye çıkaracak Q-öğrenme algoritmalarının kullanılmasıyla oluşmaktadır. Bu tür algoritmalar başlangıçta hiçbir şey bilmeden piyasadaki topladığı bilgiler ile

---

<sup>51</sup> JTC Petroleum Co. v. Piasa Motor Fuels, Inc., 190 F.3d 775, 778 (1999).

kârını en üst düzeye çıkacak en uygun stratejiyi kendisi öğrenmektedir. Kendi öğrenme yoluyla oluşabilecek bir gizli anlaşma için hiçbir delilin veya iletişimin bulunmadığı bu senaryo ile ilgili herhangi bir yasal sorumluluk bulunmamaktadır. Ancak rekabet ihlallerinin yaygın hale getirebilecek böyle bir durum karşısında yasal çalışmaların gündeme getirilmesi gerekmektedir.

#### **4.1. ABİDA 101. VE 102. MADDELERİ KAPSAMINDA ALGORİTMİK ANLAŞMALARIN DEĞERLENDİRİLMESİ**

Bu kısımda mevcut ABİDA maddelerinin Tablo 4’te bulunan senaryoları kapsayıp kapsamadığı ve nasıl ele alındığının analizi yapılmaktadır. Bu senaryolara yönelik ABİDA 101 ve 102. maddeleri<sup>52</sup> kapsamında ikiye ayrılarak incelenmektedir.

##### **4.1.1. Haberci Senaryosu**

Bu senaryo, ABİDA’ya göre yeni bir anlaşma türü olarak değerlendirilmemektedir. Bu senaryonun anlaşma türlerinin yürütülmesini kolaylaştırdığı, rakipler arası iletişimi ve gözlemi sağlamak için kullanıldığı anlaşılmaktadır. Dolayısıyla böyle bir senaryo ABİDA’nın 101 (1) madde kapsamında değerlendirilmektedir (Bartłomiejczyk 2018, 22).

##### **4.1.2. Topla ve Dağıt (Hub & Spoke)**

Topla ve Dağıt senaryosu iki şekilde ele alınmaktadır. Bunlardan ilki fiyatları tespit etmek için algoritmanın tek, diğeri ise fiyatları belirlemek için hem algoritmanın hem de veri setini aynı olmasından kaynaklanmaktadır. Bu bilgiler ışığında bu senaryonun ABİDA 101. madde kapsamında olup olmadığı rakipler arasında bilgi alış verişinin gerçekleşmesiyle oluşmaktadır (Bartłomiejczyk 2018, 28). Ayrıca ABİDA’nın yatay kılavuzunda rakipler arası bilgi paylaşımının doğrudan ya da dolaylı olabileceği ifade edilmektedir. Söz konusu senaryonun 101. madde kapsamına girebilmesi için bilgi paylaşımının bir anlaşmanın, ortak bir uygulamanın ya da bir teşebbüs birliği kararının bir parçası olması gerekmektedir. Ancak bilgi paylaşımı eğer pazardaki stratejik belirsizlikleri azaltıyor ve böylece

---

<sup>52</sup> <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=celex%3A12012E%2FTXT>, Erişim Tarihi: 10.06.2019.

anlaşmazlıkları kaldırıyorsa bu durum ortak bir uygulamaya girdikleri olarak değerlendirilmektedir (Bartłomiejczyk 2018, 28). Bu durumda ABİDA'nın 101. maddesi kapsamında hem sağlayıcı (hub) hem de acente (spoke) sorumlu tutulmaktadır (Bartłomiejczyk 2018, 28).

#### 4.1.3. Gizli Anlaşma

Bu tür senaryoların, herhangi bir davranışın gerçekleşip gerçekleşmediği dikkate alınarak yapılan bir değerlendirmede gizli bir anlaşmanın hedefine ulaşmasına kolaylaştırıcı bir etkisi ya da uyumlu bir uygulamaya yönelik bir durumu içerdiği takdirde ABİDA'nın 101. madde kapsamında olduğu ifade edilmektedir.

Bu senaryo için herhangi bir davranışın gerçekleşip gerçekleşmediği dikkate alınarak Bartłomiejczyk (2018, 36) tarafından yapılan açıklamada:

...gizli bir anlaşmanın hedefine ulaşmasına kolaylaştırıcı bir etkisi olduğu ya da uyumlu bir uygulamaya yönelik bir durumu içerdiği takdirde ABİDA'nın 101. madde kapsamında olduğu belirtilmektedir.

Rekabet otoritesi tarafından kolaylaştırıcı uygulamaların kullanımı nedeniyle tamamen bağımsız bir oligopolün tamamen bağımlı bir oligopole dönüşmesini neden olduğu tespit edildiği takdirde (Bartłomiejczyk, 2018, 39) bu durumun 102. madde kapsamında olduğu düşünülmektedir.

