

T.C.
İSTANBUL BEYKENT ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĞİ BİLİM DALI

**FİNANS PROBLEMLERİNİN ÇÖZÜMÜ İÇİN
ÖNERİLEN AI CHATBOT İLE DESTEKLENMİŞ
HİBRİT NEURAL NETWORK**

Yüksek Lisans Tezi

Tezi Hazırlayan
Ahmet AKÇAY

İstanbul, 2025

T.C.
İSTANBUL BEYKENT ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĞİ BİLİM DALI

**FİNANS PROBLEMLERİNİN ÇÖZÜMÜ İÇİN
ÖNERİLEN AI CHATBOT İLE DESTEKLENMİŞ
HİBRİT NEURAL NETWORK**

Yüksek Lisans Tezi

Tezi Hazırlayan
Ahmet AKÇAY

Öğrenci No
2320003001

ORCID ID
0009-0009-9100-6312

Danışman
Dr. Öğr. Üyesi Umut KAYA

İstanbul, 2025

YEMİN METNİ

Yüksek Lisans Tezi olarak sunduğum “**Finans Problemlerinin Çözümü İçin Önerilen AI Chatbot İle Desteklenmiş Hibrit Neural Network**” başlıklı bu çalışmanın, bilimsel ahlak ve geleneklere uygun şekilde tarafımdan yazıldığını, bu tezdeki bütün bilgileri akademik ve etik kurallar içinde elde ettiğimi, yararlandığım eserlerin tamamının kaynaklarda gösterildiğini ve çalışmamın içinde kullanıldıkları her yerde bunlara atıf yapıldığını, patent ve telif haklarını ihlal edici bir davranışımın olmadığını belirtir ve bunu onurumla doğrularım. 20/06/2025

Ahmet AKÇAY

T.C.
İSTANBUL BEYKENT ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ MÜDÜRLÜĞÜ
TEZLİ YÜKSEK LİSANS SINAV TUTANAĞI

20/06/2025

Enstitümüz *Bilgisayar Mühendisliği* Anabilim Dalı *Bilgisayar Mühendisliği* Programı yüksek lisans öğrencilerinden **2320003001** numaralı **Ahmet AKÇAY**’ın “*İstanbul Beykent Üniversitesi Lisansüstü Eğitim – Öğretim Yönetmeliği*”nin ilgili maddesine göre hazırlayarak, Enstitümüze teslim ettiği “*Finans Problemlerinin Çözümü için Önerilen AI Chatbot ile Desteklenmiş Hibrit Neural Network*” konulu tezini, Yönetim Kurulumuzun 27/05/2025 tarih ve 2025/23 sayılı toplantısında seçilen ve Taksim yerleşkesinde toplanan biz jüri üyeleri huzurunda, İstanbul Beykent Üniversitesi Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 29. maddesinin 3. fıkrası gereğince aday tarafından savunulmuş ve sonuçta adayın tezi hakkında “**OYBİRLİĞİ**” ile “**KABUL**” kararı verilmiştir.

İşbu tutanak, 2 nüsha olarak hazırlanmış ve Enstitü Müdürlüğü’ne sunulmak üzere tarafımızdan düzenlenmiştir.

DANIŞMAN
Dr. Öğr. Üyesi Um*** KA***
(İstanbul Beykent Üniversitesi)

ÜYE
Dr. Öğr. Üyesi Ze*** AL***
(İstanbul Beykent Üniversitesi)

ÜYE
Dr. Öğr. Üyesi Ar*** YE***
(İstanbul Topkapı Üniversitesi)

Adı ve Soyadı : Ahmet AKÇAY
Danışmanı : Dr. Öğr. Üyesi Umut KAYA
Derecesi ve Tarihi : Yüksek Lisans (Tezli), 2025
Alanı : Bilgisayar Mühendisliği
Anahtar Kelimeler : Şeffaf Yapay Zeka, Derin Öğrenme Mimarisi, En Küçük Kareler Modeli, Shapley Tabanlı Özellik Katkı Analizi

