

**T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İKTİSAT ANA BİLİM DALI
İKTİSAT DOKTORA PROGRAMI**

DOKTORA TEZİ

İKTİSAT VE YAPAY ZEKA ÜZERİNE ÜÇ MAKALE

**MURAT ÖZTÜRKMEN
13710006**

**TEZ DANIŞMANI
Prof. Dr. ERCAN EREN**

**İSTANBUL
2021**

**T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İKTİSAT ANA BİLİM DALI
İKTİSAT DOKTORA PROGRAMI**

DOKTORA TEZİ

**İKTİSAT VE YAPAY ZEKA ÜZERİNE ÜÇ
MAKALE**

**MURAT ÖZTÜRKMEN
13710006**

**TEZ DANIŞMANI
Prof. Dr. ERCAN EREN**

**İSTANBUL
2021**

**T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İKTİSAT ANA BİLİM DALI
İKTİSAT DOKTORA PROGRAMI**

DOKTORA TEZİ

**İKTİSAT VE YAPAY ZEKA ÜZERİNE ÜÇ
MAKALE**

**MURAT ÖZTÜRKMEN
13710006**

Tezin Enstitüye Verildiği Tarih:

Tezin Savunulduğu Tarih: 23.06.2021

Tez Oy Birliği ile Başarılı Bulunmuştur

Unvan Ad Soyad

İmza

Tez Danışmanı : Prof.Dr. Ercan EREN

Jüri Üyeleri : Prof.Dr. Murat DONDURAN

Prof.Dr. Suut DOĞRUEL

Doç.Dr. Yasemin Asu ÇIRPICI

Prof.Dr. Elçin AYKAÇ ALP

**İSTANBUL
HAZİRAN 2021**

ÖZ

İKTİSAT VE YAPAY ZEKA ÜZERİNE ÜÇ MAKALE

Murat Öztürkmen

Haziran, 2021

Son yıllarda gerek teknolojik gelişmeler gerekse de yazılım alanındaki hızlı yaygınlaşma yapay zeka çalışmalarını gözle görülür bir şekilde hızlandırmıştır. Yapay zeka teknikleri basitten karmaşığa hemen birçok sektörde de dönüşümlere yol açmaktadır. İktisat da dahil olmak üzere, psikoloji, nörobilim ve mühendislik gibi farklı disiplinlerin katkıda bulunduğu yapay zeka, uygulamada olduğu kadar teorik anlamda da etkileşimde olduğu disiplinlerde birtakım gelişmelere neden olmaktadır. Bu çalışma, iktisat bilimi ve yapay zeka ilişkisine ampirik uygulamalar temelinde odaklanmaktadır. Çalışmada genel bir iktisat ile yapay zeka ilişkisine değinildikten sonra, yapay zekanın bir alt alanı olan yapay öğrenme modelleri ile tahminsel modellemeler ve iktisadi verilerde anomali tespiti gerçekleştirilmiştir. Her bir çalışma sınırları dışında, yapay zekanın iktisadi problemleri çözümlemede önemli bir potansiyeli olduğunu vurgulamaktadır. Bir araya getirilebilecek çok boyutlu veri kümelerinden yola çıkarak, başlı başına karmaşık olan gerçeliği öngörüp, zamanında karşı aksiyonlar aldırma konusunda çalışma kapsamında yer alan yapay öğrenme yaklaşımlarının önemli bir katkısının olacaktır. Bununla birlikte olanaklı olduğu ölçüde çok daha büyük ve hatta mikro anlamda da çok daha detaylı veri kümelerinden yola çıkarak çok daha başarılı öngörülerde bulunma olanağı potansiyel olarak durmaktadır. Bu çalışma, bu potansiyelin bir göstergesi olarak da yorumlanabilir.

Anahtar Kelimeler: İktisat, Yapay Zeka, Yapay Öğrenme, Finans

ABSTRACT

THREE ESSAYS ON ECONOMICS AND ARTIFICIAL INTELLIGENCE

Murat Öztürkmen

June, 2021

In recent years, both technological developments and the rapid spread in the field of software have visibly accelerated the studies of artificial intelligence. Artificial intelligence techniques lead to transformations in many sectors from simple to complex. Artificial intelligence, which is contributed by different disciplines such as economics, psychology, neuroscience and engineering, causes some developments in the disciplines with which it interacts in theoretical as well as in practice. This study focuses on the relationship between economics and artificial intelligence on the basis of empirical applications. After discussing the relationship between general economics and artificial intelligence in the study, predictive modeling and anomaly detection in economic data were carried out with artificial learning models, which are a sub-field of artificial intelligence. Each study emphasizes that artificial intelligence has an important potential in solving economic problems outside of the study boundaries. Based on the multidimensional data sets that can be brought together, the artificial learning approaches within the scope of the study will have an important contribution in predicting the reality that is complex on its own and taking timely counter actions. However, it is potentially possible to make much more successful predictions based on much larger and even more detailed data sets in micro sense to the extent possible. This study can also be interpreted as an indicator of this potential.

Key Words: Economics, Artificial Intelligence, Machine Learning, Finance

ÖN SÖZ

Bu çalışma yıllara yayılmış bir birikimin ürünü olarak, yine yıllara yayılacak yeni çalışmaların bir öncülü olarak ortaya çıktı. Tez çalışmamda her şeyden önce çalışmalarını yıllarca takip ettiğim ve kendime örnek aldığım hocam Prof.Dr. Ercan Eren'e teşekkürlerimi sunmak isterim. Her bir tez izleme döneminde değerli katkılarından dolayı Prof.Dr. Suut Doğruel ve Prof.Dr. Murat Donduran hocalarıma müteşekkirim. Tez çalışmam süresince bana desteğini esirgemeyen eşim Funda'ya, kedimiz Salep'e ve benim için her daim motive edici olan Dr. Volkan Kaymaz, Ar.Gör. Yılmaz Köprücü, Burak Küçüker, Dr. Hüseyin Budak ve Bora Sezen'e teşekkürlerimi sunarım. En çok da bana bugüne kadar her türlü desteğini göstermiş olan babam, annem ve kardeşime müteşekkirim.

İstanbul; Haziran, 2021

Murat Öztürkmen

İÇİNDEKİLER

ÖZ	iii
ABSTRACT	iv
ÖN SÖZ	v
İÇİNDEKİLER	vi
TABLolar LİSTESİ	viii
ŞEKİLLER LİSTESİ	ix
KISALTMALAR	x
1. GİRİŞ: İKTİSAT VE YAPAY ZEKA	1
1.1. Yapay Zeka: Tanımlar ve Yaklaşımlar.....	1
1.2. İktisat ve Yapay Zeka İlişkisi	2
1.2.1. Yapay Zekanın İktisada Katkıları.....	3
1.2.2. İktisadın Yapay Zekaya Katkıları.....	3
1.3. Çalışma Planı.....	4
1.4. Kaynakça	4
2. BİST 100 ENDEKSİ İÇİN YÜKSELİŞ-DÜŞÜŞ TAHMİNİ İÇİN BİR YAPAY ÖĞRENME MODELİ	6
2.1. Giriş.....	6
2.2. Yapay Öğrenme.....	7
2.3. İlgili Literatür	8
2.4. Yükseliş-Düşüş Tahmin Modeli.....	10
2.4.1. Veri Seti Hazırlığı	10
2.4.2. Model Seçimi	12
2.4.3. Modelin Geliştirilmesi.....	13
2.4.4. Nihai Modelin Test Verisi Üzerindeki Performansı.....	16
2.5. Sonuç ve Tartışma.....	16
2.6. Kaynakça	17
3. TÜRKİYE'DE DOLAR KURU VE TÜFE'DE ANOMALİ TESPİTİ: GÖZETİMSİZ ÖĞRENME VE TAHMİNSEL ALGORİTMALAR	19
3.1. Giriş.....	19
3.2. Çalışmanın Yöntemi.....	19
3.3. Algoritmaların Karşılaştırılması İçin Hesaplanan Hareketli Z-Skorları.....	21
3.4. Çalışmada Kullanılan Gözetimsiz Öğrenme Algoritmaları.....	23
3.4.1. Gözetimsiz Öğrenme	23
3.4.2. K-Ortalamlar (K-Means) Algoritması	23
3.4.3. İzole Orman (Isolation Forest) Algoritması	24
3.4.4. Destek Vektör Makineleri (Support Vector Machines).....	24
3.5. Prophet Tahminsel Algoritması.....	25
3.6. İlgili Literatür	25

3.7. Anomali Tespitleri Ve Algoritmaların Anomali Tespiti Performanslarının Karşılaştırılması.....	27
3.7.1. Günlük Dolar Kuru Değişimi Anomali Tespiti	27
3.7.2. TÜFE Anomali Tespiti	31
3.8. Günlük Dolar Kuru Değişimi ve TÜFE Anomali Tespitinde Algoritmaların Performans Karşılaştırması	36
3.9. Sonuç ve Tartışma.....	37
3.10. Kaynakça.....	37

4. OTOMATİKLEŞTİRİLMİŞ YAPAY ÖĞRENME VE MODEL AÇIKLANABİLİRLİĞİ: İKTİSADİ BİR UYGULAMA 41

4.1. Giriş.....	41
4.2. Otomatikleştirilmiş Yapay Öğrenme.....	42
4.3. Model Açıklanabilirliği	43
4.4. İktisadi Bir Uygulama: Bileşik Öncü Göstergeler.....	44
4.5. Sonuç ve Tartışma.....	50
4.6. Kaynakça.....	51

TABLÖLAR LİSTESİ

Tablo 2.1: Algoritmaların Performans Karşılaştırması.....	13
Tablo 3.1: Günlük dolar kuru değişiminde anomali tespiti	36
Tablo 3.2: TÜFE'de anomali tespiti	36
Tablo 4.1: H2O-Automl algoritma seçim çıktısı	46
Tablo 4.2: Nihai Model Tahminleri ve Gerçek Değerler	46



ŞEKİLLER LİSTESİ

Şekil 2.1: Nihai model için eğri altında kalan alan (a) ve duyarlılık-hatırlama (b) çizimleri.....	14
Şekil 2.2: Nihai model için karmaşıklık matrisi (a) ve kalibrasyon eğrisi (b)	15
Şekil 2.3: Nihai model değişken önem grafiği.....	15
Şekil 2.4: Nihai modelin test verisi tahminleri için karmaşıklık matrisi (a) ve eğri altında kalan alan (b)	16
Şekil 3.1: Günlük dolar kuru değişimi, kaynak:TCMB	20
Şekil 3.2: TÜFE, kaynak:TCMB	21
Şekil 3.3: Günlük dolar kuru değişimi, z-skoru anomali tespiti	22
Şekil 3.4: TÜFE için z-skoru anomali tespiti	22
Şekil 3.5: K-ortalamlar ile tespit edilen anomali noktaları, günlük dolar kuru değişimi	28
Şekil 3.6: K-ortalamlar ile tespit edilen anomaliler ve z-skorumları ile belirlenen anomaliler	28
Şekil 3.7: İzole orman ile tespit edilen anomali noktaları, günlük dolar kuru değişimi	29
Şekil 3.8: İzole orman ile tespit edilen anomaliler ve z-skorumları ile belirlenen anomaliler	29
Şekil 3.9: Destek vektör makineleri ile tespit edilen anomali noktaları, günlük dolar kuru değişimi	30
Şekil 3.10: Destek vektör makineleri ile tespit edilen anomaliler ve z-skorumları ile belirlenen anomaliler	30
Şekil 3.11: Prophet ile tespit edilen anomali noktaları, günlük dolar kuru değişimi	31
Şekil 3.12: Prophet ile tespit edilen anomaliler ve z-skorumları ile belirlenen anomaliler	31
Şekil 3.13: K-ortalamlar ile tespit edilen anomali noktaları, TÜFE	32
Şekil 3.14: K-ortalamlar ile tespit edilen anomaliler ve z-skorumları ile belirlenen anomaliler	32
Şekil 3.15: İzole orman ile tespit edilen anomali noktaları, TÜFE	33
Şekil 3.16: İzole orman ile tespit edilen anomali noktaları, TÜFE	33
Şekil 3.17: DVM ile tespit edilen anomali noktaları, TÜFE	34
Şekil 3.18: DVM ile tespit edilen anomaliler ve z-skorumları ile belirlenen anomaliler	34
Şekil 3.19: Prophet ile tespit edilen anomali noktaları, TÜFE	35
Şekil 3.20: Prophet ile tespit edilen anomaliler ve z-skorumları ile belirlenen anomaliler	35
Şekil 4.1: Model tahminleri için artık analizi	47
Şekil 4.2: Değişken önem grafiği	48
Şekil 4.3: Değişkenler için SHAP grafiği	49
Şekil 4.4: Ocak ve Nisan ayı tahminleri	49

KISALTMALAR

ARIMA	: Autoregressive Integrated Moving Average
BİST 30	: Borsa İstanbul 30
BİST 50	: Borsa İstanbul 50
BİST 100	: Borsa İstanbul 100
DVM	: Destek Vektör Makineleri
LSTM	: Long-Short Term Memory
OKH	: Ortalama Kare Hata
OMH	: Ortalama Mutlak Hata
TÜFE	: Tüketici Fiyat Endeksi
TCMB	: Türkiye Cumhuriyeti Merkez Bankası
VM-SASS	: Veri Madenciliği için Sektörler Arası Standart Süreç

1. GİRİŞ: İKTİSAT VE YAPAY ZEKA

Bu çalışma, son yıllarda hem bilgisayar teknolojilerinin gelişmesi ve yaygınlaşması hem de ilgili alandaki bilgi birikiminin dünya genelinde hızla yaygınlaşmasından dolayı yapay zeka çalışmalarının iktisat alanındaki bir kesişimi olarak ampirik uygulamalar üzerinde oluşmuştur. Bu alt bölüm, yapay zeka kavramına genel bir giriş ile birlikte yapay zeka ile iktisat alanının karşılıklı ilişkilerini ortaya koymayı amaçlamaktadır. Bu doğrultuda ilk olarak literatürde mevcut olan yapay zeka kavramları ve yaklaşımları ele alınmıştır. İkinci olarak yapay zeka alanı ile iktisat alanı arasındaki mevcut ve olası karşılıklı ilişkiler ele alınmıştır.

1.1. Yapay Zeka: Tanımlar ve Yaklaşımlar

Yapay zeka kavramının, güncel uygulamalar da göz önüne alındığında farklı yaklaşımları barındırabilecek bir tanıma sahip olduğunu ifade edilebilir. Penrose (1997,11)'a göre yapay zekanın amacı (elektronik) makineler aracılığıyla insanın bilişsel yeteneklerinin simülasyonu ve hatta insanın bilişsel yeteneklerinin geliştirmektir. Whitby (2005,17), yapay zekayı sadece insanlarda değil, hayvanlarda da zeki davranışın ne olduğunu inceleyen ve insan yapımı makinelerin bu davranışlara nasıl sahip olabileceğini inceleyen bir bilim dalı olarak ele almaktadır. Russell ve Norvig (2016,1) yapay zekayı insanın dünyayı anlama, algılama ve tahmin edebilme becerisinin ötesine geçip akıllı varlıklar inşa etme süreci olarak ele almaktadır. Tarihsel olarak da yapay zeka tanımlamalarını dört ana kategoride sunmaktadırlar: insan gibi davranma, rasyonel düşünme, insan gibi hareket etme ve rasyonel hareket etme. Say (2018,83), yapay zekayı “doğal sistemlerin yapabildiği her bilişsel etkinliği yapay sistemlere, daha da yüksek başarımlar düzeylerinde nasıl yaptırabileceğimizi inceleyen bilim dalı” olarak tanımlamaktadır. Nilsson (2019,13), yapay zeka için üzerinde anlaşılmış tek bir tanım olmadığı vurgusu yaparak, makinelere zeka kazandırmaya adanmış bir etkinlik olarak tanımlamaktadır.

Yapılan tüm tanımlamalar genel olarak insan, zeka ve makine olguları üzerinde ortaklaşmaktadır. Tanımlamaları izleyerek, yapay zeka insan olmayan makineleri, en az kendisi kadar zeki olacak şekilde insanlaştırma disiplini olarak tanımlanabilir.

Genel olarak yapay zeka kavramının tanımlamalarının dışında, yetkinliklerine ve güncel ilerlemelerine göre farklı yapay zeka tanımlamaları da yapılmaktadır. Bu tanımlamalardan birisi, güçlü yapay zeka (strong artificial intelligence) ve zayıf yapay zeka (weak artificial intelligence) ikilidir. Searle (2004), zayıf yapay zekada, zihin çalışmalarında bilgisayarların temel işlevinin, örneğin bazı hipotezlerin test edilmesinde güçlü bir araç sağladığını; güçlü yapay zekada ise bilgisayarın kendisinin başlı başına zihin olduğunu belirtmektedir. Zayıf yapay zeka, sadece belirli görevleri en iyi şekilde yerine getirecek şekilde tasarlanmıştır. Benzer bir diğer tanım da dar yapay zeka (narrow artificial intelligence) ve yapay genel zeka (artificial general intelligence) ikilidir. Pennachin ve Goertzel (2007), yapay genel zekayı, belli düzeylerde kendini anlama ve otonom kontrole sahip, kimi bağlamlarda karmaşık problemleri çözebilen ve yeni problemleri de çözmeyi öğrenebilen yapay zeka sistemleri olarak; dar yapay zekayı ise satranç oynamak, hastalık teşhis etmek, araba kullanmak gibi sadece belirli görevleri icra eden programlar olarak tanımlamaktadırlar. Bu ayrımlar, önceki tanımlamalar gibi yapay zekanın, makinelerin insanlaştırılması eksenine paraleldir. Bir diğer yapay zeka tanımını ise süper zeka ya da yapay süper zeka kavramı (artificial super intelligence) ile Bostrom (2018,39) yapmaktadır. Bostrom, süper zekayı, insanların bilişsel yeteneklerini her alanda aşan her türlü zeka olarak tanımlamaktadır.