## 4.2. ABD VE YASA ÇALIŞMALARI

ABD'de 2019 yılında yapılan yasal<sup>53</sup> hazırlıklarla teşebbüslerce uygulanan algoritmaların kontrol altında tutulmaya çalışacağını göstermektedir (Robertson 2019). Bu kapsamda bir yasa hazırlandığı ve bu çalışmanın yasalaşması durumunda yasanın FTC tarafından yürütüleceği belirtilmektedir. Bu yasanın hedefinde ise büyük miktarda veriye erişim imkânı olan teşebbüslerin bulunduğu anlaşılmaktadır. Yasanın kapsamında ise yılda 50 milyon ABD Doları'ndan fazla kazanan ve en az 1 milyon kişi veya cihaz hakkında bilgi sahibi olan veya öncelikle tüketici verilerini alıp satarak, veri brokerliği yapan teşebbüslerin olacağı belirtilmektedir. Ayrıca

---

<sup>53</sup> <https://www.wyden.senate.gov/imo/media/doc/Algorithmic%20Accountability%20Act%20of%202019%20Bill%20Text.pdf>, Erişim Tarihi: 10.06.2019.

ilgili yasanın 7. maddesinin (B) bendinde doğrudan şu ifadeler kullanmaktadır:

7) YÜKSEK RİSKLİ OTOMATİK KARAR SİSTEMİ. - “Yüksek riskli otomatik karar sistemi” terimi, otomatik karar sistemi anlamına gelir.

(A) kullanılan teknolojinin yenilikçiliğini ve otomatikleştirilmiş karar sisteminin doğasını, kapsamını, içeriğini ve amacını dikkate alarak, önemli bir risk teşkil eder;

(i) tüketicilerin kişisel bilgilerinin mahremiyetine veya güvenliğine

(ii) tüketicileri etkileyen yanlış, haksız, tarafı veya ayrımcı kararlara neden olmak veya bunlara katkıda bulunmak

(B) iş performansları, ekonomik durumları, sağlıkları, kişisel tercihleri, ilgi alanları, davranışları gibi yaşamlarının hassas yönlerini analiz etme veya tahmin etme girişimleri dâhil, tüketicilerin sistematik ve kapsamlı değerlendirmelerine dayanarak kararlar verir veya insan karar vermesini kolaylaştırır, konum veya hareketler, ki—

(i) tüketicilerin yasal haklarını değiştirmek

(ii) aksi takdirde tüketicileri önemli ölçüde etkiler

...

(D) geniş, halka açık bir fiziksel yeri sistematik olarak izler

ABD, bu yasa kapsamında karar alma sistemlerinin tüketicilerin davranışlarını izlemelerini yüksek riskli olarak tanımlamaktadır. Böyle bir durum karşısında da FTC'nin bu ve benzeri bilgileri toplayan teşebbüsleri ilgili yasa tasarının devamındaki maddelere göre takip etmesini istemektedir.

#### **4.3. ALGORİTMİK ANLAŞMALARIN DEĞERLENDİRİLMESİNE İLİŞKİN TÜRK REKABET KURUMUNA ÖNERİLER**

Dünya üzerinde algoritmalar aracılığıyla yapılan anti rekabetçi anlaşmalara bu çalışma kapsamında değinilmiştir. Bu anti rekabetçi anlaşmalara bakıldığında daha çok dijital platformlarda bulunan teşebbüsler tarafından yapılmış ihtimalinin yüksek olduğu anlaşılmaktadır. Bu dijital platformların dünya üzerinde yaygınlaştıkları düşünüldüğünde Türkiye’de de bu tür anlaşmaların oluşması kaçınılmaz hale gelmektedir. Ayrıca Amazon, eBay, Uber, Airbnb, Google ve Facebook gibi uluslararası teşebbüslerin ülkemizde de faaliyet gösterdikleri bilinmektedir. Amazon.com, Inc Poster Kartel<sup>54</sup>, Uber için algoritmik tekel olabileceği kaygısı ve ikinci bölümde analizi yapılan Airbnb uygulama örneği üzerinde değerlendirme yapıldığında bu durumların bir kısmının Kanunun 4. ve

<sup>54</sup> United States of America v. David Topkins, Case3:15-cr-00201 (United States District Court, Northern District Of California, San Francisco Division, 2015)

6. maddesi kapsamında incelenebileceği düşünülmektedir. Ancak Gizli Anlaşma ya da M2M senaryolar karşısında şu an ülkemizde uygulanabilecek herhangi bir düzenleme bulunmamaktadır. Bu kapsamda algoritmalar tarafından fiyat belirlemek için kullanılan veri setlerinin Kurum tarafından kontrol edilmesi gerekmektedir.

