



DEMİR CEVHERİ FİYATLARININ MODELLENMESİ VE TAHMİNİ

UMUTCAN YALÇIN

MAYIS 2025

ÇANKAYA ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

VERİ ANALİTİĞİ ANABİLİM DALI
VERİ ANALİTİĞİ YÜKSEK LİSANS TEZİ

DEMİR CEVHERİ FİYATLARININ MODELLENMESİ VE TAHMİNİ

UMUTCAN YALÇIN

MAYIS 2025

ÖZET

DEMİR CEVHERİ FİYATLARININ MODELLENMESİ VE TAHMİNİ

YALÇIN, UMUTCAN

VERİ ANALİTİĞİ YÜKSEK LİSANS TEZİ

Danışman: Prof. Dr. İbrahim ÖZKAN

Mayıs 2025, 65 sayfa

Çalışmada demir cevheri fiyatlarını etkileyen faktörler analiz edilmiştir ve demir cevheri tek değişken olarak kullanılarak haftalık fiyat tahmin modelleri oluşturulmuştur. Fiyatlar, ETS, ARIMA, XGBoosting modelleri ve bu modellerin kombine edilmesi ile elde edilen melez bir model (*forecast combination*) kullanılmıştır. Model parametrelerinin tahminleri, model çıktıları ve öngörüler R programı kullanılarak elde edilmiştir. Çalışma sonunda kullanılan modeller karşılaştırılmış ve model başarıları tartışılmıştır. Çalışmanın sonuçları incelendiğinde kukla değişkenler kullanılarak çalıştırılan XGBoosting modeli diğer modellere nazaran daha güçlü sonuçlar sunmuştur.

Anahtar Kelimeler: Demir cevheri, Fiyat tahmini, Tahmin modelleri, ETS, ARIMA, XGBoosting

ABSTRACT

MODELLING AND FORECASTING IRON ORE PRICES

YALCIN, UMUTCAN

DATA ANALYTICS MASTER'S THESIS

Supervisor: Prof. Dr. Ibrahim Ozkan

May 2025, 65 pages

In this study, the factors affecting iron ore prices are analyzed, and price forecasting models are developed using iron ore as a univariate time series. For forecasting, ETS, ARIMA, XGBoosting, and a hybrid model combining these approaches are utilized. All models are constructed and implemented within the R environment, and their outputs are derived through R. At the end of the study, the models are compared, and their predictive performances are critically evaluated. The XGBoosting model has delivered stronger results compared to the other models.

Keywords: Iron ore, Price forecasting, Forecasting models, ETS, ARIMA, XGBoosting

TEŞEKKÜR

Sadece tez çalışması süresince değil, hayatım boyunca bana koşulsuz destek, sevgi ve sabır gösteren kıymetli aileme; hayatımda en büyük motivasyon ve huzuru sağlayan, varlığı ile her an yanımda olan sevgili eşime; tez çalışmam boyunca bilgi ve tecrübeleri ile yolumu aydınlatan, değerli katkıları ile tez çalışmama yön veren saygıdeğer tez danışmanım Prof. Dr. İbrahim Özkan'a; ayrıca beni yüksek lisans eğitimi konusunda yönlendiren değerli Kızılduman ailesine teşekkürlerimi sunarım. Tüm katkı sağlayanlara en derin saygı ve sevgilerimle...

İÇİNDEKİLER

TEZDE İNTİHAL OLMADIĞINA DAİR BEYAN SAYFASI	III
ÖZET.....	IV
ABSTRACT	V
TEŞEKKÜR.....	VI
TABLolar LİSTESİ.....	IX
ŞEKİLLER LİSTESİ.....	X
SİMGELER VE KISALTMALAR LİSTESİ.....	XI
BÖLÜM I	1
GİRİŞ: DEMİR CEVHERİ FİYATLARINI TAHMİN ETMENİN ÖNEMİ VE KAZANDIRDIKLARI	1
BÖLÜM II.....	3
DEMİR CEVHERİ FİYATLARINI ETKİLEYEN FAKTÖRLER VE TAHMİN MODELLERİ.....	3
2.1 DEMİR CEVHERİ FİYATLARINI ETKİLEYEN FAKTÖRLER	3
2.2 ZAMAN SERİSİ VE MAKİNE ÖĞRENMESİ TEMELLİ ÖNGÖRÜ YAKLAŞIMLARI.....	4
BÖLÜM III.....	7
DEMİR CEVHERİ FİYATLARI TAHMİNİNİN MODELLENMESİ.....	7
3.1 MODELLERDE KULLANILAN VERİ	7
3.2 ÜSTEL DÜZELTEME YÖNTEMLERİ İLE TAHMİN MODELLERİ.....	9
3.2.1 BASİT ÜSTEL DÜZELTME (SES)	10
3.2.2 TREND ÜSTEL DÜZELTME (TES)	11
3.2.3 DİĞER DENEMELER, METRİKLERİ VE MODEL KARŞILAŞTIRMALARI.....	13
3.3 ARIMA TAHMİN MODELLERİ	14
3.3.1 AUTOARIMA MODELİ	17
3.3.2 ARIMA (2,0,1) + (0,0,0) MODELİ.....	18

3.4	ARIMA VE ETS MODELLERİ ÜZERİNE ÇAPRAZ DOĞRULAMA VE MODELLERİN KARŞILAŞTIRILMASI	20
3.5	XGBOOSTING TAHMİN MODELİ	23
3.5.1	KUKLA DEĞİŞKENLER İLE XGBOOSTING MODELİ.....	23
3.5.2	FOURIER DÖNÜŞÜMÜ İLE XGBOOSTING MODELİ	25
3.5.3	KLASİK AYRIŞTIRMA İLE XGBOOSTING MODELİ.....	26
3.6	KOMBINE TAHMİN MODELİ	28
BÖLÜM IV		30
BULGULAR, SONUÇLAR VE KARŞILAŞTIRMALAR		30
KAYNAKÇA		32
EKLER.....		36

TABLÖLAR LİSTESİ

Tablo 1: SES Model Performans Metrikleri	11
Tablo 2: TES Model Performans Metrikleri	13
Tablo 3: Üstel Düzeltme Yöntemleri Performans Metrikleri.....	14
Tablo 4: AutoARIMA Model Parametreleri	18
Tablo 5: ARIMA(2,0,1) + (0,0,0) Model Parametreleri	20
Tablo 6: Çapraz Doğrulama Sonuçlarına Göre RMSE İstatistikleri	23
Tablo 7: Kukla Değişkenler ile XGBoosting Modeli Performans Metrikleri.....	25
Tablo 8: Fourier Dönüşümü ile XGBoosting Modeli Performans Metrikleri.....	26
Tablo 9: Klasik Ayrıştırma ile XGBoosting Modeli Performans Metrikleri	28
Tablo 10: Tüm Modeller için Hata Metrikleri	31

ŞEKİLLER LİSTESİ

Şekil 1: Demir Cevheri Fiyat Değişim Grafiği.....	8
Şekil 2: Demir Cevheri Mevsimsel Fiyat Değişim Grafiği	9
Şekil 3: Demir Cevheri Fiyat Tahmin Grafiği (SES)	10
Şekil 4: Demir Cevheri Fiyat Tahmin Grafiği (TES)	12
Şekil 5: ACF ve PACF Analizleri	17
Şekil 6: AutoARIMA ile 16 Haftalık Fiyat Tahmin Grafiği	18
Şekil 7: ARIMA(2,0,1) + (0,0,0) ile 16 Haftalık Fiyat Tahmin Grafiği.....	20
Şekil 8: ETS Modeli 1 ve 4 Adımlı Çapraz Doğrulama Sonuçları.....	22
Şekil 9: ARIMA Modeli 1 ve 4 Adımlı Çapraz Doğrulama Sonuçları	22
Şekil 10: Kukla Değişkenler ile 24 Hafta Ufuklu XGBoosting Model Tahmini	25
Şekil 11: Fourier Dönüşümü ile 24 Hafta Ufuklu XGBoosting Model Tahmini	26
Şekil 12: Fourier Dönüşümü ile Oluşturulan XGBoosting Model Tahmininin Gerçek Veri İle Karşılaştırılması	27
Şekil 13: Klasik Ayırıştırma İle 24 Hafta Ufuklu XGBoosting Model Tahmini.....	28
Şekil 14: Klasik Ayırıştırma ile Oluşturulan XGBoosting Model Tahmininin Gerçek Veri ile Karşılaştırılması	29
Şekil 15: Kombine Model ve Diğer Modellerin Fiyat Tahminleri Grafiği	30

SİMGELER VE KISALTMALAR LİSTESİ

Simgeler

R^2	: Belirleme Katsayısı
σ^2	: Hata Varyansı

Kısaltmalar

Vd.	: Ve diğerleri
ARIMA	: Otoregresif Entegre Hareketli Ortalama
ETS	: Üstel Düzeltme
METL	: Çoklu Üstel Trend Öğrenme
VAR	: Vektör Otoregresyon
SVR	: Destek Vektör Regresyonu
LSTM	: Uzun Kısa Süreli Bellek
GMDH	: Veri İşleme İçin Grup Yöntemi
CART	: Sınıflandırma ve Regresyon Ağaçları
VAF	: Açıklanan Varyans Oranı
ANN	: Yapay Sinir Ağı
CGOA	: Kaotik Oyun Optimizasyon Algoritması
AUD	: Avusturalya Doları
RMB	: Çin Yuanı
USD	: Amerikan Doları
HWES	: Holt-Winters Üstel Düzeltme
RMSE	: Karekök Ortalama Kare Hata
MAPE	: Ortalama Mutlak Yüzde Hata
MAE	: Ortalama Mutlak Hata
MASE	: Ortalama Ölçeklenmiş Hata
AIC	: Akaike Bilgi Kriteri
BIC	: Bayesyen Bilgi Kriteri

BÖLÜM I

GİRİŞ: DEMİR CEVHERİ FİYATLARINI TAHMİN ETMENİN ÖNEMİ VE KAZANDIRDIKLARI

Demir cevheri; günümüz dünyasında inşaat ve sanayi gibi modern endüstrilerin lokomotif hammaddelerinden biri haline gelmiştir. Tarih kitaplarında bahsi geçen çömlekler ve seramikler gibi, değerli ana metaller de modern dünyanın devrimcileri olmuşlardır [1]. Demir cevherinin meteoritik kullanımından, demiri çıkarıp işleyip kullandığımız bu günlere kadar değişmeyen tek şey bu ana metalin önemi olmuştur. Geçmişte silah, kap, araç gereç gibi ihtiyaçlar için kullanılan demir cevheri; günümüzde başta çelik üretimi olmak üzere akla gelebilecek her türlü üretimin içinde aktif olarak rol oynamaktadır. Bu doğası ile demir cevheri, inşaat sektörü ve altyapı projeleri için demir ve çelik maddelerinin yoğun kullanıldığı sektörler ve bu sektörlerin oluşturduğu ekonomi hacmi için stratejik öneme sahiptir.

Bahsedilen önem ve ekseriyetle çeliğin hayatımızdaki yeri sonucu demir cevheri piyasaları, hammaddenin fiyatı, arzı ve talebi milletler ve şirketler için önemi yadsınamaz bir ekonomik gösterge haline gelmiştir. Bu yüzden ki ekonomistler ve ilgili endüstri paydaşları için bu cevherin fiyat hareketleri oldukça ilgi çekici ve kritik bir araştırma sahası oluşturmıştır. Bu sahanın getirisi ve sahadaki gelişmeler ile piyasa yapıcılar, ilgili sektör paydaşları vd. piyasa dinamiklerini öngörebilmek ve çeşitli pozisyonlar alabilmek adına demir cevheri fiyat trend ve tahminlerine ihtiyaç duymaktadır.

Demir cevheri fiyatlarındaki volatilité; global ekonomik konjonktür, jeopolitik koşullar, arz ve talep dengesi döviz dalgalanmaları ve diğer emtiaların fiyat değişimleri gibi pek çok faktörden etkilenmektedir. Bu yüzden doğru tahmin modelleri oluşturmak risk yönetimi konusunda iyileştirmelerin yapılmasına yardımcı olmaktadır. İnşaat sektöründen yola çıkılacak olursa, demir cevheri fiyat tahminlerinin doğru modellenmesi, doğrudan inşaat demir ve çeliği stoklarının yönetimi konusunda iyileştirmelerin yapılması ve maliyet kontrolünün sağlanmasını mümkün kılmaktadır.

Son birkaç on yılda zaman serisi analizleri ve makine öğrenmesi yöntemlerinin eksponansiyel gelişme hızı katkısıyla da demir cevheri gibi emtiaların fiyat tahminleri yapılmaktadır. Bu çalışmanın da ana iskeletini oluşturacak olan *ARIMA*, *XGBoost*, *ETS* yöntemleri bu tahminlerin yapılması adına kullanılan model ve yöntemlerden yaygın olarak kullanılanların bir kısmıdır. Bu çalışmada demir cevheri fiyatlarının tahmin edilebilmesi için “Yüksek Kaliteli Demir Cevheri 62% Fe CFR Vadeli İşlemleri- (TIOc1)” [2] tarihsel verileri kullanılacaktır. *ARIMA*, *ETS* ve *XGBoosting* modelleri ve bu modellerin bir kombine hali ile tek değişkenli fiyat tahmin modelleri kurulacaktır. Bu modellerin performansları çeşitli ölçümler ile değerlendirilip elde edilen ampirik sonuçlar, bulgular ve sonuçlar bölümünde tartışılacaktır. Bu çalışmada modellerin oluşturulup sonuçlarının incelenmesi için R programı (Ek-1) ve R paketlerinden (Ek-2) yararlanılmıştır [3-19]. Bu amaçla kullanılan tüm R kodları ekler kısmında ve tüm R paketleri ve yöntemler kaynakça kısmında belirtilmiştir.

BÖLÜM II

DEMİR CEVHERİ FİYATLARINI ETKİLEYEN FAKTÖRLER VE TAHMİN MODELLERİ

Demir cevheri fiyatlarını etkileyen faktörler ve fiyatların tahminleri ve pek çok akademik çalışmaların odağında yer almıştır. Bu çalışmalarda genel olarak emtia fiyatına etki eden faktörlerin benzer olduğu ifade edilmektedir. Literatürde çok değişkenli modeller ve çeşitli etki faktörleri çalışılmış olsa da bu çalışmada tek değişkenli tahmin modeline odaklanılacak ve “Yüksek Kaliteli Demir Cevheri 62% Fe CFR Vadeli İşlemleri- (TIOc1)” [2] verilerinin öngörülleri üzerinde durulmuştur.