1.2. İktisat ve Yapay Zeka İlişkisi

Yapay zeka tanımlamalarından da anlaşılacağı gibi, yapay zeka disiplinlerarası bir konumda yer almaktadır. Mühendislik ve matematik gibi disiplinler olduğu kadar, zihin ve bilinç problemlerinde ve davranışsal problemlerde psikoloji, bilişsel psikoloji ve özellikle karar verme anlarında iktisat biliminin yapay zeka ile ilişkisi kaçınılmaz olmaktadır. Bu bağlamda iki yönlü ilişkiden söz etmek mümkündür: yapay zekanın iktisat bilimine katkısı ve iktisat biliminin yapay zekaya katkısı.

1.2.1. Yapay Zekanın İktisada Katkıları

Yapay zekanın iktisada katkılarını hem teorik hem de uygulama temelinde ele almak mümkündür.

Penrose, yapay zekanın sonuçlarını tartışırken robotik, uzman sistemler ve psikoloji alanındaki etkileri bağlamında da tartışmıştır (Penrose, 1997,12). Burada psikoloji bağlamındaki sonuçları dikkate değerdir: özetle insan davranışlarının bilgisayarlarla modellenebilme potansiyeli ve bu potansiyel ile birlikte de insan aklının ve düşünme süreçlerinin detaylarına inilebilme olanağı yapay zekanın önemli katkılarından. Bu durumun iktisat ile ilişkisi de açıkça belirmektedir. Yapay zekanın iktisat için önemli bir potansiyel katkısı, insan davranışlarının iktisadi açıdan modellenebilmesi olmaktadır. Marwala (2015), yapay zekanın iktisat üzerindeki potansiyel etkisini sınırlı rasyonellik, etkin piyasa hipotezi ve beklenti teorisi üzerinden tartışmaktadır. Marwala (2015)'e göre, yapay zekanın sınırlı rasyonelite için, sınırlayıcı bir olanak sağlar: daha fazla gizli örüntüye ve daha fazla bilgiye ulaşılabilir ve karar verme süreçlerinde insanların daha rasyonel kararlar vermesine olanak sağlar. Piyasalarda alım-satım aktörler daha fazla ve daha güçlü yapay zeka sistemlerle donatıldıkça piyasaların etkin olması için olanak sağlar. İktisadi kararları alanlar sadece insanlar değil, yapay zeka ile donatılmış makinelerle birlikte insanlar olduğunda, bu durum beklenti teorisi için de farklı sonuçlar yaratabilir.

Tüm bunlar yapay zekanın iktisat üzerine olası teorik etkiler olarak gruplanabilir. Bir başka açıdan ise yapay zekanın uygulamada iktisadi faaliyetlerdeki kullanımınıdır. Günümüzde yapay zeka e-ticaret, sağlık, iletişim, insan kaynakları, siber güvenlik, taşımacılık ve tedarik zinciri, endüstriyel üretim ve perakende alanlarında uygulama alanı bulmaktadır.

1.2.2. İktisadın Yapay Zekaya Katkıları

Yapay zeka alanının disiplinler arası bir alan olduğu aşikardır. Russell ve Norvig (2016, 5-16) yapay zekanın temellerini tartışırken farklı disiplinlerin yapay zeka alanına olan katkılarını ele almaktadır. Yapay zekanın iktisadi teorilere olası katkıları gibi iktisat teorisinin de yapay zekaya katkıları mevcuttur. İktisadın katkıları daha çok (rasyonel) karar verme süreçleri ile bu süreçlerin modellenmesi bağlamında yoğunlaşmaktadır. Olasılık teorisi ile fayda teorisini bir araya getiren karar teorisi, belirsizlik altında karar verme, oyun teorisi gibi konular, iktisat teorisinin yapay

zekaya bazı katkılarıdır. Yine iktisatta karar süreçlerinin modellenmesinde kullanılan Bellman eşitlikleri, yöneylem araştırması yaklaşımları gibi araçlar da yapay zeka alanına katkılarıdır.

1.3. Çalışma Planı

Bu çalışma, iktisat ve yapay zeka alanlarının kesişiminde, üç ampirik çalışmadan oluşmaktadır. Çalışma, yapay zekanın bir alt alanı olarak yapay öğrenme yöntemlerinin iktisadi problemlerin çözümünde nasıl rol alabileceğine dair bir kesit oluşturmaktadır.

Çalışmada ilk olarak farklı yapay öğrenme yöntemleri ile borsa yükseliş-düşüş tahmin modellemesi gerçekleştirilmiştir. Borsanın yükseliş-düşüş yönü iki farklı sınıf olarak alınmış, borsa yönü birçok değişken ışığında yüksek tahmin performansı ile doğru tahmin edilmiştir.

Çalışmanın ikinci kısmında, Türkiye’de günlük dolar kuru değişimi ve aylık tüketici fiyat endeksi günlük değişimi için anomali tespiti yaklaşımları karşılaştırmalı olarak çalışılmıştır. Sınıflandırma ya da regresyon modellerinden farklı olarak, hedef değişkenin olmadığı veriler için veriden yola çıkarak anomali olarak adlandırılabilen gözlem noktaları anomali olarak işaretlenmiştir.

Çalışmanın üçüncü ve son kısmında, bir ülkenin genel iktisadi durumunun bir göstergesi olarak bileşik öncü göstergeler hedef değişkeni üzerine, aylık bazda makro değişkenlerin girdi olarak yer aldığı farklı yapay öğrenme modelleri arasından en iyi tahmin performanslı model seçilerek, açıklanabilir yapay zeka yaklaşımları ile model tahminleri değerlendirilmiştir.

1.4. Kaynakça

Bostrom, Nick. 2018. **Süper Zeka-Yapay Zeka Uygulamaları, Tehlikeler ve Stratejiler**. çev. Ferit Burak Aydar. İstanbul: Koç Üniversitesi Yayınları.

Marwala, Tshilidzi. [01.01.2021]. "Impact of Artificial Intelligence on Economic Theory". <https://arxiv.org/abs/1509.01213>

Nilsson, J. Nils. 2019. **Yapay Zeka-Geçmişi ve Geleceği**. 2. bs. çev. Mehmet Doğan. İstanbul: Boğaziçi Üniversitesi Yayınevi.

- Pennachin, Cassio, Ben Goertzel. 2007. Contemporary Approaches to Artificial General Intelligence. **Artificial General Intelligence**. ed. Cassio Pennachin, Ben Goertzel. Berlin: Springer:1-30.
- Penrose, Roger. 1997. **Kralın Yeni Usu 1**. çev. Tekin Dereli. Ankara: Türkiye Bilimsel ve Teknik Araştırma Kurumu.
- Russell, J. Stuart, Peter Norvig. 2016. **Artificial Intelligence:A Modern Approach** 3. bs.. Essex, İngiltere: Pearson Education Limited.
- Say, Cem. 2018. **50 Soruda Yapay Zeka**. 5. bs. İstanbul: 7 Renk Basım Yayın ve Fimcilik Ltd. Şti.
- Searle, R. John. 2004. Minds, Brains, and Programs. **The Turing Test-Verbal Behavior as the Hallmark of Intelligence**. ed. S. M. Shieber. Londra: The MIT Press: 200-224
- Whitby, Blay. 2005. **Yapay Zeka-Yeni Başlayanlar İçin Bir Kılavuz**. çev.Çiğdem Karabağlı. İstanbul: İletişim Yayıncılık A.Ş.

2. BİST 100 ENDEKSİ İÇİN YÜKSELİŞ-DÜŞÜŞ TAHMİNİ İÇİN BİR YAPAY ÖĞRENME MODELİ

2.1. Giriş

Yapay öğrenme yöntemleri, özellikle son on yılda, teknolojik altyapının gelişmesi ve yaygınlaşmasıyla, iktisadi öngörü modellerinde de sıkça kullanılan yöntemler haline gelmiştir. Büyük veriden sonuçlar çıkarmada, örüntüler keşfetmede ve öngörüler oluşturmada yapay öğrenme yöntemleri, iktisatta bilhassa da finasta yaygınlaşmaktadır.

Finansal verilerin işlenmesi ve finansal verilerdeki örüntülerin tanınması ve bunların açığa çıkarılması, işlem hacmi ve araçları gittikçe artan borsalarda, iktisadi ajanlar için oldukça önemlidir. Finansal piyasalarda yatırımcılar hızlı ve doğru ya da doğruya yakın tahminler yapmak istmektedirler. Yapay öğrenme algoritmalarının ve yapay zeka uygulamalarının finansal piyasalardaki kullanımının artışı piyasa ajanlarına hem gelecek için daha iyi tahminler üretme hem de sahip oldukları portföyü optimal bir biçimde ayarlama olanağı yaratmıştır. Bunun yanında finansal alandaki yapay öğrenme algoritmaları verilerden yatırımcılar için kullanışlı sinyaller türetmeyi, etkin varlık tahsisini, piyasa stratejilerini test edilip geliştirilmesini de olumlu yönde etkilemektedir (Jansen, 2020, 2). Piyasalarda yapay zeka ile güçlendirilmiş bilgisayar işlemcileri arttıkça, piyasaların etkinliği artma eğilimi göstermektedir (Marwala, 2015).

Bu çalışmada BİST 100 endeks fiyatları yükseliş-düşüş tahmini için bir yapay öğrenme algoritması çalışılmıştır. Farklı algoritmalarından, belirlenen model seçim kriterlerine göre en iyi model seçilmiştir. Seçilen en iyi model ile de, eğitim ve değerlendirme veriseti dışındaki bir dönem için 100 günlük veriseti için yükseliş ve düşüş tahminleri gerçekleştirilmiştir.

Çalışmada ilk olarak yapay öğrenme kavramının tanımı yapılmış, farklı yapay öğrenme yaklaşımlarına değinilmiştir. İkinci olarak, modelleme sürecine değinilmiş ve seçilen en iyi modelin sonuçları yorumlanmıştır.

2.2. Yapay Öğrenme

Yapay öğrenme kavramı için literatürde birbirine yakın sayılabilecek tanımlar yapılmıştır. Samuel (1959), yapay öğrenme kavramını bilgisayarların açıkça programlanmadan öğrenmelerini sağlayan çalışma alanı olarak tanımlamıştır. Raschka ve Mirjalili (2017)'e göre yapay öğrenme, veriyi anlamlandıran algoritmaların bir uygulaması ve bilimidir. Yapay öğrenme, bir anlamda disiplinlerarası bir alandır. Yapay öğrenme, istatistik teorisini matematiksel modeller oluştururken kullanmaktadır. Örneklerden çıkarım yapmaktadır. Yapay öğrenmede bilgisayar biliminin de önemli bir rolü vardır ve bu iki yönlüdür: İlki, eldeki büyük veriyi öğrenmek, saklamak ve işlemek için optimizasyon problem çözen algoritmalara ihtiyaç vardır. İkincisi, uygun model öğrenildiğinde, modelden çıkarım yapılması ve modelin sunulması gereklidir. Algoritmaların hızı ve karmaşıklığı da önemlidir.

Yapay öğrenme genel olarak gözetimli öğrenme, gözetimsiz öğrenme, yarı-gözetimli öğrenme, derin öğrenme ve pekiştirmeli öğrenme olarak sınıflandırılabilir (Alpaydın (2014, 5-11); Hastie ve diğ. (2008)). Gözetimli öğrenme (supervised learning) genel olarak, girdileri kategorik etiketlere (label) eşleme problemlerinde sınıflandırma veya girdileri sürekli değişkenlere eşleme problemlerinde regresyon biçimindedir. Hem regresyon hem de sınıflandırmada amaç, girdi verilerinde doğru çıktı verilerini etkin bir şekilde üretmemize olanak sağlayan spesifik ilişkiler veya yapıyı bulmaktır (Bishop, 2006, 3). Gözetimli öğrenme ile karşılaştırıldığında, gözetimsiz öğrenme (unsupervised learning) yalnızca çıktıları veya etiketleri olmayan girdi verileri üzerinde çalışmaktadır. Bu nedenle, gözetimsiz öğrenmede, gözetimli öğrenme durumunda olduğu gibi modeli düzelten bir öğretmeni yoktur (Goodfellow ve diğ., 2016, 105). Yarı-gözetimli öğrenmede (semi-supervised learning) girdi verilerinin az bir kısmı etiketli çıktı verilerine sahipken, geri kalan kısmı etiketlenmemiştir. Yarı-gözetimli öğrenmede amaç, sadece gözetimli öğrenmedeki gibi etiketli verilerden örüntüleri keşfetmek değil, tüm veriden örüntüleri keşfetmektir (Russell ve Norvig, 2016, 695). Etiketlenmemiş verilerin etkili bir şekilde kullanılması, kümeleme ve yoğunluk tahmini gibi gözetimsiz öğrenme yöntemlerinin kullanılmasını gerektirebilir. Kategoriler veya örüntüler keşfedildikten sonra, gözetimsiz öğrenmeden elde edilen etiketler, sonraki gözetimli öğrenme modelleri için etiketlenmemiş veriyi etiketlemek için kullanılabilir. Derin öğrenme (deep learning),

yapay öğrenmede, farklı soyutlama düzeylerine karşılık gelen, birden fazla seviyede öğrenmeye çalışan bir dizi algoritmadır. Derin öğrenmede genellikle yapay sinir ağları kullanılır. Bu öğrenilmiş istatistiksel modeller, daha yüksek seviyeli kavramların daha düşük seviyedeki kavramlardan tanımlandığı ve aynı alt seviyedeki kavramların birçok daha yüksek seviyeli kavramın tanımlanmasına yardımcı olabileceği farklı kavram seviyelerine karşılık gelir. Pekiştirmeli öğrenme (reinforcement learning), sayısal bir ödül sinyalinin en üst düzeye çıkarmak için ne yapılması gerektiğini (durumların eylemlerle nasıl eşleştirileceğini) öğrenmektir (Sutton ve Barto, 2018, 1). Pekiştirmeli öğrenmede öğrenen (learner) algoritmaya hangi eylemleri gerçekleştireceği söylenmez, bunun yerine öğrenen algoritmanın hangi eylemlerin daha fazla ödül getireceğini, onları deneyerek keşfetmesi gerekir.

Bu öğrenme yaklaşımlarının yanında son yıllarda farklı yaklaşımlar da geliştirilmiştir. Transfer öğrenme ve meta öğrenme bunlardan ikisidir. Transfer öğrenme, bir modelin ilk olarak bir görev üzerinde eğitildiği, daha sonra modelin bir kısmı veya tamamı ilgili bir görevin başlangıç noktası olarak kullanılan bir öğrenme türüdür. Transfer öğrenmede, algoritma iki veya daha fazla farklı görev gerçekleştirmektedir; P1 görevindeki varyasyonları açıklayan birçok faktörün P2 görevinin öğrenilmesi için yakalanması gereken varyasyonlarla ilişkili olduğunu varsayılır (Goodfellow ve diğ., 2016, 36). Mevcut öğrenme algoritmaları yalnızca bir görevi yerine getirmektedir. Meta öğrenmenin geldiği yer burasıdır. Meta öğrenme, çeşitli görevleri sıfırdan eğitmek zorunda kalmadan gerçekleştirmeyi öğrenebilen çok yönlü bir yapay öğrenme modeli oluşturur. Meta öğrenme modeli az sayıda veri noktasına sahip çeşitli ilgili görevler üzerine eğitilir, bu nedenle yeni bir ilgili görev için önceki görevlerden elde edilen öğrenme kullanılabilir ve bunları en baştan eğitmek zorunda kalınmaz.

2.3. İlgili Literatür

BİST 100 fiyatlarının tahminleriyle ilgili literatürde bir grup çalışma klasik zaman serisi yöntemleriyle volatilité tahminine odaklanmıştır. Bunlar arasında Altuntaş ve Çolak (2015) yaptıkları çalışmada, BİST 100 endeksindeki düzensiz fiyat hareketlerini klasik zaman serisi yöntemleriyle modellemişlerdir. Çalışmada fiyat hareketlerinde 1994-2001 dönemi için stabil, 2001-2009 dönemi için hem simetrik hem de asimetric fiyat hareketlerinin varlığı bulgusunu elde etmişlerdir. Günay

(2014), yaptığı çalışmada, BİST-100 endeksinin volatilisindeki uzun dönemli bellek yapısına odaklanmıştır. Bunun için klasik zaman serisi yöntemlerinden FIGARCH'dan yararlanmıştır. Çalışmada 1990-2013 dönemi için uzun dönem belleğin varlığı bulgusunu elde etmiştir. Kuzu (2018), BİST 100 endeksi getiri volatilitesi için TGARCH modelinin daha uygun model olduğu sonucuna ulaşmıştır.

Son yıllarda yapay öğrenme algoritmalarının finasta tahminsel modellerde sıklıkla kullanılmasıyla literatürde borsa ve hisse senedi fiyat tahminleriyle ilgili çalışmalar da artmaya başlamıştır. Burada da iki yaklaşım sözkonusudur.

Birincisi, fiyat veya fiyatların değişiminin kendisine odaklanan sürekli değişkenin tahminidir. Bu kapsamda gerçekleştirilmiş çalışmalardan Dağlıoğlu ve Kırıl (2018), BİST 100 fiyatlarının değişim oranlarını saklı markov modellerinin (hidden markov model) ileri-geri algoritmasıyla tahmin etmişlerdir. Çalışmada değişim oranlarında etkili olan, içsel faktörler olarak nitelendirdikleri döviz kuru, faiz oranı ve para arzı bağlamında alt durumların gerçekleşme olasılıkları tahmin edilmiştir. Bu kapsamdaki bir diğer çalışmada, Sarıkaya (2019), BİST 100 fiyat tahmini için yapay sinir ağları ve regresyon modelleriyle çalışmıştır. Çalışmada hata kareler ortalaması ölçütüne göre yapay sinir ağlarının, kübik regresyon modelinden daha iyi tahmin sonucu ürettiği bulgusunu elde etmiştir. Akşehir ve Kılıç (2019), 2016-2019 dönemi için banka hisse senetlerinin fiyat tahminlerini regresyon temelli yapay öğrenme yöntemleriyle tahmin çalışması gerçekleştirmişlerdir. Teknik göstergelerin bulunduğu verisetinden tam ve değişken sayısının azaltıldığı indirgenmiş modelin R2 ölçütüne göre karşılaştırıldığı çalışmada indirgenmiş model ile elde edilen tahminlerin daha iyi olduğu bulgusuna ulaşmışlardır.