Türk rekabet hukuku uygulamalarında, algoritmaların incelenmesi gerektiği durumlar karşısında araştırma tekniklerinde de bazı değişikliklere gidilmesi gerekmektedir. Örneğin Kurul bilgi isteme sayesinde teşebbüslerden herhangi bir bilgiyi alabilmektedir. Ancak algoritmik fiyat değişiklikleri çok hızlı bir şekilde gerçekleştiği için teşebbüslerin verileri üzerinde anlık çalışma imkânının olması gerekmektedir. Bir başka değişiklik ise ihlalin süresinin ne kadar olduğunun hesaplanması ve bir anlaşmada katılımcıların kimler olabileceğinin belirlenmesi ve son olarak bu anlaşmanın piyasadaki etkisinin neler olduğunun ölçümleyebilmesi için yapılan fiyat değişikliklerin kayıtları tutulması gerekmektedir. Bu bağlamda Kurul tarafından önaraştırma ve soruşturma usullerinde değişikliklere gidilmesi gerekmektedir. Bu değişiklikler sırasıyla veri analizlerinin yapılacağı bir birim oluşturulması ve ilgili sektör üzerinde sürekli inceleme yapabileceğine dair bir yetkinin verilmesi, veri inceleme süresince rekabet ihlalinin olduğu şüphesi olduğu an soruşturma sürecine geçilmesi ve son olarak elde edinilen bulgular aracılığıyla ceza verilip verilmemesinin değerlendirilmesi şeklinde tasarlanmaktadır. Ayrıca bu tür çalışmalar büyük miktarda veri saklamak ve işlemek için merkezi işlemcileri hızlarının ve kapasite boyutunun çok yüksek olmasına ihtiyaç duyulmaktadır.

Bu tür değişikliklerin Türk rekabet hukuku kapsamında hayata geçirilebilmesi için Kurumun özel yazılımını ve donanımını hazırlaması gerekmektedir. Bu yazılım ve donanımlar sayesinde veriler incelenebilecek ve veri setleri üzerindeki olası bir anormallikle karşılaşması halinde gerekli önemlerin alınması sağlanabilecektir.

## SONUÇ

Son yıllarda uluslararası teşebbüsler tarafından fiyatların AI algoritmaları aracılığıyla belirlenmesi ve fiyatların belirlenmesinde insan faktörü etkisinin azaltılmasıyla yaşanan gelişmeler, rekabet otoritelerinin incelemelerinin odağını oluşturan insan temelli yapılan anlaşmaların yerini yavaş yavaş algoritma temelli anlaşmaların almasına neden olmakta; bu doğrultuda algoritmaların oluşturduğu anlaşmaların rekabet hukukundaki önemi gündeme gelmekte ve algoritmik anlaşmaların rekabet hukuku uygulamalarına konu olmaya başladığı gözlenmektedir. Yaşanan bu gelişmelerin, benzer bir değişimin gözlenmeye başladığı Türkiye uygulamalarına da yön vermede etkili olacağı düşünülmektedir. Bu doğrultuda, ileride Türk rekabet hukukunda AI'nın daha da önem kazanacağı; dolayısıyla AI uygulamalarının sonuçlarının daha fazla incelmeye konu olacağı beklenmektedir. Tez kapsamında, algoritmaların rekabet karşıtı eylemleri hangi durumlar karşısında oluşturabileceği değerlendirilmekte; algoritmaların neden oldukları rekabet karşıtı eylemler belirlenirken dikkat edilmesi gereken hususlar doğrultusunda, rekabet otoritelerinin bu davranışları ne şekilde cezalandırmaları gerektiği sorusuna cevap aranmaktadır.

AI algoritmaları tarafından fiyatların belirlenmesinin teşebbüsler için hem zaman açısından hem de doğruluk açısından insana göre daha başarılı olduğu ortaya çıkmaktadır. Dolayısıyla AI algoritmaları sektörde giderek daha yaygın hale gelmeye başlamaktadır. Bu durum karşısında teşebbüsler AI algoritmalarından kazanmış oldukları kârlarını daha da artırabilmek için pazarı şeffaflaştırmaya başlamaktadır. Dolayısıyla şeffaflaşan pazarlar algoritmalar arasında bir anlaşma olma olasılığını oldukça yükseltmesine neden olmakta; teşebbüsler arasında insan faktörü olmadan bir anlaşmanın oluşmasına sebebiyet vermekte ve en nihayetinde teşebbüslerin kârının artmasına katkı sağlamaktadır. Teşebbüslerin kârlarını artırma isteği pazardaki fiyatların yükselmesine sebebiyet vermekte ve pazardaki

rekabetçi yapının bozulmasına yol açmaktadır. Bozulan piyasa şartlarına yönelik rekabet otoriteleri tarafından ne şekilde müdahale edileceğine ve rekabet yasalarının uygulanması bakımından hangi cezai işlemlerin yürütüleceği konusunda kısa süre içerisinde gerekli yasal değişiklikler yapılmalı ve rekabet otoritelerinin bilişim alt yapısını algoritmik inceleme yapabilecek şekilde yenilemesi gerekmektedir.