2.1 DEMİR CEVHERİ FİYATLARINI ETKİLEYEN FAKTÖRLER

Demir cevheri fiyatlarının dünya ekonomisi için ne kadar büyük ölçüde önem teşkil ettiği çalışmanın önceki bölümlerinde işlenmiştir. Fiyat dalgalanmaları tüketen ve üreten ülkeler dışında küresel olarak ticareti ve makroekonomik göstergeleri de etkilemektedir. Literatürde demir cevheri fiyatlarını etkileyen faktörler; arz ve talep dengesi, makroekonomik göstergeler, enerji üretimi ve fiyatları, döviz fiyat dalgalanmaları, nakliye ve lojistik fiyatları, jeopolitik konjonktürel durumlar ve piyasanın genel durumu olarak özetlenmiştir. Bunların yanında cevher kaynakları artan arz ile tükenmekte olup bu durum yatırım maliyetlerini artırmakta ve sektörde yapısal değişikliklere sebep olmaktadır [20]. Bu yapısal değişiklikler, sermaye getirisi beklentilerinin düşmesini sağlayıp demir cevheri fiyatları üzerinde baskı oluşturabilecek hale gelmiştir.

Cevher fiyatlarındaki değişimleri ve sebeplerini tartışırken odaklanılması gereken bir başka nokta da üretim döngüsü ve bu döngü içerisindeki üretim elemanlarıdır. Yapılan çalışmalar gösteriyor ki; demir cevheri hammadde kaynaklı çelik üretimi kapasitesinin demir cevheri fiyatları volatilitesi üzerinde anlamlı bir etkiye sahiptir [21]. Bunun yanında çelik ve hurda çelik fiyatları, bu üretimlerin neredeyse tamamında kullanılan petrolün fiyat değişimleri, nakliye için navlun ve

liman stok maliyetlerindeki deęişimlerin hızlı bir şekilde demir cevheri fiyatlarına yansıdığı gözlemlenmiştir.

Uzun yıllar boyunca üretici endekslerine baęlı fiyatlanan demir cevheri emtiası 2008 krizinden sonra spot fiyatlama sistemine geçerek önemli bir dönüşüm içine girmiştir [22]. Üretici endeksli fiyatlama volatilitiyi sınırlandırsa da şeffaflık ve verimlilik söz konusu olduğunda yetersiz kalmıştır. Spot fiyatlamaya geçiş demir cevheri fiyatlamalarını daha serbest hale getirmiştir. Bunun karşılığında ise fiyat volatilitesinde artışlar gözlemlenmiştir.

Söz konusu demir cevheri olduğunda Çin'in etkisi yadsınamaz durumdadır. Zira, emtia talebinin %60 kadarını Çin karşılamaktadır. Bu yüzden en büyük ithalatçı olarak Çin'in fiyatların belirlenmesinde oldukça büyük bir etkisi vardır [23]. Bu noktada Çin'deki üretimin sürdürülebilirliği ve çevre politikaları sonucu üretim kapasitesindeki deęişimlerin demir cevheri fiyatlarını doğrudan etkilediği ve fiyatlamada yapısal dönüşümlere sebep olabileceği gözlemlenmiştir.

2.2 ZAMAN SERİSİ VE MAKİNE ÖĞRENMESİ TEMELLİ ÖNGÖRÜ YAKLAŞIMLARI

Demir cevheri fiyat öngörü yaklaşımlarında yaygın olarak klasik zaman serisi modellerinden ARIMA ve ETS kullanılmaktadır [24]. Bu çalışmada da ARIMA, ETS, XGBoosting ve bu modellerin kombinasyonundan oluşan bir kombine model oluşturulup karşılaştırmaları yapılmıştır. Bu modellerin dışında literatürde çeşitli denemeler ve araştırmalar yapılmıştır. Bu araştırmalara örnek verilecek olursa; demir cevheri fiyatlarını tahmin etmek için son teknoloji çok aşamalı tandem öğrenme (METL) modeli kullanılmıştır. Önerilen METL modelinin, tek kademeli ve diğer kategorize edilmiş modellerinden yüksek oranda daha iyi performans gösterdiği gözlemlenmiştir [25]. Bunlar gibi pek çok denemeden hareketle, zaman serilerinde tahmin yapmak için temel olarak geleneksel zaman serisi tahmin modelleri ve makine öğrenmesi temelli modeller kullanılmaktadır. Klasik zaman serisi tahminlerinde sıklıkla, zaman serisi analizlerine dayalı ARIMA ve VAR modelleri, tahminlerde son verilere fazlalıkla ağırlık veren üstel düzeltme (ETS) modelleri ve ekonomik teorilere dayalı olarak arz talep, döviz kurları gibi deęişkenleri kullanan yapısal modeller kullanılır. Makine öğrenmesi temelli modellerde de doğrusal olmayan ilişkiler modellenebilir ve çeşitli veri kaynakları ile bütünleşmiş tahminler yapılabilir. Bu bağlamda destek vektör regresyonu (SVR), karar ağaçları, rastgele ormanlar, yapay

sinir ağırları (ANN) ve derin öğrenme modelleri (örneğin LSTM) gibi modeller ve algoritmalar kullanılır. Bu algoritmalar, ekonomik göstergeler, hava durumu verileri ve piyasa duyarlılığı gibi çeşitli veri türlerini kullanarak daha esnek ve veri odaklı tahminler yapabilirler [26]. Emtia fiyat tahminlerinde makine öğrenmesi temelli yöntemlerden XGBoosting için oldukça heyecan verici sonuçlar elde edilmiştir. XGBoost'un büyük ve karmaşık veri setleriyle başa çıkma konusundaki üstün yeteneği onu tercih edilen modellerden kılmaktadır. Özellikle çoklu girdi değişkenlerinin modele dahil edilmesiyle, yalnızca geçmiş fiyatlara dayalı klasik modellere kıyasla tahmin doğruluğunun önemli ölçüde arttığı gösterilmiştir. Model performansı iteratif testlerle değerlendirilmiş ve etken faktörlerin dahil edilmesinin model başarımını güçlendirdiği ortaya konmuştur [27]. 2024 yılının sonlarında yapılan bir çalışmada geleneksel istatistiksel modellerin, örneğin ARIMA, sınırlılıklarına karşın, XGBoost ve LSTM gibi makine öğrenimi algoritmalarının karmaşık ve doğrusal olmayan ilişkileri daha başarılı şekilde modelleyebildiğini gösterilmiştir. Ayrıca, melez (hibrit) modellerin ve dikkat mekanizmalarının tahmin doğruluğunu artırmada etkili olduğu vurgulanmıştır [28]. Demir cevheri fiyatları tahmini için bir GMDH (*Group Method of Data Handling*) algoritması da geliştirilmiştir. Bu model ANN, SVR, CART ve ARIMA modelleri ile karşılaştırılmıştır. Modellerin açıklama kapasitesi GMDH için %97,89, SVR için %90,81, ANN için %80,95, ARIMA için ise yalnızca %23,87 olarak hesaplanmıştır. Bu çalışma, klasik modellerin doğrusal olmayan fiyat yapısını açıklamada yetersiz kaldığını ortaya koymuştur [29]. GMDH modelinin VAF değerinin %97,89 gibi çok yüksek çıkması, modelin çok güçlü bir açıklama gücüne sahip olduğunu gösterse de bu durum aşırı öğrenme şüphesini doğurabilir. Bu durum özellikle de kullanılan test setinin küçük olduğu veya modele uygun şekilde ayrılmadığı durumlarda gözlemlenir. Diğer modellere kıyasla bu kadar yüksek bir başarı düzeyi varsa, modelin yapısı itibarıyla eğitime aşırı uyum gösterip, genellenebilirliğinin düşük olma ihtimali göz ardı edilmemelidir. Başka bir çalışmada kaotik çekirge optimizasyon algoritması (CGOA) kullanılmıştır. Çalışmada, modelin doğruluğu klasik NN, GA–NN, PSO–NN, GOA–NN ile karşılaştırılmış ve CGOA–NN'nin tüm modellerden daha yüksek performans gösterdiği belirlenmiştir. 1989–2018 dönemine ait aylık verilerle yapılan analizde, AUD ve RMB kuru, enflasyon oranları, altın, gümüş, bakır, hurda ve petrol fiyatları gibi ekonomik göstergeler girdi değişkeni olarak kullanılmıştır. Elde edilen sonuçlara göre, CGOA–NN modeli RMSE, MSE ve MAE gibi hata metriklerinde anlamlı iyileşme sağlamış ve istatistiksel

olarak gerek deęerlere en yakın tahminleri retmiřtir [30]. Tm bu alıřmaların yanında ETS modellerinde gemiř verilere dayalı tahminler de yapılıp dřk hatalar ile karřılařılmıř ve ETS modellerinin tahmin iin uygun modeller olduęu tespit edilmiřtir. 2024 yılında bu alıřmanın da konusu olacak benzer bir alıřma yapılmıřtır. Kumar'ın alıřmasına gre alep tahmini ve dinamik fiyatlandırma stratejilerinin etkinlięini artırmak amacıyla *Holt-Winters Exponential Smoothing* (HWES) ve ARIMA modellerini karřılařtırmalı olarak incelemektedir. Bu kapsamda geliřtirilen tahmin algoritmaları ve fiyatlandırma modeli, tedarik zinciri ynetimi ve maliyet optimizasyonu aısından nemli katkılar saęlamaktadır ve uygun tahmin sonuları sunmaktadır [31].

Modellerin kıyaslanması ve doęruluklarının llmesi sz konusu olduęunda genellikle RMSE, MAE, MAPE, MASE gibi performans metrikleri kullanılmaktadır. Yapılan alıřmalara gre klasik zaman serisi modelleri bu metrikler ile lldęnde kısa vadeli tahminlerde makul sonu ve performanslar gstermiřtir. Bunun yanında makine ęrenmesi temelli tahmin modelleri doęrusal olmayan iliřkilere sahip volatil fiyat rejimlerinde daha iyi sonular retmektedir.

BÖLÜM III


DEMİR CEVHERİ FİYATLARI TAHMİNİNİN MODELLENMESİ

3.1 MODELLERDE KULLANILAN VERİ

Çalışmada tek değişkenli modeller üzerinden bir uygulama işletileceği için modellerde kullanılacak veri sadece demir cevheri fiyatlarının türevlerinden olacaktır. Önceki başlıklarda da belirtildiği üzere çalışmada, Yüksek Kaliteli Demir Cevheri 62% Fe CFR Vadeli İşlemleri- (TIOc1)” [2] verisi kullanılmıştır. Bu tarihsel veri içinde içinden Ekim 2014 ile Ekim 2024 tarihleri arasındaki 10 yıllık fiyatlar çalışmada kullanılmıştır. Veri incelendiğinde mesai günleri dışında yani başka bir deyişle piyasanın kapalı olduğu günlerde eksik verilerin mevcudiyeti gözlemlenmiştir. Bu eksik verilerin tamamlanması çalışmanın başlangıcında ilerlenebilmesi adına zaruri olmuştur. Eksik verilerin tahmini için bazı adımlar atılmıştır. İlk olarak, tarihsel serinin başında ve sonunda mevcut eksik gözlemler veri setinden çıkarılmıştır. Bu işlemin ardından veri setinin içinde yer alan eksik gözlemler lineer enterpolasyon yaklaşımı ile doldurulmuştur. Lineer enterpolasyon yöntemi özellikle ekonomik veri içeren düzenli frekanstaki setlerde sıklıkla tercih edilen basit ama etkili bir yöntemdir. Bu yaklaşımda eksik veriler, kendinden önceki ve sonraki veriler arasındaki doğrusal ilişkiye göre tahmin edilmektedir. Bu yaklaşım sayesinde veriler zaman serisinin yapısı ve eğilimi bozulmadan yapay olarak tamamlanabilmektedir.

Veri setindeki eksik veriler tamamlandıktan sonra demir cevheri vadeli işlem fiyatları haftalık hale getirilmiştir. Aşağıda demir cevheri vadeli işlemleri için 2014 Ekim ile 2024 Ekim dönemleri arasındaki 10 yıllık periyot için haftalık fiyat değişimleri gösterilmiştir (Şekil 1).

Haftalık Demir Cevheri Fiyatları 2014 Ekim - 2024 Ekim




Kaynak: Investing / Iron ore fines 62% Fe CFR Futures - (TIOc1)

Şekil 1: Demir Cevheri Fiyat Değişim Grafiği

Şekil 1’ de görüldüğü gibi demir cevheri fiyatları 10 yıllık periyot içinde artan ve azalan pek çok dalgalanma dönemi geçirmiştir. 2015–2016 yıllarında fiyatlar düşüş eğilimi içerisinde 50 doların altına kadar düşmüştür. Bu dönemde küresel emtia fiyatlarında Çin ekonomisindeki yavaşlama sebepli genel bir düşüş gözlemlenmiştir. Fiyatlar, 2016–2020 yavaşça artarak 120 dolar seviyesine kadar ulaşmış ve trend ortalamasına geri dönmüştür. Bu dönemde küresel dengeli büyüme ile istikrarlı bir bant aralığında genel olarak yükselen bir seyre sahip olmuştur. COVID-19 pandemi döneminin başlangıcı olan 2020 yılı sonrası emtia fiyatının sert yükselerek 2021 yılında 220 doları aşarak zirve yapmıştır. 2022–2023 yıllarında küresel enflasyonun artması ile fiyatlarda sert dalgalanmalar yaşanmıştır [32]. 2024’te ise fiyatlar 100–140 dolar aralığında görece dengeli bir dalgalanma göstermiştir. Genel olarak, grafik demir cevheri piyasasının küresel gelişmelere duyarlı ve oldukça dalgalı bir yapıya sahip olduğunu ortaya koymaktadır.

Fiyat dalgalanmalarının senelere göre değişimleri yanı sıra yıl içindeki mevsimsel etkilere göre de değişip değişmediği kontrol edilmesi gerekir. Mevsimsel değişimin gösterildiği mevsimsellik grafiği (Şekil 2) aşağıda gösterilmiştir. Fiyat serilerinin bir mevsimsellik içermediği grafikten görülmektedir. Bu açıdan, çalışmada

kullanılan tahmin modellerinde mevsimsellik olmadığı varsayılacaktır.




Şekil 2: Demir Cevheri Mevsimsel Fiyat Değişim Grafiği

3.2 ÜSTEL DÜZELTEME YÖNTEMLERİ İLE TAHMİN MODELLERİ

Üstel düzeltme yöntemleri zaman serilerinde sıklıkla başvurulmuş tahmin yöntemlerindendir. Genel olarak geçmiş gözlemlere farklı ağırlıklar atayarak gelecekteki değerleri tahmin etmeyi amaçlamaktadır. Son gözlemler daha ağırlıklı olacak şekilde geçmiş gözlemlerin çok daha az ağırlıkta etki etmesi prensibi ile çalışmaktadır (Bağcı, 2020). ETS modeli, hata (E), trend (T) ve mevsimsellik (S) bileşenlerini içeren yapıdadır. Model bileşenleri; toplamsal (A), çarpımsal (M) veya bileşenin olmadığını ifade eden *yok* (N) olarak tanımlanabilir. Üstel düzeltme yöntemleri temel olarak üç başlık ve yöntemde kullanılmaktadır. Bu çalışmada da bu başlıklar kullanılarak tahmin modelleri oluşturulmuştur.

