

## BÖLÜM 2

# KOVID-19 PANDEMİ SÜRECİ ALTINDA BRENT HAM PETROL FİYATLARININ ÖNGÖRÜLMESİ: KOŞULLU LSTM MODELİ

Aygül ANAVATAN<sup>1</sup>

### GİRİŞ

Birincil yakıtlar, yani ham petrol, doğal gaz ve elektrik kömürü, birincil enerjiye yönelik toplam küresel talebe hakimdir. Bunların arasında ham petrol, uygulamaların evrenselliği ve taşımada ikame maddelerinin pratikte bulunmaması nedeniyle özellikle önemli bir rol oynamaktadır. Brent tipi ham petrol, dünya piyasasında en önemli ham petrol fiyatlama kaynaklarından biri olarak kabul edilmekte ve dünyada işlem gören ham petrol arzının üçte ikisinin fiyatını belirlemek için kullanılmaktadır.

Yenilenemez güç kaynaklarından biri olan ham petrol, çağdaş endüstrinin can damarıdır. Sanayi, ulaşım, otomobil, kozmetik, enerji, kimya, ilaç gibi birçok sektörde kullanılan ham petrol, dünya ekonomisinde çok önemli yere sahiptir ve bu nedenle “siyah altın” olarak kabul edilmektedir.

Tarihsel olarak, enerji kaynakları toplumsal refah ve ekonomik büyüme için stratejik öneme sahiptir. Bu nedenle, ham petrol fiyat dalgalanmalarını tahmin etmek önemli bir konudur. Ham petrol fiyat değişimleri, piyasalardaki birçok risk faktöründen etkilendiği için bu fiyat, geçmişe oranla daha karmaşık doğrusal olmayan davranış göstermekte ve yatırımcılar için daha fazla risk seviyesi oluşturmaktadır. Bununla birlikte, ham petrol zaman serilerinin kaotik ve doğrusal olmayan özellikleri, ham petrol fiyatlarının yüksek doğrulukta tahmin edilmesini zorlaştırmaktadır.

Petrol şirketleri, altın, ham petrol ve dolar ile olan ilişkileri nedeniyle küresel borsadaki ekonomik göstergeleri, dünya ekonomisini ve piyasasını büyük ölçüde etkileyen dünyanın en büyük şirketleri arasındadır. Petrolün bankalar, imalat şirketleri, rafineriler gibi birçok büyük finans kuruluşunun kararları üzerinde yük-

<sup>1</sup> Dr. Öğr. Üyesi, Pamukkale Üniversitesi Ekonometri Bölümü, aanavatan@pau.edu.tr

sek bir etkiye sahip olduğu düşünüldüğünde, petrol fiyatlarının gelecekteki eğilimini doğru bir şekilde tahmin etmek önem kazanmaktadır. Ayrıca, petrol birçok sektörde üretim süreçlerine girdi olarak katıldığından maliyetlerin ortaya çıkarılmasında önemli rol oynamaktadır. Petrol ekonomik değerinden dolayı birçok ülkede ekonomik krizlerin de temel sebebi olmuştur. Bu nedenle petrol fiyatlarının geçmiş verilerinin analiz edilmesi oldukça önemlidir. Finansal piyasalardaki en büyük zorluk, piyasanın geleceğini modellemek ve tahmin etmektir. Finansal piyasalarda ele alınması gereken en önemli konulardan biri, küresel ekonomiyi önemli ölçüde etkileyen petrol getirisinin ve fiyatının gelecekteki eğilimidir. Bu analizleri gerçekleştirebilmek için geleneksel yöntemlerin yanı sıra son yıllarda popüler olan yapay zekâ teknikleri kullanılmaktadır.

Makine ve derin öğrenme gibi çeşitli yaklaşımlarla uygulanan parametrik olmayan modellerin, klasik doğrusal modellere göre veri setine çok daha iyi uyum sağlayabildiği ortaya çıkarılmıştır (Sajadi vd., 2022).

Literatürde, derin öğrenme teknikleriyle petrol fiyatlarını modelleyen pek çok çalışma bulunmaktadır (Ali Salamai (2023), Bildirici vd. (2020), Bristone vd. (2020), Cen & Wang (2019), Chen vd. (2017), Firouzjaee & Khaliliyan (2022), Guo (2019), Heravi vd. (2022), Jiang vd., (2022), Kim vd. (2022), Li vd., (2019), Makala & Li (2019), Niu vd. (2021), Safi vd. (2022) ve Zhao vd. (2017)). Yiğit vd. (2021), Brent Petrol fiyatlarına ait 1987 ile 2020 yıllarına ait toplam 8267 veriyi ARIMA ve LSTM modeli ile tahmin etmiştir. LSTM modelinin daha iyi tahminler verdiği sonucuna ulaşmıştır. Sajadi vd. (2022), kovid-19 ve SARS dönemini inceleyerek Brent petrol getirilerine ait öngörülerini hesaplamıştır. Aynı model tahmini için LSTM ve CNN'i (evrişimli sinir ağı) birleştiren hibrit bir model önermiştir.