Tahminsel yaklaşımlardan ikincisi ise artış veya azalış gibi fiyat yönü tahminine odaklanan sınıflandırma temelli yaklaşımlardır. Çalışkan ve Deniz (2015), BİST 30 endeksinde işlem gören hisse senetleri fiyatlarının fiyat yönlerinin tahmini için yapay sinir ağlarıyla tahminsel model çalışmışlardır. Yaptıkları çalışmada fiyat yönü tahmininde ortalama 0.58 doğruluk skoru (accuracy) elde etmişlerdir. Özçalıcı (2016), BİST 30 endeks fiyatları için 1 gün sonraki, 2 gün sonraki ve 20 gün sonraki fiyat tahminini yapay sinir ağlarıyla modellemiştir. 20 gün sonraki fiyat tahminini 0.72'ye varan doğruluk skoru ile tahmin etmiştir. Filiz, Karaboğa ve Akoğul (2017), BİST 50 endeksinin değişim değerleri için bir sınıflandırma modeli üzerinde çalışmışlardır. Çalışmada k en yakın komşu algoritması (k-nearest neighbour), Naive

Bayes sınıflandırıcısı, C4.5 sınıflandırma algoritması ve yapay sinir ağıları algoritması kullanmışlar, sınıflandırma başarısı olarak 0.9271 doğruluk skoru elde etmişlerdir. Kara (2019), BİST 100 endeksine ait 1995-2019 dönemi için, on adet teknik göstergenin bağımsız değişkenler arasında yer aldığı veri kümesi üzerinde yapay öğrenme yöntemleri ile yön tahmini çalışmıştır. Çalışmada yedi farklı yapay öğrenme algoritmasından yapay sinir ağıları ile 0.8383 doğruluk skoru elde edilmiştir.

2.4. Yükseliş-Düşüş Tahmin Modeli

Çalışmada 01-04-2000 ile 12-02-2020 dönemi için, Borsa İstanbul (BİST) 100 endeks fiyatlarına ait günlük olarak gözlemlenmiş açılış, yüksek, düşük, kapanış ve hacim değişkenlerinden oluşan veriseti kullanılmıştır. Yükseliş-düşüş yönü değişkenini elde edebilmek için yükseliş yönünün 1, düşüş yönünün ise 0 ile kodlandığı hedef değişken oluşturulmuştur.

Çalışmada BİST 100 endeks fiyatlarının yükseliş-düşüş yönüne dair bir yapay öğrenme sınıflandırma modeli kurulmuş ve kurulan modelin performansı çeşitli metriklerle incelenmiştir.

2.4.1. Veri Seti Hazırlığı

Hedef değişken olan fiyat yönünün tahmininden önce veri setinde mevcut değişkenlerden yeni değişkenler türetilmiştir.

İlk olarak türetilen değişken grubu tarih bazlı değişkenlerdir. Tarih değişkenleri olarak 'Haftanın Günü', 'Hafta', 'Ay', 'Çeyrek', 'Ayın Başı Mı', 'Ayın Sonu Mu', 'Çeyreğin Başı Mı', 'Çeyreğin Sonu Mu', 'Yılın Sonu Mu' değişkenleri türetilmiştir. Böylece borsa yönünün tahmininde zaman olgusu da modele dahil edilmiştir.

Zaman bazlı değişkenlerin dışında teknik göstergeler mevcut veri setinden türetilmiştir. Teknik göstergeler, bir finansal enstrümanın geçmiş ve cari fiyatlarına ve hacimlerine dayalı verileri analiz eder ve istatistiksel bilgiler vermektedir. Bu, bir finansal enstrümanın gelecekteki fiyatlarının nereye gideceğini (yukarı veya aşağı) tahmin etmeye yardımcı olmaktadır. Teknik göstergeler öncü veya artçı göstergeler olabilmektedir. Öncü göstergeler, trend başlamak üzere olduğunda veya bir tersine dönüş gerçekleşmek üzereyken alım-satım sinyalleri verir. Başka bir deyişle, trendi yönlendirir. Dolayısıyla, bu göstergeler yaklaşan trendi tahmin etmede yardımcı olur.

Artçı göstergeler, bir trend başladıktan sonra veya bir tersine dönüş gerçekleşikten sonra alım-satım sinyalleri verir. Dolayısıyla, bu göstergeler mevcut trendi bulmada yardımcı olur.

Çalışmada dört farklı teknik gösterge grubu türetilmiştir. İlk teknik gösterge grubu trend göstergeleridir. Bu göstergeler, eğer varsa piyasadaki trendi gösterir. Bu göstergelere, salınımlı bir dalga gibi, zamanla yüksek ve düşük değerler arasında salınım yaptıkları için osilatör de denilmektedir. Bu tür göstergeler genellikle artçı, ancak bazen öncü de olabilir. Basit hareketli ortalama (trend_sma), üstel hareketli ortalama (trend_ema), ağırlıklı hareketli ortalama (trend_wma), hareketli ortalama uyumsuzluğu göstergesi (trend_macd), ortalama yönsel hareket indeksi (trend_adx), vortex göstergesi (trend_vi), trix göstergesi (trend_trix), kitle indeksi (trend_mi), emtia kanal indeksi (trend_cci), Ichimoku göstergesi (trend_ichimoku), parabolik durdurma ve geri alma göstergesi (trend_sar), Aroon göstergesi (trend_aroon) ve Schaff trend göstergesi (trend_stc) trend değişkenleri olarak oluşturulmuştur. İkinci teknik gösterge grubu ise momentum göstergeleridir. Bu göstergeler bize mevcut trendin ne kadar güçlü olduğunu ve ayrıca mevcut trendde bir tersine dönme olasılığının olup olmadığını gösterir. Bu göstergeler genellikle öncü göstergelerdir. Göreli güç indeksi (momentum_rsi), stokastik göreli güç indeksi (momentum_stoch_signal), doğru güç indeksi (tmomentum_tsi), nihai osilatör göstergesi (momentum_uo), stokastik osilatör göstergesi (momentum_stoch) ve Williams %R göstergesi (momentum_wr) momentum değişkenleri olarak oluşturulmuştur. Üçüncü teknik gösterge grubu volatilité göstergeleridir. Bu göstergeler, yönden bağımsız olarak (yani, düşüş veya yükseliş) fiyat hareketinin değişim oranını ölçer. Bu göstergeler, fiyatların ne kadar hızlı veya yavaş değiştiğini anlamaya yardımcı olmaktadır. Bollinger bantları (volatility_bbp) ve Donchian kanalı (volatility_dch) da volatilité değişkenleri olarak oluşturulmuştur. Bu göstergeler genellikle gecikmeli ve artçı göstergelerdir. Son teknik gösterge grubu ise hacim göstergeleridir. Bu göstergeler de, zamanla trendin ne kadar hızlı veya yavaş değiştiğini gösteren göstergelerdir. Hacim ne kadar yüksek olursa mevcut trend o kadar güçlü olur, bu nedenle bu göstergeler mevcut trendin gücünü bulmaya yardımcı olur. Bu göstergeler hem öncü hem de artçı olabilir. Hacim-fiyat trendi (volume_vpt) ve hareket kolaylığı (volume_em) değişkenleri, hacim değişkenleri olarak oluşturulmuştur.

2.4.2. Model Seçimi

Wolpert (1996) hedef değişken hakkında herhangi bir varsayımda bulunmadan bir eğitim veriseti ve bir yapay öğrenme algoritması ile faydalı teorik sonuçlar elde etmenin mümkün olup olmadığını incelemektedir. Wolpert'in gösterdiği gibi gürültüsüz bir veriseti (rastgele varyasyonun olmadığı, yalnızca trendin bulunduğu) ve maliyet fonksiyonunun hata oranı olduğu bir yapay öğrenme algoritması, tüm yapay öğrenme algoritmaları, bir genelleme hata oranıyla (modelin bir doğrulama verisetindeki hata oranı) değerlendirildiğinde eşdeğerdir. Bu doğrultuda çalışmada tek bir yapay öğrenme modeli yerine, hedef değişken tahmininde en uygun çözümleri verebilecek yapay öğrenme algoritması, onbeş farklı yapay öğrenme algoritması eğitilerek elde edilmiştir.

Çalışmada eğitilen algoritmalar doğrusal modeller, kuadratik ayırdedici analiz (quadratic discriminant analysis), ridge regresyonu, destek vektör makinesi (support vector machine), k-yakın komşu sınıflandırıcısı (k-nearest neighbour classifier), naïve bayes, ağaç bazlı algoritmalar ve topluluk öğrenme (ensemble learning) algoritmaları yer almıştır.

Algoritmaların performansının karşılaştırılmasında tüm algoritmaların değerlendirilmesi için on katlı çapraz geçerlilik (k-fold cross validation) veri kümeleri üzerinde eğitim gerçekleştirilmiştir. Bunun yanında nihai aşamada seçilen algoritmanın performansının görülmesi için son yüz günlük veriseti, test veriseti olarak ayrılmıştır.

Algoritmaların karşılaştırılmasında ve performansa göre sıralanmasında yapay öğrenmede sıkça kullanılan sınıflandırma modeli ölçütleri kullanılmıştır. Algoritmaların performanslarının karşılaştırıldığı Tablo 2.1'de sınıflandırma ölçütü olarak doğruluk (accuracy), eğri altında kalan alan (area under curve), kesinlik (precision), hatırlama (recall), kesinlik ve doğruluk ölçütlerinin ağırlıklı harmonik ortalaması olan F skoru, kappa skoru ve Matthew korelasyon katsayısının yanında algoritmaların çalışma süreleri raporlanmıştır. Ölçütlere göre en başarılı performansı gösteren algoritma, bir topluluk öğrenme algoritması olan Light Gradient Boosting Machine (LightGBM) algoritması olarak gözlemlenmiştir. LightGBM algoritması ile borsa yönü tahmininde eğitim verisinde 0.8937 doğruluk skoru, 0.9634 eğri altında kalan alan skoru, 0.9003 hatırlama skoru, 0.8977 duyarlılık skoru, 0.8989 F1 skoru,


0.7869 Kappa skoru ve 0.7870 Matthew korelasyon skoru elde edilmiştir. Algoritmalarından elde edilen skorlar ne kadar yüksek ise, algoritma performansının da o kadar yüksek olduğu söylenebilir. Algoritmanın, tek bir doğruluk skoru yerine birden fazla skorda daha yüksek performans göstermesi, diğerlerine göre daha başarılı olduğunu göstermektedir.

Tablo 2.1: Algoritmaların Performans Karşılaştırması

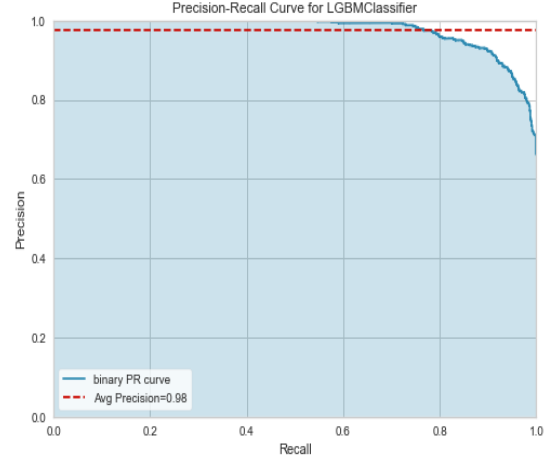
Model	Accuracy	AUC	Recall	Precision	F1	Kappa	MCC	Time
Light Gradient Boosting Machine	0.8937	0.9634	0.9003	0.8977	0.8989	0.7869	0.787	0.5315
Extreme Gradient Boosting	0.8884	0.9624	0.8912	0.8957	0.8934	0.7763	0.7764	1.1613
CatBoost Classifier	0.8817	0.9583	0.8891	0.8861	0.8874	0.7627	0.7631	10.6067
Linear Discriminant Analysis	0.8761	0.9547	0.8849	0.8807	0.8823	0.7515	0.7524	0.1332
Ridge Classifier	0.8755	0	0.8864	0.8787	0.882	0.7503	0.7513	0.0213
Gradient Boosting Classifier	0.8663	0.9487	0.8742	0.8718	0.8728	0.7319	0.7322	5.9327
Ada Boost Classifier	0.8621	0.9454	0.8721	0.8665	0.869	0.7234	0.724	1.3535
Random Forest Classifier	0.7855	0.868	0.7516	0.8244	0.7858	0.5719	0.5749	0.1239
Decision Tree Classifier	0.7782	0.7776	0.7889	0.7894	0.7888	0.5552	0.5557	0.1976
Extra Trees Classifier	0.7723	0.8612	0.7884	0.7802	0.7841	0.5433	0.5436	0.2838
Logistic Regression	0.7421	0.801	0.7804	0.7416	0.7604	0.4815	0.4824	0.0597
Naive Bayes	0.6856	0.7882	0.895	0.647	0.7499	0.3563	0.3932	0.0154
K Neighbors Classifier	0.5787	0.5901	0.5976	0.5991	0.5982	0.1555	0.1555	0.1063
Quadratic Discriminant Analysis	0.5265	0.5411	0.2475	0.6249	0.3225	0.0805	0.1034	0.127
SVM - Linear Kernel	0.5248	0	0.3822	0.5329	0.3345	0.066	0.0927	0.1507

2.4.3. Modelin Geliştirilmesi

Borsa yönünü en iyi şekilde tahmin eden algoritma, diğer algoritmalar arasından elde edildikten sonra nihai modeli elde etmek için algoritmanın hiperparametreleri için de parameter optimizasyonu gerçekleştirilmiştir. Nihai algoritma ise 0.9093 doğruluk skoru, 0.9723 eğri altında kalan alan (bkz. Şekil 2.1a), 0.9081 hatırlama skoru ile 0.9183 duyarlılık skoru (bkz. Şekil 2.1b), 0.9132 F1 skoru, 0.8183 kappa skoru ve 0.8184 Matthew korelasyon katsayısı ile ilk modele göre performans açısından biraz daha iyileşme göstermiştir.



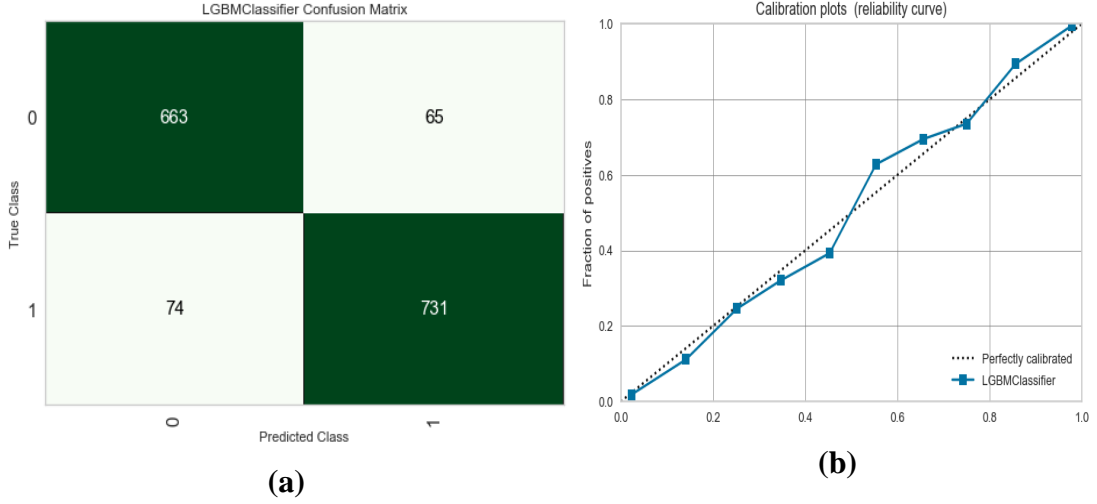
(a)



(b)


Şekil 2.1: Nihai Model İçin Eğri Alında Kalan Alan (a) Ve Duyarlılık-Hatırlama (b) Çizimleri

Nihai modelin performansının bir diğer göstergesi olarak da Şekil 2.2a'daki karmaşıklık matrisi (confusion matrix) ve Şekil 2.2b'deki kalibrasyon (calibration) eğrilerine bakılabilir. Karmaşıklık matrisi doğru ve yanlış sınıflandırılan gözlem noktalarının sayısını ve doğruluk, kesinlik gibi ölçütlerin hesaplanabileceği çıktıyı sunar. Köşegen elemanlar, tahmin edilen etiketin gerçek etikete eşit olduğu noktaların sayısını temsil ederken, köşegen dışı elemanlar, sınıflandırıcı tarafından yanlış etiketlenenlerdir. Karmaşıklık matrisinin diyagonal değerleri ne kadar yüksek olursa, o kadar iyidir, bu da tahmin edilen birçok doğru gözlem sayısı olduğunu gösterir. Kalibrasyon eğrisi ise, tahmin literatüründe genellikle "güvenilirlik" diyagramları olarak da adlandırılır, ancak tahmin olasılıklarının ne kadar iyi kalibre edildiğini özetledikleri için "kalibrasyon" grafikleri veya eğrileri olarak da adlandırılabilir. Tahminler ne kadar iyi kalibre edilirse veya daha güvenilir olursa, noktalar grafiğin sol alt köşesinden sağ üst köşesine kadar ana köşegene o kadar yakın görünür.