3.2.1 Basit Üstel Düzeltme (SES)

Basit üstel düzeltme yöntemi genel olarak verinin durağan olduğu, trend ve mevsimsellik içermediği durumlarda kullanılan bir tahmin yöntemidir. Bu durum başka bir deyiş ile $ETS(A, N, N)$ şeklinde sembolize edilebilir. Çalışmada bu yöntem ile bir model oluşturulmuştur. Bu model kullanılarak yapılan tahmin ve model performansını ölçmek için kullanılacak metrikler aşağıdaki gibi açıklanmıştır.



Şekil 3: Demir Cevheri Fiyat Tahmin Grafiği (SES)

Şekil 3'te gösterilen grafikte demir cevheri fiyatlarının tahmin grafiği gösterilmiştir. Grafikte gerçek fiyatlar (siyah çizgi) ve model tahminleri (turuncu çizgi) gösterilmiştir. Ayrıca tahminler %80 ve %90 seviyesinde güven aralıklarını gösteren koyu ve açık mavi bantlar ile desteklenmiştir. SES modeli, veri setinin geçmiş bölümlerinde oldukça başarılı olarak gerçek fiyatlara yakın tahminler üretmiştir. Özellikle trend veya mevsimsellik içermeyen dönemlerde modelin performansı güçlüdür. Model 5 adımlı tahmin yapacak şekilde ayarlanmıştır yani 5 hafta sonrası tahmin etmektedir. Bahsedilen koyu ve açık mavi bantların adımlar ilerlediğinde açıldığı gözlemlenmiştir. Bu durum ufuk ilerledikçe modelin performansının düştüğünün bir göstergesidir. Grafikte de görüleceği üzere model, son haftalardaki fiyat düşüşünün ardından yatay bir seyir beklemekte; bu da SES modelinin mevcut

seviyeyi devam ettirme eğiliminde olduğunu göstermektedir. SES modeli için parametreleri incelemek için gerekli olan model denklemi aşağıda gösterilmiştir.

$$\widehat{y_{t+1}} = l_t \quad (3.1)$$

$$l_t = \alpha y_t + (1 - \alpha)l_{t-1} \quad (3.2)$$

Burada;

$\widehat{y_{t+1}}$: $t + 1$ dönemine ait tahmin değeri,

l_t : seviye bileşeni,

y_t : gerçek gözlem değeri,

α : düzleştirme parametresi ($0 < \alpha < 1$)

değerlerini temsil etmektedir.

Tablo 1: SES Model Performans Metrikleri


Metrik	Değer
α	~ 1
l_0	78,44
σ^2	19,52
AIC	4831,80
AIC_c	4831,85
BIC	4844,58

Modelin performans metrikleri Tablo 1’de gösterilmiştir. Model, 78,44 USD (l_0) seviyesinden tahminlemeye başlamıştır. Modelde alfa (α) değerinin 1’e yakınsadığı gözlemlenmektedir. Bu durum modelin tahmin için son gözleme ağırlık verdiğini, geçmiş değerleri neredeyse *dikkate almadığını* göstermektedir. Başka bir deyişle model tahmin için çok hızlı tepki vermektedir fakat geçmiş veriyi kullanarak öğrenememektedir. Bunun yanında yüksek hata varyansı gözlemlenmiştir (σ^2). Bu durum yüksek volatiliteye sahip bir zaman serisi için doğal karşılanabilecek bir durum olduğu düşünülmektedir fakat bu metrik diğer yöntemleri kullandığımız modellerin metrikleri ile kıyaslanınca daha anlamlı hale gelecektir. Bilgi kriterleri ise alternatif modeller ile karşılaştırma için anlamlı bir metrik olarak kullanılacaktır.

3.2.2 Trend Üstel Düzeltme (TES)

Bu bölümde, demir cevheri fiyatlarının öngörüsünde kullanılan Trend Üstel Düzeltme (TES) modeli incelenmiştir. TES modeli, ETS(A, A, N) yapısındadır ve hem

seviye (level) hem de doğrusal trend bileşenlerini içermektedir. Mevsimsel bileşen modele dahil edilmemiştir.



Şekil 4: Demir Cevheri Fiyat Tahmin Grafiği (TES)

Şekil 4'te gösterilen grafikte demir cevheri fiyatlarının tahmin grafiği gösterilmiştir. Grafikte gerçek fiyatlar (siyah çizgi) ve model tahminleri (turuncu çizgi) gösterilmiştir. Ayrıca tahminler %80 ve %90 seviyesinde güven aralıklarını gösteren koyu ve açık mavi bantlar ile desteklenmiştir. Grafikte de gözlemlenebildiği üzere serinin genel eğilimlerini takip edebilmiş gözükmektedir. Özellikle trend varlığının görüldüğü zamanlarda model uyumunun oldukça uygun olduğu gözlemlenmiştir. Modelin metrikleri ve özet raporu aşağıda Tablo 2'de gösterilmiştir. Bu tablodaki parametreleri açıklamak için modelin denklemi de aşağıda gösterilmiştir.

$$\widehat{y_{t+h}} = l_t + hb_t \quad (3.3)$$

$$l_t = \alpha y_t + (1 - \alpha)(l_{t-1} + b_{t-1}) \quad (3.4)$$

$$b_t = \beta(l_t - l_{t-1}) + (1 - \beta)b_{t-1} \quad (3.5)$$

Burada;

$\widehat{y}_{t+1}$: $t + h$ dönemine ait tahmin değeri,

l_t : seviye bileşeni,

y_t : gerçek gözlem değeri,

b_t : trend bileşeni

α : düzleştirme parametresi ($0 < \alpha < 1$)

β : trend düzleştirme parametresi

h : tahmin ufku

değerlerini temsil etmektedir.

Tablo 2: TES Model Performans Metrikleri

Metrik	Değer
α	~ 1
l_0	82,95
σ^2	19,60
AIC	4836
AIC_c	4836,12
BIC	4857,30

Tablo 2’deki metrikler incelendiğinde SES modeli ile benzer değerler çıktığı görülmektedir. Dolayısı ile SES modeli için metrik değerlendirmeleri, TES modeli için de geçerlidir. Çalışmadaki zaman serisinde dalgalanmalar ve trend görünürlüğü birlikte gözlemlendiği için TES modelinin açıklama gücünün daha iyi olduğu kanısına ulaşılabilir. TES modeli, SES ile karşılaştırıldığında kısa vadeli öngörülerde benzer hata değerleri sunsa da trend takibi açısından daha başarılı bir performans sergilemiştir.

3.2.3 Diğer Denemeler, Metrikleri ve Model Karşılaştırmaları

Bu bölümde demir cevheri fiyatlarını öngörebilmek için farklı düzeltme yöntemleri uygulanmıştır. Daha önceki başlıklarda SES ve TES modelleri incelenmişti. Bu modellerin yanında “damped” ve “autoETS” modelleri için de R programlama ile modeller oluşturulmuştur. Damped-Holt modelinde ETS(A,Ad,N) yapısında sönümlü trend içeren bir model baz alınır. Aşağıda Damped-Holt model denklemi gösterilmiştir.

$$\widehat{y}_{t+h} = l_t + \phi \cdot \frac{1 - \phi^h}{1 - \phi} \cdot b_t \quad (3.6)$$

$$l_t = \alpha y_t + (1 - \alpha)(l_{t-1} + \phi b_{t-1}) \quad (3.7)$$

$$b_t = \beta(l_t - l_{t-1}) + (1 - \beta)\phi b_{t-1} \quad (3.8)$$

Burada;

$\widehat{y}_{t+h}$: $t + h$ dönemine ait tahmin değeri,

l_t : seviye bileşeni,

y_t : gerçek gözlem değeri,

b_t : trend bileşeni

α : düzleştirme parametresi ($0 < \alpha < 1$)

β : trend düzleştirme parametresi

h : tahmin ufku

ϕ : sönümlenme parametresi ($0 < \phi < 1$)

değerlerini temsil etmektedir.

Bunların yanında Auto ETS modelinde ise R, en uygun ETS modelini otomatik seçmektedir. Bunun için kullanılan kodlar ve paketler ek (Ek-1: R kodları, Ek-2: R paketleri) ve kaynakça kısmında gösterilmiştir. Modellerin performans metrikleri aşağıda gösterilmiştir. Performans metriği olarak; RMSE, MAE, MAPE ve MASE gibi hata metrikleri ölçülmüştür. Bu metriklerin birbirleriyle karşılaştırılması sonucu ETS model performansları değerlendirilecektir.

Tablo 3: Üstel Düzeltme Yöntemleri Performans Metrikleri

Model	RMSE	MAE	MAPE	MASE
<i>Auto</i>	4,31	2,68	2,79	0,11
<i>Damped</i>	4,30	2,70	2,80	0,11
<i>Holt</i>	4,50	2,87	2,99	0,12
SES	4,45	2,70	2,79	0,11

Tablo 3'te gösterilen hata metrikleri, temelde modeller hakkında performans ipuçları sunmaktadır. Bahsedilen metrikler ya da hatalar incelendiğinde en düşük hata değerlerinin sırası ile “Damped” ve “AutoETS” modellerinde elde edildiği gözlemlenmiştir. “Holt” modelinde ise en yüksek hata değerleri gözlemlenmiştir. Bu durum sönümlü trend yapısında sahip trendin etkisi çok olmayacak şekilde modele dahil eden *damped* modellerin daha iyi performans koyduğu sonucunu göstermektedir. Bunun yanında, hata değerlerine göre SES modelinin de seviye varsayımına dayanarak güçlü bir karşılaştırma modeli olduğu gözlemlenmiştir [24].

3.3 ARIMA TAHMİN MODELLERİ


Klasik zaman serisi tahmin modellerinde en çok kullanılan yöntem ve modellerden biri de ARIMA'dır. Model, zaman serisi verilerindeki trend ve mevsimsellik gibi bileşenleri etkili bir şekilde modelleyip kısa vadeli tahminlerde yüksek doğruluk sağlayabilmektedir. Bu modelin özellikle ekonomik göstergeler, emtia fiyatları ve finansal veriler üzerinde kısa dönemli tahminlerde başarılı sonuçlar verdiği görülmektedir [33]. ARIMA (otoregresif bütünleşik hareketli ortalama), AR ve MA bileşenleri ile olası stokastik trendlerin ayrışması (bütünleşme) üzerine kurulur. Otoregresif AR bileşeni serinin önceki değerlerinin tahmin için kullanan bileşendir. MA yani hareketli ortalama bileşeni ise tahmin hatalarının önceki gözlemler baz alınarak modellenmesi üzerine kurulmuştur. ARIMA model kurgulaması serinin durağanlığının kontrol edilmesi, model parametrelerinin belirlenmesi, modelin kurulması, modelin uygunluğunun ve kalitesinin kontrol edilmesi ve tahmin adımlarından oluşmaktadır.

ARIMA modellerinde uygulama için zaman serilerinde durağanlık beklenir. Durağanlık, serinin ortalama, varyans ve kovaryans gibi istatistiksel özelliklerinin zaman içinde sabit kalması anlamına gelir. Bu nedenle, modellemeye önce serinin bu özelliği taşıyıp taşımadığı kontrol edilmelidir. Durağanlığı test etmek için genellikle ADF (*Augmented Dickey-Fuller*) testi uygulanır. Eğer seride trend veya mevsimsellik gibi yapılar varsa, bu durum durağanlığı bozar. Bu gibi durumlarda fark alma işlemi ve logaritmik dönüşüm veya Box-Cox dönüşümü uygulanır. Bu ön işlemlerle serinin ortalaması ve varyansı sabitlenerek durağanlık sağlanmaya çalışılır. Eğer bir fark alma yeterli değilse, ikinci veya üçüncü derece farklar alınabilir. Model kurulmadan önce ise model bileşenleri (p,d,q) belirlenir. ARIMA modeli, geçmiş değerlerin seriyi etkileme oranının göstergesi olan otoregresif (AR) terim sayısı (p) , serinin kaç fark alma işlemi ile durağan hale geldiğini gösteren fark sayısı (d) ve geçmiş hata terimlerinin etkisinin göstergesi olan hareketli ortalama (MA) terim sayısı (q) temel bileşenlerinden oluşur. Bu parametrelerin belirlenmesi için hem teorik bilgi hem de grafiksel analizler kullanılır. Özellikle ACF (*Autocorrelation Function*) ve PACF (*Partial Autocorrelation Function*) grafiklerinden faydalanılır. PACF grafiğindeki ani kesilme (p) değerine işaret eder. ACF grafiğindeki ani kesilme ise (q) değerine işaret eder. Bu analizlerle elde edilen p ve q değerlerine göre farklı ARIMA modelleri denenebilir. Model parametreleri belirlendikten sonra ARIMA modeli için AR ve MA terimleri tahmin edilir gerekirse sabit terim modele dahil edilir. Modelin kurulumu R,

Python gibi dillerde yapılabilir. R ortamında genellikle `arima()` ya da otomatik seçim yapan `auto.arima()` fonksiyonları tercih edilir. Bu fonksiyonlar, AIC (*Akaike Information Criterion*) gibi bilgi kriterlerini en aza indiren modeli seçerek süreci kolaylaştırır. Uygun model seçilip çalıştırıldığı zaman modelin performansı ölçülmesi gerekmektedir. Bu uygunluklar test edilirken Ljung-Box testi, ACF/PACF artık grafikleri, histogram ve Q-Q plot, AIC, BIC, RMSE, MAPE gibi test, grafik ve metrikler incelenir. Model bu testlerde zayıf performans gösterirse, parametreler yeniden gözden geçirilerek farklı bir yapı denenebilir. Bu adımlar uygulandıktan ve model validasyonu tamamlandıktan sonra ARIMA modeli gelecekteki değerleri tahmin etmek için kullanılır. Tahmin edilen değerler, gerçek veriler ile grafik üzerinde gösterilir, tahminlerin güven aralıkları grafik üzerinde görselleştirilir ardından model performans metrikleri hesap edilerek modelin tahmin doğruluğu değerlendirilir. Bu aşamada tahminlerin ekonomik ve pratik anlamları da irdelenebilir. Örneğin, yüksek sapmalar varsa bu durum serinin yapısal değişikliklere uğradığını veya dışsal faktörlerin etkili olduğunu gösterebilir. ARIMA modeli, uygun şekilde uygulandığında güçlü tahmin kabiliyetine sahip bir araçtır ve zaman serileri analizlerinde sıklıkla kullanılan güçlü bir modelleme sürecini yansıtır.