Rekabet hukuku uygulamalarında, AI algoritmaları aracılığıyla yapılan anlaşmaların tek bir algoritma kullanılarak mı yoksa birden fazla algoritma kullanılarak mı yapıldığına bakılarak rekabet ihlal türleri belirlenmektedir. Bu kapsamda belirlenen dört tür senaryonun birincisinde birden fazla teşebbüsün aralarında yapmış oldukları açık anlaşmaların yatay bir anlaşma olarak değerlendirilmektedir. İkinci senaryo Topla ve Dağıt'ta (Hub & Spoke) ise birden fazla sağlayıcının olduğu ve her bir sağlayıcının çok fazla bayisinin olduğu göz önünde bulundurulduğunda sağlayıcı ile bayi arasında kullanılan algoritmanın ortak olması ve her bir sağlayıcı ile bayileri şeklinde gruplanmış dikey yapının yapmış olduğu anlaşma ise dikey anlaşma olarak düşünülmektedir. Ancak pazarda kullanılan algoritmaların aralarında en ufak bir iletişimin veya bilgi paylaşımının olmadığı durumlarda bile algoritmalar tarafından gizli anlaşmaların oluştuğu gözlenmektedir. Bu durumların pazar şeffaflığı ve kullanılan algoritmanın türüne bağlı olduğu anlaşılmaktadır. Pazarın şeffaflaşmasıyla beraber ML ve DL algoritmalarıyla yapılacak tahminlerin doğruluk oranlarının giderek yükseldiği görülmektedir. ML algoritmalarına daha sonra kazandırılan hafıza ve kendin öğren yöntemiyle pazarın şeffaflaşmasına gerek kalmadan öğrenmesini en iyi stratejiyle tamamlamış algoritmaların teşebbüslerin kârlarını en üst düzeye çekmeye çalıştıkları da anlaşılmaktadır.

Rekabet hukuku ihlalleri kapsamında algoritmik anlaşmalar çok farklı durumlarda karşımıza çıkmaktadır. Bu farklı durumların oluşmasının en önemli nedenleri pazar yapısını değiştirebilmesi, pazara yeni girmiş oyuncuların pazarda kalabilmesi ve rakip teşebbüsü ceza mekanizmalarıyla istediği şekilde yönlendirilmesi olarak belirlenmektedir. Ayrıca algoritmalar pazar yapısını şeffaflaştırarak da değiştirmektedirler. Şeffaflaşan pazar yapısının algoritmalar tarafından daha hızlı bir şekilde öğrenilebildiği ve bu durumda pazara yeni girmiş oyuncunun aralarındaki anlaşmalara uymaması durumunda ceza mekanizmasıyla davranışları kontrol altına alınabilmektedir. Böyle bir durum pazardaki rekabetin ortadan kalk-

masına ve teşebbüslerin kârlarını en üst düzeye çıkarmalarına neden olmaktadır.

AI algoritmalarının yapmış oldukları anlaşma türlerinin ne şekilde oluşturulduğu başlangıçta 4 farklı algoritmayla açıklanmaya çalışılmaktadır. Bu algoritmalar izleme, paralel, sinyal ve AI algoritmalarından oluşmaktadır. İzleme algoritması rakip teşebbüsün yapmış olduğu eylemleri izleyerek kendi fiyatlarını belirlemelerine olanak sağlamaktadır. İkinci algoritma türü paralel algoritma lider teşebbüsün hareketlerinin tekrarlandığı durumlarda ortaya çıkmakta, bir diğer tür olan sinyal algoritması ise rakip teşebbüslere sinyal göndererek bilgi paylaşımının olduğu durumları ifade etmektedir. Son algoritma türü olarak AI algoritmaları ise kendin öğren yöntemi üzerine kurgulanmakta ve bu sayede kazanmış olduğu etkinliği diğer algoritma anlaşmaları arasında farklı bir konuma getirmektedir. Bu algoritmaların buldukları anlaşmalarda herhangi bir iletişim veya bilgi paylaşımına dair bir delil bırakmadığı da yapılan deneylerde ortaya konulmaktadır. Bu durumu açıklığa kavuşturabilmek için öncelikle hiçbir bilgi verilmeden deneyler başlatılmaktadır. Daha sonra AI algoritmaları deney süreci ilerledikçe en iyi yol stratejisini öğrenerek bu durumu tersine çevirmeyi başarabilmektedir. Bu başarı ise RL algoritmalarının özel bir türü olan Q-öğrenme algoritmalarıyla sağlanmaktadır. Q-öğrenme algoritmaları keşif ve hafıza gibi özelliklere sahip olduğu için öğrendiği adımları tekrardan öğrenmesine gerek kalmadan en iyi yol stratejisini en başarılı şekilde uygulayabilmektedir. Tabi bu algoritmanın uyarlaması için kullanılan öğrenme, sınırlı hafıza ve keşif değişkenlerinin en iyi duruma göre ayarlanması gerekmektedir. Bu tür ayarlamaların en iyi şekilde yapılmadığı durumlarda ise deneyler algoritmanın öğrenme hızı üzerinde olumsuz etki yaptığını ortaya koymaktadır. Bu algoritmalar ile deneylere devam edilmekte ve deneylerin sonuçları incelendiğinde ortaya başka bir sorun çıkmaktadır. Bu sorun tanımlayacak olursak rakip firmaların ne tür bir AI algoritmasının kullandığının belirlenmesinin çok zor olması oluşturmaktadır. Bu durum algoritma tarafından pazar yapısının öğrenilmesi sürecinin daha da uzamasına sebebiyet vermektedir. Bu olumsuz durumlar karşısında algoritmalara yeterli süre verildiğinde her türlü deneyde gizli bir anlaşma yapabildikleri sonucuna ulaşılmaktadır.