ÖZ

FİNANS PROBLEMLERİNİN ÇÖZÜMÜ İÇİN ÖNERİLEN AI CHATBOT İLE DESTEKLENMİŞ HİBRİT NEURAL NETWORK

Bu çalışmada, altın fiyatları, Bitcoin piyasa davranışı ve USD/TRY döviz kuru dalgalanmaları gibi karmaşık finansal zaman serisi tahmin problemlerine çözüm getirmeyi amaçlayan yenilikçi bir hibrit tahminleme çerçevesi sunulmaktadır. Önerilen sistem, iki farklı modelleme yaklaşımını bir araya getirmektedir: doğrudan ve orantılı eğilimleri vektörleştirilmiş girdiler üzerinden tespit etmeye yönelik klasik bir doğrusal modelleme bileşeni ile, yapılandırılmış ardışık verilerden doğrusal olmayan zamansal desenleri öğrenme yetisine sahip yoğun katmanlarla desteklenmiş Uzun Kısa Süreli Bellek (LSTM) tabanlı bir derin öğrenme bileşeni. Modelin çıktılarının yorumlanabilirliğini artırmak ve güvenilirliğini pekiştirmek amacıyla, her bir girdi değişkeninin tahmin üzerindeki katkısını niceliksel olarak ortaya koyan oyun teorisi temelli bir yöntem olan SHAP (Shapley Additive Explanations) entegre edilmiştir. Ayrıca sistem, kullanıcıların tahmin sonuçlarına gerçek zamanlı olarak erişmesini ve bu sonuçlara ilişkin doğal dilde açıklamalar almasını sağlayan etkileşimli bir yapay zeka destekli sohbet asistanı ile donatılmıştır. Deneysel sonuçlar, bütünsel mimarinin bağımsız modellere kıyasla daha yüksek tahmin doğruluğu sağladığını ortaya koymakta ve yaklaşık %5,2 ortalama mutlak yüzde hata (MAPE) oranı ile önemli bir performans iyileşmesi göstermektedir. Model karmaşıklığını yorumlanabilirlik ve kullanıcı etkileşimiyle dengeleyen bu yaklaşım, finansal tahminleme sistemlerindeki temel zorluklara etkili bir çözüm sunmaktadır. Sonuç olarak, bu çalışma finansal analiz ve karar destek ortamlarında uygulanabilir, açıklanabilir ve kullanıcı odaklı bütüncül bir çözüm önermektedir.

Name and Surname : Ahmet AKÇAY
Supervisor : Asst. Prof. Dr. Umut KAYA
Degree and Date : Master's (Thesis), 2025
Major : Computer Engineering
Keywords : Transparent artificial intelligence; Deep learning architecture;
Ordinary least squares model; Shapley-based feature attribution

ABSTRACT

AN AI CHATBOT-SUPPORTED HYBRID NEURAL NETWORK FOR SOLVING FINANCIAL PROBLEMS

In this research, a novel hybrid forecasting framework is introduced, aiming to tackle the intricacies of financial time series prediction, particularly in the context of gold prices, Bitcoin market behavior, and USD/TRY currency fluctuations. The proposed system combines two distinct modeling approaches: a classical linear modeling component, utilized to uncover direct and proportional trends through vectorized inputs, and a deep learning-based component, specifically a Long Short-Term Memory (LSTM) network augmented by dense layers, which is adept at learning nonlinear temporal patterns from structured sequence data. To improve interpretability and facilitate trust in model outcomes, the framework incorporates Shapley Additive Explanations (SHAP), a game-theoretic technique that quantifies each input feature's contribution to the model's predictions. Furthermore, the system is equipped with a conversational AI assistant capable of providing users with real-time insights and textual explanations of forecast results. This interactive feature bridges the gap between complex model outputs and end-user comprehension, making the system both technically rigorous and practically accessible. Empirical evaluations demonstrate that the integrated architecture delivers superior forecasting accuracy compared to standalone models, yielding a mean absolute percentage error (MAPE) of approximately 5.2%. By aligning model complexity with interpretability and user interaction, this approach addresses key challenges in financial prediction systems. Overall, the study offers a comprehensive, explainable, and user-centric solution that can be effectively deployed in financial analytics and decision-support environments.

İÇİNDEKİLER

Sayfa No.