Uygulama adımları incelendiğinde ilk adım serinin durağan olup olmadığını test etmek ve durağanlaştırma işlemleri için fark alma yöntemleri uygulamaktır. Bu adımdan sonra AR ve MA bileşenleri için uygun gecikme (lag) değerleri belirlenir ve artıkların bağımsız ve normal dağıldığı doğrulanır. Bu çalışmada da ilk olarak bahsedilen testler yapılmıştır. Şekil 5'te bu testler görselleştirilmiştir. Bu testler ARIMA modelini kurarken bazı fikirler vermelidir. Bu fikirler ile ARIMA model

parametrelerin belirlenebilir model doğruluklarını artırılıp optimizasyonlar yapılabilmektedir.




Şekil 5: ACF ve PACF Analizleri

Yukarıdaki grafiklerde (Şekil 5) demir cevheri fiyatlarının haftalık zaman serisi ile buna ait ACF ve PACF analizleri görülmektedir. Zaman serisi grafiği, özellikle 200. haftadan sonra belirgin bir artış ve ardından dalgalı seyir göstererek serinin durağan olmadığını ortaya koymaktadır. ACF grafiğinde otokorelasyonlar yavaş bir şekilde azalarak trendin varlığına işaret ederken, PACF grafiği yalnızca birinci gecikmede anlamlı bir sıçrama göstererek seride AR(1) yapısının olabileceğini düşündürmektedir.

3.3.1 AutoARIMA Modeli

Çalışmada otomatik ARIMA modeli ile bir tahmin yapılmıştır. Modelin uygun parametrelerinin belirlenmesi için forecast paketinin `auto.arima()` fonksiyonu kullanılmıştır. Bu fonksiyon, bilgi kriterlerine (AIC, BIC) göre en uygun model yapısını otomatik olarak seçmektedir. Bu fonksiyon kullanılarak yapılan 16 hafta ufuklu tahmin aşağıdaki görselde (Şekil 7) gösterilmiştir.



Şekil 6: AutoARIMA ile 16 Haftalık Fiyat Tahmin Grafiği

Şekil 6'da gösterilen grafikte açık ve koyu mavi olarak gösterilen güven aralıkları ve veriyi devam ettiren mavi çizgi (tahmin) gözükmemektedir. Güven aralığı göstergeleri grafikte zamansal olarak ilerledikçe açılmaktadır. Bu durum tahmin performanslarının daha uzun vadelerde düştüğünü göstermektedir. Tahmin çizigisi ise kısa vadede fiyatların büyük bir sıçrama yapmayacağını yatay eğilimde serinin devam edeceğini göstermektedir. Tahminler yatayken güven aralıklarının geniş olması modelin yüksek volatilité beklentisi ile çalıştığını göstermektedir. Bu duruma pandemi dönemindeki sıçrama etki etmiş ve bu beklentiye sebep olmuş olabilir. Modelin anlamlılığını ölçebileceğimiz bazı metrikler aşağıda Tablo 4' te gösterilmiştir.

Tablo 4: AutoARIMA Model Parametreleri


Metrik	Tahmin	Std. Sapma	İstatistik	P-Değeri
<i>ar1</i>	1,88	0,07	25,5	$1,07 \times 10^{-57}$
<i>ar2</i>	-0,9	0,07	-13,41	$8,17 \times 10^{-28}$
<i>ma1</i>	-0,83	0,12	-6,71	$3,33 \times 10^{-10}$
<i>sar1</i>	0,04	0,11	0,32	$7,46 \times 10^{-1}$

<i>sabit</i>	2,25	0,06	36,44	$1,71 \times 10^{-78}$
--------------	------	------	-------	------------------------

AutoARIMA için model parametreleri incelendiğinde ar1 ve ar2 katsayıları oldukça anlamlı bulunmuş ve bu durum, geçmiş dönem fiyatlarının mevcut fiyatlar üzerinde güçlü bir etkisi olduğunu göstermektedir. Benzer şekilde, ma1 terimi de istatistiksel olarak anlamlıdır ve geçmiş hataların modele katkı sağladığını ortaya koymaktadır. Ancak, mevsimsel otoregresif katsayı olan sar1 anlamsız çıkmıştır. Bu da seride belirgin bir mevsimsellik etkisinin olmadığını veya modelin bu yönüyle sadeleştirilebileceğini göstermektedir. Modelde yer alan sabit terimin ise anlamlı olduğu düşünülmektedir.

3.3.2 ARIMA (2,0,1) + (0,0,0) Modeli

Demir cevheri fiyatlarının zaman serisi analizine yönelik olarak ARIMA(2,0,1) + (0,0,0) modeli oluşturulmuştur ve bu modelin tahmin sonuçları Şekil 7’de gösterilmiştir. Modelde geçmiş verilerin 2 gecikmeli hali kullanılmıştır ve seri durağan kabul edilip herhangi fark alma işlemi yapılmamıştır. Modelde geçmiş hata terimleri ise 1 gecikmeli olarak modele dahil edilmiştir. Ayrıca mevsimsel bileşenler modele dahil edilmemiştir. Grafik üzerinde siyah çizgi geçmiş yıllara ait haftalık demir cevheri fiyatlarını (USD cinsinden) ifade ederken, sağ tarafta yer alan mavi alanlar modelin geleceğe yönelik tahminlerini ve bu tahminlerin güven aralıklarını göstermektedir. Koyu mavi alan %80, açık mavi alan ise %95 güven aralığını temsil etmektedir. Tahmin süresi uzadıkça bu güven aralıklarının genişlemesi, modelin geleceğe dönük belirsizliğinin arttığını ortaya koymaktadır. 2021 yılında gözlemlenen fiyat zirvesi dışında, serinin genel olarak 80–150 USD bandında dalgalandığı, 2024 yılı başı itibarıyla ise fiyatlarda düşüş yaşandığı gözlemlenmektedir. ARIMA modeline göre, önümüzdeki dönemde fiyatlarda sınırlı da olsa bir toparlanma başka bir deyiş ile küçük bir düşüş öngörülmüştür.



Şekil 7: ARIMA(2,0,1) + (0,0,0) ile 16 Haftalık Fiyat Tahmin Grafiği

Modelin performansını ölçmek için diğer yöntemlerde ve ayrıca AutoARIMA modelinde de gösterildiği gibi birtakım metriklerin incelenmesi gerekmektedir. Bu durumun gereceğini Tablo 5’te model ile ilgili parametre çıktıları gösterilmiştir.

Tablo 5: ARIMA(2,0,1) + (0,0,0) Model Parametreleri

Metrik	Tahmin	Std. Sapma	İstatistik	P-Değeri
<i>ar1</i>	1,89	0,07	27,02	$6,56 \times 10^{-61}$
<i>ar2</i>	-0,91	0,06	-14,26	$3,98 \times 10^{-30}$
<i>ma1</i>	-0,84	0,12	-7,03	$5,96 \times 10^{-11}$
sabit	2,32	0,06	38,18	$2,31 \times 10^{-81}$


Tablo 5’te gösterilen metrik çıktılarının yorumu model performanslarını ölçmek için oldukça kıymetli ipuçları sunmaktadır. Metrikler incelendiğinde tüm model bileşenlerinin istatistiksel olarak anlamlı olduğu gözlemlenmiştir. Birinci ve ikinci dereceden otoregresif (AR) katsayıları zaman serisinin geçmiş değerler ile güçlü bir bağlantısı olduğunu göstermektedir. Bunun yanında ikinci derecen otoregresif katsayısının işareti negatiftir. Bu durum seride düzeltici bir etkinin olabileceğini akıllara getirmektedir. Bunların yanında hareketli ortalama (MA) katsayısı da serideki hata terimlerinin modelde anlamlı bir etkisi olduğunu göstermektedir. Ayrıca modelde yer alan sabit terimin yüksek istatistiksel anlamlılığı, serinin genel seviyesinin modellenmesinde önemli bir rol oynadığını göstermektedir. Tüm parametreler için p değerleri oldukça düşük hesaplanmıştır. Bu durum modelin tahmin gücünün yüksek olduğunu ve veriye iyi bir şekilde uyum sağladığını göstermektedir.

Bahsedilen parametreler dışında modelin istatistiksel uygunluğunu değerlendirmekte kullanılan σ^2 , log-likelihood, AIC, AIC_c ve BIC performans metrikleri de incelenmiştir. Bu metriklerin incelenmesi modelin veriye ne denli uyum gösterdiği ve aşırı uyum riskinin var olup olmadığını anlamak konusunda oldukça etkilidir. Öncelikle, modelin σ^2 değeri 22,18 olarak hesaplanmıştır. Bu değer artık varyansını yani modelin ne kadar hata yaptığını ifade eder. Düşük bir σ^2 değeri modelin öngörülerde tutarlı olduğunun göstergesidir. Log-likelihood değeri ise modelin veriyi açıklama olasılığını logaritmik ölçekte gösterir ve burada -465,42 olarak hesaplanmıştır; bu değer çalışmanın ilerleyen kısımlarında diğer modellerle karşılaştırma yapıldığında daha fazla anlam ifade edecektir. AIC (Akaike Bilgi Kriteri), modelin hem uyum kalitesini hem de karmaşıklığını anlatan bir metriktir. Düşük AIC değeri modelin tercih edilebilir olduğunu gösterir. Modelde AIC değeri 940,84'tür. AIC_c değeri ise küçük örneklem için AIC'nin düzeltilmiş halidir ve modelin genelleme yeteneğini daha iyi yansıtmaya açıktır. Modelde değeri 941,24 ile AIC'ye çok yakındır, bu da örneklem büyüklüğünün yeterli düzeyde olduğunun bir göstergesidir. BIC (Bayesyen Bilgi Kriteri) ise modelin karmaşıklığını ölçer. Bu model için BIC değeri 956,12'dir. AIC ve BIC'nin birlikte değerlendirilmesi, modelin ne ölçüde açıklayıcı ve sade olduğunu ortaya koyar. AIC/BIC değerinin küçüklüğü de model adına olumlu sinyaller vermektedir. İncelenen tüm metrikler, modelin istatistiksel olarak anlamlı, veriye uyum sağlamış ve uygun karmaşıklıkta olduğunu göstermiştir.


3.4 ARIMA VE ETS MODELLERİ ÜZERİNE ÇAPRAZ DOĞRULAMA VE MODELLERİN KARŞILAŞTIRILMASI

Zaman serisi modellerinde performans değerlendirmesi yapmak için çapraz doğrulama oldukça yaygın kullanılan önemli bir tekniktir. Çapraz doğrulama çalışmanın şimdiye kadarki kısmında anlatılan ETS ve ARIMA modellerinin tahmin doğruluğunu test etmek için önemli bir rol oynayacaktır. Zaman serisi modellerinde klasik k katlı çapraz doğrulama yöntemi zaman bağımlılığı sebebi ile uygun değildir. Bu sebeple kaydırmalı pencere yöntemleri tercih edilmektedir [24]. Bu yöntemde, eğitim veri seti zamanla ileri kaydırılarak her adımda yeni tahminler yapılır ve modelin farklı dönemlerdeki performansı ölçülür. Bu işlem, hem kısa vadeli (örneğin 1 adımlı) hem de orta vadeli (örneğin 4 adımlı) öngörüler için uygulanarak, modelin farklı tahmin ufuklarındaki başarısını ortaya koymaktadır. Değerlendirme için genellikle

MAE, RMSE ve MAPE gibi hata metrikleri kullanılır; bu metrikler tahminlerin ortalama sapmasını, büyük hatalara duyarlılığını ve yüzdesel hata oranını ölçerek model karşılaştırmasına da olanak tanır [34]. Çalışmaya konu olan ETS ve ARIMA modellerinde 1 ve 4 adımlı çapraz doğrulama uygulanmış ve tahmin hataları zamana karşı olarak değerlendirilmiştir. Değerlendirmelerin görsel sonuçları aşağıda Şekil 8 ve Şekil 9’da gösterilmiştir.



Şekil 8: ETS Modeli 1 ve 4 Adımlı Çapraz Doğrulama Sonuçları



Şekil 9: ARIMA Modeli 1 ve 4 Adımlı Çapraz Doğrulama Sonuçları

Şekil 8’de görüleceği üzere ETS modelinin 1 adımlı tahminlerde RMSE, MAE, MAPE ve MPE hata metrikleri düşük seyretmiştir. Başka bir deyiş ile model kısa vadede istikrarlı bir performans ortaya koymuştur. Buna karşıt olarak 4 adımlı

tahminlerde özellikle demir cevheri fiyatlarındaki volatilitenin arttığı pandemi sonrası yıllarda ciddi hata artışları meydana gelmiştir. Modelin tahmin ufku arttıkça model başarısında bir düşüş gözlemlenmektedir. Bunların dışında genel olarak ETS model tahminleri yanlılıktan uzak tahmin üretiminde bulunsun da bazı dönemlerde negatif sapma eğilimi ile fiyatları olduğundan düşük tahmin etmiştir. Benzer olarak Şekil 9’da ise ARIMA modelinin 1 ve 4 adımlı tahmin performansları gösterilmektedir. ARIMA modeli de 1 adımlı tahminlerde yüksek öngörü gücü gösterse de 4 adımlı tahminlerde yüksek volatilité dönemlerinde ETS modelinde de görülen performans kaybını yaşamaktan kaçınamamıştır. ARIMA modelinde de genel olarak tarafsız tahminler üretilmiştir. Her iki modelin de sonuçlarına göre ortak kanı kısa vadeli tahminlerde başarı sağlansa da tahmin ufku genişlediğinde model performansları düştüğü yönündedir. Modeller piyasadaki ani yapısal kırılmalara karşı zayıf kalabilmektedirler.

Şekil 8 ve 9’da gösterilen bulguların yanında ETS ve ARIMA modellerinin 1 ve 4 adımlı tahminlerine ilişkin RMSE değerlerinin özet istatistikleri Tablo 6’da belirtilmiştir. Bu tablo grafiklerde gözlemlenen sonuçları nicel olarak da kavrayabilmek adına iyi bir araç olacaktır.

Tablo 6: Çapraz Doğrulama Sonuçlarına Göre RMSE İstatistikleri

Model	Min. RMSE	Ort. RMSE	Sd. RMSE	Mak. RMSE
ARIMA (1 Adım)	1,16	4,13	1,98	9,98
ARIMA (4 Adım)	1,18	4,20	2,04	10,30
ETS (1 Adım)	1,86	8,01	4,28	20,90
ETS (4 Adım)	2,04	7,98	4,21	21,40


Tablo 6’da gösterilen değerlere göre kısa vadeli tahminlerde ARIMA modelinin daha tutarlı ve daha düşük hata aralığında performans gösterdiği, buna karşılık ETS modelinin de yine benzer şekilde doğruluk sağlasa da hata metriklerinin biraz daha fazla olduğu gözlemlenmiştir. Nicel olarak incelendiğinde de kısa vadeli tahminlerde her iki model de yüksek doğrulukla çalışsa da ARIMA tutarlılık konusunda az da olsa daha iyi bir performans göstermiştir. Konu uzun vadeli tahminlere gelince her iki modelin de performansı bariz şekilde düşmüştür. Uzun vadeli tahminlerde de ARIMA modeli nispeten daha iyi performans göstermiştir. Genel olarak modellerin tahmin performansları literatürdeki bulgular ile örtüşmektedir.