AI algoritmalarının kullanıldığı durumlar birbirleriyle kıyaslandıklarında ise ML ve DL algoritmalarının var olan veri setleri üzerinden tahmin yapabildikleri

ancak RL algoritmaların ise elde veri bulunmadan bunun yerine rakip teşebbüslerin gerçekleştirmiş olduğu eylemler üzerine kendi kârını en üst seviyeye çıkarmak için en iyi yol stratejisiyle kendi öğrendiği anlaşılmaktadır. Bu durumda ML ve DL algoritmalarının piyasanın şeffaf olduğu durumlarda daha iyi sonuçlar verdiği ancak RL algoritmalarının böyle bir duruma ihtiyacı olmadığı düşünülmektedir. RL algoritmalarının sabit ortamlardaki bu başarısı gizli anlaşmaların varlığının ispatı için en net durumlar olmasına karşın bu tür algoritmaların bile gerçek ortamda ne şekilde çalışacağına dair bazı kaygılar bulunmaktadır. Bunlar fiyatların belirlendiği piyasa yapısının deney ortamlarındaki gibi sabit olmadığı aksine çok değişkenli bir yapıda olduğu ve rakip teşebbüslerin kullandığı AI uygulamalarının kullanıldığı algoritmanın belirlenmesinde bazı zorlukların bulunması olarak tanımlanmaktadır. Bu gibi durumlar için ise DL algoritmalarının Q-öğrenme algoritmalarıyla birleştirilerek çok değişkenli pazar yapısında daha hızlı çalışmasının sağlanabileceği ve böylelikle birden fazla algoritma kullanımı sayesinde rakip teşebbüslerin hangi algoritmaları kullandığının belirlenebileceği ifade edilmektedir.

Bu deneyler sonucunda rekabet hukuku dünyasında algoritmaların hangi tür bir ihlale konu olacağı açıklanmaya çalışılmaktadır. Bu tartışmalar sonucunda tez kapsamında belirlenen dört farklı senaryo için şu tespitler yapılmaktadır. İlk senaryo haberci senaryosunda yatay bir anlaşma olduğu, Topla ve Dağıt (Hub & Spoke) senaryosunda ise belli koşullar altında dikey bir anlaşma olduğu, makineden makineye senaryosu için ise teşebbüslerin pazar payları ve hangi pazarlarda etki doğurduklarına bakılarak bir anlaşma mı yoksa bir kötüye kullanma mı olduğu ve en son senaryo gizli anlaşmanın ise şu an için rekabet ihlali olarak değerlendirilmediği ifade edilmektedir.

Dolayısıyla, AI uygulamalarının kullanmış oldukları algoritmaların rekabet otoriteleri tarafından incelenmesi ve pazar üzerindeki etkisinin takip edilmesi gerekmektedir. Çünkü algoritmalar pro-competitive (etkinlik artırıcı, asimetrik enformasyonu ortadan kaldıran) ve anti-competitive (rekabeti sınırlayan anlaşmaları ve denetimini kolaylaştıran, cheating ihtimalini azaltan) yönleriyle pazardaki bütün oyuncular üzerinde dijital bir göz varmış gibi onları kontrol edebilmektedir. Bu bilgiler ışığında teşebbüsler tarafından herhangi bir anlaşma oluşturması düşüncesi olmasa bile AI algoritmalarının zaman içerisinde gizli bir anlaşma yapma

ihtimali bulunmaktadır. Bu durumda AI algoritması kendisi için en iyi kârı bir gizli anlaşma aracılığıyla elde edebileceğini keşfedebilmektedir. Sonuç olarak algoritmaların kullanıldığı sektörlerin ve algoritmaları kullanan bütün teşebbüslerin incelenmesi pazardaki rekabetin korunması açısından yararlı olacağı düşünülmektedir. Ancak algoritmaların incelenmemesi durumunda teşebbüsler tarafından suiistimal edilmeye açık bir durum oluşacak ve rekabet karşıtı eylemlerin odağı haline geleceği kanaati oluşmaktadır; başka bir ifadeyle, algoritmaların rekabet otoriteleri tarafından sürekli kontrol edilmesi gerekmektedir.

## ABSTRACT

Algorithmic pricing has become an indispensable part of business life. Enterprises prefer AI algorithms because they produce more successful results than people-oriented decision-making processes. The price determinations made by the use of AI algorithms with increasing use make the market more transparent. As market transparency increases, the accuracy of the algorithms increases, thus undertakings increase their profits. This development of AI algorithms allows rival undertakings to negotiate only with Q-learning algorithms without having to communicate with each other. Many competing authorities do not see such confidential agreements as illegal. The fact that the competition authorities do not prohibit these agreements causes the algorithms to be used more in the market for price calculation. This, in turn, causes enterprises to increase their profit rates to the detriment of consumers.

In this study, an ML algorithm similar to the ML algorithm used by Airbnb has been designed and it is shown that a highly successful price estimate can be made. Over time, Airbnb trained the ML algorithm and increased accuracy. Thus, it gained the trust of the hosts and increased the use of the application. As a result, Airbnb increased the commission amount, which led to higher accommodation prices. They use such pricing algorithms in digital platforms such as Amazon, Google, Facebook, eBay and Airbnb. The use of these algorithms in terms of these undertakings to operate in our country is a concept. For this reason, the Turkish Competition Authority should examine sectors and undertakings that use these algorithms. Otherwise, there will be a legal gap and the enterprises will increase their profits and cause prices to increase in the market.