Jiao vd. (2022) metin madenciliği teknolojisi ve derin öğrenme modeline dayalı olarak ham petrol piyasasının oynaklığını tahmin etmek için bir yöntem önermiştir. İlk olarak, metin madenciliği teknolojisi, ham petrol piyasasının haber başlıklarında gizlenen duygusal kutupluluk puanı, yatırımcı duyarlılığı sınıflandırması ve risk faktörleri dahil olmak üzere metinsel özellikleri oluşturmak için kullanılmıştır. Ardından, ham petrol piyasasının dalgalanmalarını yansıtan diğer özelliklerle birlikte metinsel özellikler LSTM modelinin girdileri olarak birleştirilmiştir.

Zhang & Hong (2022) ve Nasir vd. (2023) ARIMA ve LSTM modeli ile ham petrol fiyatlarını incelemiştir. Daneshvar vd. (2022), Brent tipi ham petrolün fiyatını tahmin etmek için yinelemeli sinir ağının mimarisi olan LSTM ve çift yönlü LSTM yöntemlerini uygulamıştır. Altan & Karasu (2022), petrol fiyatlarını tahmin etmede LSTM modelinin yanı sıra, trend, volatilité ve momentum gibi tek-

nik göstergeleri ve kaotik Henry gaz çözünürlüğü optimizasyonunu (CHGSO) içeren yeni bir tahmin modeli denemiştir. Santoso vd. (2022) ise derin öğrenme teknikleriyle petrol boru hattındaki basıncı tahmin etmiştir. Manowska & Bluszcz (2022), Polonya pazarındaki mevcut durumu ve 2040'a kadar olan süreçte ham petrol tüketimini analiz etmeyi amaçlamıştır.

Bu çalışmanın amacı, Brent petrol fiyatlarını istatistiksel yöntem olan ARIMA ve derin öğrenme tekniği olan LSTM ve koşullu LSTM modellerini kullanarak tahmin etmek ve öngörü yapmaktır. Serinin kendi değerlerine ek olarak avro/dolar endeksi, doğalgaz fiyatı, ABD dolar endeksi, kovid-19 kukla değişkeni girdi olarak kullanılmıştır. Bu çalışmanın, literatüre katkısı kovid-19 etkisinin göz önüne alınmasıdır. Koşullu LSTM modelinin kullanılması sayesinde, kovid-19 etkisini temsil eden kukla değişken eğitim setine dahil edilmeden yardımcı (auxiliary) özellik olarak modele eklenebilmektedir.

Çalışmanın geri kalanı şu şekilde organize edilmiştir. Öncelikle yöntem başlığı altında çalışmada kullanılan ARIMA, LSTM ve koşullu LSTM modellerinin yapısı aktarılmıştır. Ardından araştırma modeli tanıtılmış ve verilerin analizinde izlenen yol açıklanmıştır. Daha sonra bulgular raporlanmış ve sonuç, tartışma ve öneriler sunularak çalışma tamamlanmıştır.

## **YÖNTEM**

### **ARIMA Modeli**

Otoregresif hareketli ortalama (ARMA) modeli, Box & Jenkins (1970) tarafından hareketli ortalama ve otoregresif modellerin birleştirilmesiyle ortaya atılmıştır.  $\{\epsilon_t\}$ 'nin sıfır ortalamalı beyaz gürültü süreci ve  $k=1,2,..p$  için  $cov(\epsilon_t, y_{t-k})=0$  olan ARMA(p, q) modeli Denklem (1)'deki gibi yazabilir:


$$y_t = c + \sum_{i=1}^p a_i y_{t-i} + \sum_{j=1}^q b_j \epsilon_{t-j} + \epsilon_t \quad (1)$$

Denklem (1)'de p, AR derecesini ve q, MA derecesini ifade etmektedir. ARMA modelinde bağımlı değişken durağan değilse, durağanlık derecesine göre fark alınarak otoregresif bütünleşik hareketli ortalama (ARIMA) modeli tahmin edilmektedir. ARIMA modeli (p, d, q) olmak üzere üç bileşenden oluşmaktadır. Burada d, durağanlık derecesini göstermektedir. Bir zaman serisinin tanıtılmasını belirlemek, tahmin etmek ve gerçekleştirmek için ARIMA modellerinde Box-Jenkins yaklaşımı kullanılabilir. İlk olarak, zaman serisinin durağan olması veya durağan hale getirilmesi için fark alınması gerekmektedir. Daha sonra Akaike bilgi kriterleri (AIC) veya Schwartz bilgi kriterleri (SIC) gibi bir bilgi kriteri karşılaştırılarak p ve q derecesi tespit edilmektedir.

## LSTM Modeli

Hochreiter & Schmidhuber (1997) tarafından önerilen uzun kısa süreli bellek (long short-term memory-LSTM) yöntemi, tekrarlayan sinir ağlarının (recurrent neural networks-RNN) bir türüdür. Tekrarlayan sinir ağları, bilginin devam etmesine izin veren, içinde döngüler bulunan ağlardır. Tekrarlayan bir sinir ağı, aynı ağı her biri bir sonrakine mesaj ileten birden fazla kopyası olarak düşünülebilir. Bu zincir benzeri yapı, tekrarlayan sinir ağlarının serilerle yakından ilişkili olduğunu ortaya koymaktadır. RNN'ler konuşma tanıma, dil modelleme, çeviri, resim alt yazısı gibi çeşitli sorunlara uygulamada başarılıdır. Bu başarıların temelinde, tekrarlayan sinir ağlarının bir türü olan LSTM'lerin kullanılması yer almaktadır.