3.5 XGBOOSTING TAHMİN MODELİ

XGBoosting, karar ağaçları temelli bir öğrenme algoritmasıdır. Bu model 2001 yılında Friedman tarafından geliştirilen “Gradient Boosting” modelinin daha hızlı, verimli ve düzenlenmiş versiyonudur. Bu algoritmanın geliştirilme amacı “Gradient Boosting” algoritmasının eksiklerini gidermek ve daha büyük veri kümeleri ile modeller kurmayı mümkün kılmaktır. XGBoost, ikinci dereceden Taylor serisi açılımı kullanarak daha hassas bir optimizasyon süreci sağlar [35]. Ayrıca L1 (lasso) ve L2 (ridge) regularizasyon teknikleri entegre edilerek modellerin aşırı öğrenme eğilimi azaltılmıştır [36]. Bu özellikler sayesinde genelleme kabiliyeti yüksek istikrarlı bir model elde edilmiştir. Tüm bu model özelliklerin ek olarak modelin yorumlanabilirlik yeteneği de oldukça yüksektir. Özetle XGBoost modeli yüksek doğruluk sonuçları alınabilen, aşırı öğrenmeye karşı direnen, yorumlanabilir ve yüksek verimli bir tahmin modeli yöntemi olması sebebi ile bu çalışmada yer almıştır. Çalışmada; bu model ile yapılan demir cevheri fiyat tahminleri açıklanacak olup performansı, diğer modeller ile karşılaştırılacaktır. Model oluşturulurken farklı bileşenler ile denenmiştir. Bu denemeler ile modelden tahminler alınmış ve gerçek değerler ile bu tahminler karşılaştırılmıştır. Ayrıca tüm modellerde olduğu gibi performans metrikleri ölçülüp sonuçlar grafik ve tablolar ile gösterilmiştir.

3.5.1 Kukla Değişkenler ile XGBoosting Modeli

XGBoosting modelinde kukla değişkenler kullanarak mevsimsellik modelleme yaklaşımı çalışmada her bir haftayı ayrı bir değişken olarak temsil eder. Bu yöntem sabit ve düzenli mevsimsel desen gösteren serilerde daha etkili sonuçlar vermektedir çünkü her dönem için özgün bir etki tahmini yapılmasına olanak tanır. Bu yaklaşımın en büyük avantajı, mevsimsel etkileri açık ve yorumlanabilir biçimde temsil etmeye olanak sağlamasıdır. Bu yöntem ile oluşturulan modelin tahmin sonuçları Şekil 10’da performans ve hata metrikleri ise Tablo 7’de gösterilmiştir.



Şekil 10: Kukla Değişkenler ile 24 Hafta Ufuklu XGBoosting Model Tahmini

Şekil 10’da görüldüğü üzere model, geçmiş dönemlerdeki dalgalanmalara rağmen 24 haftalık ufukta nispeten daha durağan bir fiyat hareketi beklemektedir.

Tablo 7: Kukla Değişkenler ile XGBoosting Modeli Performans Metrikleri


Metrik	Değer
<i>ME</i>	0,0096
<i>RMSE</i>	0,6719
<i>MAE</i>	0,5057
<i>MPE</i>	-0,0126
<i>MAPE</i>	0,5286
<i>MASE</i>	0,0206
<i>ACF1</i>	-0,1718

Tablo 7’de gösterilen metrikler incelendiğinde modelin başarılı bir uyum gösterdiği gözlemlenmiştir. Ortalama hata değeri sıfıra oldukça yakındır. Dolayısı ile modelin aşırı ya da az uyum sağlayıp yanlış tahmin yapmadığı düşünülmektedir. RMSE ve MAE değerlerinden hareketle modelin ciddi hatalar yapmadığı ve yüksek doğruluğa sahip olduğu gözlemlenmiştir. MAPE değeri de oldukça düşük hesaplanmıştır. Bu durum modelin eğitim verisinde yüksek öngörü gücüne sahip olduğunu ortaya koyar. Ayrıca MASE değerinin 0,0206 gibi çok düşük bir düzeyde olması, modelin mevsimsel *naive* modele kıyasla çok daha başarılı olduğunu kanıtlamaktadır [37]. Artıkların birinci dereceden otokorelasyonu (ACF1) ise negatif ve düşük düzeyde olup, model artıklarında yapısal bir desenin kalmadığını göstermektedir. Tüm bu metrikler incelendiğinde; model, ileriye dönük fiyat

tahmininde daha yatay sayılabilecek bir tahminde bulunsa da genel doğruluk açısından tatmin edici sonuçlar göstermiştir.

3.5.2 Fourier Dönüşümü ile XGBoosting Modeli

Fourier dönüşümü; periyodik desenleri, sinüs ve kosinüs fonksiyonları kullanarak sürekli ve düzgün biçimde modeller [38]. Bu yöntem uzun vadeli döngüsel zaman serilerinin incelendiği çalışmalarda daha çok tercih edilmektedir. Çalışmada bu yöntem de denenmiş olup 24 hafta ufuklu model tahmini Şekil 11’ de gösterilmiştir.



Şekil 11: Fourier Dönüşümü ile 24 Hafta Ufuklu XGBoosting Model Tahmini


Modelin performans ve hata metrikleri de model performansını daha iyi tayıne edebilmek adına aşağıda Tablo 8’de gösterilmiştir.

Tablo 8: Fourier Dönüşümü ile XGBoosting Modeli Performans Metrikleri

Metrik	Değer
<i>ME</i>	-1,93
<i>RMSE</i>	10,42
<i>MAE</i>	8,28
<i>MPE</i>	-3,73
<i>MAPE</i>	8,36
<i>MASE</i>	0,34
<i>ACF1</i>	0,98

Tablo 8’de gösterilen ortalama hata (ME) değeri negatif yönde bir eğilmeye işaret etmektedir. Başka bir deyiş ile modelin olağandan düşük tahminlerde bulunduğunu göstermektedir. RMSE ve MAE değerleri yüksek hesaplanmıştır. Bu durum modelin tahmin yaparken nispeten daha çok hata yaptığını göstermiştir. En dikkat çeken bulgu ise ACF1 değerinin yüksek hesap edilmiş olmasıdır. Bu değerin

yüksek hesaplanması, artıklar arasında ciddi derecede otokorelasyon bulunduğunu ve modelin zaman serisindeki bağımlılık yapısını yeterince çözümleyemediğini, serinin dinamik yapısını tam olarak öğrenemediğini göstermektedir.




Şekil 12: Fourier Dönüşümü ile Oluşturulan XGBoosting Model Tahmininin Gerçek Veri İle Karşılaştırılması

Şekil 12’de gösterilen grafik, modelin eğitim verisi üzerindeki uyumunu ortaya koymaktadır. Mavi çizgi, modelin tahmin ettiği değerleri, gri çizgi ise gözlemlenen gerçek fiyatları göstermektedir. Grafikte modelin genel hareketleri yakaladığı, ancak ani artış ve düşüşlerde gerçek değerlere paralel hareket edemediği görülmektedir. Tüm bu gözlemlerden hareket ile Fourier dönüşümü ile oluşturulan XGBoosting modelinin, bu çalışma özelinde kısmi bir başarı gösterdiği düşünülmektedir.

3.5.3 Klasik Ayırıştırma ile XGBoosting Modeli

Klasik ayırıştırma ile kurulan modelde; zaman serisi, temel olarak bileşenlere ayrıştırılmaktadır. Bu bileşenler; trend ve mevsimsellik bileşenleridir. Yöntemde her bir bileşen ayrı bir yapı olarak ele alınmaktadır. Şekil 13’te ayırıştırma yöntemiyle eğitilen modelin 24 haftalık fiyat tahminleri gösterilmiştir. Mavi çizgi, fiyatların artış yönlü keskin bir projeksiyon sunduğunu, bu modelin gelecekteki eğilimleri agresif biçimde yukarı yönlü olacak şekilde öngördüğünü göstermektedir. Bu eğilim, modelin trend bileşenini aşırı vurguladığını ve belki de mevsimsel yapıyı yeterince dengelemediğini düşündürmektedir.




Şekil 13: Klasik Ayrıştırma İle 24 Hafta Ufuklu XGBoosting Model Tahmini

Modelin performans ve hata metrikleri de model performansını daha iyi tayin edebilmek adına aşağıda Tablo 9’de gösterilmiştir.

Tablo 9: Klasik Ayrıştırma ile XGBoosting Modeli Performans Metrikleri

Metrik	Değer
<i>ME</i>	-17,18
<i>RMSE</i>	23,11
<i>MAE</i>	19,41
<i>MPE</i>	-22,17
<i>MAPE</i>	23,59
<i>MASE</i>	0,79
<i>ACF1</i>	0,98

Negatif ortalama hata değeri, modelin bazı zamanlarda gözlem değerlerinin altında tahmin yaptığını ortaya koymaktadır. RMSE ve MAE hata metrikleri yüksek seviyelerdedir ve tahmin sapmalarının ciddi boyutlarda olduğunu göstermektedir. Ortalama mutlak yüzde hata MAPE, bu modelin önceki modellere kıyasla daha düşük doğrulukla çalıştığını işaret etmektedir. En dikkat çekici bulgu yine önceki modelde de açıklandığı üzere, artıkların birinci dereceden otokorelasyonunun (ACF1) oldukça yüksek olmasıdır. Bu durum, modelin zaman serisindeki yapıyı tam anlamıyla öğrenemediğini gösteriyor olabilir.




Şekil 14: Klasik Ayrıştırma ile Oluşturulan XGBoosting Model Tahmininin Gerçek Veri ile Karşılaştırılması

Şekil 14’te yer alan uyum grafiği modelin geçmiş verilere olan uyumunu ortaya koymaktadır. Görüldüğü üzere, mavi çizgi, genel eğilimleri takip etse de birçok kritik dönemde gerçek değerlere kıyasla önemli düzeyde ayrışmalar göstermektedir. Bu bağlamda tüm sonuçlar incelendiğinde klasik ayrıştırma yöntemi ile bütünleşmiş XGBoosting modelinin kısmi başarı gösterdiği düşünülmektedir.

3.6 KOMBİNE TAHMİN MODELİ

Çalışmanın bu bölümünde, önceki bölümlerde anlatılan modeller ile bir kombine model tasarımı yapıp sonuçlar tartışılacaktır. Zaman serilerinin tahminlerinde kullanılan modeller çoğu zaman tüm değişimleri ve desenleri yakalayamazlar. Tahmin modellerinde farklı modellerin çeşitli avantajları mevcuttur. Dolayısı ile bu modellerin çıktılarının birleştirilmesi tahmin doğruluğunu artırabilmektedir [39]. Çalışmanın önceki bölümlerinde kullanılan ETS, ARIMA ve XGBoost modellerinin her biri farklı avantajlara sahiptir. ETS modelleri, mevsimsellik ve trend gibi bileşenleri açık bir şekilde modelleyebilirken ARIMA, durağanlaştırılmış seriler üzerinde iyi performans gösterir ve geçmiş hataları da dikkate alır. Öte yandan, XGBoost gibi makine öğrenmesi algoritmaları, doğrusal olmayan ilişkileri öğrenme kapasitesiyle klasik yöntemlerin eksik kaldığı noktalarda avantaj sağlar. Bu modellerin tahminlerinin belirli ağırlıklarla bir araya getirilmesi, model varyansını azaltarak daha dengeli, genellenebilir ve doğrulanabilirliği yüksek tahminler sunar.

Modelleri kombine etmenin birden fazla yolu vardır. Ağırlıklı ortalamalar ve daha karmaşık kombinasyonlar kullanmak için pek çok çalışma yapılmış olsa da basitçe ortalama kullanmanın performans seviyesi olarak yenilmesinin çok zor olduğu kanıtlanmıştır [40]. Bu durumun ışığında; demir cevheri fiyatlarının tahmini için kullanılan modeller, eşit ağırlıklı ortalama alma yöntemi ile kombine edilmiştir. Kombine model tahminlerinin 24 haftalık tahmin ufkı ile diğer model tahminleri ile karşılaştırıldığı grafik Şekil 15’te gösterilmiştir.



Şekil 15: Kombine Model ve Diğer Modellerin Fiyat Tahminleri Grafiği

Şekil 15’te de görüldüğü gibi kombine model diğer modellerin arasında bir tahmin ile kendini göstermektedir. Kombine model, her modelin eşit ağırlıkta ortalaması ile hesaplandığı için diğer modellerin daha ılımlı veya agresif kalan yönlerini törpülemiş gibi gözükmemektedir. Kombine modelin performansını incelemek ve diğer modeller ile karşılaştırmak için ise önceki modellerde de yararlanılan metrikler incelenmelidir. Bu metrikleri elde etmek için kombine modelde kullanılan demir cevheri fiyatları zaman serisi eğitim ve test setlerine ayrılmış ve hata metrikleri hesaplanmıştır. Hata metrikleri yalnızca kombine model için değil, kombine modelde kullanılan tüm diğer modeller için de hesaplanmıştır. Bu metrikler sonuçlar ve bulgular kısmında gösterilip diğer modeller ile karşılaştırmalar yapılacaktır. Kombine model, diğer üç tahmin tekniğinin güçlü yönlerini birleştirerek dengeli bir tahmin performansı sunma eğilimindedir. Bu durum, özellikle farklı model çıktılarının ortalamasının genel hata oranını dengeleyici etkisini göstermekte ve kombine model kullanımının demir cevheri fiyat tahmininde etkili bir enstrüman olabileceğini gözler önüne sermektedir.

BÖLÜM IV

BULGULAR, SONUÇLAR VE KARŞILAŞTIRMALAR

Çalışmada temel hedef olarak demir cevheri gerçekleşen fiyatları ile bu emtianın gelecekteki fiyatlarını tahmin etmektir. Bu bağlamda pek çok tek değişkenli tahmin modeli denenmiş olup sonuçları irdelenmiştir. Bu modeller ETS, ARIMA, XGBoosting modelleridir. Bunların yanında yine bu modellerin bir eşit ağırlıklı kombinasyonu olan kombine model de çalışılmıştır. Çalışılan bu modellerin performans metrikleri ve tahminleri önceki kısımlarda açıklanmıştır. Çalışmanın bu kısmında ise bu modeller birbirleri ile karşılaştırılacak olup sonuca hangisinin daha sağlam adımlar ile ulaştığı tartışılacaktır.