## KAYNAKÇA

AIRBNB, (2018), “Seattle Airbnb Open Data”, <https://www.kaggle.com/airbnb/seattle>, Erişim Tarihi:13.06.2019.

AIRBNB, “How is the price determined for my reservation?”, <https://www.airbnb.com/help/article/125/how-is-the-price-determined-for-my-reservation?locale=en>, Erişim Tarihi:13.06.2019.

AIRBNB, (2019). “New Study: Airbnb Community Generates £502 Million in Economic Activity in the UK”,<https://www.airbnb.co.uk/press/news/new-study-airbnb-community-generates-502-million-in-economic-activity-in-the-uk>, Erişim Tarihi:13.06.2019.

ARSLAN B. (2015) “Rekabet Hukuku Uygulamalarında Karşıolgusal Analiz”, Rekabet Uzmanlık Tezleri Serisi, No:140, Ankara

AVRUPA KOMİSYONU, (2015), “Antitrust: Commission fines broker ICAP € 14.9 million for participation in several cartels in Yen interest rate derivatives sector”, [http://europa.eu/rapid/press-release\\_IP-15-4104\\_en.htm](http://europa.eu/rapid/press-release_IP-15-4104_en.htm), Erişim Tarihi:13.06.2019.

AVRUPA KOMİSYONU, (2017). “Algorithms and competition” , [https://wayback.archive-it.org/12090/20191129221651/https://ec.europa.eu/commission/commissioners/2014-2019/vestager/announcements/bundeskartellamt-18th-conference-competition-berlin-16-march-2017\\_en](https://wayback.archive-it.org/12090/20191129221651/https://ec.europa.eu/commission/commissioners/2014-2019/vestager/announcements/bundeskartellamt-18th-conference-competition-berlin-16-march-2017_en), Erişim Tarihi: 13.06.2019.

BARTLOMIEJCZYK A. (2018), Algorithmic Pricing Under Eu Competition Law, Amsterdam, NETHERLANDS

BEAL V. (2019). “Big Data Analytics”, [https://www.webopedia.com/TERM/B/big\\_data\\_analytics.html](https://www.webopedia.com/TERM/B/big_data_analytics.html), Erişim Tarihi:13.06.2019.

BERGEMANN D. and VALIMAKI J. (2006). “Bandit Problems”

BHATIA D. (2017). “What is the difference between an RMSE and RMSLE (logarithmic error), and does a high RMSE imply low RMSLE?”,<https://www.quora.com/What-is-the-difference-between-an-RMSE-and-RMSLE-logarithmic-error-and-does-a-high-RMSE-imply-low-RMSLE>, Erişim Tarihi:08.06.2019.

- CALVANO, CALZOLARI, DENICOLO VE PASTORELLO (2019). “Artificial Intelligence, Algorithmic Pricing and Collusion”, [https://papers.ssrn.com/sol3/papers.cfm?abstract\\_id=3304991](https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3304991).
- CHEN T. (2014). “Introduction to Boosted Trees”, <https://homes.cs.washington.edu/~tqchen/pdf/BoostedTree.pdf>, Erişim Tarihi:13.06.2019.
- CHEW J. (2016). “You Can Still Get Uber and Lyft During the Blizzard”, <http://fortune.com/2016/01/22/jonas-snowstorm-uber-lyft/>, Erişim Tarihi:13.06.2019.
- CORMEN, LEISERSON, RIVEST and STEIN (2001). “Introduction to Algorithms”, Boston, USA, s. 5
- COURSERA, (2019). Machine Learning for Data Analysis, <https://www.coursera.org/lecture/machine-learning-data-analysis/what-is-lasso-regression-0KIy7>, Erişim Tarihi: 08.06.2019.
- CYBULSKI J. L. , (2019). “House Price Prediction in King County Using Keras”, <https://www.kaggle.com/hugosjoberg/house-prices-prediction-using-keras>, Erişim Tarihi:13.06.2019.
- DECAROLIS, ROVIGATTI (2017). Online Auctions and Digital Marketing Agencies, Chicago, USA.
- DEIS A. (2019). “AirBnB Seattle Reservation Prices Analysis”, <https://www.kaggle.com/aleksandradeis/airbnb-seattle-reservation-prices-analysis/data>, Erişim Tarihi: 13.06.2019.
- DOJ, (2015). “Former E-Commerce Executive Charged with Price Fixing in the Antitrust Division’s First Online Marketplace Prosecution”, <https://www.justice.gov/opa/pr/former-e-commerce-executive-charged-price-fixing-antitrust-divisions-first-online-marketplace>, Erişim Tarihi:13.06.2019.
- ETHEM ALPAYDIN (2017), Yapay Öğrenme, Üçüncü Baskı, Sarıyer, İSTANBUL, s. 383
- EZRACHI, A. ve STUCKE, M.-E. (2016). “Virtual Competition”, First Printing London, ENGLAND
- EZRACHI, A. ve STUCKE, M.-E. (2017). “Artificial Intelligence & Collusion: When Computers Inhibit Competition”, London, ENGLAND
- FRESHFIELDS BRUCKHAUS DERINGER LLP. (2017) ,Pricing algorithms: the digital collusion scenarios, <https://www.freshfields.com/globalassets/our-thinking/campaigns/digital/mediainternet/pdf/freshfields-digital---pricing-algorithms---the-digital-collusion-scenarios.pdf>, Erişim Tarihi:13.06.2019.