LSTM modelinin tasarlanmasındaki temel amaç, uzun bellekteki bağımlılıkları öğrenebilmesidir. LSTM ağındaki kapılar, çıktının 0 ile 1 arasında olduğu sigmoid aktivasyon fonksiyonu ile bilgi işlemeye yardımcı olmaktadır. Unutma kapısı, önceki bilginin kullanılıp kullanılmayacağını ve evet ise ne kadar kullanılabileceğini belirleyen önceki adımdaki bilgi akışını kontrol etmektedir. Girdi kapısı, bu mevcut bilgiyi süreçte kullanıp kullanmadığımızı ve kullanıyorsak ne kadarını kullanmamız gerektiğini inceleyen yeni bilgiyi kontrol etmektedir. Son olarak çıktı kapısı, önceki ve şimdiki zaman adımlarından ne kadar bilginin birleştirilip bir sonraki adıma aktarılması gerektiğini incelemektedir. Şekil 1'de dört katmanlı bir LSTM modeli verilmiştir.



Şekil 1. LSTM Modelindeki Etkileşimli Dört Katman (Kaynak: Olah (2015))

Şekil 1'de görüldüğü gibi LSTM girdi ( $x_t$ ), unutma ( $\sigma$ ) ve çıktı ( $h_t$ ) olmak üzere üç kapıya ve çıktı aktivasyon fonksiyonlarına sahiptir. Sarı kutular eğitilmiş sinir

ağı katmanlarını, pembe daireler ise vektör toplama, çarpma gibi noktasal işlemleri temsil etmektedir. İlk sırada yer alan Sigmoid ( $\sigma$ ) katmanı, her bileşenin ne kadarının bir sonraki katmana geçmesine izin verildiğini gösterir ve sıfır ile bir arasında değerler alır. Sıfır değeri “hiçbir şeyin geçmesine izin verme” anlamına gelirken, bir değeri “her şeyin geçmesine izin ver” anlamına gelir. Buna “*unutma katmanı*” adı verilir.

Bir sonraki adım, hücrede hangi yeni bilgilerin depolanacağına karar vermektir. Buna karar verirken ilk olarak, “*girdi geçidi katmanı*” olarak adlandırılan sigmoid katmanı, hangi değerlerin güncelleneceğini belirler. Ardından, “*tanh katmanı*” yeni aday değerlerin bir vektörünü oluşturur ve hücre güncellemesi oluşturmak için bu iki katmandaki bilgiler birleştirilir.

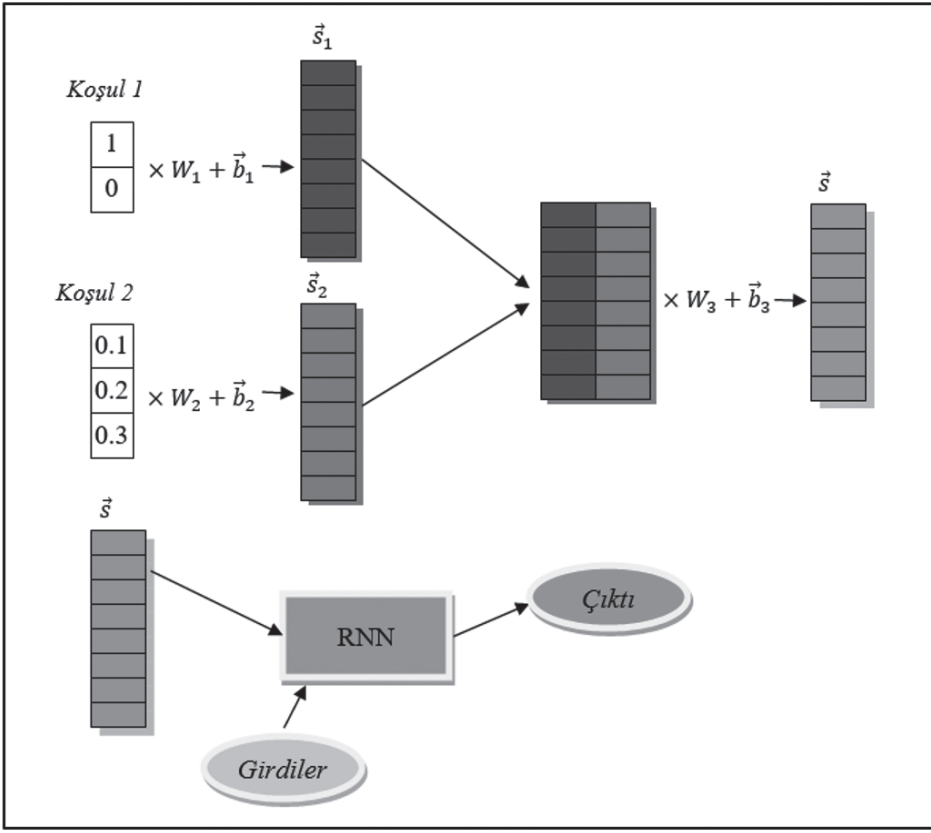
Son olarak, çıktıya karar verilmektedir. Buna karar verirken ilk olarak, hücrede hangi kısımların çıkarılacağını belirleyen sigmoid katmanı çalıştırılır. Ardından, hücredeki değerleri -1 ile 1 arasında sıkıştırmak için değerler fonksiyonuna tabi tutulur ve sigmoid katmanının çıktısıyla çarpılır. Böylece, sadece karar verilen parçalar hücrenin çıktısı olarak alınır.