ÖZ

ABSTRACT

TABLolar LİSTESİ iv

ŞEKİLLER LİSTESİ v

KISALTMALAR vi

SÖZLÜK..... vii

GİRİŞ..... 1

1. YAPAY ZEKA, SOHBET BOTLARI VE SİNİR AĞLARINA YÖNELİK LİTERATÜR TARAMASI

1.1. Finans ve Yapay Zeka 3

1.2. Sohbet Botlarının Tarihçesi 4

1.3. YZ Tabanlı Sohbet Botları ve Bilişsel Yaklaşımlar 6

1.4. Sohbet Botlarının Finanstaki Yeri 9

1.5. Metin Tabanlı Sohbet Botları 10

1.6. Açıklanabilir Yapay Zeka 11

1.7. Açıklanabilir YZ Uygulamaları..... 14

1.8. YZ Açıklayıcı Araçlar 17

1.8.1. Yerel Konumlandırılabilir Modelden Bağımsız Açıklamalar 18

1.8.2. Shapley Katkı Temelli Açıklamalar ve Oyun Kuramı 19

1.8.3. Finansal YZ Uygulamalarının Genişletilmiş Etkileri 20

1.8.4. Makine Öğreniminde Shapley Toplamsal Açıklamalar 22

1.9. Modeller için YZ Yardımcılar 24

1.10. Yapay Sinir Ağları 25

1.10.1. Yapay Sinir Ağları Teorisi 25

1.10.2. Üretken Yapay Sinir Ağları 26

1.10.3. Geri Yayılımlı Sinir Ağları Algoritması 27

1.11. Finansal Yapay Sinir Ağları Algoritmaları..... 28

1.11.1. Finansal Risk Yönetimi..... 28

2. METODOLOJİ

2.1. Veri Setleri ve Ön İşleme.....	30
2.2. Hibrit Model ve Girdi Yapısı.....	34
2.3. Yapay Sinir Ağı Bileşeni ve Hibrit Entegrasyon Stratejisi	37
2.4. Performans Değerlendirmesi ve Karşılaştırmalı Kıyaslama	40
2.5. Hibrit Tahmin Modelinin SHAP Tabanlı Açıklanabilirliği.....	42
2.6. Model Açıklanabilirliği için Yapay Zekâ Asistanı Entegrasyonu	44

3. MODEL PERFORMANSI VE AÇIKLANABİLİRLİK

3.1. Tahmin Performansı Değerlendirmesi	47
3.2. Mevcut Hibrit Modellerle Karşılaştırmalı Analiz ve Doğrulama	49
3.3. Bitcoin Forecasting Performance and Statistical Observations	51
3.4. Uyarlanabilir Davranış ve Prophet Modeli ile Karşılaştırma	53
3.5. Hibrit Model Tahminlerinin SHAP Analizi ve Yorumlanabilirliği	55
3.6. Yapay Zekâ Asistanının Kullanılabilirliğe ve Karar Alma Sürecine Katkısı	56

4. TARTIŞMA

SONUÇ	61
KAYNAKÇA.....	63

EKLER

EK-1: Financial_app_1	68
EK-2: Financial_app_2	69
EK-3: Financial_app_3	70
EK-4: Financial_app_4	71
EK-5: Financial_app_5	72
EK-6: Data_fetcher	73
EK-7: Model_utils_1.....	74
EK-8: Model_utils_2.....	75
EK-9: Explainer	76
EK-10: Helper_with_Llama(Local)	77
EK-11: Helper_with_openai_api(Remote)	78
EK-12: User_interface_data(Streamlit)	79
EK-13: User_interface_result_shp(Streamlit).....	80

EK-14: User_interface_explainer_with_helper(Streamlit)	81
EK-15: User_interface_model_tunnig(Streamlit)	82



TABLolar LİSTESİ

	Sayfa No.
Tablo 1. Girdi Değişkenleri.....	30
Tablo 2. Açıklanabilir Varyans Tablosu	31
Tablo 3. Bileşen Yükleri	32
Tablo 4. Değişkenlerin Korelasyon Matrisi	32
Tablo 5. Verisetleri ve Hedef Değişkenler.....	33
Tablo 6. Tanımlayıcı İstatistikler	34
Tablo 7. Farklı Parametrelerle Hibrit Modelin Performans Karşılaştırması.....	47
Tablo 8. Model Performans Karşılaştırması	48
Tablo 9. Model Sonuçlarının Literatürdeki Karşılaştırmaları.....	49
Tablo 10. Değişken Tanımları.....	56

ŞEKİLLER LİSTESİ

	Sayfa No.
Şekil 1. Pencere ve Data Örnek Stili	36
Şekil 2. Model Yapısı	42
Şekil 3. Tahmin Edilen ve Gerçek Dolar/TL Fiyatları	51
Şekil 4. Tahmin Edilen ve Gerçek BTC/USD Fiyatları	53
Şekil 5. Tahmini ve Gerçek Altın-Dolar Fiyatı Karşılaştırması	54
Şekil 6. SHAP Özet Grafiği.....	55
Şekil 7. SHAP Etki Grafiği.....	60

KISALTMALAR

ABD Doları	: Amerikan Doları
AYZ	: Açıklanabilir Yapay Zekâ
BTC	: Bitcoin
GY	: Geriye Yayılım
KKK	: Katkı Temelli Açıklamalar
KKH	: Kök Kare Hata
OAH	: Ortalama Mutlak Hata
OMYH	: Ortalama Mutlak Yüzde Hata
TL	: Türk Lirası
UZK	: Uzun Kısa Süreli Bellek
YDA	: Yinelenen Derin Ağ
YZ	: Yapay Zeka

SÖZLÜK

ABD/TL Döviz Kuru: Amerikan Doları ile Türk Lirası arasındaki değişim oranı. Ekonomik analizlerde temel bir finansal gösterge olarak değerlendirilir.

Açıklanabilir Yapay Zekâ (AYZ): Makine öğrenimi modellerini insanlar için daha şeffaf ve yorumlanabilir hâle getirmeye odaklanan YZ alt alanı. Sorumlu ve hesap verebilir YZ uygulamaları için kritik bir rol oynar.