- FTC, "The Antitrust Laws", <https://www.ftc.gov/tips-advice/competition-guidance/guide-antitrust-laws/antitrust-laws>, Erişim Tarihi:13.06.2019.
- GAL ve ELKIN-KOREN (2017). "Algorithmic Consumers", Cambridge, USA, s.
- GÉRON A. (2019) Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow, Fifth Release, USA
- GRAEF (2016). Data as Essential Facility Competition and Innovation on Online Platforms, University in Leuven, BELGUIM
- HARRINGTON JR J. E. (2017). Developing Competition Law for Collusion by Autonomous Price Setting Agents, Philadelphia, USA.
- HEARTY J. (2016) Advanced Machine Learning with Python, First Edition, Birmingham, UK
- JEFFS C. (2019), E-Commerce Competition Enforcement Guide, London, UK
- BROWNLEE, J, (2016). "How to Develop Your First XGBoost Model in Python with scikit-learn", <https://machinelearningmastery.com/develop-first-xgboost-model-python-scikit-learn/> Erişim Tarihi:13.06.2019.
- MKARIITHI (2018). "Real Estate Sales Price Prediction", <https://www.kaggle.com/mkariithi/real-estate-sales-price-prediction>, Erişim Tarihi:13.06.2019.
- KENTON W. (2019). "Winner-Takes-All Market", <https://www.investopedia.com/terms/w/winner-takes-all-market.asp>, Erişim Tarihi:13.06.2019.
- KLEIN T. (2018), "Autonomous Algorithmic Collusion: Q-Learning Under Sequential Pricing", [https://papers.ssrn.com/sol3/papers.cfm?abstract\\_id=3195812](https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3195812), Erişim Tarihi:13.06.2019.
- MARSLAND, S. (2015). "Machine Learning An Algorithmic Perspective", Second Edition, Florida, USA, s. 4
- MASKIN E. and TIROLE J. (1988) "A Theory Of Dynamic Oligopoly, II: Price Competition, Kinked Demand Curves, And Edgeworth Cycles", <http://code.uab.es/xmg/Docencia/IO-en/IOreadings/BertrandParadox/MaskinTirole.pdf>, Erişim Tarihi:13.06.2019.
- MITCHELL T.M. (1997). "Machine Learning", USA, s. 2
- NOEL M.D., (2011) Edgeworth Price Cycles, [http://www.noeleconomics.com/research/articles/NOEL\\_palgrave.pdf](http://www.noeleconomics.com/research/articles/NOEL_palgrave.pdf), Erişim Tarihi:13.06.2019.
- NOWAG, J. (2016). "The UBER-Cartel? UBER between Labour and Competiti-

on Law”, s. 1

OECD (2017). *Algorithms And Collusion Competition policy in the digital age*, Paris,FRANCE. s. 27,29,31

OECD (2004). “Fighting Hard Core Cartels In Latin America And The Caribbean, Santiago”, CHILE, s. 9

OECD (2018). “Personalised Pricing in the Digital Era – Note by the United States”, Paris,FRANCE. s. 3

OHLHAUSEN M. K. (2017). “Should We Fear The Things That Go Beep In the Night? Some Initial Thoughts on the Intersection of Antitrust Law and Algorithmic Pricing” [https://www.ftc.gov/system/files/documents/public-statements/1220893/ohlhausen\\_-\\_concurrences\\_5-23-17.pdf](https://www.ftc.gov/system/files/documents/public-statements/1220893/ohlhausen_-_concurrences_5-23-17.pdf), Erişim Tarihi:13.06.2019.

OXERA (2018). “Algorithmic competition”, *Prepared for European Commission*, [http://ec.europa.eu/competition/information/digitisation\\_2018/contributions/oxera/oxera\\_algorithmic\\_competition.pdf](http://ec.europa.eu/competition/information/digitisation_2018/contributions/oxera/oxera_algorithmic_competition.pdf), s. 3, Erişim Tarihi:13.06.2019.

OXERA (2017). “When algorithms set prices: winners and losers” , <https://www.oxera.com/agenda/when-algorithms-set-prices-winners-and-losers/>, Erişim Tarihi:13:06.2019.

PAL S. (2018). “Scikit-learn Tutorial: Machine Learning in Python”, <https://www.dataquest.io/blog/sci-kit-learn-tutorial/>, Erişim Tarihi:05.06.2019.

PATEL P. (2018). “Why Python is the most popular language used for Machine Learning”, <https://medium.com/@UdacityINDIA/why-use-python-for-machine-learning-e4b0b4457a77>, Erişim Tarihi:13.06.2019.

RAMAN K. (2015) “Mastering Python Data Visualization”, Birmingham, UK

ROBERTSON A. (2019), “A New Bill Would Force Companies to Check Their Algorithms for Bias”, <https://www.theverge.com/2019/4/10/18304960/congress-algorithmic-accountability-act-wyden-clarke-booker-bill-introduced-house-senate>, Erişim Tarihi:10.06.2019.