### **Koşullu LSTM Modeli**

Koşullu yinelemeli yapay sinir ağları modellerinde, zamanla değişmeyen (time-invariant) değişkenler üzerinde zaman serisi tahminleri koşullandırılmaktadır. Koşullu yinelemeli katman eklemek, zamana bağlı olmayan dışsal girdilere sahip zaman serileri için avantajlı olmaktadır. Eğer zamandan bağımsız girdiler varsa model tahmininde aşağıdaki seçenekler mevcuttur (Remy, 2020);

- zamandan bağımsız girdileri zaman serisi verileriyle birleştirmek (bu yöntem tavsiye edilmemektedir)
- bu girdileri RNN katmanının çıktısıyla birleştirmek (RNN katmanı bu yardımcı bilgiyi görmeyeceğinden, bu bir tür RNN sonrası ayarlamadır.)

Şekil 2’de koşullu yinelemeli sinir ağı mimarisi verilmektedir. Koşul 1’deki gibi bir kukla değişken kullanılabilmesi gibi, koşul 2’deki gibi sayısal değerlere sahip zamanla değişmeyen bir değişken dışsal olarak ele alınabilir. İlk aşamada, koşullar ağırlıklandırılarak  $\vec{s}$  vektörü elde edilir ardından  $P(x_{t+1}|x_{0:t}, \vec{s})$  ifadesi modellenir.



Şekil 2. Koşullu Yinelemeli Sinir Ağı Mimarisi

Şekil 2'deki RNN modeli için LSTM, GRU (Kapı Özyinelemeli Geçitler-Gated Recurrent Units) gibi çeşitli yöntemler kullanılabilir.

#### Araştırma Modeli

Modelin yapısını tasarlarken, verimli bir hesaplama yükü sağlamak için aktivasyon fonksiyonu olarak "relu" kullanılmıştır. İterasyon sayısı ve küme büyüklüğü çoğunlukla literatürde kabul gören değerleri ile 100 ve 32 olarak alınmıştır. Çalışmada Adam optimizasyon yönteminin tercih edilmesinin sebebi RMSProp ve Momentum'un bir kombinasyonu olmasıdır. Adam optimizasyon yöntemi ile her parametre için uyarlanabilir öğrenme oranı hesaplanabilmektedir. Tablo 1'de analizde kullanılan LSTM modellerinin özellikleri sunulmaktadır.

**Tablo 1. Tahmin edilen LSTM modelinin özellikleri**

Özellik	Değer
Girdi Katmanı Sayısı	1 (100 Nöron)
Ara Katman Sayısı	4 (100 Nöron)
Çıktı Katmanı Sayısı	1 (1 Nöron)
Aktivasyon Fonksiyonu	Relu
İterasyon sayısı	100
Küme (Batch) Büyüklüğü	32
Pencere Büyüklüğü	20
Optimizasyon	Adam

## Verilerin Analizi

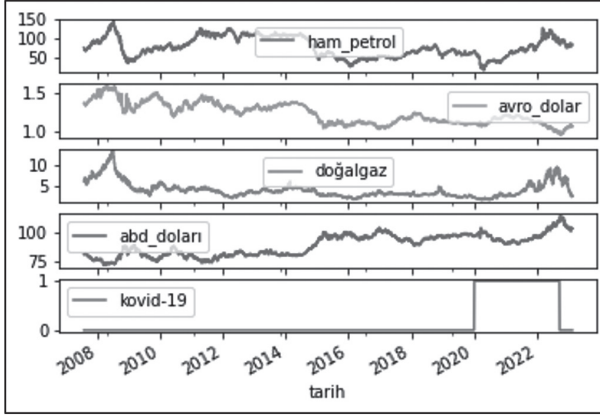
Uygulamada kullanılan Brent petrol fiyatları, avro/dolar endeksi, doğalgaz fiyatı, ABD dolar endeksi değişkenleri *Yahoo Finance* internet sitesinden elde edilmiştir. Kovid-19 kukla değişkeni kovid-19 vakasının görüldüğü ilk tarih olan 31/12/2019 ile öldürücü etkisini kaybettiği 18/09/2022 tarihe kadar 1, diğer zamanlarda 0 olacak şekilde oluşturulmuştur. 30/07/2007 ile 14/02/2023 tarihleri arasında Brent petrole ait fiyat verisi olan günlere göre zaman serisi oluşturulmuş ve diğer değişkenlere ait eksik gözlemler doğrusal interpolasyon yöntemiyle doldurulmuştur. Girdi değişkenleri aşağıdaki denkleme göre normalize edilmiştir:

$$x_{norm} = \frac{x - x_{min}}{x_{maks} - x_{min}} \quad (2)$$

Verilerin analizinde Python programlama dili kullanılmıştır. ARIMA, LSTM ve koşullu LSTM olmak üzere üç tür model tahmin edilmiştir. Koşullu LSTM modelinin tahmini için, Remy (2020) tarafından geliştirilen `cond_rnn` paketi kullanılmıştır. Eğitim seti eğitildikten sonra ortalama mutlak hata (MAE), ortalama mutlak yüzde hata (MAPE), ortalama yüzde hata (MPE), hata kareler ortalamasının karekökü (RMSE) ölçütlerine göre modellerin performansları karşılaştırılmıştır. Ardından her model için 60 günlük öngörü yapılmıştır.