Şekil 2.2: Nihai Model İçin Karmaşıklık Matrisi (a) Ve Kalibrasyon Eğrisi (b)

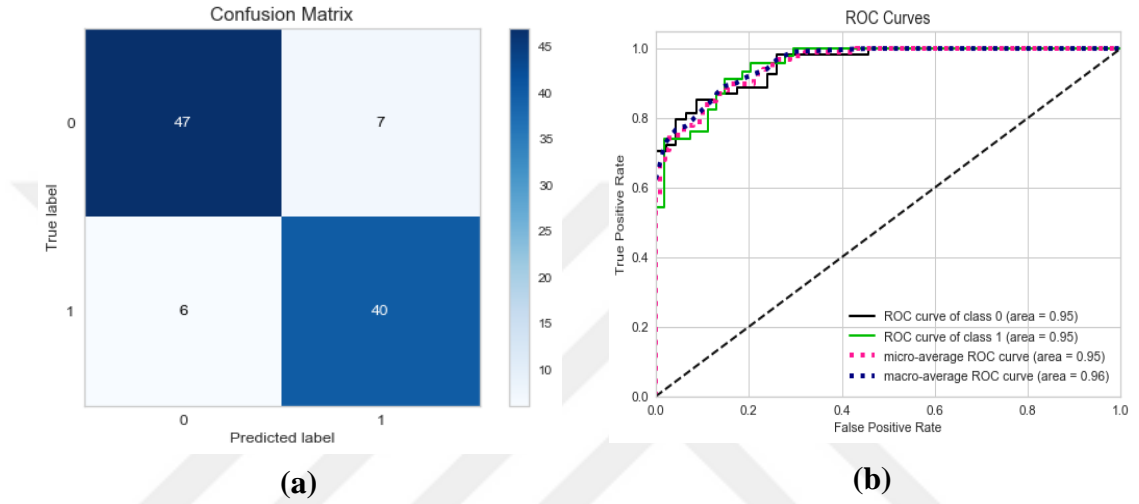
Model performansının yanında önemli bir çıktı da modelde yer alan değişkenlerin borsa yönünü gösteren değişken üzerindeki etkisidir. LightGBM gibi topluluk öğrenmesi algoritmalarında bunu gösteren bir çıktı değişken önem grafiğidir. Şekil 2.3'teki değişken önem grafiğinde hedef değişkenin tahmininde önemli olan ilk on değişken gösterilmiştir. Buna göre teknik göstergelerden özellikle momentum değişkenlerinin borsa yönünü tahminde çok daha baskın oldukları gözlemlenmektedir. Trend değişkenleri de önem açısından öne çıkmaktadır.



Şekil 2.3: Nihai Model Değişken Önem Grafiği

2.4.4. Nihai Modelin Test Verisi Üzerindeki Performansı

Nihai modelin test verisi üzerindeki performansı da eğitim ve değerlendirme verisetlerindeki yüksek performansa yakın olarak gözlemlenmiştir. Nihai model, test verisinde 0.87 doğruluk skoru, 0.95 eğri altında kalan alan, 0.87 hatırlama ile 0.89 duyarlılık skoru, 0.86 F1 skoru göstermiştir (bkz. Şekil 2.4a ve Şekil 2.4b).



Şekil 2.4: Nihai Modelin Test Verisi Tahminleri İçin Karmaşıklık Matrisi (a) Ve Eğri Altında Kalan Alan (b)

2.5. Sonuç ve Tartışma

Bu çalışmada BİST 100 endeksi fiyat yükseliş ve düşüş yönü tahmini için en iyi tahmin performansını gösteren bir yapay öğrenme modeli çalışılmıştır. Çalışmada onbeş farklı yapay öğrenme algoritması ile borsa yönü tahmin edilmiş, tahmin ölçütleri açısından en iyi sonucu veren algoritma için hiperparametre eniyilemesi yapılarak nihai model olan LightGBM modeli oluşturulmuştur.

Literatürdeki çalışmalarla karşılaştırıldığında, nihai modelin tahmin performansının yüksek bir düzeyde olduğu söylenebilir. Bununla birlikte, literatürdeki diğer çalışmalarla karşılaştırıldığında, hedef değişken üzerinde baskın olan değişkenlerin sunulmuş olması bu çalışmanın ayırt edici bir başka yönünü oluşturmaktadır. Modelin ve yaklaşımın uygulamada önemli bir faydasının, gerek gerçek zamanlı

gerekse de gelecek tahminleri ve bu tahminlere dayalı karar alma süreçlerinde öne çıkması olarak belirtilebilir. Geçmiş veriden hareketle öğrenen algoritmanın bu anlamda bireysel ya da kurumsal karar alıcılar için bir fikir verebileceği ve buna göre anlık ya da yakın gelecek yatırım planları yaparak daha etkin süreçler yönetebilecekleri söylenebilir.

Yapay öğrenme algoritmaları ve yaklaşımların sadece bu çalışmadakilerle sınırlı olmamakla birlikte, tahmin performansının nihai modelden çok daha iyi olduğu farklı yaklaşımlar da gelecekteki çalışmalarda yeniden türetilir.

2.6. Kaynakça

- Akşehir, Zinnet D., Erdal Kılıç. 2019. Makine Öğrenmesi Teknikleri ile Banka Hisse Senetlerinin Fiyat Tahmini. **Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi**, c.12 s.2: 30-39.
- Alpaydın, Ethem. 2014. **Introduction to Machine Learning**. ABD: Massachusetts Institute of Technology.
- Altuntaş, Semra T., Fatma D. Çolak. 2015. BİST-100 Endeksinde Volatilitenin Modellenmesi Ve Öngörülmesinde ARCH Modelleri. **İstanbul Üniversitesi İşletme Fakültesi İşletme İktisadi Enstitüsü Yönetim Dergisi**, c.25 s.79: 208-223.
- Bishop, Christopher M. 2006. **Pattern Recognition and Machine Learning**. Singapore: Springer.
- Çalışkan, Muhammed M. T., Devran Deniz. 2015. Yapay Sinir Ağlarıyla Hisse Senedi Fiyatları ve Yönlerinin Tahmini. **Eskişehir Osmangazi Üniversitesi İİBF Dergisi**, c.10. s.3: 177- 194.
- Dağlıoğlu, Cansu, Gülsen Kırıl. 2018. Ekonomik Yatırım Araçları Getirilerinin Saklı Markov Modeli ile Tahmin Edilmesi: Türkiye Örneği. **Uluslararası Ekonomi ve Yenilik Dergisi**, c.4. s.1: 61-75.
- Filiz, Enes, Hasan A. Karaboğa, Serkan Akoğul. 2017. BIST-50 Endeksi Değişim Değerlerinin Sınıflandırılmasında Makine Öğrenmesi Yöntemleri Ve Yapay Sinir Ağları Kullanımı. **Ç.Ü. Sosyal Bilimler Enstitüsü Dergisi**, c.26. s.1: 231-241.
- Goodfellow, Ian., Yoshua Bengio, Aaron Courville. 2016. **Deep Learning**. Cambridge, MA: MIT Press.
- Günay, Samet. 2014. Yapısal Kırılmalar Dahilinde BIST-100 Endeksi Volatilitelerinin Uzun Dönemli Bellek Analizi. **Journal of Yasar University**, c.9. s.36: 6261-6380.

- Hastie, Trevor, Robert Tibshirani, Jerome Friedman. 2008. **The Elements of Statistical Learning**. 2. bs. California: Springer.
- Jansen, Stephen. 2020. **Machine Learning for Algorithmic Trading**. 2. bs. Birmingham, UK: Packt Publishing Ltd.
- Kara, İsmail. 2019. Borsa Endeksi Hareket Yönünün Tahmininde Sınıflandırma Yöntemlerinin Performanslarının Karşılaştırılması: BİST 100 Örneği. Afyon Kocatepe Üniversitesi Sosyal Bilimler Enstitüsü, İşletme Anabilim Dalı. Afyon: Doktora Tezi.
- Kuzu, Serdar. 2018. Borsa İstanbul Endeksi (BIST 100) Getiri Volatilesinin ARCH Ve GARCH Modeli İle Tahmin Edilmesi. **Muhasebe ve Vergi Uygulamaları Dergisi**, 10. Yıl Özel Sayısı:608-624.
- Marwala, Tshildzi. [01.06.2015]. Impact of Artificial Intelligence on Economic Theory. arXiv.org: 1509.01213
- Özçalıcı, Mehmet. 2016. Yapay Sinir Ağları ile Çok Aşamalı Fiyat Tahmini: BIST30 Senetleri Üzerine Bir Araştırma. **Dokuz Eylül Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi**, c.31. s.2: 209-227.
- Raschka, Sebastian., Vahid Mirjalili. 2017. **Python Machine Learning**. 2. bs. Birmingham: Packt Publishing Ltd.
- Russell, Stuart J., Peter Norvig. 2016. **Artificial Intelligence-A Modern Approach** 3. bs. Malaysia: Pearson.
- Samuel, Arthur. 1959. Some Studies in Machine Learning Using the Game of Checkers. **IBM Journal of Research and Development**. c.3. s.3: 535-554.
- Sarıkaya, Görkem. 2019. Yapay Sinir Ağları Ve Regresyon Modelleri İle Bist Ulusal -100 Endeksinin Tahmini. **21. Yüzyılda Eğitim Ve Toplum Eğitim Bilimleri Ve Sosyal Araştırmalar Dergisi**, c.8. s.23: 325-340.
- Sutton, Richard S., Andrew G. Barto. 2018. **Reinforcement Learning-An Introduction**. 2. bs. London: MIT Press.
- Wolpert, David H. 1996. The Lack of A Priori Distinctions Between Learning Algorithms. **Neural Computation**. s.8: 1341-1390.

3. TÜRKİYE’DE DOLAR KURU VE TÜFE’DE ANOMALİ TESPİTİ: GÖZETİMSİZ ÖĞRENME VE TAHMİNSEL ALGORİTMALAR

3.1. Giriş

İktisadi zaman serileri, tüketici ve üretici fiyat endeksleri, döviz kurları, faiz oranları, üretim seviyesi gibi makro iktisadi göstergeler olarak iktisat politikası yapıcıları ve iktisadi ajanlar tarafından izlenebilmektedir. Gözlenen bu seriler, ülkeler ve iktisadi ajanlar için gelecek beklentilerinde ve planlarında öncü göstergeler olarak kullanılabilirlerdir.

Öncü göstergeler olarak kullanılan değişkenler, ilgili gözlem kaynağı için uygun iktisat politikası kümesi oluşturmak için değerlendirilebilmektedir. Bu göstergeler aynı zamanda içinde tarihsellik de barındırdığı için kimi zaman olağandışı olarak gözlenen ve belki de bir kriz ya da aşırılık anlamına gelebilecek davranışları da göstermektedir.

Bu çalışmada Türkiye’de 2005-2019 dönemi için gözlenen günlük dolar kuru değişimi ve aylık tüketici fiyat endeksi için anomali tespiti yapılmıştır. Her iki seri için iki farklı yöntem grubu kullanılmış ve yöntem grupları için anomali noktalarının tespitinin performans karşılaştırması yapılmıştır.

Seriler için uygulanan ilk yöntem grubu gözetimsiz yapay öğrenme algoritmalarıdır. Gözetimsiz yapay öğrenme algoritmaları, etiketli olmayan verilerde etiketlerin öğrenilmesi, ilk bakışta kuralların belirli olmadığı verilerde kuralların öğrenilmesi, anomalilerin tespiti gibi amaçlar için sıkça kullanılmaktadır.

Çalışma kapsamında anomali tespiti için ikinci bir algoritma olarak da Prophet zaman serisi tahminsel algoritması sınanmıştır.


3.2. Çalışmanın Yöntemi

Çalışmada, TÜFE ve günlük dolar kurundaki değişim için anaomali tespitinde gözetimsiz öğrenme algoritmaları ile tahminsel modelin performansı

karşılaştırılmıştır. Bu amaçla, ilk olarak serilerde anomali noktaları istatistiksel olarak belirlenmiştir. İstatistiksel yöntem olarak hareketli z-skoru kullanılmıştır. Hareketli z-skorum ile belirlenen anomali noktaları, gözetimsiz öğrenme ve tahminsel model algoritmalarının tespit edebildiği anomali noktalarının karşılaştırılması için gösterge olarak kullanılmıştır.


Anomali noktalarının tespitinde gözetimsiz öğrenme algoritmalarından k-ortalamlar, izole orman ve destek vektör makineleri algoritmaları kullanılmıştır. Tahminsel yöntem olarak Prophet algoritması kullanılmıştır. Söz konu algoritmalarla tespit edilen anomaliler için algoritmaların tahminlerdeki doğruluk değerlerine odaklanılmıştır. Doğruluk değerleri arasındaki karşılaştırma, algoritmaların, serilerdeki anomalileri tahmindeki başarı performansını değerlendirmeye imkan tanımıştır.

Çalışmanın konusu olan günlük dolar kuru değişim Şekil 3.1'deki gibi, TÜFE ise Şekil 3.2'deki gibi gösterilmiştir.



Şekil 3.1: Günlük Dolar Kuru Değişimi

Veri Kaynağı: Türkiye Cumhuriyeti Merkez Bankası. [01.01.2021]. Elektronik Veri Dağıtım Sistemi. <https://evds2.tcmb.gov.tr/>



Şekil 3.2: TÜFE

Veri Kaynağı: Türkiye Cumhuriyeti Merkez Bankası. [01.01.2021]. Elektronik Veri Dağıtım Sistemi. <https://evds2.tcmb.gov.tr/>

3.3. Algoritmaların Karşılaştırılması İçin Hesaplanan Hareketli Z-Skorları

Bu çalışmada, gözetimsiz öğrenme algoritmalarının ve Prophet tahminsel algoritmasının performans karşılaştırmasının yapılabilmesi için, başlangıç olarak zaman serilerinde anomali noktalarının işaretlenmesi için z-skoru kullanılmıştır. Zaman serileri için hesaplanan hareketli z-skorumları, özellikle akan verilerde anomali tespitinde temel istatistiksel yaklaşımlardan birisidir (Akoglu ve Faloutsos, 2010; Hu ve diğ., 2019; Viswanathan ve diğ., 2012).

Bir veri noktası t için hareketli z-skoru, t zamanından hemen önce hareketli ortalamasının çıkarılması ve t zamanından hemen önceki standart sapmaya bölünmesi ile standartlaştırılan t nin değeridir. W , gözlem sayısı bakımından pencere genişliğini gösterebilir. Buna göre hareketli z-skoru aşağıdaki gibi yazılabilir Hu ve diğ. (2019):

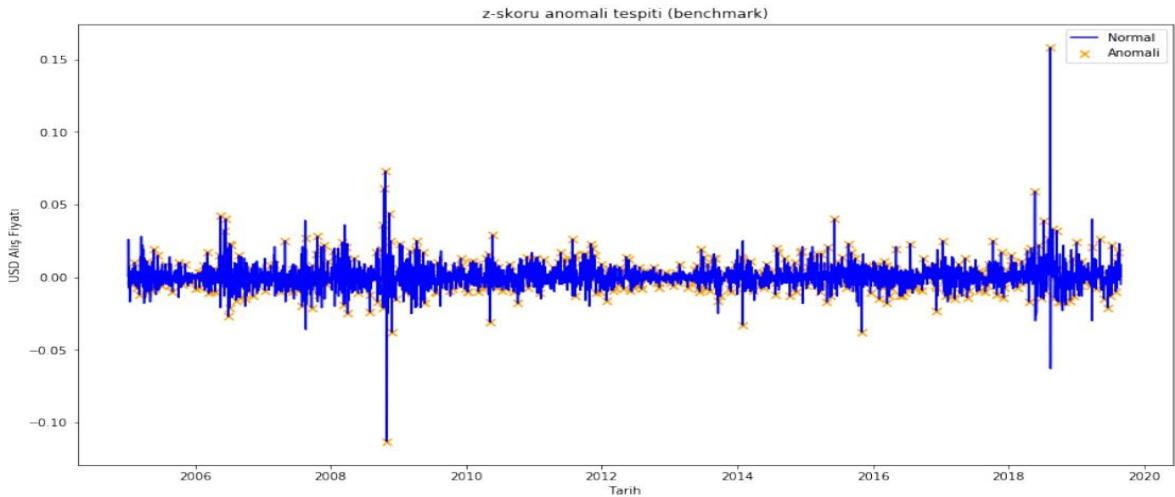
$$z(t) = \frac{t - \bar{t}}{s_t}$$

Burada \bar{t} hareketli ortalamayı, s_t ise hareketli standart sapmayı gösterir;

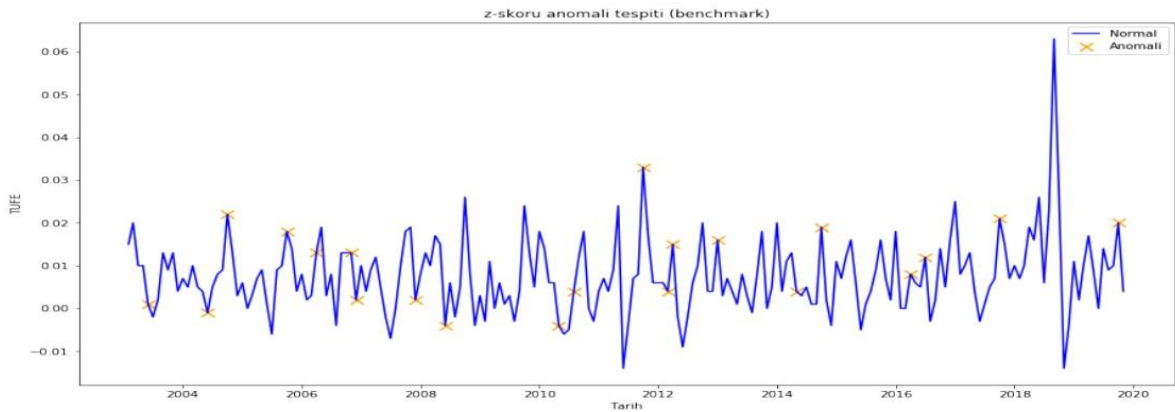
$$\bar{t} = (1/n) \sum_{i=1}^n t_i$$

$$s_t = \sqrt{(1/n) \sum_{i=1}^n (t_i - \bar{t})^2}$$

Z-skorları ile belirlenen günlük dolar kuru değişimine ait anomaliler Şekil 3.3'te, TÜFE'ye ait anomaliler ise Şekil 3.4'te gösterilmiştir. Her iki seride de z-skorları ile belirlenen anomali noktaları, özellikle uç noktalarda yer aldıkları gözlemlenmiştir.