Model performanslarını ölçmek için temel olarak hata metrikleri kullanılmıştır. Bu hata metriklerinin değerleri ve birbirlerine karşı nerede bulundukları model performansları hakkında bize fikir vermektedir. Model performanslarını kıyaslamak için bu metriklerin gösterildiği ve karşılaştırıldığı kısım aşağıda Tablo 11’de gösterilmiştir. Bu tablonun özümsemesi bize model performansları ile ilgili bilgiler verecek ve model performanslarını karşılaştırmamızı sağlayacaktır.

Tablo 10: Tüm Modeller için Hata Metrikleri

Model	RMSE	MAE	MAPE	MASE
<i>SES</i>	4,45	2,70	2,79	0,11
<i>TES</i>	4,50	2,87	2,99	0,12
<i>Damped – Holt</i>	4,30	2,66	2,80	0,12
<i>Auto ARIMA</i>	4,21	2,59	2,71	0,10
<i>ARIMA (2,0,1)</i>	4,65	3,14	2,71	0,19
<i>XGBoosting (Kukla)</i>	0,67	0,51	0,52	0,02
<i>XGBoosting (Fourier)</i>	10,42	8,28	8,36	0,34
<i>XGBoosting (Ayrıştırma)</i>	23,11	19,41	23,59	0,79
<i>Kombine Model</i>	8,19	10,97	8,24	0,31

Tablo 10’da gösterildiği gibi, çalışmada *ETS*, *ARIMA*, *XGBoost* ve bu modellerin kombine hali ile demir cevheri fiyat tahmini yapılmıştır. Bu modellerde

performansları karşılaştırmak için RMSE, MAE, MAPE ve MASE metrikleri yorumlanmıştır. Tabloda gösterilen sonuçlar açıklanacak olursa; Kukla değişkenlerle oluşturulan XGBoosting modeli, tüm metriklerde en düşük değerleri elde ederek açık ara en başarılı model olmuştur. Bu sonuç, yapısal kırılmaların ya da rejim değişimlerinin kukla değişkenlerle etkin şekilde temsil edilmesinin, XGBoost algoritmasının güçlü öğrenme yeteneğiyle birleştiğinde yüksek doğruluk sağladığını göstermektedir. Klasik modeller arasında en iyi performansı gösteren Auto ARIMA, otomatik parametre seçimiyle zaman serisindeki temel desenleri başarıyla yakalamıştır. Damped-Holt modeli ise trend bileşenini zamanla sönümleyerek, klasik ETS modelleri (SES, TES) arasında daha iyi sonuçlar vermiştir. Kombine model ise üç temel modelin çıktılarının ortalaması alınarak oluşturulmuş, bazı modellerden daha düşük hata sağlamış olsa da, kukla değişkenli XGBoost modelinin gerisinde kalmıştır. Buna karşılık Fourier ve ayrıştırma bileşenleriyle yapılandırılan XGBoost modelleri, özellikle yüksek RMSE ve MAE değerleriyle kötü performans sergilemiş, bu da uygunsuz model yapılandırmasının, güçlü algoritmalarda dahi yüksek hataya yol açabileceğini göstermiştir. Ayrıca, sabit parametrelili manuel ARIMA(2,0,1) modelinin, Auto ARIMA modeline kıyasla daha yüksek hata üretmesi, uygun parametre seçiminin model başarısında ne denli kritik olduğunu ortaya koymaktadır. Genel olarak değerlendirildiğinde, doğru değişken seçimi ve model yapılandırmasıyla makine öğrenmesi tabanlı yaklaşımların klasik zaman serisi modellerine kıyasla çok daha yüksek başarı sağladığı, ancak bu başarının doğru modelleme stratejilerine sıkı sıkıya bağlı olduğu görülmektedir.

Çalışmada tek değişkenli modeller ile ilgili tahminler yapılmış olsa da başka diğer birbirleri ile bağlantılı değişkenlerin de fiyat tahmini üzerinde etkileri olduğu aşikardır. Çalışmada diğer değişken etkileri dışarıda bırakılmış olup başka çalışmalarda bu konu üstüne de araştırmalar yapılabilir. Fakat çalışma bu hali ile de umut verici sonuçlar göstermiştir. Bu çalışmadaki sonuçlar, bulgular, yorumlar ve bu çalışmaya eklenebilecek pek çok geliştirme ile demir cevheri fiyat tahminleri doğruluğu çok yüksek seviyelere çıkarılabilecek olup bu durum ilgili sektör paydaşlarını yakından ilgilendirip fiyat tahmininin ilgi çekici bir konu olması halinin devamını sağlayacaktır.

KAYNAKÇA

- [1] FATHALİZADEH Ali (2024), “Eski Çağda Demir Üretimi, Teori ve Teknolojisi”, *Metalurji Dergisi*, Sayı 164, ss. 53-60.
- [2] INVESTING (2025), *Yüksek Kaliteli Demir Cevheri 62% Fe CFR Vadeli İşlemleri-(TIOc1)*, <https://tr.investing.com/commodities/iron-ore-62-cfr-futures>, ET. 25.10.2024.
- [3] BRAYN Jennifer ve WICKHAM Hadley (2023), *readxl: Read Excel Files (R Paketi)*, <https://github.com/tidyverse/readxl>, ET. 03.04.2025.
- [4] ZEİLEİS Achim ve GROTHENDİECK Gabor (2005), “zoo: S3 Infrastructure for Regular and Irregular Time Series.”, *Journal of Statistical Software*, Cilt 14, Sayı 6, ss. 1–27.
- [5] RYAN Jeffrey A. ve ULRICH Joshua M. (2024), *xts: eXtensible Time Series (R Paketi)*, <https://cran.r-project.org/web/packages/xts> , ET. 03.04.2025.
- [6] WICKHAM Hadley, AVERICK Mara, BRYAN Jennifer, CHANG Winston, D’AGOSTINO McGOWAN Lucy, FRANÇOIS Romain, GROLEMUND Garrett, HAYES Alex, HENRY Lionel, HESTER Jim, KUHN Max, LIN PEDERSEN Thomas, MILLER Evan, MILTON BACHE Stephan, MÜLLER Kirill, OOMS Jeroen, ROBINSON David, SEIDEL Dana Paige, SPINU Vitalie, TAKAHASHI Kohske, VAUGHAN Davis, WILKE Claus, WOO Kara ve YUTANI Hiroaki (2019), “Welcome to the tidyverse”, *Journal of Open Source Software*, Cilt 4, Sayı 43, s. 1686.
- [7] SAX Christoph (2021), *tsbox: Class-Agnostic Time Series in in R (R Paketi)*, <https://cran.r-project.org/web/packages/tsbox>, ET. 03.04.2025.
- [8] HYNDMAN Rob J., ATHANASOPOULOS George, O'HARA-WILD Mitchell, PALIHAWADANA Nuwani ve WICKRAMASURIYA Shanika (2024), *fpp3: Forecasting: Principles and Practice (3rd Edition) (R Paketi)*, <https://cran.r-project.org/web/packages/fpp3>, ET. 03.04.2025.

- [9] HYNDMAN Rob, ATHANASOPOULOS George, BERGMEIR Christoph, CACERES Gabriel, CHHAY Leanne, O'HARA-WILD Mitchell, PETROPOULOS Fotios, RAZBASH Slava, WANG Earo ve YASMEEN Farah (2025), *forecast: Forecasting Functions for Time Series and Linear Models (R Paketi)*, <https://cran.r-project.org/web/packages/forecast>, ET. 03.04.2025.
- [10] IANNONE Richard, CHENG Joe, SCHLOERKE Barret, HUGHES Ellis, LAUER Alexandra, SEO JooYoung, BREVOORT Ken ve ROY Olivier (2024), *gt: Easily Create Presentation-Ready Display Tables (R Paketi)*, <https://cran.r-project.org/web/packages/gt>, ET. 03.04.2025.
- [11] O'HARA-WILD Mitchell, HYNDMAN Rob, WANG Earo, COOK Di, TALAGALA Thiyanga ve CHHAY Leanne (2024), *feasts: Feature Extraction and Statistics for Time Series (R Paketi)*, <https://cran.r-project.org/web/packages/feasts>, ET. 03.04.2025.
- [12] O'HARA-WILD Mitchell, HYNDMAN Rob, WANG Earo, CACERES Gabriel, BERGMEIR Christoph, HENSEL Tim-Gunnar ve HYNDMAN Timothy (2024), *fable: Forecasting Models for Tidy Time Series (R Paketi)*, <https://cran.r-project.org/web/packages/fable>, ET. 03.04.2025.
- [13] ROBINSON David, HAYES Alex ve COUCH Simon (2025), *broom: Convert Statistical Objects into Tidy Tibbles (R Paketi)*, <https://cran.r-project.org/web/packages/broom>, ET. 03.04.2025.
- [14] GROLEMUND Garrett ve WICKHAM Hadley (2011), "Dates and Times Made Easy with lubridate", *Journal of Statistical Software*, Cilt 40, Sayı 3, ss. 1–25.
- [15] WICKHAM Hadley (2007), "Reshaping Data with the reshape Package", *Journal of Statistical Software*, Cilt 21, Sayı 12, ss. 1–20.
- [16] WICKHAM Hadley, FRANÇOIS Romain, HENRY Lionel, MÜLLER Kirill ve VAUGHAN Davis (2023), *dplyr: A Grammar of Data Manipulation (R Paketi)*, <https://cran.r-project.org/web/packages/dplyr>, ET. 03.04.2025.
- [17] LIN PEDERSEN Thomas (2024), *patchwork: The Composer of Plots (R Paketi)*, <https://cran.r-project.org/web/packages/patchwork>, ET. 03.04.2025.
- [18] WEISS Christoph E., ROETZER Gernot R. ve RAVIV Eran (2025), *ForecastComb: Forecast Combination Methods (R Paketi)*, <https://cran.r-project.org/web/packages/ForecastComb>, ET. 03.04.2025.

- [19] ELLIS Peter (2024), *forecastxgb: xgboost ile Zaman Serisi Tahmini (R Paketi)*, <https://github.com/ellis/forecastxgb-r-package>, ET. 03.04.2025.
- [20] PUSTOV Alexander, MALANICHEV Alexander ve KHOBOTILOV Ilya (2013), “Long-term Iron Ore Price Modeling: Marginal Costs vs. Incentive Price”, *Resources Policy*, Cilt 38, Sayı 4, ss. 558–567.
- [21] MA Yiqun ve ZHEN Wei (2020), “Market Fundamentals and Iron Ore Spot Prices”, *Economic Record*, Cilt 96, Sayı 315, ss. 470–489.
- [22] WARELL Linda (2014), "The effect of a change in pricing regime on iron ore prices", *Resources Policy*, Sayı 41(C), ss. 16-22.
- [23] MAO Yingming ve QIAO Han (2011), “The Analysis on the Sensitivity of Steel Enterprise to Iron Ore Price”, *2011 IEEE International Conference on Business Intelligence and Financial Engineering (BIFE)*, Wuhan, Çin.
- [24] HYNDMAN Rob J. ve ATHANASOPOULOS George (2021), *Forecasting: Principles and Practice*, <https://otexts.com/fpp3/>, ET. 26.10.2024.
- [25] PAN Wei, LIU Shuqiang, KUMRAL Mehmet vd. (2024), “Iron Ore Price Forecast Based on a Multi-Echelon Tandem Learning Model”, *Natural Resources Research*, Cilt 33, ss. 1969–1992.
- [26] RIBEIRO Diogo (2023), *Forecasting Commodity Prices Using Machine Learning: Techniques and Applications*, <https://diogoribeiro7.github.io>, ET. 17.04.2025.
- [27] NITHIN D., MANOJ G., REDDY B. Sai Sandeep, ABHISHEK D., KISHORE R. Sudha ve KUMAR K. Kranthi (2024), “ECPX: Empowering Commodity Price Prediction Using XGBoost Algorithm”, *İçinde, Proceedings of International Conference on Intelligent Vision and Computing (ICIVC 2023)*, ss. 124–134, Springer Nature Switzerland AG, Singapur.
- [28] WANI Mohit, PATIL Yash ve KSHIRSAGAR Varsha (2024), “Commodity Trend Analysis and Prediction Using Machine Learning”, *International Journal of Scientific Research and Engineering Development (IJSRED)*, Cilt 7, Sayı 6, ss. 392–399.
- [29] LI Diyuan, MOGHADDAM Mohammad Reza, MONJEZI Masoud, JAHED ARMAGHANI Danial ve MEHRDANESH Amirhossein (2020), “Development of a Group Method of Data Handling Technique to Forecast Iron Ore Price”, *Applied Sciences*, Cilt 10, Sayı 7, ss. 1-20.

- [30] EWEES Ahmed A., ABD EL-AZIZ Mohamed, ALAMEER Zakaria, YE Haiwang ve ZHANG Jianhua (2020), “Improving Multilayer Perceptron Neural Network Using Chaotic Grasshopper Optimization Algorithm to Forecast Iron Ore Price Volatility”, *Resources Policy*, Cilt 65, Makale No 101555.
- [31] KUMAR Lalji, KHEDLEKAR Sudhakar ve KHEDLEKAR U.K. (2024), “A Comparative Assessment of Holt Winter Exponential Smoothing and Autoregressive Integrated Moving Average for Inventory Optimization in Supply Chains”, *Supply Chain Analytics*, Cilt 8, ss. 1-16.
- [32] WORLD BANK GROUP (2023), *Commodity Markets Outlook: Executive Summary, April 2023: Lower Prices, Little Relief*, World Bank Group, Washington, Amerika Birleşik Devletleri.
- [33] AWAN Abid Ali (2023), *Time Series Analysis: ARIMA Models in Python*, <https://www.kdnuggets.com/2023/08/time-series-analysis-arima-models-python.html>, ET. 25.01.2025.
- [34] SHUMWAY Robert H. ve STOFFER David S. (2017), *Time Series Analysis and Its Applications: With R Examples*, Beşinci Basım, Springer, Amerika Birleşik Devletleri.
- [35] CHEN Tianqi ve GUESTRIN Carlos (2016), “XGBoost: A Scalable Tree Boosting System”, *İçinde, Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD '16)*, ss. 785–794, Association for Computing Machinery, Toronto, Kanada.
- [36] ZHOU Zhi-Hua (2021), *Machine Learning*, Springer, Singapur.
- [37] HYNDMAN Rob J. ve KOEHLER Anne B. (2006), “Another Look at Measures of Forecast Accuracy”, *International Journal of Forecasting*, Cilt 22, Sayı 4, ss. 679–688.
- [38] HARVEY Andrew C. (1990), *The Econometric Analysis of Time Series*, MIT Press, Cambridge MA.
- [39] BATES J. M. ve GRANGER C. W. J. (1969), “The Combination of Forecasts”, *Journal of the Operational Research Society*, Cilt 20, Sayı 4, ss. 451–468.
- [40] WANG Weiran, VASNEV Andrey L. ve RADCHENKO Peter (2023), “Flexible Global Forecast Combinations”, *arXiv*, <https://arxiv.org/abs/2207.07318>, ET. 09.04.2025.