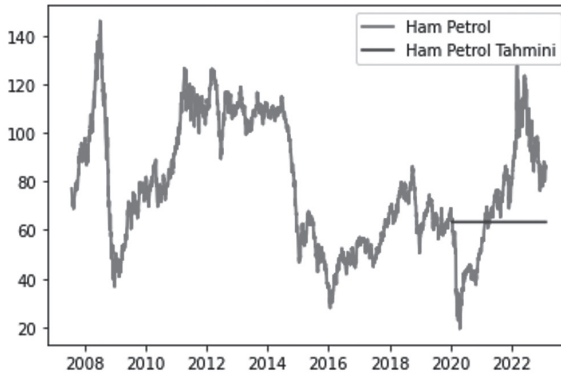
## BULGULAR

Brent petrol fiyatlarını tahmin etmek için gerçekleştirilen zaman serisi analizinde ARIMA, LSTM ve koşullu LSTM modeli karşılaştırılmıştır. Modellerde 30/07/2007 ile 14/02/2023 tarihleri arasındaki günlük Brent petrol fiyatları, avro/dolar endeksi, doğalgaz fiyatı, ABD dolar endeksi ve kovid-19 kukla değişkeni girdi olarak kullanılmıştır. Analizde kullanılan değişkenlerin zamana bağlı değişimi Şekil 3'te gösterilmektedir.



Şekil 3. Değişkenlerin zamana bağlı grafiği


Çalışmada, 30/07/2007 ile 14/02/2023 tarihleri arasında kullanılan değişkenlere ait toplam 3857 adet veri kullanılmıştır. Bu verilerin %80'i (3065 adet, 30/07/2007-22/01/2020) eğitim için, %20'si (722 adet, 23/01/2020-14/02/2023) test için ayrılmıştır. Öncelikle ARIMA model denemeleri yapılmış ve Akaike bilgi kriterine (AIC) göre en iyi model ARIMA(3,1,2) olarak seçilmiştir. LSTM modelleri için, model mimarisi girdi katmanı, 4 gizli katman ve çıktı katmanını olacak şekilde oluşturulmuştur. Adam optimizasyon fonksiyonu kullanılarak veriler optimize edilmiş ve hata kareler ortalamasını minimize edecek şekilde modeller derlenmiştir. LSTM modelinde relu aktivasyon fonksiyonu kullanılmıştır. Aşırı uyum (overfitting) problemi ile başa çıkmak için koşullu LSTM modelinin tahmininde her katmandan sonra bırakma (dropout) katmanı<sup>2</sup> eklenmiştir. ARIMA, LSTM ve koşullu LSTM modelleri için tahmin sonuçları sırasıyla Şekil 4-6'da gösterilmektedir.



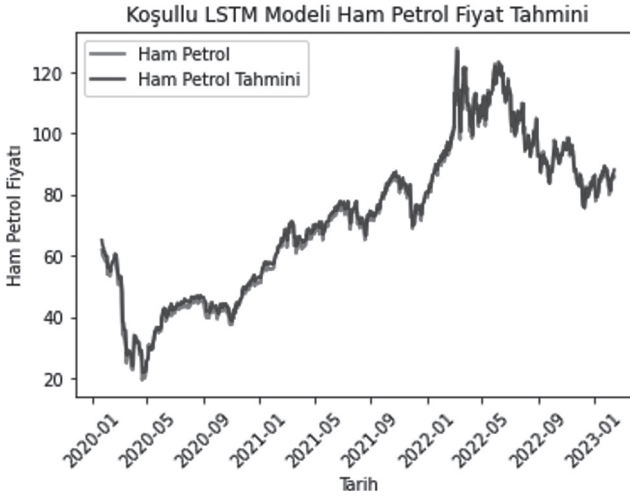
Şekil 4. ARIMA modeli için tahmin sonuçları

<sup>2</sup> Bu katman, eğitim süresi boyunca her adımda bir frekans oranı ile girdi birimlerini rassal olarak 0 yapar ve bu da aşırı uyumlamayı önlemeye yardımcı olur. 0 yapılmayan girdiler, tüm girdilerin toplamı değişmeyecek şekilde  $1/(1-\text{oran})$  oranında büyütülür.