Şekil 3.3: Günlük dolar kuru değişimi, z-skoru anomali tespiti



Şekil 3.4: TÜFE için z-skoru anomali tespiti

3.4. Çalışmada Kullanılan Gözetimsiz Öğrenme Algoritmaları

3.4.1. Gözetimsiz Öğrenme

Makine öğrenmesi algoritmaları, çalışılan veri tipine ve hedeflenen bulguya göre çeşitlenmektedir. Genel olarak makine öğrenmesi algoritmaları gözetimli öğrenme, gözetimsiz öğrenme ve yarı-gözetimli öğrenme şeklinde gruplandırılmaktadır (Zhu, Goldberg, 2009; Dasgupta, Nath, 2016; Alloghani ve diğ., 2020).

Bir hedef değişkenin olduğu ve hedef değişkenin kategorik sınıflar veya sürekli değişken olduğu veriler üzerinde genellikle gözetimli algoritmaları uygulanırken, bir hedef değişkenin olmadığı, veriden etiketlerin türetilmeye çalışıldığı durumlarda gözetimsiz öğrenme algoritmalarına başvurulmaktadır. Bu çalışmanın problemiği olarak zaman serilerinde önceden etiketlenmemiş anomalilerin tespiti için de gözetimsiz öğrenme algoritmalarından faydalanılmıştır.

3.4.2. K-Ortalamlar (K-Means) Algoritması

K-ortalamlar algoritması, eldeki veriyi kendi içinde türdeş kümelere ayırmak için kullanılan basit yapay öğrenme algoritmalarından birisidir. Her küme, birbirine en yakın veri noktalarından oluşur.

K-ortalamlar algoritması, iteratif adımlardan oluşur (Alpaydın, 2012, 119; Dangeti, 2017, 305). Verisinde, k tane $(1), \dots, (k)$ başlangıç noktası mevcutken, algoritma iki adımı takip eder. İlk adım, atama adımındır. Atama adımında her bir gözlem, ortalaması en küçük Öklid uzaklığına sahip olan kümeye atanır; bu sezgisel olarak "en yakın" ortalamadır (Matematiksel olarak, bu, gözlemlerin ortalamalarla oluşturulan Voronoi diyagramına göre bölünmesi anlamına gelmektedir).

$$S^{(t)} = \{ p \mid |p - \mu_j^{(t)}|^2 \leq |p - \mu_{j'}^{(t)}|^2 \forall j, j', 1 \leq j, j' \leq k \}$$

Bu adımda, her bir p veri noktası, sadece bir $S^{(t)}$ kümesine atanır. İkinci adım olan güncelleme adımında, yeni kümelerdeki gözlemlerin yeni ortalamaları (centroids) hesaplanır.

$$\mu_j^{(t+1)} = \frac{1}{|S_j^{(t)}|} \sum_{p \in S_j^{(t)}} p$$

Atamalar artık deęişmedięinde algoritma yakınsar. Algoritma, optimumun bulunacaęını garanti etmez. Algoritma genellikle nesnelere mesafeye göre en yakın kümeye atama olarak sunulur. Öklid mesafesi(kare) dışında farklı bir uzaklık fonksiyonu kullanmak algoritmanın yakınsamasını durdurabilir. Küresel (spherical) k-ortalamlar ve k-medoidler gibi k-ortalamların çeşitli modifikasyonlarının, diğer uzaklık ölçümlerinin kullanılmasına izin vermek için önerilmiştir.

3.4.3. İzole Orman (Isolation Forest) Algoritması

Anomali tespitinde görece yeni algoritmalar olan izole orman (isolation forest) algoritması, k-ortalamlar algoritmasından farklı olarak uzaklık yerine anomali olarak tespit edilen gözlem değerlerini verinin geri kalanın izole eden ağaç bazlı bir algoritmadır.

İzole orman algoritması da iki adımlı bir süreçtir (Liu ve dię. 2008; Ding, Fei, 2013) : İlk aşamada, izole ağaçlar (iTrees) oluşturmak için bir eğitim veri kümesi kullanılır. İkinci aşamada, test setindeki her bir örnek bir önceki aşamadaki iTrees derlemesinden geçirilir ve örneğe aşağıda açıklanan algoritma kullanılarak uygun bir “anomali skoru” atanır. İzole ormanda tanımlanan anomali skoru:

$$s(x) = 2^{-\frac{E(h(x))}{c(n)}}$$

Burada $h(x)$, x gözleminin yol uzunluğu, $c(n)$, bir ikili arama ağacında (binary search tree) başarısız aramaların ortalama yol uzunluğudur ve harici düğümlerin sayısıdır.

Her gözleme bir anomali skoru verilir ve aşağıdaki karar esas alınarak verilebilir: Skor, 1'e yakınsa anomali olarak işaretlenir. 0.5'ten küçük skora sahip gözlemler normal olarak işaretlenir. Tüm skorlar 0,5'e yakınsa, tüm örneklemin açıkça farklı anomalileri olduğu görülmez.

3.4.4. Destek Vektör Makineleri (Support Vector Machines)

Destek vektör makineleri, k-boyutlu bir uzayda (k tane deęişkenin olduğu bir veride) gözlem noktalarını en iyi şekilde birbirinden ayıracak bir hiper-uzayı bulmaya çalışan algoritmadır (Alpaydın, 2012, 265). Özellikle bir gözetimli öğrenme algoritması olarak sınıflandırma problemlerinin çözümünde tercih edilmektedir (Furey ve dię., 2000; Pavlidis ve dię., 2004; Hastie ve dię., 2008, 423).

Geleneksel DVM'lerin aksine, tek sınıflı destek vektör makineleri (DVM) ise anomaly tespiti problemlerinde tercih edilen algoritmalarındandır (Wang ve diğ., 2004; Li ve diğ., 2003). Tek sınıflı DVM, bilinen sınıfın gözlemleri ile orijini arasında maksimum ayırım sağlayan bir karar sınırı öğrenir. Karar sınırının diğer tarafında gözlemlerin sadece küçük bir kısmının kalmasına izin verilir: bu gözlemler anomali olarak kabul edilir.

Algoritma, verileri uygun bir çekirdek fonksiyonu (kernel function) kullanarak bir özellik uzayı H 'ye eşleme ve daha sonra eşlenen vektörleri başlangıç noktasından maksimum kenar boşluğu (margin) ile ayırmaya çalışarak özetlenebilir (Wang, 2004):

$$\begin{aligned} \gamma(\mathbf{x}) &= \{ +1, & \mathbf{x} \in S \\ & -1, & \mathbf{x} \in S^c \end{aligned}$$

3.5. Prophet Tahminsel Algoritması

Prophet algoritması, ölçekte zaman serisi tahmini yapmak için yazılmıştır (Taylor ve Letham, 2017). Prosedür, üç ana model bileşenine sahip ayrıştırılabilir, toplamsal bir zaman serisi modelini kullanır, trend, mevsimsellik ve tatiller:

$$y(t) = g(t) + s(t) + h(t) + e(t)$$

Burada $g(t)$ periyodik olmayan değişimleri de içeren trend modeli; $s(t)$ periyodik değişimleri içeren mevsimsel modeli; $e(t)$, düzenli olmayan, tatiller gibi etkileri ve

$h(t)$, diğer bileşenlerle içerilmeyen değişimleri gösterir. Genelleştirilmiş toplamsal modele (generalized additive model-GAM) benzer şekilde, regresör olarak zamana sahip olan Prophet, zamanın bileşenleri olarak birçok doğrusal ve doğrusal olmayan fonksiyonuna uydurur (function fit). Prophet, her gözlemin zamana bağlı bağımlılığına açıkça bakmak yerine, tahmin problemini bir tür doğrusal olmayan eğri uydurma (curve fitting) problemi olarak ele almaktadır.

3.6. İlgili Literatür

Çalışma, daha genel olarak zaman serilerinde anomaly tespiti ile özel olarak da iktisadi zaman serilerinde anomaly tespiti kapsamına girmektedir. Dolayısıyla bu altbaşlıkta ilk olarak genel literature, ikinci olarak da özel literature yer verilecektir.

Salvador ve Chan (2005), NASA verileri üzerinde yaptıkları çalışmada, kümeleme temelli bir anomali tespiti algoritması geliştirmişlerdir. Geliştirdikleri algoritmanın, normal davranışları izleyerek anomalileri ortaya çıkarmada oldukça başarılı olduğunu göstermişlerdir.

Günümüzde sensörler, log kayıtları gibi çok büyük boyutlu zaman serileri için anomalilerin hızlı ve doğru bir şekilde tespiti de önem kazanmaya başlamıştır. Qiu ve diğ. (2012) yaptıkları çalışmada Granger grafiksel modellerine dayalı dayanıklı anomali skorları üreten bir algoritma geliştirdiklerini ifade etmişlerdir. Wei ve diğ. (2005), sensor verilerinde anomali tespiti için, istenilen alan için özelleştirilebilecek çevrimiçi bir anomali tespiti algoritması önermişlerdir.

Li ve diğ. (2017), çok değişkenli zaman serilerinde anomali tespiti için saklı markov modellerine dayalı bir algoritma önermişlerdir. Önerdikleri algoritma, zaman serilerinin çok değişkenli olarak dönüşümüne dayanmaktadır.

Yapay öğrenme ve derin öğrenme temelli anomali tespiti algoritmaları hem tahminsel modellere hem de gözetimsiz öğrenme temelli etiketlemeye dayalı olarak çalışılmıştır. Büyük ölçekli ve oldukça uzun hafızalı zaman serileri için uzun-kısa dönem hafıza (long-short term memory) sinir ağları son yıllarda oldukça fazla çalışmalara dahil olmuştur. Malhotra ve diğ. (2015) anomali olmayan bir seride eğittikleri yığın LSTM ağını, anomalilerin tespiti için kullanmışlar ve anomali tespitinde başarılı sonuçlar elde etmişlerdir. Shipmon ve diğ. (2017) gürültü ve yüksek dönemsellik içeren websitesi trafiği örüntülerinde anomali durumlarını tespit etmek için derin sinir ağları, özyinelemeli sinir ağları ve LSTM ağlarıyla çalışmışlardır. Huang ve diğ. (2017), büyük ölçekli zaman serilerinin gözlemlendiği bulut servislerinde anomali tespiti için destek vektör veri tanımlama (support vector data description) algoritması geliştirmişlerdir. Algoritma performansını Iris veriseti ve Yahoo gösterge verisetleri üzerinde test etmişler, anomali tespitinde yüksek performans sağladıklarını göstermişlerdir.

Gözetimsiz öğrenme yöntemleri ile zaman serilerinde anomali tespiti, anomali gözlemlerinin etiketlenmesi de literatürde çalışılan alanlardandır. Ahmad ve diğ. (2017), birbirinden bağımsız kaynaklardan gelen gerçek zamanlı akan veriler (streaming data) için, gözetimsiz öğrenme yaklaşımıyla hiyerarşik geçici bellek (hierarchical temporal memory) isimli bir algoritma geliştirmişler, gerçek zamanlı


verilerde anomali davranışlarının etiketlenmesinde başarılı sonuçlar almışlardır. Munir ve diğ. (2019) de gerçek zamanlı verilerde anomali davranışlarının tespiti için derin sinir ağı temelli, gözetimsiz öğrenme algoritması geliştirmişlerdir. Xu ve diğ. (2018), büyük internet şirketlerinin zamana bağlı olarak takip ettikleri anahtar göstergelerdeki anomalilerin tespiti için Donut isimli değişimsel oto-kodlayıcı (variational auto-encoder) temelli bir algoritma geliştirmişlerdir. Geliştirdikleri algoritmanın gözetimli öğrenme teknikleri ve baz değişimsel oto-kodlayıcı algoritmasına göre çok daha iyi performans gösterdiğini belirtmişlerdir.

Anomali tespiti için üzerinde çalışılan zaman serileri, endüstriyel veriler olabildiği gibi finansal zaman serileri de olmaktadır. Ferdousi ve Maeda (2006), Bangladeş stok piyasasında brokerlerin anomali davranışlarını tespit edebilmek için bir gözetimsiz öğrenme algoritması olan eş grup analizi (peer group analysis) algoritması kullanmışlar ve başarılı sonuçlar elde etmişlerdir. Akouemo ve Povinelli (2016) yaptıkları çalışmada, Bayesyen temelli olasılıksal bir anomali tespiti algoritması çalışmışlar, doğal gaz tüketim verileri üzerinde önceden anomali olarak etiketlenen gözlemlerden yol çıkarak, etiketlenmemiş veride anomalileri olasılıksal olarak tahmin etmişlerdir. Siffer ve diğ. (2017), uç değer teorisine dayanan bir anomali tespiti algoritması geliştirmişler, anlık olarak akan enerji alanı verilerinde ölçeklenebilir ve etkin sonuçlar elde etmişlerdir. Chou ve Telaga (2014), enerji tüketiminde anomali tespiti için tahminsel temelli iki aşamalı bir algoritma üzerinde çalışmışlardır. Tahminsel aşamada yapay sinir ağı ve ARIMA bazlı hibrit bir model kullanmışlar, anomali tespitini de tahmin edilen değerler üzerinden 2-sigma yöntemiyle gerçekleştirmişlerdir.

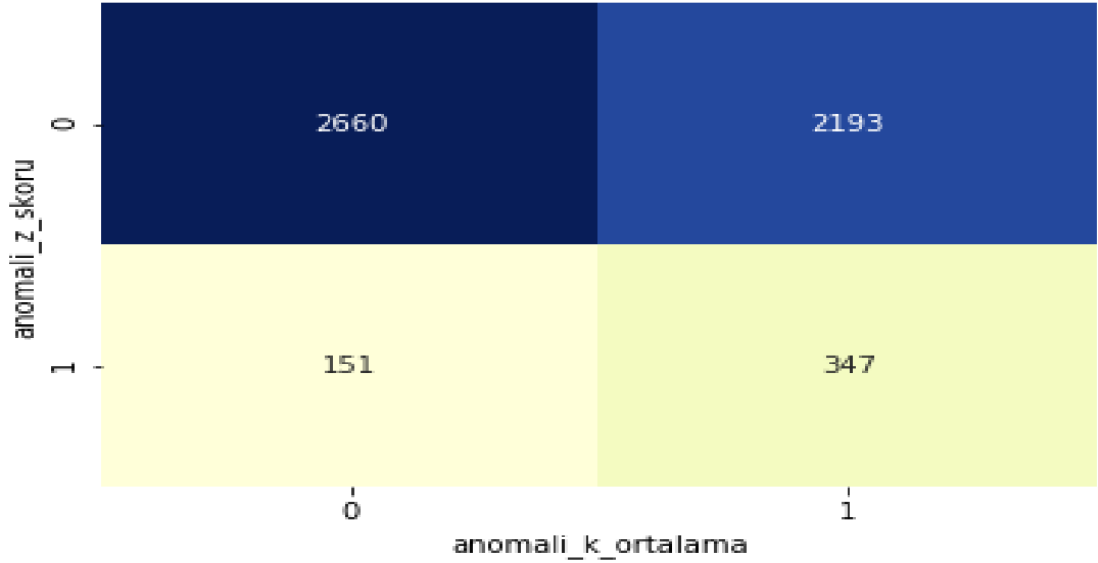
3.7. Anomali Tespitleri Ve Algoritmaların Anomali Tespiti Performanslarının Karşılaştırılması

3.7.1. Günlük Dolar Kuru Değişimi Anomali Tespiti

K-ortalamlar ile tespit edilen anomali noktaları Şekil 3.5'te, z-skorları ile tespit edilen anomalilerle karşılaştırılması Şekil 3.6'da gösterilmiştir. Z-skorları ile işaretlenen değerler karşılaştırıldığında, k-ortalamlar algoritması yaklaşık %56 doğruluk oranına (accuracy), yaklaşık %70 kesinlik oranına sahip olduğu gözlemlenmiştir.




Şekil 3.5: K-ortalamalar ile tespit edilen anomali noktaları, günlük dolar kuru değişimi




Şekil 3.6: K-ortalamalar ile tespit edilen anomaliler ve z-skorları ile belirlenen anomaliler

İzole orman algoritmasıyla tespit edilen anomali noktaları Şekil 3.7’de, hareketli z-skoru ile tespit edilen anomalilerle karşılaştırılması Şekil 3.8’de gösterilmiştir. İzole orman modeli ile işaretlenen anomali değerleri, z-skorları ile karşılaştırıldığında yaklaşık %68 doğruluk ve %81 kesinlik oranlarına sahip olduğu gözlemlenmiştir. Bu, k-ortalamlar ile işaretlenenden çok daha iyi bir performans demektir.