EKLER

EK 1: R Kodları

```
data.raw <- read_excel("Tez_Dataset_R03.xlsx")
data.zoo <- zoo(data.raw[,-1], order.by = data.raw$DATE)
iron_ore <- data.zoo[,"IRON_ORE"]
iron_ore <- na.trim(iron_ore, sides = "both")
iron_ore <- na.approx(iron_ore)
iron_ore_wk <- to.weekly(iron_ore)
colnames(iron_ore_wk) <- c("Open", "High", "Low", "Close")
autoplot(iron_ore_wk) +
  labs(
    title = "Haftalık Demir Cevheri Fiyatları",
    subtitle = "Ekim 2014 - Ekim 2024",
    x = ""
  ) +
  theme_bw() +
  theme(
    plot.title = element_text(hjust = 0.5),
    plot.subtitle = element_text(hjust = 0.5)
  )
iron_ore_wk4 <- iron_ore_wk[,4]
data.raw$DATE <- as.Date(data.raw$DATE)
data_raw_1 <- data.raw |>
  pivot_longer(!DATE, names_to = "Metal", values_to = "Fiyat")
iore_df <- ts_df(iron_ore_wk4)
iore_tsible <- iore_df |>
  mutate(Date = yearweek(time)) |>
  as_tsibble(index = Date)
iore_tsible <- iore_tsible |>
  mutate(Date2 = as.Date(Date))
ggplot(iore_tsible, aes(x = Date2, y = value)) +
  geom_line() +
  scale_x_date(
    date_breaks = "1 year",
    date_labels = "%Y",
    expand = c(0.01, 0)
  ) +
  labs(
    title = "Haftalık Demir Cevheri Fiyatları",
    subtitle = "2014 Ekim - 2024 Ekim",
    x = "",
    y = "Fiyat (USD)",
    caption = "Kaynak: Investing / Iron ore fines 62% Fe CFR Futures - (TIOc1)"
  ) +
```

```

theme_bw() +
theme(
  plot.title = element_text(hjust = 0.5),
  plot.subtitle = element_text(hjust = 0.5)
)
iore_tsible |>
gg_season(value) +
labs(
  title = "Haftalık Demir Cevheri Fiyatları",
  subtitle = "Mevsimsellik Grafiği",
  y = "Fiyat (USD)",
  x = "Yıllar"
) +
theme_bw() +
theme(
  plot.title = element_text(hjust = 0.5, face = "bold", size = 14),
  plot.subtitle = element_text(hjust = 0.5),
  legend.position = "right"
)
ggtsdisplay(
  iron_ore_wk4,
  main = "Demir Cevheri Fiyatları Zaman Serisi & ACF ve PACF",
  xlab = "Gecikme (Hafta)",
  theme = theme_bw() +
  theme(
    plot.title = element_text(hjust = 0.5, face = "bold", size = 14)
  )
)
iore_ses <- iore_tsible |>
model(ETS(value ~ error("A") + trend("N") + season("N")))
report(iore_ses)
fc_ses <- iore_ses |>
forecast(h = 5)
fc_ses |>
autoplot(iore_tsible) +
geom_line(aes(y = .fitted), col="#D55E00",
  data = augment(iore_ses)) +
labs(y="Fiyat (USD)", x="Tarih", title="Demir Cevheri Fiyatları (SES)") +
guides(colour = "none") +
theme_bw() +
theme(
  plot.title = element_text(hjust = 0.5),
  plot.subtitle = element_text(hjust = 0.5)
)
model_summary_ses <- glance(iore_ses)
model_params_ses <- tidy(iore_ses)
alpha_value <- model_params_ses %>% filter(term == "alpha") %>% pull(estimate)
l0_value <- model_params_ses %>% filter(term == "l[0]") %>% pull(estimate)
ses_table <- tibble(

```



```

Metric = c("Model", "Alpha", "Initial Level (I[0])", "Sigma2", "AIC", "AICc",
"BIC"),
Value = c(
  "ETS(A,N,N)",
  round(alpha_value, 2),
  round(I0_value, 2),
  round(model_summary_ses$sigma2, 2),
  round(model_summary_ses$AIC, 2),
  round(model_summary_ses$AICc, 2),
  round(model_summary_ses$BIC, 2)
)
)
ses_table %>%
  gt() %>%
  tab_header(
    title = "SES Model Raporu",
    subtitle = "ETS(A,N,N) Model Özeti"
  ) %>%
  fmt_number(
    columns = c(Value),
    decimals = 4
  ) %>%
  cols_label(
    Metric = "Metrik",
    Value = "Değer"
  ) %>%
  tab_style(
    style = list(cell_text(weight = "bold")),
    locations = cells_column_labels(everything())
  ) %>%
  opt_table_outline() %>%
  opt_align_table_header(align = "center")
iore_tes <- iore_tsible |>
  model(ETS(value ~ error("A") + trend("A") + season("N")))
report(iore_tes)
fc_tes <- iore_tes |>
  forecast(h = 5)
fc_tes |>
  autoplot(iore_tsible) +
  geom_line(aes(y = .fitted), col="#D55E00",
    data = augment(iore_tes)) +
  labs(y="Fiyat (USD)", x= "Tarih", title="Demir Cevheri Fiyatları (TES)") +
  guides(colour = "none") +
  theme_bw() +
  theme(
    plot.title = element_text(hjust = 0.5),
    plot.subtitle = element_text(hjust = 0.5)
  )
model_summary_tes <- glance(iore_tes)
model_params_tes <- tidy(iore_tes)

```

```

alpha_value_tes <- model_params_tes %>% filter(term == "alpha") %>%
pull(estimate)
l0_value_tes <- model_params_tes %>% filter(term == "l[0]") %>% pull(estimate)
tes_table <- tibble(
  Metric = c("Model", "Alpha", "Initial Level (l[0])", "Sigma²", "AIC", "AICc",
"BIC"),
  Value = c(
    "ETS(A,N,N)",
    round(alpha_value_tes, 2),
    round(l0_value_tes, 2),
    round(model_summary_tes$sigma2, 2),
    round(model_summary_tes$AIC, 2),
    round(model_summary_tes$AICc, 2),
    round(model_summary_tes$BIC, 2)
  )
)
tes_table %>%
gt() %>%
tab_header(
  title = "TES Model Raporu",
  subtitle = "ETS(A,A,N) Model Özeti"
) %>%
fmt_number(
  columns = c(Value),
  decimals = 4
) %>%
cols_label(
  Metric = "Metrik",
  Value = "Değer"
) %>%
tab_style(
  style = list(cell_text(weight = "bold")),
  locations = cells_column_labels(everything())
) %>%
opt_table_outline() %>%
opt_align_table_header(align = "center")
accuracy_results <- iore_tsible |>
stretch_tsibble(.init = 10) |>
model(
  SES = ETS(value ~ error("A") + trend("N") + season("N")),
  Holt = ETS(value ~ error("A") + trend("A") + season("N")),
  Damped = ETS(value ~ error("A") + trend("Ad") +
season("N")),
  Auto = ETS(value)
) |>
forecast(h = 1) |>
accuracy(iore_tsible)
accuracy_table <- accuracy_results %>%
select(.model, RMSE, MAE, MAPE, MASE) %>%
rename(Model = .model)

```

```

accuracy_table %>%
  gt() %>%
  tab_header(
    title = "Tahmin Modelinin Doğruluk Metrikleri",
    subtitle = "ETS Modellerinin Karşılaştırması"
  ) %>%
  fnt_number(
    columns = c(RMSE, MAE, MAPE, MASE),
    decimals = 2
  ) %>%
  cols_label(
    RMSE = "Root Mean Squared Error",
    MAE = "Mean Absolute Error",
    MAPE = "Mean Absolute Percentage Error",
    MASE = "Mean Absolute Scaled Error"
  ) %>%
  tab_style(
    style = list(cell_text(weight = "bold")),
    locations = cells_column_labels(everything())
  ) %>%
  opt_table_outline() %>%
  opt_align_table_header(align = "center")
accuracy_results_comp <- iore_tsible |>
  filter(row_number() < n()) |>
  stretch_tsibble(.init = 52) |>
  model(
    ETS(value),
    ARIMA(value)
  ) |>
  forecast(h = 1) |>
  accuracy(iore_tsible) |>
  select(.model, RMSE:MAPE)
accuracy_table_comp <- accuracy_results_comp %>%
  rename(Model = .model)
accuracy_table_comp %>%
  gt() %>%
  tab_header(
    title = "Tahmin Modelinin Doğruluk Metrikleri",
    subtitle = "ETS ve ARIMA Modellerinin Karşılaştırması"
  ) %>%
  fnt_number(
    columns = c(RMSE, MAE, MAPE),
    decimals = 2
  ) %>%
  cols_label(
    Model = "Model",
    RMSE = "Root Mean Squared Error",
    MAE = "Mean Absolute Error",
    MAPE = "Mean Absolute Percentage Error"
  ) %>%

```

```

tab_style(
  style = list(cell_text(weight = "bold")),
  locations = cells_column_labels(everything())
) %>%
opt_table_outline() %>%
opt_align_table_header(align = "center")
iore_tsible |>
model(ARIMA(value)) |>
forecast(h = "16 weeks") |>
autoplot(iore_tsible) +
labs(title = "Demir Cevheri Öngörüleri (16 Hafta)",
  y = "Fiyat (USD)") +
theme_bw() +
theme(
  plot.title = element_text(hjust = 0.5),
  plot.subtitle = element_text(hjust = 0.5)
)
iore_tsible |>
model(ARIMA(value)) |>
forecast(h = "16 weeks") |>
autoplot(iore_tsible |> filter_index("2021-11-01" ~ .)) +
labs(title = "Demir Cevheri Öngörüleri (ARIMA)",
  y = "Fiyat (USD)") +
theme_bw() +
theme(
  plot.title = element_text(hjust = 0.5),
  plot.subtitle = element_text(hjust = 0.5)
)
iore_tsible |>
model(ETS(value)) |>
forecast(h = "16 weeks") |>
autoplot(iore_tsible |> filter_index("2021-11-01" ~ .)) +
labs(title = "Demir Cevheri Öngörüleri (16 Hafta)",
  y = "Fiyat (USD)") +
theme_bw() +
theme(
  plot.title = element_text(hjust = 0.5),
  plot.subtitle = element_text(hjust = 0.5)
)
iore_tsible |>
model(ETS(value)) |>
forecast(h = "32 weeks") |>
autoplot(iore_tsible) +
labs(title = "Demir Cevheri Öngörüleri (32 Hafta)",
  y = "Fiyat (USD)") +
theme_bw() +
theme(
  plot.title = element_text(hjust = 0.5),
  plot.subtitle = element_text(hjust = 0.5)
)

```

```

dt <- iore_tsible$time[length(iore_tsible$time)-156]
iore_2 <- iore_tsible |>
  filter_index(as.character(dt) ~ .)
fit_arma <- iore_2 |> model(ARIMA(value))
report(fit_arma)
fit_arma |> gg_tsresiduals(lag_max = 12)
fit_arma |>
  resid() |>
  as_tibble() |>
  select(.resid) |>
  ggtsdisplay(
    main="Son 156 Hafta ile ARIMA Residuals",
    theme=theme_bw()) +
  theme(
    plot.title = element_text(hjust = 0.5),
    plot.subtitle = element_text(hjust = 0.5)
  )
fit_arma2 <- iore_2 |> model(ARIMA(value ~ pdq(2,0,1) + PDQ(0,0,0)))
report(fit_arma2)
fit_arma2 |> gg_tsresiduals(lag_max = 12)
fit_arma2 |>
  resid() |>
  as_tibble() |>
  select(.resid) |>
  ggtsdisplay(
    main="Son 156 Hafta ile ARIMA(2,0,2) Residuals",
    theme=theme_bw()) +
  theme(
    plot.title = element_text(hjust = 0.5),
    plot.subtitle = element_text(hjust = 0.5)
  )
arma_params1 <- tidy(fit_arma)
arma_params2 <- tidy(fit_arma2)
arma_params1 %>%
  select(!.model) %>%
  gt() %>%
  tab_header(
    title = "ARIMA Model Parametreleri",
    subtitle = "Katsayı Tahmini"
  ) %>%
  fmt_number(
    columns = c(estimate, std.error, statistic),
    decimals = 2
  ) %>%
  fmt_scientific(
    columns = c(p.value),
    decimals = 2
  ) %>%
  cols_label(
    term = "Terim",

```

```

estimate = "Tahmin",
std.error = "Std. Sapma",
statistic = "İstatistik",
p.value = "P-Değeri"
) %>%
tab_style(
  style = list(cell_text(weight = "bold")),
  locations = cells_column_labels(everything())
) %>%
opt_table_outline() %>%
opt_align_table_header(align = "center")
arima_params2 %>%
select(!.model) %>%
gt() %>%
tab_header(
  title = "ARIMA(2,0,1) + (0,0,0) Model Parametreleri",
  subtitle = "Katsayı Tahmini"
) %>%
fmt_number(
  columns = c(estimate, std.error, statistic),
  decimals = 2
) %>%
fmt_scientific(
  columns = c(p.value),
  decimals = 2
) %>%
cols_label(
  term = "Terim",
  estimate = "Tahmin",
  std.error = "Std. Sapma",
  statistic = "İstatistik",
  p.value = "P-Değeri"
) %>%
tab_style(
  style = list(cell_text(weight = "bold")),
  locations = cells_column_labels(everything())
) %>%
opt_table_outline() %>%
opt_align_table_header(align = "center")
week(head(iron_ore_wk4))
iron_ore_ts <- ts(coredata(iron_ore_wk4), start=c(2014,40), frequency = 52)
iron_xgb <- xgbar(iron_ore_ts)
summary(iron_xgb)
fc_xgbar <- forecast(iron_xgb, h = 24)
plot(fc_xgbar)
iron_xgb2 <- xgbar(iron_ore_ts, trend_method = "differencing", seas_method =
"fourier")
plot(forecast(iron_xgb2, 24))
summary(iron_xgb2)
iron_xgb <- xgbar(iron_ore_ts, maxlag = 26,