Şekil 5. LSTM modeli için tahmin sonuçları



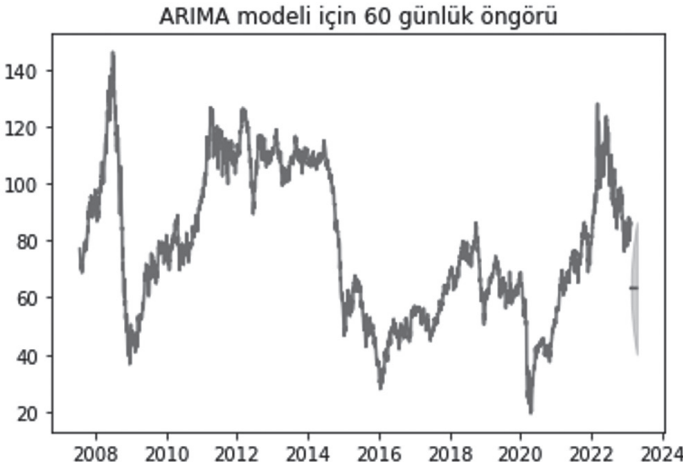
Şekil 6. Koşullu LSTM modeli için tahmin sonuçları

Şekil 4'e göre ARIMA modelinin serinin artış veya azalışlarını yakalayamadığı neredeyse sabit değerlerde tahmin verdiği görülmektedir. Yani, ARIMA modeli Brent Petrol fiyatlarındaki trendi yakalayamamaktadır. Şekil 5-6'ya göre hem LSTM modelinin hem de koşullu LSTM modelinin petrol fiyatlarındaki artış ve düşüşlerini tahmin ettiği söylenebilir. Ancak, LSTM model tahminlerinin kovid-19 pandemisinin başladığı döneme kadar gerçekleşen değerlerden yüksek (overestimated) olduğu, kovid-19 pandemisinden sonra ise gerçekleşen değerlerin altında (underestimated) kaldığı söylenebilir. Koşullu LSTM modeli ise

gözlem değerlerine yakın tahminler üretmektedir. Modellerin verimliliği MAE, MAPE, MPE ve RMSE performans değerlendirme ölçütlerine göre değerlendirilmekte ve özet sonuçlar Tablo 2'de verilmektedir.


Tablo 2. Önerilen modellerin performansları				
Modeller	MAE	MAPE	MPE	RMSE
ARIMA	22.1593	0.3517	0.0294	26.2220
LSTM	3.9029	0.0611	0.0020	4.9912
Koşullu LSTM	1.6550	0.0265	0.0145	2.3333

Tablo 2'de ARIMA modelinin tüm kriterlere göre en düşük performansa sahip olduğu görülmektedir. LSTM modeli MPE kriterine<sup>3</sup> için en uygun modeldir. Ancak diğer üç kritere göre koşullu LSTM modeli daha iyi uyuma sahiptir. Kriterlerin çoğuna göre koşullu LSTM modeli tercih edilmektedir. Bu modellere göre yapılan 60 günlük öngörüler sırasıyla Şekil 7-9'da sunulmaktadır.




Şekil 7. ARIMA modeli için 60 günlük öngörü (15/02/2023-15/04/2023)

<sup>3</sup> MPE'nin MAPE'den tek farkı mutlak değer işlemcisinin olmamasıdır. Pozitif ve negatif yüzdelik hataların birbirini götürmesi ve modelde ne kadar hata olduğuna dair fikir vermemesi açısından dezavantajlıdır. Avantajlı yönü ise, modelin negatif hataya (underestimation) mı pozitif hataya (overestimation) mı sahip olduğuna dair fikir verebilmesidir.

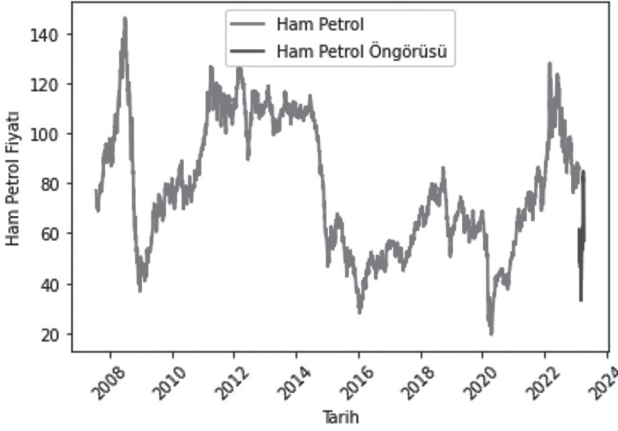


**Şekil 8.** LSTM modeli için 60 günlük öngörü (15/02/2023-15/04/2023)



**Şekil 9.** Koşullu LSTM modeli için 60 günlük öngörü (15/02/2023-15/04/2023)

Şekil 9'da koşullu LSTM modelinin öngörülerinde aşırı dalgalanma olduğu gözlenmektedir. Öngörülerdeki başarısızlık, veri setinin aşırı öğrenmesinden kaynaklanabilmektedir. Aşırı öğrenme için önlem almak amacıyla her katmanın sonuna %20 bırakma katmanı eklenerek tekrarlanan öngörü sonuçları Şekil 10'da verilmektedir.



**Şekil 10.** Koşullu LSTM modeli için 60 günlük öngörü (15/02/2023-15/04/2023) (%20 bırakma katmanı ile)

## **SONUÇ, TARTIŞMA VE ÖNERİLER**

Petrolün bankalar ve imalat şirketleri birçok büyük finans kuruluşunun kararları üzerinde yüksek bir etkiye sahip olduğu düşünüldüğünde, petrol fiyatlarının gelecekteki eğilimini doğru bir şekilde tahmin etmek önem kazanmaktadır.