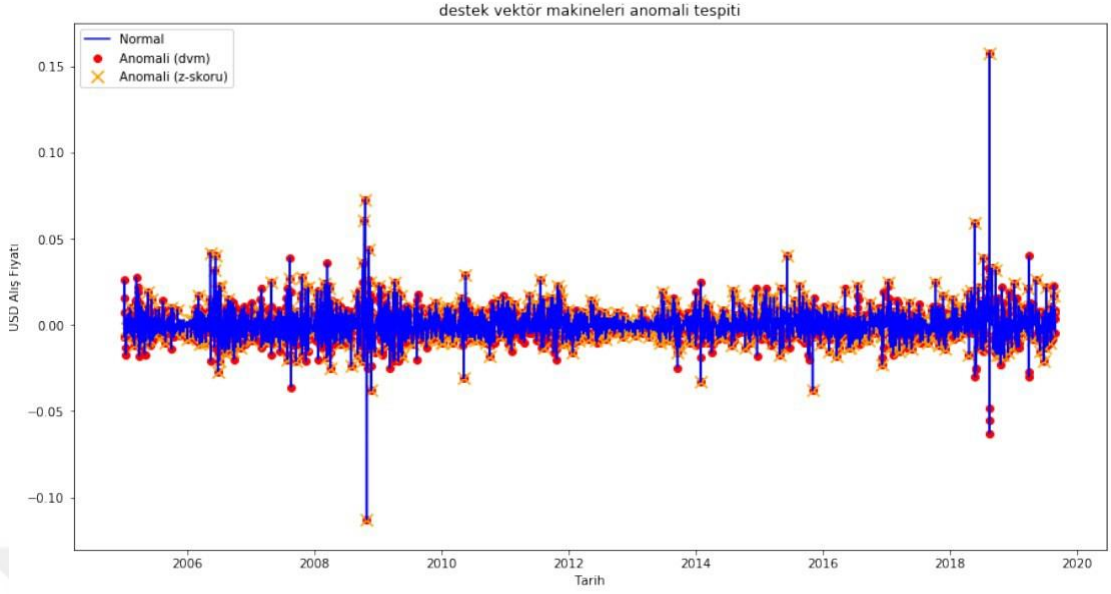


Şekil 3.7: İzole orman ile tespit edilen anomali noktaları, günlük dolar kuru değişimi

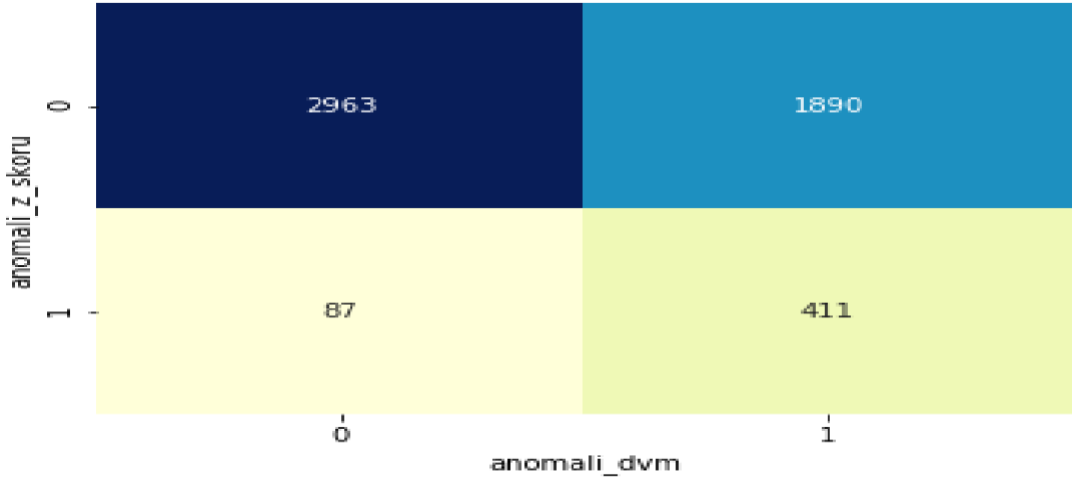


Şekil 3.8: İzole orman ile tespit edilen anomaliler ve z-skorları ile belirlenen anomaliler

Destek vektör makineleri (DVM) algoritmasıyla tespit edilen anomali noktaları Şekil 3.9'de, hareketli z-skoru ile tespit edilen anomalilerle karşılaştırılması Şekil 3.10'de gösterilmiştir. DVM ile işaretlenen anomaliler, z-skorları ile işaretlenenler ile karşılaştırıldığında yaklaşık %63 doğruluk ve yaklaşık %83 kesinlik oranları elde edildiği gözlemlenmiştir.

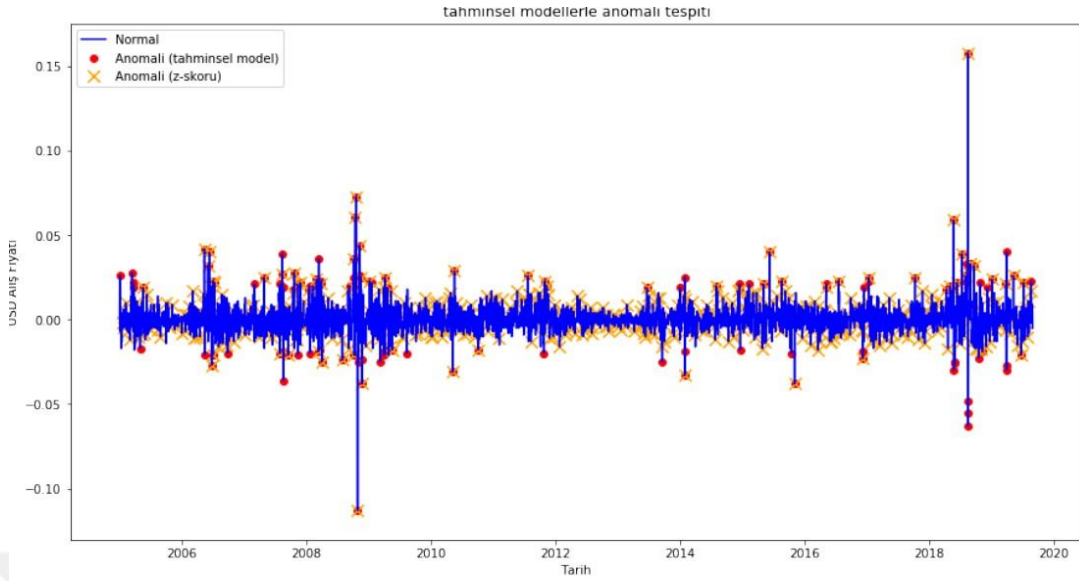


Şekil 3.9: Destek vektör makineleri ile tespit edilen anomali noktaları, günlük dolar kuru değişimi




Şekil 3.10: Destek vektör makineleri ile tespit edilen anomaliler ve z-skorları ile belirlenen anomaliler

Prophet algoritmasıyla tespit edilen anomali noktaları Şekil 11’de, hareketli z-skoru ile tespit edilen anomalilerle karşılaştırılması Şekil 12’de gösterilmiştir. Tahminsel model ile yapılan anomali etiketleri z-skorları yapılan etiketlemelerle karşılaştırıldığında yaklaşık %90 gibi bir doğruluk oranına ulaşılsa da kesinlik oranı yaklaşık %13 gibi bir oran olarak gözlemlenmiştir.



Şekil 3.11: Prophet ile tespit edilen anomali noktaları, günlük dolar kuru değişimi

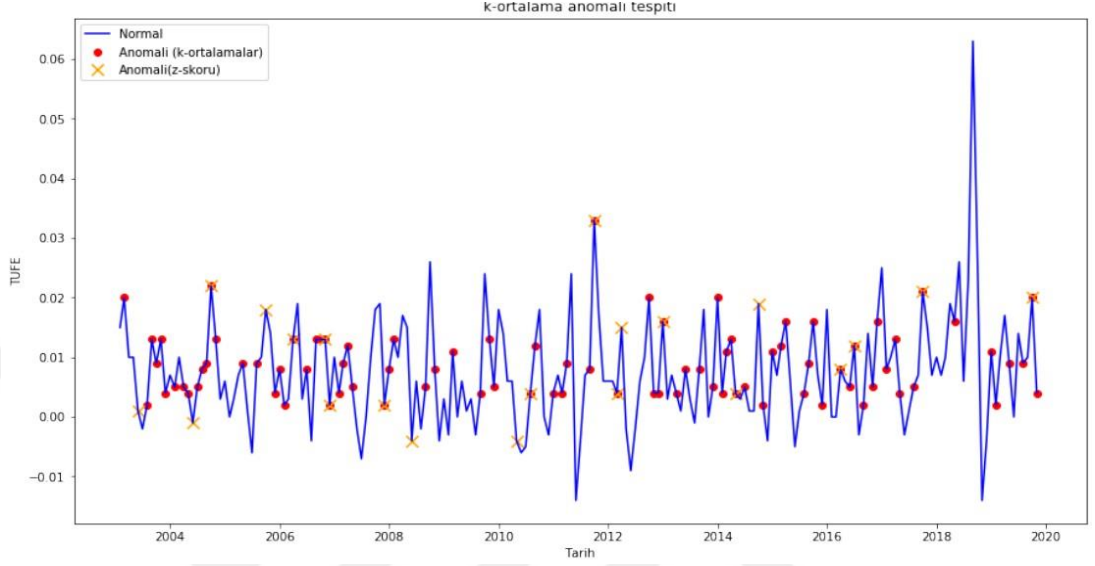


Şekil 3.12: Prophet ile tespit edilen anomaliler ve z-skorumları ile belirlenen anomaliler


3.7.2. TÜFE Anomali Tespiti

K-ortalamlar algoritmasıyla tespit edilen anomali noktaları Şekil 3.13'te, hareketli z-skoru ile tespit edilen anomalilerle karşılaştırılması Şekil 3.14'te gösterilmiştir. K-

ortalamalar algoritması, TÜFE için z-skorum ile işaretlenen anomalileri yaklaşık %60 doğruluk ve yaklaşık % 67 kesinlik oranı ile işaretleyebilmiştir.




Şekil 3.13: K-ortalamalar ile tespit edilen anomali noktaları, TÜFE



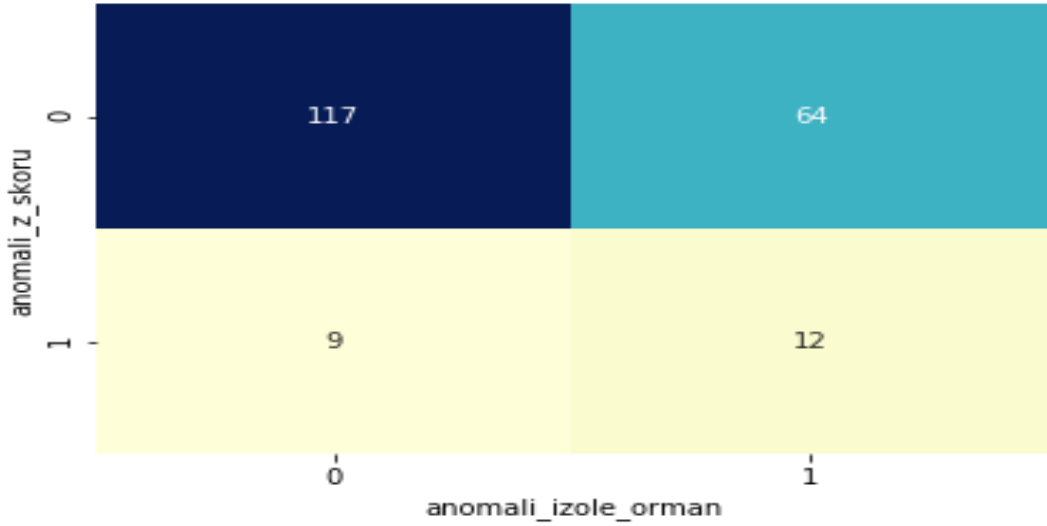
Şekil 3.14: K-ortalamalar ile tespit edilen anomaliler ve z-skorum ile belirlenen anomaliler

İzole orman algoritmasıyla tespit edilen anomali noktaları Şekil 3.15’de, hareketli z-skoru ile tespit edilen anomalilerle karşılaştırılması Şekil 3.16’da gösterilmiştir. İzole

orman algoritması, z-skorları ile işaretlenen anomali gözlemleri karşılaştırıldığında yaklaşık %63 doğruluk ve %57 kesinlik ile TÜFE’de anomalileri işaretleyebilmiştir.



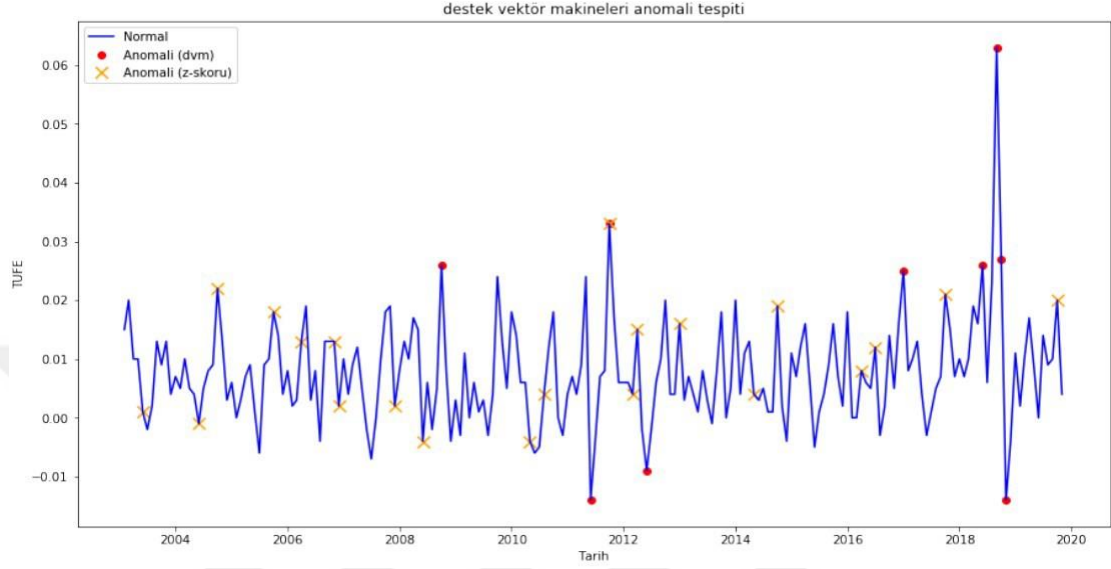
Şekil 3.15: İzole orman ile tespit edilen anomali noktaları, TÜFE




Şekil 3.16: İzole orman ile tespit edilen anomali noktaları, TÜFE

Destek vektör makineleri algoritmasıyla tespit edilen anomali noktaları Şekil 3.17’de, hareketli z-skoru ile tespit edilen anomalilerle karşılaştırılması Şekil 3.18’de gösterilmiştir. DVM algoritması, z-skorları ile işaretlenen anomaliler gösterge olarak

alındığında yaklaşık %86 doğruluk oranı gösterse de, yaklaşık % 5 kesinlik oranı göstermiştir.




Şekil 3.17: DVM ile tespit edilen anomali noktaları, TÜFE



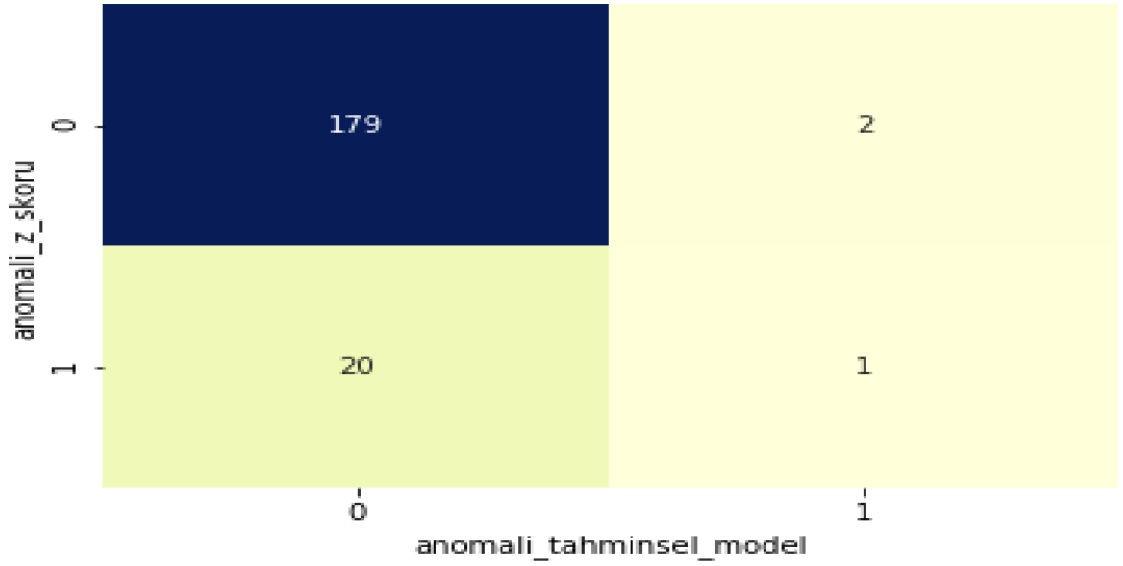
Şekil 3.18: DVM ile tespit edilen anomaliler ve z-skorları ile belirlenen anomaliler

Prophet algoritmasıyla tespit edilen anomali noktaları Şekil 3.19’da, hareketli z-skoru ile tespit edilen anomalilerle karşılaştırılması Şekil 3.20’de gösterilmiştir.

Prophet algoritması, z-skorum ile işaretlenen anomali noktaları gösterge alındığında yaklaşık %89 doğruluk değeri ve yaklaşık %5 kesinlik değeri göstermiştir.



Şekil 3.19: Prophet ile tespit edilen anomali noktaları, TÜFE



Şekil 3.20: Prophet ile tespit edilen anomaliler ve z-skorum ile belirlenen anomaliler

3.8. Günlük Dolar Kuru Değişimi ve TÜFE Anomali Tespitinde Algoritmaların Performans Karşılaştırması

Çalışmada, Türkiye’de günlük dolar kuru değişiminde ve TÜFE’de anomalilerin tespiti için gözetimsiz öğrenme algoritmaları ile Prophet tahminsel algoritmasının, hareketli z-skorları ile önceden işaretlenmiş anomali noktaları gösterge alınarak serilerdeki olağandışı davranışları tespit etmelerinin performansı ölçülmüştür. Performans ölçütleri olarak doğruluk ve kesinlik oranlarına odaklanılmıştır.

Günlük dolar kuru değişiminde anomalilerin tespitinde özellikle izole orman ve DVM algoritmalarının yüksek doğruluk ve kesinlik oranları ile daha başarılı performans gösterdikleri gözlemlenmiştir (bkz. Tablo 3.1).

Tablo 3.1: Günlük dolar kuru değişiminde anomali tespiti

	Doğruluk Oranı	Kesinlik Oranı
K-Ortalamlar	0.56	0.70
İzole Orman	0.68	0.81
DVM	0.63	0.83
Prophet	0.91	0.13

TÜFE’de anomalilerin tespitinde K-ortalamlar ve izole orman algoritmalarının daha yüksek doğruluk ve kesinlik oranları ile performans gösterdikleri gözlemlenmiştir (bkz. Tablo 3.2).