ROTH A.E and EREV I., (1993). “Learning in Extensive-Form Games: Experimental Data and Simple Dynamic Models in the Intermediate Term”, Haifa, ISRAEL

SALCEDO (2015). “Pricing Algorithms and Tacit Collusion”, Pennsylvania, USA.

SCHWALBE (2017). “Algorithms, Machine Learning, and Collusion”, <https://pa->

[pers.ssrn.com/sol3/papers.cfm?abstract\\_id=3232631](https://pers.ssrn.com/sol3/papers.cfm?abstract_id=3232631), Erişim Tarihi:13.06.2019.

SEABORN, (2018). “Seaborn: Statistical Data Visualization”, <https://seaborn.py-data.org/>, Erişim Tarihi:13.06.2019.

HECTOR YEE and BAR IFRACH, (2015), ‘Aerosolve: Machine learning for humans’, Airbnb, <https://medium.com/airbnb-engineering/aerosolve-machine-learning-for-humans-55efcf602665>, Erişim Tarihi: 12.06.2019.

SCIENCEDIRECT, “Fundamental and Practical Aspects of Neural Computing (2019).”, <https://www.sciencedirect.com/topics/engineering/learning-rate>, Erişim Tarihi: 13.06.2019.

SUTTON R.S. and BARTO A.G. (2017). “Reinforcement Learning: An Introduction”, Second Edition, London, ENGLAND, s. 1

SYNCED, (2018). “AI Powered Dynamic Pricing Is Everywhere”, <https://medium.com/syncedreview/ai-powered-dynamic-pricing-is-everywhere-4271a9939d11>, Erişim Tarihi:13.06.2019.

TECHNOPEDIA, (2019). “Internet Bot”, <https://www.techopedia.com/definition/24063/internet-bot>, Erişim Tarihi:13.06.2019.

TUCK ve WELLFO (2014). “Big Mistakes Regarding Big Data”, USA, s. 7

XGBOOST, (2019). “Introduction to Boosted Trees”, <https://xgboost.readthedocs.io/en/latest/tutorials/model.html>, Erişim Tarihi:13.06.2019.

VRMINTEL, (2015). “Inside Airbnb’s Algorithm”, <https://www.vrminintel.com/inside-airbnbs-algorithm/>, Erişim Tarihi:05.06.2019.

WALTMAN L. and KAYMAK U. (2008), “Q-Learning Agents in a Cournot Oligopoly Model”

WANI A.M., BHAT F.A.,AFZAL S. And KHAN A.I. (2020). “Advances in Deep Learning”, First Printing, Kashmir, INDIA, s. 2

### **ABD Temyiz Mahkemesi ve Bölge Mahkemeleri Kararları**

Jtc Petroleum Company, Plaintiff-Appellant, v. Piasa Motor Fuels,, 190 F.3d 775, 778 (United States Court of Appeals,Seventh Circuit., 1999).

United States of America v. David Topkins, Case3:15-cr-00201 (United States District Court, Northern District Of California, San Francisco Division, 2015)

United States of America v. Barclays Plc, Violation: 15 U.S.C. § 1 (United States District Court, District Of Connecticut, 2015)

United States of America v. Jpmorgan Chase & Co., Violation: 15 U.S.C. § 1 (United States District Court, District Of Connecticut, 2015)

United States of America v. The Royal Bank Of Scotland Plc, Violation: 15 U.S.C. § 1 (United States District Court, District Of Connecticut, 2015)

United States of America v. Ubs Ag, Violation: 18 u.s.c. §§ 1343 &2 (United States District Court, District Of Connecticut, 2015)

United States of America Plaintiff v. Airline Tariff Publishing Company,, Civil Action No.: 92 2854 (United States District Court, District Of Columbia, 1993)

United States v. Apple, Inc., 952 F. Supp. 2d 638 (S.D.N.Y. 2013), aff'd, 791 F.3d 290 (2d Cir. 2015).

United States v. Apple, Inc., 791 F.3d 290, 310 (2d Cir. 2015), cert. denied, 136 S. Ct. 1376 (2016).

United States v Verizon Wireless, 630 F.3d 622, 628–29 (S.D.N.Y, 2010).

### **Yunanistan Rekabet Komisyonu (GCC)**

Decision No. 495/VI/2010, Greece Competition Commission v. Carrefour's Greek business (Carrefour Marinopoulos S.A.),[ 2010]

### **Avrupa Komisyonu Kararları**

Case C-74/14, Eturas v Others [2016], OJ C 24

Case AT.39861, Yen Interest Rate Derivative [2015]

C-194/14 P AC Treuhand v. Commission [2015]

Case T-193/02, Laurent Piau v Commission of the European Communities (2005), ECLI:EU:T:2005:22, para

Case C-413/06, Bertelsmann AG and Sony Corporation of America v Independent Music Publishers and Labels Association (Impala) (2008), ECLI:EU:C:2008:392, paragraf 120-121.



Üniversiteler Mahallesi  
1597. Cadde No: 9  
06800 Bilkent - Çankaya /ANKARA  
[http:// www.rekabet.gov.tr](http://www.rekabet.gov.tr)