Tahminlerde kullanılan klasik yöntemlerin doğrusal bir yapıya sahip olması, karmaşık ve doğrusal olmayan durumlarda kullanılmalarını uygunsuz hale getirmektedir. Bu nedenle mevcut çalışmada bu sorunu çözmek için yapay zekâ modellerinden yararlanılmıştır.

Derin öğrenme tekniği olan LSTM, uzun bellekteki bağımlılıkları öğrenme kapasitesine sahip RNN modelinin bir dalıdır. Bazen, daha güvenilir bir tahminde bulunmak için geçmiş bilgilere ve veri eğilimlerine ihtiyaç duyulmaktadır. RNN'ler, mevcut verilerin işlenmesinde uzun vadeli bilgileri kullanabilmekte; ancak, yalnızca sınırlı sayıda kısa bellekli bağımlılığı öğrenebilmektedir. Ayrıca RNN ağları, daha uzun mesafelerde geçmiş bilgileri geri çağırma yeteneklerini kaybetmektedirler. LSTM, geçmiş bilgileri mevcut bilgilerle bağlayabilen ve veri işleme sırasında uzun bellekli veri bağımlılıklarını koruyabilen bir RNN uzantısı olarak düşünülebilir. RNN'de bir işlem katmanı varken, LSTM'de dört işlem katmanı bulunmaktadır. Her LSTM bloğu, bir bellek hücresinin yanı sıra girdi, unutmaya ve çıktı kapılarında oluşmaktadır.

Koşullu LSTM mimarisi, zamanla değişmeyen değişkenler üzerinde zaman serisi tahminlerini koşullandırılmaya olanak sağlamaktadır. Koşullu yinelemeli katman eklemek, zamana bağlı olmayan dışsal girdilere sahip zaman serileri için avantajlı olmaktadır.

Bu çalışmada, Brent petrol fiyatları ARIMA, LSTM ve koşullu LSTM modelleri ile tahmin edilmiş ve 60 günlük öngörü değerleri elde edilmiştir. Tüm modellerde Brent petrol fiyatları, avro/dolar endeksi, doğalgaz fiyatı, ABD dolar endeksi, covid-19 kukla değişkeni girdi olarak kullanılmıştır. Bu çalışmanın literatüre katkısı koşullu LSTM modeli kullanarak covid-19 etkisinin eğitim setine dahil edilmeksizin yardımcı bir özellik olarak ele alınmasıdır.

Analiz sonucunda, koşullu LSTM modeli performans kriterleri gereği en iyi model olarak seçilmiştir. Ancak öngörü değerlerindeki oynaklığın fazla olması modelin aşırı öğrenmeye sahip olduğuna dair şüphe uyandırmaktadır. Aşırı öğrenme sorununa önlem olarak her katmanın sonuna %20 bırakma katmanı eklenerek tekrar öngörümleme yapılmıştır. Oynaklık bir miktar azalsa da nispeten kısa bir öngörü dönemi için fazla olduğu yorumu yapılabilir. Bu durum, bu çalışmada kullanılan veri setine özgü olabileceği gibi koşullu LSTM modelinin öngörü performansı ile de ilgili olabilir. Gelecek çalışmalarda, koşullu LSTM modelinin öngörü performansını iyileştirecek şekilde bu çalışmanın geliştirilmesi mümkündür.

## **KAYNAKLAR**

- Altan, A., & Karasu, S. (2022). Crude oil time series prediction model based on LSTM network with chaotic Henry gas solubility optimization. *Energy*, 242, 122964. <https://doi.org/10.1016/j.energy.2021.122964>
- Bildirici, M., Bayazit, N. G., & Ucan, Y. (2020). Analyzing crude oil prices under the impact of COVID-19 by using LSTARGARCHLSTM. *Energies*, 13, 1–18. <https://doi.org/10.3390/en13112980>
- Box, G. E. P., & Jenkins, G. M. (1970). *Time series analysis: Forecasting and control*. San Francisco, CA: Holden-Day.
- Bristone, M., Prasad, R., & Abubakar, A. A. (2020). CPPCNDL: Crude oil price prediction using complex network and deep learning algorithms. *Petroleum*, 6, 353–361. <https://doi.org/10.1016/j.petlm.2019.11.009>
- Cen, Z., & Wang, J. (2019). Crude oil price prediction model with long short term memory deep learning based on prior knowledge data transfer. *Energy*, 169, 160–171. <https://doi.org/10.1016/j.energy.2018.12.016>
- Chen, Y., He, K., & Tso, G. K. F. (2017). Forecasting Crude Oil Prices: A Deep Learning based Model. *Procedia Computer Science*, 122, 300–307. <https://doi.org/10.1016/j.procs.2017.11.373>
- Daneshvar, A., Ebrahimi, M., Salahi, F., Rahmaty, M., & Homayounfar, M. (2022). Brent Crude Oil Price Forecast Utilizing Deep Neural Network Architectures. *Computational Intelligence and Neuroscience*, 2022, 6140796. <https://doi.org/10.1155/2022/6140796>
- Firouzjaee, J. T., & Khaliluyan, P. (2022). Considering interpretability of the LSTM Architecture for Oil Stocks Prices Prediction (Statistical Finance). <http://arxiv.org/abs/2201.00350>
- Guo, J. (2019). Oil price forecast using deep learning and ARIMA. 2019 International Conference on Machine Learning, Big Data and Business Intelligence (MLBDBI), 241–247. <https://doi.org/10.1109/MLBDBI48998.2019.00054>
- Heravi, M. M. L., Khorrampanah, M., & Houshmand, M. (2022). Forecasting Crude Oil Prices Using Improved Deep Belief Network (IDBN) and Long-Term Short-Term Memory Network (LSTM). 30th International Conference on Electrical Engineering (ICEE), 823–826. <https://>