Tablo 3.2: TÜFE’de anomali tespiti

	Doğruluk Oranı	Kesinlik Oranı
K-Ortalamlar	0.61	0.67
İzole Orman	0.64	0.57
DVM	0.86	0.05
Prophet	0.89	0.05

3.9. Sonuç ve Tartışma

Sensörlerden yaratılan verilerin, web sitelerinin anlık olarak yarattığı verilerin, endüstriyel alanda yaratılan zamana bağlı büyük verilerin, finasta özellikle piyasalarda anlık olarak yaratılan verilerin, kullanıcılar ve ilgili verilere göre politika üretkenler açısından öngörülebilir seyirde izlenmesi gerekmektedir. Bununla birlikte tüm bu verilerde zamanla olağandışı durumlar, yükseliş ve düşüşler, kırılımlar gözlemlenebilmektedir. Özellikle gerçek zamanlı olarak yığın olarak akan zaman verilerinde gerçekleşen anomali davranışlarının, verinin olduğu anda ya da verinin olduğu an'a yakın bir zaman noktasında tespit edilebilmesi gerekmektedir.

Anlık olarak akan verilerde gerçek zamanlı anomali tespiti için geliştirilen algoritmaların, eğer öncesinde etiketlenmiş bir veriden anomali davranışlarını öğrenemediği durumlarda tek başına algoritmanın anomali davranışını işaretleyebilmesi gerekmektedir. Bununla birlikte ilgili çalışmalar yığın verilerde anomali tespiti için geliştirilen algoritmaların ölçeklenebilir olması gerektiğini de göstermiştir.

Bu çalışmada Türkiye'de günlük dolar kurun değişimleri ile TÜFE'de anomali tespiti için gözetimsiz öğrenme algoritmaları ile Prophet tahmin algoritmasının performansı karşılaştırılmıştır. Gözetimsiz öğrenme algoritmalarının daha iyi performans gösterdiği gözlenmiştir.

Burada değinilmemiş farklı gözetimsiz algoritmaları ile aynı serilerde başarılı anomali tespitinin gerçekleştirilebilmesi diğer çalışmalar için bir olanak olabilir. Bununla birlikte gözetimsiz öğrenme ile etiketlenmiş veriler, gelecek çalışmalarda daha geniş kapsamlı gözetimli öğrenme algoritmaları geliştirmeye imkan sağlayabilir. Buradan da, ekonominin anlık olarak izlenebildiği bir dünyada, hızlı bir şekilde olağandışı durumlar öngörülüp iktisadi karar birimleri tarafından önlemler alınabilir.

3.10. Kaynakça

Ahmad, Subutai, Alexander Lavin, Scott Purdy, Zuha Agha. 2017. Unsupervised real-time anomaly detection for streaming data. **Neurocomputing**. s.262: 134-147.

- Akoglu, Leman, Christos Faloutsos. 2010. Event detection in time series of mobile communication graphs. **27th Army Science Conference, 29 Kasım-2 Aralık 2010**. Florida: ABD: 2.
- Akouemo, Hermine N., Richard J. Povinelli. 2016. Probabilistic anomaly detection in natural gas time series data. **International Journal of Forecasting**. c.32. s.3: 948-956.
- Alloghani, Mohamed, Dhiya Al-Jumeily, Jamila Mustafina, Abir Hussain, Ahmed J. Aljaaf. 2020. A Systematic Review on Supervised and Unsupervised Machine Learning Algorithms for Data Science. **Unsupervised and Semi-Supervised Learning for Data Science**. ed. M. W. Berry, A. Mohamed ve B. W. Yap. İsviçre: Springer: 3-21
- Alpaydın, Ethem. 2012. **Yapay Öğrenme**. 2. bs. İstanbul: Boğaziçi Üniversitesi Yayınevi.
- Chou, Jui-Sheng., Abdi Telaga. 2014. Real-time detection of anomalous power consumption. **Renewable and Sustainable Energy Reviews**. s.33: 400-411.
- Dangeti, Pratap. 2017. **Statistics for Machine Learning**. 1. bs. Birmingham: Packt Publishing.
- Dasgupta, Ariruna, Asoke Nath. 2016. Classification of Machine Learning Algorithms. **International Journal of Innovative Research in Advanced Engineering**, c.3. s.3: 6-11.
- Ding, Zhigou, Minrui Fei. 2013. An Anomaly Detection Approach Based on Isolation Forest Algorithm for Streaming Data using Sliding Window. **IFAC Proceedings Volumes**. c.46. s.20: 12-17.
- Ferdousi, Zhing, Akira Maeda. 2006. Unsupervised Outlier Detection in Time Series Data. **22nd International Conference on Data Engineering Workshops (ICDEW'06)**. Atlanta, GA, ABD.
- Furey, Terrence S., Nello Cristianini, Nicole Duffy, David W. Bednarski, Michel Schummer, David Haussler. 2000. Support vector machine classification and validation of cancer tissue samples using microarray expression data. **Bioinformatics**. c.16. s.10: 906-914.
- Hastie, Trevor, Robert Tibshirani, Jerome Friedman. 2008. **The Elements of Statistical Learning**. 2. bs. İsviçre: Springer.
- Hu, Min, Xiaowei Feng, Shengchen Zhou, Wei Xu. 2019. Anomaly Detection in Time Series Data Based. **ATCI 2018**. İsviçre: Springer: 477-484
- Huang, Chengqiang, Geyong Min, Yulei Wu, Yiming Ying, Ke Pei, Zuochang Xiang. [01.06.2017]. Time Series Anomaly Detection for Trustworthy Services in Cloud Computing Systems, *IEEE Transactions on Big Data*. <https://ieeexplore.ieee.org/document/7937930>

- Li, Jinbo, Witold Pedrycz, Iqbal Jamal. 2017. Multivariate time series anomaly detection: A framework of Hidden Markov Models. **Applied Soft Computing**. s.60: 229-240.
- Li, Kun-Lun, Hou-Kuan Huang, Sheng-Feng Tian, Wei Xu. 2003. Improving one-class SVM for anomaly detection. **Proceedings of the 2003 International Conference on Machine Learning and Cybernetics**. Xi'an: 3077-3081.
- Liu, Fei Tony, Kai Ming Ting, Zhi-Hua Zhou. 2008. Isolation Forest. **2008 Eighth IEEE International Conference on Data Mining**. Pisa: 413-422.
- Malhotra , Pankaj, Lovekesh Vig, Gautam Shroff, Puneet Angarwal. 2015. Long short term memory networks for anomaly detection in time series. **23rd European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning Proceedings**. Bruges, Belçika: 89-100.
- Munir, Mohsin, Shoaib A. Siddiqui, Andreas Dengel, Sheraz Ahmed. 2019. DeepAnT: A Deep Learning Approach for Unsupervised Anomaly Detection in Time Series. **IEEE Access**. s.7: 1991-2005.
- Pavlidis, Paul, Ilan Wapinski, William S. Noble. 2004. Support vector machine classification on the web. **Bioinformatics**, c.20. s.4: 586–587.
- Qiu, Huida, Yan Liu, Niranjana Subrahmanya, Weichang Li. 2012. Granger Causality for Time-Series Anomaly Detection. **2012 IEEE 12th International Conference on Data Mining**. Brüksel: 1074-1079.
- Salvador, Stan, Philip Chan. 2005. Learning States and Rules for Detecting Anomalies in Time Series. **Applied Intelligence**. s.23: 241-255.
- Shipmon, Dominique T., Jason M. Gurevitch, Paolo M. Piselli, Stephen T. Edwards. [11.08.2017]. Time Series Anomaly Detection; Detection of anomalous drops with limited features and sparse examples in noisy highly periodic data. <https://arxiv.org/abs/1708.03665>
- Siffer, Alban, Pierre-Alain Fouque, Alexandre Termier, Christine Largouet. 2017. Anomaly Detection in Streams with Extreme Value Theory. **Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD '17)**. New York, ABD: Association for Computing Machinery: 1067–1075
- Taylor, Seen J., Benjamin Letham. [01.01.2020]. Forecasting at scale. <https://doi.org/10.7287/peerj.preprints.3190v2>
- Viswanathan, Krishnamurthy, Lakshminarayan Choudur, Vanish Talwar, Chengwei Wang, Greg Macdonald, Wade Satterfield. 2012. Ranking Anomalies in Data Centers. **IEEE Network Operations and Management Symposium**. Maui, HI: 79-87.
- Wang, Yanxin, Johnny Wong, Andrew S. Miner. 2004. Anomaly intrusion detection using one class SVM. **Proceedings from the Fifth Annual IEEE SMC Information Assurance Workshop**. West Point, NY: 358-364.

- Wei, Li, Kumar, Nitin Kumar, Venkata Lolla, Eamonn Keogh, Stefano Lonardi, Chotirat A. Ratanamahatana. 2005. Assumption-Free Anomaly Detection in Time Series. **SSDBM**. s.5: 237-242.
- Xu, Haowen, Wenxiao Chen, Nengwen Zhao, Zeyan Li, Jiahao Bu, Zhihan Li, Ying Liu, Youjian Zhao, Dan Pei, Yang Feng, Jie Chen, Zhaogang Wang, Honglin Qiao. 2018. Unsupervised Anomaly Detection via Variational Auto-Encoder for Seasonal KPIs in Web Applications. **WWW '18: Proceedings of the 2018 World Wide Web Conference**. Lyon, Fransa: 187-196.
- Zhu, Xiaojin, Andrew B. Goldberg. 2009. Introduction to Semi-Supervised Learning. **Synthesis Lectures on Artificial Intelligence and Machine Learning**. c.3. s.1: 1-130.



4. OTOMATİKLEŞTİRİLMİŞ YAPAY ÖĞRENME VE MODEL AÇIKLANABİLİRLİĞİ: İKTİSADİ BİR UYGULAMA

4.1. Giriş

Yapay öğrenme algoritmalarının sayısı, gerek gözetimli öğrenme yöntemlerinde olsun, gerek gözetimsiz öğrenme yöntemlerinde olsun uygulayıcılar için gittikçe artmaktadır. Uygulayıcılar ve modelleme üzerinde çalışan geliştiriciler ilgilendikleri problem için en uygun algoritmayı seçmek için çok sayıdaki algoritmayı kısıtlı bir sürede seçmek durumunda kalmaktadırlar. Seçilen en iyi algoritma ve algoritmanın hiperparametreleri ilgilenilen problemde belli bir anda iyi sonuçlar verse de, koşullar ve verideki gözlemlerin dağılımı değiştiğinde zamanla güncellenmesi ve gerektiğinde yeniden bir algoritma seçim sürecine gidilmesi gerekebilmektedir.

Son yıllarda gerek bilgisayar teknolojisinin gelişimi, gerek yapay öğrenme yazılım altyapısının erişilebilirliğinde artış olsun, çeşitli faktörlerle birçok farklı algoritma arasından veriye en uygun algoritmanın seçilmesi, ham veri içinde yeni değişkenlerin yaratılması ve verinin temizlenmesi gibi süreçler otomatikleştirilmiş yapay öğrenme yaklaşımı ile çözülebilmekte, zaman tasarrufu yaratabilmektedir. Algoritmanın seçilmesinin yanında bir diğer problem de karakutu olarak ifade edilen yapay öğrenme algoritmalarının sonuçlarının tıpkı doğrusal regresyon modeli gibi açık ve yorumlanabilir olması da başka bir ihtiyacı doğurmuştur. Bu problem için de son yıllarda açıklanabilir yapay öğrenme ve daha genel olarak açıklanabilir yapay zeka çalışma konuları ortaya çıkmıştır.

Bu çalışmada Türkiye için aylık bileşik öncü gösterge endeksi 2000-01:2020-05 dönemi için 47 değişken ile otomatikleştirilmiş yapay öğrenme süreci ile en uygun algoritma seçilerek modellenmiş, modelin tahminleri ve modelin işleyişi açıklanabilir yapay öğrenme araçlarıyla açıklanarak iktisadi açıdan yorumlanmıştır.

Bu kapsamda çalışmada ilk olarak otomatikleştirilmiş yapay öğrenme kavramı ve literatürdeki yaklaşımlar ele alınmaktadır. İkinci olarak yapay öğrenme algoritmaları için açıklanabilirlik ve ilgili literatür tartışılmaktadır. Üçüncü olarak

otomatikleştirilmiş yapay öğrenme çerçevesinde aylık bileşik öncü göstergeler endeksi için uygun model oluşturulmakta ve çıktılar model açıklama araçlarıyla iktisadi açıdan tartışılmaktadır. Son olarak, otomatikleştirilmiş yapay öğrenme ve model açıklanabilirliği yaklaşımları çalışma özelinden iktisadi katkıları bağlamında tartışılmaktadır.

4.2. Otomatikleştirilmiş Yapay Öğrenme

Son yıllarda, yapay zeka ve yapay öğrenme gibi uygulamalar ve teknolojiler, çeşitli iş alanlarında ve araştırma alanlarında önemli ölçüde benimsenmiştir. Özellikle yapay öğrenmedeki gelişmeler ve yaygınlaşma, sağlık hizmetleri, finansal hizmetler ve perakende hizmetleri gibi iş alanlarını dönüştürmeye devam etmektedir.

Her bir sektör özelinde ve araştırma alanında yapay öğrenme uygulamaları, ihtiyaca özel problemleri çözmeyi hedeflemektedir. Bununla birlikte, sektörler arasında veri işleme ve modelleme aşamalarının genel olarak bir standarda uyduğu söylenebilir. Genel olarak uçtan uca veri işleme projelerinde günümüzde sıklıkla uyulan süreçlerden biri Veri Madenciliği için Sektörler Arası Standart Süreç (VM-SASS) metodolojisidir (Wirth, Hipp, 2000). Bir veri işleme projesini tasarlamak altı adımdan oluşmakta ve geliştiricilerin ihtiyaçlarına göre döngü yinelemelerine sahip olabilir. Bu adımlar iş anlayışı, veriyi anlama, veri hazırlama, modelleme, değerlendirme ve dağıtımdır. Otomatikleştirilmiş yapay öğrenme süreci de tıpkı VM-SASS süreci gibi, bu sürecin teknik bir kısmını standart hale getirmektedir. Otomatikleştirilmiş yapay öğrenmede standart hale getirilen süreç genel olarak veri hazırlığı ve yapay öğrenme algoritmalarının çalışıldığı, seçildiği ve optimize edildiği döngülerdir. Böyle bir süreç de, veri ön işleme, öznitelik mühendisliği, veri çıkarma ve seçim gibi alanlarda özel uzmanlık gerektiren birkaç adımı içermektedir. Sadece bu değil, yapay öğrenme uzmanlarının da doğru algoritmayı seçmesi ve doğruluğunu en üst düzeye çıkarmak için hiperparametrelerde optimizasyon görevlerini gerçekleştirilmesi gerekmektedir.

Otomatikleştirilmiş yapay öğrenme, yapay öğrenme algoritmalarını teknoloji dışı uzmanlar için kullanılabilir hale getirmenin yanı sıra yapay öğrenmenin verimliliğini artırmak ve bununla ilgili araştırmaları hızlandırmak için de geliştirilmektedir. Bunun yanında otomatikleştirilmiş yapay öğrenme tüm model hazırlama sürecini otomatikleştirebilmektedir; çok yönlü endüstrilere uygulanabilen akıllı model

seçimini kullanabilmektedir; modeller için hiperparametre optimizasyonu süreçlerini kısaltabilmekte ve model seçimi sürecini hızlandırabilmektedir.

Otomatikleştirilmiş yapay öğrenme çalışmaları ve bu alanda geliştirilmiş yazılımlar genel olarak otomatikleştirilen yapay öğrenme sürecine (değişken seçimi, model seçimi, algoritma seçimi, yapay sinir ağı mimarisi oluşturma) ve içerdiği tekniklere göre (optimizasyon yöntemi, model seçimindeki performans teknikleri, öğrenme yaklaşımları) sınıflandırılabilir (Yao ve diğ., 2019). Genel olarak, günümüzde de sıklıkla yapay öğrenme süreçlerinde kullanılan otomatikleştirilmiş yapay öğrenme çerçeveleri arasında Auto-Weka (Kotthoff ve diğ., 2017), Auto-Sklearn (Feurer ve diğ., 2015), TPOT (Olson ve diğ., 2016), Auto-ml (Parry, 2020), Auto-Keras (Jin ve diğ., 2019), MLjar (MLJAR, 2020), Datarobot (Datarobot Python Client, 2020) ve H2O-Automl (H2O-Automl, 2020) yer almaktadır.

4.3. Model Açıklanabilirliği

Yapay öğrenme literatüründe son yıllarda sıkça tartışılan bir diğer alan, model açıklanabilirliği, açıklanabilir yapay öğrenme veya açıklanabilir yapay zeka olarak da adlandırılan olgudur. Bu, aynı zamanda bu çalışmadaki uygulamanın üzerinde durduğu bir diğer konudur. Açıklanabilir yapay zeka, bir yapay öğrenme modelinin tahminlerini anlamak için süreç olarak özetlenebilir. Buradaki temel fikir, modeli olabildiğince yorumlanabilir kılmaktır; bu, esasen girdi değişkenlerin güvenilirliğini ve nedenselliğini test etmeye yardımcı olacaktır.

Genel olarak, açıklanabilir yapay zeka sistemleri, model girdi değişkenlerinin bir değerlendirmesini sağlamakta ve modelin itici gücü olan değişkenleri tanımlamaktadır. Daha sonra bu modellerin tahminlerine güvenip güvenmemeye karar vermede bir kontrol olanağı vermektedir.

Model açıklanabilirliğiyle ilgili yöntemler farklı açılardan gruplanabilmektedir (Molnar, 2020). İlgili kıstaslardan birisi model açıklanabilirliğinin içsel ya da model sonrası (post hoc) olmasıdır. Bu kriter, açıklanabilirliğin yapay öğrenme modelinin karmaşıklığını (içsel) kısıtlayarak mı yoksa algoritmanın eğitiminden sonra modeli analiz eden yöntemler (post hoc) uygulayarak mı elde edildiğini ayırt etmektedir. Bir diğer kıstas, modele özgü olma ya da modelden bağımsız olma biçimindedir. Modele özgü yorumlama yaklaşımı, belirli model sınıflarıyla sınırlıdır. Modelden bağımsız

yorumlama yaklaşımı herhangi bir yapay öğrenme modelinde kullanılabilir ve model eğitildikten sonra uygulanmaktadır (post hoc). Bir başka kıstas ise açıklanma yönteminin bireysel bir tahminin yorumlanmasına ya da bir bütün olarak modelin davranışıyla ilgili olmaya dayanmaktadır.