```

```

trend_method = "differencing",
seas_method = "decompose")
summary(iron_xgb)
fc_xgbar <- forecast(iron_xgb, h = 24)
plot(fc_xgbar)
xgb_bind <- ts.union(fitted(iron_xgb), iron_ore_ts)
colnames(xgb_bind) <- c("Fitted", "Actual")
ts_df(xgb_bind)
autoplot(xgb_bind) +
  scale_color_manual(values=c("blue", "gray40")) +
  labs(
    title = "Demir Cevheri Fiyatları (XGBoost)",
    subtitle = "Mavi: Tahmin, Gri: Gerçek",
    y = "",
    x = ""
  ) +
  theme_bw() +
  theme(
    plot.title = element_text(hjust = 0.5),
    plot.subtitle = element_text(hjust = 0.5)
  )
xgb_bind2 <- ts.intersect(fitted(iron_xgb), iron_ore_ts)
colnames(xgb_bind) <- c("fitted", "Actual")
yardstick::rmse_vec(as.vector(xgb_bind2[,2]), as.vector(xgb_bind2[,1]))
sqrt(mean((xgb_bind[,2]-xgb_bind[,1])^2, na.rm = TRUE))
iron_xgb2 <- xgbar(iron_ore_ts, maxlag = 52,
  trend_method = "differencing",
  seas_method = "fourier")
plot(forecast(iron_xgb2, 24))
summary(iron_xgb2)
autoplot(ts.union(fitted(iron_xgb2), iron_ore_ts)) +
  scale_color_manual(values=c("blue", "gray40")) +
  labs(
    title = "Demir Cevheri Fiyatları (XGBoost)",
    subtitle = "Mavi: Tahmin, Gri: Gerçek",
    y = "",
    x = ""
  ) +
  theme_bw() +
  theme(
    plot.title = element_text(hjust = 0.5),
    plot.subtitle = element_text(hjust = 0.5)
  )
iron_ore_ts <- ts(coredata(iron_ore_wk4), start=c(2014,40), frequency = 52)
fc_arima <- forecast(auto.arima(iron_ore_ts), h=24)
fc_ets <- forecast(ets(iron_ore_ts), h=24)
fc_xgb <- forecast(xgbar(iron_ore_ts), h=24)
fc_combined <- (fc_arima$mean + fc_ets$mean + fc_xgb$mean) / 3
plot(fc_xgb, main="Forecast Combination (Eşit Ağırlıklı)")
lines(fc_arima$mean, col="blue")

```

```

lines(fc_ets$mean, col="green")
lines(fc_combined, col="red", lwd=2)
legend("topright", legend=c("ARIMA", "ETS", "XGBoost", "Combined"),
      col=c("blue", "green", "black", "red"), lty=1, lwd=c(1,1,1,2))
train <- window(iron_ore_ts, end=c(2024,52))
test_horizon <- 24
fit_arma <- auto.arma(train)
fit_ets <- ets(train)
fit_xgb <- xgbar(train)
fitted_arma <- fitted(fit_arma)
fitted_ets <- fitted(fit_ets)
fitted_xgb <- fitted(fit_xgb)
actual_values <- train[(length(train) - length(fitted_arma) + 1):length(train)]
comb_model <- lm(actual_values ~ fitted_arma + fitted_ets + fitted_xgb)
coeffs <- coef(comb_model)
fc_combined <- coeffs[1] +
  coeffs[2] * forecast(fit_arma, h=test_horizon)$mean +
  coeffs[3] * forecast(fit_ets, h=test_horizon)$mean +
  coeffs[4] * forecast(fit_xgb, h=test_horizon)$mean
plot(fc_xgb, main="Forecast Combination (Regresyon Ağırlıklı)")
lines(fc_arma$mean, col="blue")
lines(fc_ets$mean, col="green")
lines(fc_combined, col="red", lwd=2)
legend("topright", legend=c("ARIMA", "ETS", "XGBoost", "Combined"),
      col=c("blue", "green", "black", "red"), lty=1, lwd=c(1,1,1,2))
x <- data.frame(iron_ore_wk4, covid=1,
  date=seq.Date(as.Date("2014/10/1"), by = "week", length.out=523))
x.zoo <- zoo(x$iron_ore_wk4, order.by = x$date)
x.f <- rollapply(x.zoo, 52,
  FUN= function(x) coredata(forecast(auto.arma(x),10)$mean),
  fill = NA, align="right")
ms <- function(x1, x1.f){
  xx <- na.omit(merge(x1,x1.f))
  mss <- 0
  for (i in 1:(dim(xx)[1]-10)){
    mss <- mss + mean((coredata(xx[i,2:11]) - coredata(xx[i:(i+9),1]))^2)
  }
  mss/(dim(xx)[1]-10)
}
ms(x.zoo, x.f)
df_plot_actual <- data.frame(date = time(x.zoo), value = coredata(x.zoo), type =
"Gerçek Veri")
df_plot_forecast <- data.frame(date = time(x.f), value = coredata(x.f)[,1], type =
"Tahmin")
df_plot <- rbind(df_plot_actual, df_plot_forecast)
ggplot(df_plot, aes(x = date, y = value, color = type)) +
  geom_line(size = 1) +
  scale_color_manual(values = c("Gerçek Veri" = "black", "Tahmin" = "blue")) +
  ggtitle("Demir Cevheri Fiyat Tahmini vs Gerçek Veriler (Rollapply)") +
  labs(x = "Tarih", y = "Fiyat (USD)", color = "Veri Türü") +

```



```

  theme_minimal()
iore_tsible_w <- iore_tsible |>
  slide_tsibble(.size=78) |>
  rename(id=.id)
accuracy_sliding <- c()
for(i in unique(iore_tsible_w$id)){
  accuracy_slide_comp <- iore_tsible_w |>
    filter(id==i) |>
    stretch_tsibble(.init = 52) |>
    model(
      ETS(value),
      ARIMA(value)
    ) |>
    forecast(h = "1 month") |>
    accuracy(iore_tsible_w) |>
    select(.model, RMSE:MAPE) |>
    mutate(slide = i)
  accuracy_sliding <- rbind(accuracy_sliding, accuracy_slide_comp)
}
iore_tsible_w <- iore_tsible |>
  slide_tsibble(.size=104) |>
  rename(id=.id)
accuracy_sliding_4 <- c()
accuracy_sliding_1 <- c()
param_ETS <- c()
param_arima <- c()
for(i in unique(iore_tsible_w$id)){
  iore_tsible_ws <- iore_tsible_w |>
    filter(id==i)
  fc <- iore_tsible_ws |>
    stretch_tsibble(.init = 78) |>
    model(
      ETS(value),
      ARIMA(value)
    )
  param_ETS <- rbind(param_ETS,
    tidy(fc) |> select(-.model) |> mutate(slide=i))
  report(fc) |> dplyr::filter(grepl('ARIM', .model)) |> select(.model:BIC)
  acc <- fc |>
    forecast(h = "1 month") |>
    accuracy(iore_tsible_ws) |>
    select(.model, RMSE:MAPE) |>
    mutate(slide = i)
  accuracy_sliding_4 <- rbind(accuracy_sliding_4, acc)
  acc_1 <- fc |>
    forecast(h = 1) |>
    accuracy(iore_tsible_ws) |>
    select(.model, RMSE:MAPE) |>
    mutate(slide = i)
  accuracy_sliding_1 <- rbind(accuracy_sliding_1, acc_1)

```

```

}
a1 <- accuracy_sliding_1 |>
  dplyr::filter(grepl('ARIM', .model)) |>
  ggplot(aes(x=RMSE)) +
  geom_histogram(binwidth=0.5, fill="gray60", color="#e9ecef", alpha=0.9) +
  labs(
    title = "RMSE of 1-Step Cross Validation",
    subtitle = "Sliding Window: 78 Obs.",
    y=""
  ) +
  theme_bw() +
  theme(
    plot.title = element_text(size=15)
  )
a4 <- accuracy_sliding_4 |>
  dplyr::filter(grepl('ETS', .model)) |>
  ggplot(aes(x=RMSE)) +
  geom_histogram(binwidth=0.5, fill="gray60", color="#e9ecef", alpha=0.9) +
  labs(
    title = "RMSE of 4-Step Cross Validation",
    subtitle = "Sliding Window: 78 Obs.",
    y=""
  ) +
  theme_bw() +
  theme(
    plot.title = element_text(size=15)
  )
a1 / a4
accuracy_sliding_1 |>
  dplyr::filter(grepl('ARIM', .model)) |>
  ggplot(aes(x=slide, y=RMSE)) +
  geom_line() +
  labs(
    title = "RMSE of 1-Step Cross Validation",
    subtitle = "Sliding Window: 78 Obs.",
    y="RMSE",
    x = ""
  ) +
  theme_bw() +
  theme(
    plot.title = element_text(size=15)
  )
accuracy_sliding_4 |>
  dplyr::filter(grepl('ARIM', .model)) |>
  ggplot(aes(x=slide, y=RMSE)) +
  geom_line() +
  labs(
    title = "RMSE of 4-Step Cross Validation",
    subtitle = "Sliding Window: 78 Obs.",
    y="RMSE",

```

```

    x = ""
  ) +
  theme_bw() +
  theme(
    plot.title = element_text(size=15)
  )
a1_rmse <- accuracy_sliding_1 |> filter(grepl('ARIM', .model)) # |> select(.model,
RMSE, slide)
a4_rmse <- accuracy_sliding_4 |> filter(grepl('ARIM', .model)) # |> select(.model,
RMSE, slide)
a1_rmse |>
  filter(grepl('ARIM', .model)) |>
  ggplot(aes(x=slide, y=RMSE)) +
  geom_line() +
  geom_line(data=a4_rmse, aes(x=slide, y=RMSE), col="blue", linetype=2) +
  labs(
    title = "RMSE of 1 and 4-Step Cross Validation",
    subtitle = "Sliding Window: 78 Obs., Solid= 1-step",
    y="RMSE",
    x = ""
  ) +
  theme_bw() +
  theme(
    plot.title = element_text(size=15)
  )
dt <- iore_tsible_w |> group_by(id) |> slice_tail(n = 1) |> ungroup()
arima_cv <- left_join(a1_rmse, a4_rmse, by=join_by(".model", "slide")) |>
  mutate(date=dt$time)
arima_rmseplot <- arima_cv |>
  ggplot(aes(x=date, y=RMSE.y)) +
  geom_line(linetype=2) +
  geom_line(aes(x=date, y= RMSE.x)) +
  labs(
    title = "RMSE: 1 ve 4-Adım CV",
    subtitle = "Kayan Pencere: 78 Göz., Kesikli= 4-adım",
    y="RMSE",
    x = ""
  ) +
  theme_bw() +
  theme(
    plot.title = element_text(size=11)
  )
arima_maeplot <- arima_cv |>
  ggplot(aes(x=date, y=MAE.y)) +
  geom_line(linetype=2) +
  geom_line(aes(x=date, y= MAE.x)) +
  labs(
    title = "MAE",
    # subtitle = "Kayan Pencere: 78 Göz., Kesikli= 4-adım",
    y="MAE",

```

```

    x = ""
  ) +
  theme_bw() +
  theme(
    plot.title = element_text(size=11)
  )
  arima_mapeplot <- arima_cv |>
  ggplot(aes(x=date, y=MAPE.y)) +
  geom_line(linetype=2) +
  geom_line(aes(x=date, y= MAPE.x)) +
  labs(
    title = "MAPE",
    # subtitle = "Sliding Window: 78 Obs., Solid= 1-step",
    y="MAPE",
    x = ""
  ) +
  theme_bw() +
  theme(
    plot.title = element_text(size=11)
  )
  arima_mpeplot <- arima_cv |>
  ggplot(aes(x=date, y=MPE.y)) +
  geom_line(linetype=2) +
  geom_line(aes(x=date, y= MPE.x)) +
  labs(
    title = "MPE",
    # subtitle = "Sliding Window: 78 Obs., Solid= 1-step",
    y="MPE",
    x = ""
  ) +
  theme_bw() +
  theme(
    plot.title = element_text(size=11)
  )
  (arima_rmseplot + arima_maeplot) / (arima_mapeplot + arima_mpeplot)
  e1_rmse <- accuracy_sliding_1 |> filter(grepl('ETS', .model)) # |> select(.model,
  RMSE, slide)
  e4_rmse <- accuracy_sliding_4 |> filter(grepl('ETS', .model)) # |> select(.model,
  RMSE, slide)
  ets_cv <- left_join(e1_rmse, e4_rmse, by=join_by(".model", "slide")) |>
  mutate(date=dt$time)
  ets_rmseplot <- ets_cv |>
  ggplot(aes(x=date, y=RMSE.y)) +
  geom_line(linetype=2) +
  geom_line(aes(x=date, y= RMSE.x)) +
  labs(
    title = "RMSE: 1 ve 4-Adım CV",
    subtitle = "Kayan Pencere: 78 Göz., Kesikli= 4-adım",
    y="RMSE",
    x = ""
  )

```

```

) +
theme_bw() +
theme(
  plot.title = element_text(size=11)
)
ets_maeplot <- ets_cv |>
ggplot(aes(x=date, y=MAE.y)) +
geom_line(linetype=2) +
geom_line(aes(x=date, y= MAE.x)) +
labs(
  title = "MAE",
  # subtitle = "Kayan Pencere: 78 Göz., Kesikli= 4-adım",
  y="MAE",
  x = ""
) +
theme_bw() +
theme(
  plot.title = element_text(size=11)
)
ets_mapeplot <- ets_cv |>
ggplot(aes(x=date, y=MAPE.y)) +
geom_line(linetype=2) +
geom_line(aes(x=date, y= MAPE.x)) +
labs(
  title = "MAPE",
  # subtitle = "Sliding Window: 78 Obs., Solid= 1-step",
  y="MAPE",
  x = ""
) +
theme_bw() +
theme(
  plot.title = element_text(size=11)
)
ets_mpeplot <- ets_cv |>
ggplot(aes(x=date, y=MPE.y)) +
geom_line(linetype=2) +
geom_line(aes(x=date, y= MPE.x)) +
labs(
  title = "MPE",
  y="MPE",
  x = ""
) +
theme_bw() +
theme(
  plot.title = element_text(size=11)
)
(ets_rmseplot + ets_maeplot) / (ets_mapeplot + ets_mpeplot)
tb4 <- accuracy_sliding_4 |>
group_by(.model) |>
summarise(

```

```
  min_RMSE=min(RMSE),
  mean_RMSE=mean(RMSE),
  sd_RMSE=sd(RMSE),
  max_RMSE=max(RMSE)
) |>
rename(Model=.model) |>
mutate(Model=str_replace(Model, fixed("(value)"), "_4"))
accuracy_sliding_1 |>
group_by(.model) |>
summarise(
  min_RMSE=min(RMSE),
  mean_RMSE=mean(RMSE),
  sd_RMSE=sd(RMSE),
  max_RMSE=max(RMSE)
) |>
rename(Model=.model) |>
mutate(Model=str_replace(Model, fixed("(value)"), "_1")) |>
rbind(tb4)
```

EK 2: R Paketleri

```
library(readxl)
library(zoo)
library(xts)
library(tidyverse)
library(tsbox)
library(fpp3)
library(forecast)
library(gt)
library(feasts)
library(fable)
library(broom)
library(ForecastComb)
library(lubridate)
library(dplyr)
library(forecastxgb)
library(reshape2)
library(patchwork)
```