doi.org/10.1109/ICEE55646.2022.9827452

- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9, 1735–1780. <https://doi.org/doi:10.1162/neco.1997.9.8.1735>
- Jiang, H., Hu, W., Xiao, L., & Dong, Y. (2022). A decomposition ensemble based deep learning approach for crude oil price forecasting. *Resources Policy*, 78, 102855. <https://doi.org/10.1016/j.resourpol.2022.102855>
- Jiao, X., Song, Y., Kong, Y., & Tang, X. (2022). Volatility forecasting for crude oil based on text information and deep learning PSO-LSTM model. *Journal of Forecasting*, 41, 933–944. <https://doi.org/10.1002/for.2839>
- Kim, J. M., Han, H. H., & Kim, S. (2022). Forecasting Crude Oil Prices with Major S&P 500 Stock Prices: Deep Learning, Gaussian Process, and Vine Copula. *Axioms*, 11, 375. <https://doi.org/10.3390/axioms11080375>
- Li, X., Shang, W., & Wang, S. (2019). Text-based crude oil price forecasting: A deep learning approach. *International Journal of Forecasting*, 35, 1548–1560. <https://doi.org/10.1016/j.ijforecast.2018.07.006>
- Makala, D., & Li, Z. (2019). Economic Forecasting With Deep Learning: Crude Oil. *MATTER: International Journal of Science and Technology*, 5(2), 213–228. <https://doi.org/10.20319/mijst.2019.52.213228>
- Manowska, A., & Bluszcz, A. (2022). Forecasting Crude Oil Consumption in Poland Based on LSTM Recurrent Neural Network. *Energies*, 15, 4885. <https://doi.org/10.3390/en15134885>
- Nasir, J., Aamir, M., Haq, Z. U., Khan, S., Amin, M. Y., & Naeem, M. (2023). A new approach for forecasting crude oil prices based on stochastic and deterministic influences of LMD Using ARIMA and LSTM Models. *IEEE Access*, 11, 14322–14339. <https://doi.org/10.1109/ACCESS.2023.3243232>
- Niu, T., Wang, J., Lu, H., Yang, W., & Du, P. (2021). A Learning System Integrating Temporal Convolution and Deep Learning for Predictive Modeling of Crude Oil Price. *IEEE Transactions on Industrial Informatics*, 17(7), 4602–4612. <https://doi.org/10.1109/TII.2020.3016594>
- Olah, C. (2015). Understanding LSTM Networks. GitHub Repository. <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>
- Remy, P. (2020). Conditional RNN for Keras. GitHub Repository. [https://github.com/philipperemy/cond\\_rnn](https://github.com/philipperemy/cond_rnn)
- Safi, S., Aliyu, S., Ibrahim, K. S., & Sanusi, O. I. (2022). Can Oil Price Predict Exchange Rate? Empirical Evidence from Deep Learning. *International Journal of Energy Economics and Policy*, 12(4), 482–493. <https://doi.org/10.32479/ijeep.13200>
- Sajadi, S. M. A., Khodae, P., Hajizadeh, E., Farhadi, S., Dastgoshade, S., & Du, B. (2022). Deep Learning-Based Methods for Forecasting Brent Crude Oil Return Considering COVID-19 Pandemic Effect. *Energies*, 15, 8124. <https://doi.org/10.3390/en15218124>
- Salamai, A. A. (2023). Deep learning framework for predictive modeling of crude oil price for sustainable management in oil markets. *Expert Systems with Applications*, 211, 118658. <https://doi.org/10.1016/j.eswa.2022.118658>
- Santoso, A., Wijaya, F. D., Setiawan, N. A., & Waluyo, J. (2022). Data Mining Algorithms for Operating Pressure Forecasting of Crude Oil Distribution Pipelines to Identify Potential Blockages. *Machine Learning and Knowledge Extraction*, 4, 700–714. <https://doi.org/10.3390/make4030033>
- Yahoo Finance. (n.d.). Retrieved February 14, 2022, from <https://finance.yahoo.com/>
- Yiğit, T., Aksoy, B., Ersoy, M., Şenol, R., & Salman, O. K. M. (2021). Petrol fiyatlarının zaman serileri ve LSTM modeli kullanılarak tahminlenmesi. *Uluslararası Teknolojik Bilimler Dergisi*, 13(1), 34–38.
- Zhang, K., & Hong, M. (2022). Forecasting crude oil price using LSTM neural networks. *Data Science in Finance and Economics*, 2(3), 163–180. <https://doi.org/10.3934/dsfe.2022008>
- Zhao, Y., Li, J., & Yu, L. (2017). A deep learning ensemble approach for crude oil price forecasting. *Energy Economics*, 66, 9–16. <https://doi.org/10.1016/j.eneco.2017.05.023>