Doğrusal regresyon modelleri, lojistik regresyon modelleri, genelleştirilmiş doğrusal regresyon modelleri, karar ağaçları ve karar kuralları gibi modeller türettikleri çıktılarının yorumlanabilmesi açısından içsel olarak açıklanabilirlik sağlamaktadırlar. Modelden bağımsız yöntemler ise son yıllarda geliştirilen yöntemlerden oluşmaktadır. Kısmi bağımlılık grafiği (partial dependency plot), bir veya iki girdi değişkeninin bir yapay öğrenme modelinin tahmin edilen sonucu üzerindeki marjinal etkisini göstermektedir (Zhao, Hastie, 2017). Bireysel koşullu beklenti (individual conditional expectation) grafikleri, bir girdi değişkeni değiştiğinde tahmininin nasıl değiştiğini gösteren, veri gözlem noktası başına bir satır göstermektedir (Goldstein ve diğerleri, 2014). Birikimli yerel etkiler grafiği, girdi değişkenlerinin ortalama olarak bir yapay öğrenme modelinin tahminlerini nasıl etkilediğini açıklamaktadır (Apley, Zhu, 2019). Permütasyon değişken önemi yöntemi, değişken değerlerini değiştirdikten sonra modelin tahmin hatasındaki artışı ölçmektedir, ki bu, değişken ile gerçek sonuç arasındaki ilişkiyi bozmaktadır (Breiman, 2001). Yerel yorumlanabilir model bağımsız açıklamalar (local interpretable model-agnostic explanations-LIME) tahmin edilen gözlemler etrafında yerel olarak yorumlanabilir bir modeli öğrenerek, herhangi bir sınıflandırıcının tahminlerini yorumlanabilir ve tutarlı bir şekilde açıklayan yeni bir açıklama tekniğidir (Riberio ve diğ., 2016). Shapley toplamsal açıklama (Shapley additive explanations-SHAP) değerleri, global ve yerel düzeylerde açıklanabilirlik sunarak model şeffaflığını artırmaktadır (Lundberg, Lee, 2017). Global olarak, her bir değişkenin hedef değişkene olumlu ya da olumsuz ne kadar katkıda bulunduğunu tahmin etmektedirler. Yerel olarak ise, belirli bir gözlemin neden bir sınıfa ait olarak atandığını ve değişkenlerin katkılarını açıklamaktadırlar.

4.4. İktisadi Bir Uygulama: Bileşik Öncü Göstergeler

Bileşik öncü göstergeler (composite leading indicators), iktisadi faaliyetin uzun dönemli potansiyel seviyesi etrafında dalgalanmasını gösteren iş döngülerindeki dönüm noktalarının erken sinyallerini sağlamak için tasarlanmıştır (OECD, 2020).

Bu çalışmada bir hedef değişken olarak bileşik öncü göstergeler baz alınarak, 47 makro iktisadi değişken ile bir yapay öğrenme modeli oluşturulmuştur. Çalışmada model aşaması, otomatikleştirilmiş yapay öğrenme sürecine dayanmaktadır. Çalışmada otomatikleştirilmiş yapay öğrenme süreci için H2O-Automl yazılım çerçevesi kullanılmıştır. Çalışmada, girdi değişkenler olarak iş güven endeksi (business confidence index), tüketici güven endeksi (consumer confidence index, BİST 30, BİST 50, BİST 100 endekslerinin kapanış fiyatları ile sektörlere ait endekslerin kapanış fiyatları, 1-2-3-5 ve 10 yıllık hazine tahvili fiyatları, enflasyon oranı, hisse fiyat endeksi (share price index), döviz kuru, tasfiye olunacak bireysel kartlar, tasfiye olunacak kurumsal kartlar, M1 para arzı, M2 para arzı, M3 para arzı, repo, imalat sanayi kapasite kullanım oranı, sanayi üretim endeksi, işsizlik oranı ve zaman değişkeni olarak da aylar modele dahil edilmiştir. Değişkenler Ocak 2000 ile Mayıs 2020 dönemi için aylık olarak düzenlenmiştir. Veri setinde, son beş aylık dönem test verisi olarak ayrılmış, seçilen algoritma ile nihai model oluşturulup test dönemi için tahminler gerçekleştirilmiştir.

En iyi algoritma seçim aşaması otomatikleştirilmiş, algoritma seçim süreci için 120 saniye parametresi ile maksimum 20 model parametresi kısıt olarak eklenmiştir. Bu süreç sonucunda yirmi beş farklı algoritma farklı hiperparametre kombinasyonları altında eğitim verisi üzerinde eğitilmiş, yirmiiç farklı model ortalama kare hata (OKH) ve ortalama mutlak hata (OMH) ölçütlerine göre sıralanmıştır (bkz. Tablo 4.1). Algoritma seçimi sonucunda en düşük OKH ve OMH ölçütlerine sahip olan ve model hiperparametreleri ayarlanmış eğitim hızlandırma makinesi (gradient boosting machine-GBM) algoritması en iyi model olarak gözlemlenmiştir. GBM ile eğitim verisi üzerindeki tahminlerde 0.54 ortalama kare hata, 0.45 ortalama mutlak hata gerçekleştiği gözlemlenmiştir.

Tablo 4.1: H2O-Automl algoritma seçim çıktısı

Model	OKH	OMH
GBM_grid_1_AutoML	0.5485	0.4524
GBM_1_AutoML	0.5855	0.4759
GBM_grid_1_AutoML_model_6	0.6053	0.4917
XRT_1_AutoML	0.6223	0.5035

GBM_4_AutoML	0.6361	0.5071
GBM_2_AutoML	0.6537	0.5082
GBM_grid 1_AutoML_model_3	0.6614	0.5497
GBM_3_AutoML	0.6683	0.4935
DRF_1_AutoML	0.7085	0.5331
GBM_grid 1_AutoML_model_1	0.7264	0.5626
GBM_grid 1_AutoML_model_4	0.7570	0.5419
DeepLearning_grid 1_AutoML_model_1	1.5832	0.7841
GBM_grid 1_AutoML_model_5	1.7614	0.8688
DeepLearning_grid 2_AutoML_model_1	1.8064	0.8257
GLM_1_AutoML	2.3461	0.9780
DeepLearning_grid 3_AutoML_model_1	2.4400	0.9712
DeepLearning_1_AutoML	3.0364	1.1722
StackedEnsemble_BestOfFamily_AutoML	4.4208	1.4131
StackedEnsemble_All_Models_AutoML	4.7376	1.4680
DeepLearning_grid 1_AutoML_model_2	6.3988	1.9081
DeepLearning_grid 3_AutoML_model_2	10.1522	2.5366
DeepLearning_grid 2_AutoML_model_2	20.6184	3.7125

Seçilen algoritma ile nihai model oluşturulmuş ve test verisi için de tahminler üretilmiştir. Son beş aylık dönem için yapılan tahminler incelendiğinde (bkz. Tablo 4.2) ilk üç aylık dönem için yapılan tahminler, gerçek değerlere oldukça yakın olarak gözlemlenmiş, son iki aylık tahminlerdeki sapma yüksek gözlemlenmiştir.


Tablo 4.2: Nihai Model Tahminleri ve Gerçek Değerler

Tarih	CLI	Tahmin
2020-01	101.26	101.56
2020-02	100.92	101.81
2020-03	100.40	100.53
2020-04	79.62	100.09
2020-05	95.00	100.52

Tablo 4.2'deki tahmin ve gerek deęerler iin OKH lt 90.0636 olarak hesaplanmıřtır. Bu deęerin, son iki aylık tahminlerdeki yksek sapmadan kaynaklandığı belirtilebilir. İlk  aylık OKH lt 0.3016 olarak hesaplanmıřtır. Bu da eęitim veri setinde eęitilen modelin OKH lt ile tutarlıdır denilebilir.


Modelin tahminleri kadar, hem model dzeyinde hem de deęiřken dzeyinde tahminlerin nasıl gerekleřtięi ile ilgili gzlemler de nemlidir. Bunun iin model iin kullanılan H2O-Automl yazılım erevesi ile model aıklamaları tretilmiřtir.

İlk olarak modelle ilgili artık analizi gerekleřtirilmiřtir (bkz. řekil 4.1). Artık analizi, bir test veri setindeki tahmin edilmiř deęerleri ve kalıntıları karřılařtırmaktadır. İdeal bir model ıktısı olarak, kalıntılar rastgele daęılmalıdır. Bu grafikteki desenler, model seimiyle ilgili olası sorunları gsterebilir. Model sonucu elde edilen grafik, hataların rastgele olarak daęıldığını gstermektedir.



řekil 4.1: Model tahminleri iin artık analizi


Modelle ilgili ikinci bir çıktı değişken önem grafiğidir. Değişken önem grafiği, modeldeki en önemli değişkenlerin göreceli önemini göstermektedir. Şekil 4.2'deki değişken önem grafiğinden de görülebileceği gibi, model tahminlerinde bileşik öncü göstergeler indeksi tahminlerinde sektörlerle ilgili aylık ortalama kapanış fiyatlarının oldukça önemli olarak gözlemlenmiştir. Sektörler için en önemli değişken olarak da tekstil sektörü gözlemlenmiştir. Sektörler dışında iş güven endeksi ile tüketici güven endeksinin de önemli değişkenler arasında yer aldığı gözlemlenmiştir.



Şekil 4.2: Değişken önem grafiği


Modelin açıklanması için üçüncü çıktı SHAP özet grafiğidir. SHAP özet grafiği, tahmin edilen her gözlem için değişkenlerin katkısını göstermektedir. Değişken katkılarının ve sapma (bias) teriminin toplamı, modelin ham tahminine, yani ters bağlantı fonksiyonunu uygulamadan önceki tahminine eşittir. Şekil 4.3'deki SHAP özet grafiğinden de görülebileceği gibi, önemli değişkenler arasında da yer alan iş güven endeksinin tahminler üzerinde oldukça negatif yönde bir etkisi gözlemlenmiştir. Tekstil, turizm, teknoloji ve enformasyon teknolojisi gibi sektörlerin aylık ortalama kapanış fiyatları ise tahminler üzerinde pozitif yönde etkide bulunduğu gözlemlenmiştir. Tüketici güven endeksinin de tahminler üzerinde negatif etkiye sahip olduğu görülmektedir. M2 para arzı, imalat sanayi kapasite kullanım oranı, 1 yıllık devlet tahvili aylık ortalama fiyatı ve dolar kuru

değişkenlerinin de benzer düzeyde ve negatif yönde etkide bulunduğu gözlemlenmiştir.



Şekil 4.3: Değişkenler için SHAP grafiği

Değişkenler bazında model açıklanabileceği gibi, değişkenlerin test verisindeki gözlem noktalarını tahminlerindeki etkileri de açıklanabilmektedir. Nihai modelin tahminlerinde düşük sapmalı Ocak ayı (bkz. Şekil 4.4a) ile yüksek sapmalı tahminin yapıldığı Nisan ayı (bkz. Şekil 4.4b) için ilgili tahminlerde hangi değişkenlerin ne yönde etkide bulunduğu da açıklanabilmektedir.



Şekil 4.4: Ocak ve Nisan ayı tahminleri

Ocak ayı tahmininde enformasyon teknolojileri, teknoloji, turizm ve tekstil gibi sektörlerin aylık ortalama kapanış fiyatlarının pozitif yönde; tüketici güven endeksi, imalat sanayi kapasite kullanım oranı, M2 para arzı, BIST 30 aylık ortalama kapanış fiyatı, iş güven endeksi ve dolar kuru gibi değişkenler ise negatif yönde etkide bulunmuştur. Tahminsel sapmanın yüksek olduğu Nisan ayı için Ocak ayı tahmininde pozitif yönde etkide bulunan değişkenlerin etkisinin görece daha zayıf olduğu, iş güven endeksinin ise baskın bir biçimde negatif yönde etkili olduğu gözlemlenmiştir.

4.5. Sonuç ve Tartışma

Bu çalışmada, son yıllarda yapay öğrenme literatüründe sıkça tartışılan otomatikleştirilmiş yapay öğrenme ve yapay öğrenme modellerinin açıklanabilirliğinin bir uygulaması olarak Türkiye için bileşik öncü göstergeler için bir modelleme ve model açıklama süreci gerçekleştirilmiştir. Yapay öğrenme algoritmalarının finasta ve iktisatta önemli bir kullanım amacı, büyük verinin işlenmesi ve tahminsel modellerin oluşturulması olmuştur. Böylece bir anlamda iktisat politikası ve iktisadi ajanlar açısından erken uyarı sistemi olabilecek uygulamaların da altyapısını oluşturmaktadır. Bu çerçevede, bileşik öncü göstergeler üzerine aylık periyotta 2000-01 ile 2020-05 dönemi için 47 makro iktisadi değişken ile model seçim süreci otomatikleştirilerek en düşük tahmin hatasına sahip model seçilmiş, ardından uygun model açıklama araçları ile model ve tahminler hem model hem de tahmin edilen gözlem düzeyinde açıklanmaya çalışılmıştır. Çalışmanın genel bir sonucu olarak Nisan ve Mayıs ayı için tahminlerde büyük bir sapma gözlemlense de Ocak, Şubat ve Mart ayları için tahminlerdeki sapma oldukça düşük olarak gözlemlenmiştir. 2020 yılı için Nisan ve Mayıs aylarının COVID-19 pandemisinden kaynaklı olarak olağanüstü bir dönemde yer almasından dolayı büyük tahminsel sapmaya yol açtığı söylenebilir. Bununla birlikte ileri bir çalışma için, 47 makro değişken yanında olağanüstü dönemler için de ağırlıklandırılmış ya da ham bir biçimde ek değişkenler de girdilere eklenerek bu dönemlerin de algoritmalar tarafından öğrenilmesi sağlanabilir. İleri çalışmalar için bir başka alternatif ise, aylık bazda derlenen verilerin, olanaklı olduğu ölçüde günlük ya da haftalık bazda derlenerek algoritmaların çok daha büyük boyutlu verilerden öğrenmesini sağlamak olabilir. Son olarak otomatikleştirilmiş yapay öğrenme süreci ile açıklanabilir yapay

öğrenme araçları birlikte, iktisat politikası yapımcıları tarafından uygun bir erken uyarı sistemi aracı olarak kullanılabilir, gerekli olağandışı değişkenler gözlemlendiğinde ilgili alana hızlı bir şekilde müdahale edilerek önlemler alınabilir.

4.6. Kaynakça

- Apley, Daniel W., Jingyu Zhu. [19.08.2019]. Visualizing the Effects of Predictor Variables in Black Box Supervised Learning Models. <https://arxiv.org/pdf/1612.08468>
- Breiman, Leo. 2001. Random Forests. **Machine Learning**. s.45: 5-32.
- Datarobot Python Client. [29.10.2020]. Data Robot. <https://datarobot-public-api-client.readthedocs-hosted.com/en/v2.22.1/>
- Feurer, Matthias, Aaron Klein, Katharina Eggenberger, Jost Springenberg, Manuel Blum, Frank Hutter. 2015. Efficient and robust automated machine learning. **Advances in Neural Information Processing Systems**. s.28: 2962-2970.
- Goldstein, Alex, Adam Kapelner, Justin Bleich, Emil Pitkin. [20.03.2014]. Peeking Inside the Black Box: Visualizing Statistical Learning with Plots of Individual Conditional Expectation. <https://arxiv.org/abs/1309.6392>
- H2O-Automl. [29.10.2020]. Github. <https://github.com/h2oai/h2o-3>
- Jin, Haifeng, Qingquan Song, Xia Hu. 2019. Auto-Keras: An Efficient Neural Architecture Search System. **KDD '19: Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining**. New York: ACM: 1946-1956.
- Kotthoff, Lars, Chris Thornton, Holger H. Hoos, Frank Hutter, Kevin Leyton-Brown. 2017. Auto-weka 2.0: Automatic model selection and hyperparameter. **The Journal of Machine Learning Research**. c.18. s.1: 826-830.
- Lundberg, Scott. Su-In Lee. 2017. A unified approach to interpreting model predictions. **Advances in neural information processing systems**. Long Beach, CA: 4765-4774.
- MLJAR. [29.10.2020]. Github. <https://github.com/mljar/mljar-api-python>
- Molnar, Christoph. (2020, Kasım 2). *Interpretable Machine Learning*. github.io: <https://christophm.github.io/interpretable-ml-book/> adresinden alındı
- OECD. [02.11.2020]. Composite leading indicator (CLI). doi:doi:10.1787/4a174487-en
- Olson, Randal S., Nathan Bartley, Ryan J. Urbanowicz, Jason H. Moore. 2016. Evaluation of a tree-based pipeline optimization tool for automating data science. **Proceedings of the Genetic and Evolutionary Computation Conference**. New York: ACM: 485-492.

- Parry, Preston. [29.10.2020]. Auto-ml: Automated machine learning for production and analytics. https://github.com/ClimbsRocks/auto_ml
- Riberio, Marco T., Sameer Singh, Carlos Guestrin. [09.08.2016]. "Why Should I Trust You?": Explaining the Predictions of Any Classifier. <https://arxiv.org/abs/1602.04938>
- Wirth, Rüdiger, Jochen Hipp. 2000. CRISP-DM: Towards a Standard Process Model for Data Mining. **Proceedings of the 4th international conference on the practical applications of knowledge discovery and data mining**. Londra, İngiltere: Springer-Verlag: 29-39.
- Yao, Quanming, Mengshuo Wang, Yuqiang Chen, Wenyuan Dai, Yu-Feng Li, Wei-Wei Tu, Qiang Yang, Yang Yu. [16.10.2019]. Taking the Human out of Learning Applications: A Survey on Automated Machine Learning. arXiv:1810.13306: <https://arxiv.org/abs/1810.13306>.
- Zhao, Qingyuan, Trevor Hastie. 2017. Causal interpretations of black-box models. **Journal of Business & Economic Statistics**. c. 39. s. 1: 272-281.