Altın Fiyatı: Ekonomik göstergeler, yatırımcı duyarlılığı ve küresel finansal istikrar gibi faktörlerden etkilenen piyasa değeri.

Bitcoin (BTC): Yüksek dalgalanma özelliğine sahip, merkeziyetsiz dijital kripto para birimi. Spekülatif yatırım ve korunma amacıyla sıklıkla kullanılır.

Doğrusal Regresyon: Bağımlı değişken ile bir veya birden fazla bağımsız değişken arasındaki doğrusal ilişkiyi modelleyen istatistiksel yöntem.

Hibrit Model: Tahmin doğruluğunu ve yorumlanabilirliği artırmak amacıyla hem lineer hem de doğrusal olmayan modelleme yaklaşımlarını birleştiren bir sistem.

Katkı Temelli Açıklamalar (KKA): Model tahminlerini açıklamak için her bir girdi öz niteliğinin katkısını hesaplayan oyun kuramı temelli bir yöntem.

Kök Kare Hata (KKH): Tahmin edilen ve gerçek değerler arasındaki farkların karelerinin ortalamasının karekökünü hesaplayan ve büyük hataları daha fazla cezalandıran bir ölçüt.

Ortalama Mutlak Hata (OAH): Tahmin edilen ve gerçek değerler arasındaki hata büyüklüğünün ortalamasını hesaplayan, basit bir doğruluk ölçütü.

Ortalama Mutlak Yüzde Hata (OMYH): Tahmin hatasını yüzde olarak ifade eden bir ölçüt olup, farklı modeller ve veri kümeleri arasında karşılaştırma yapılmasını kolaylaştırır.

Öznitelik Atfı: Girdi değişkenlerinin model çıktısı üzerindeki etkisinin belirlenmesi süreci.

Sinir Ağı: İnsan beynindeki nöron sistemini taklit edecek şekilde yapılandırılmış, karmaşık veri kümelerindeki desenleri ve ilişkileri tanımak için kullanılan hesaplama modeli.

Sohbet Tabanlı YZ Asistanı: Karmaşık veri sistemleriyle sezgisel diyaloglar aracılığıyla etkileşim kurmayı mümkün kılan, doğal dili anlayıp üretebilen bir YZ sistemi.

Uzun Kısa Süreli Bellek (UZK): Zamansal verilerdeki uzun vadeli bağımlılıkları öğrenebilen bir tür yinelenen sinir ağı. Özellikle zaman serisi davranışlarının modellenmesinde etkilidir.

Yapay Zekâ (YZ): Makinelerin insan bilişsel işlevlerini taklit etmesi. YZ; öğrenme, akıl yürütme ve kendi kendini düzeltme yetilerini içerir. Bu çalışmada YZ, tahmin görevlerini mümkün kılar ve doğal dil ile etkileşimi destekler.

Zaman Serisi Tahmini: Zaman sıralı veri noktalarının analiz edilerek gelecekteki değerlerin öngörülmesi süreci. Finans alanında fiyat ve kur eğilimlerini tahmin etmek amacıyla yaygın şekilde kullanılır.

GİRİŞ

Küresel finansal sistemlerin artan karmaşıklığı ve varlık fiyatlarındaki yüksek frekanslı, doğrusal olmayan desenlerin ortaya çıkması, geleneksel tahmin yöntemlerini güvenilir karar verme süreçleri için yetersiz hâle getirmiştir. Altın, kripto paralar (örneğin Bitcoin) ve USD/TRY gibi döviz kurları gibi finansal araçlar; jeopolitik olaylar, makroekonomik göstergeler ve piyasa duyarlılığı gibi çok sayıda dinamik ve birbirleriyle ilişkili değişkene tabidir. Bu nedenle, yalnızca yüksek doğruluk sunan değil, aynı zamanda hızla değişen finansal rejimlere uyum sağlayabilen tahminleme çerçevelerine olan talep giderek artmaktadır. Geleneksel istatistiksel modeller, özellikle doğrusal regresyon, basitlikleri ve yorumlanabilirlikleri sayesinde zaman serisi verilerindeki doğrudan eğilimleri modellemek için yaygın olarak kullanılmaktadır. Ancak bu modeller, finansal veri kümelerinde doğal olarak bulunan doğrusal olmayan bağımlılıkları ve zamansal karmaşıklığı çoğu zaman yakalayamamaktadır. Buna karşılık, özellikle Uzun Kısa Süreli Bellek (UZK) ağları gibi yinelenen derin öğrenme mimarileri, ardışık verilerden öğrenme ve uzun vadeli zamansal bağımlılıkları modelleme konusunda önemli başarılar elde etmiştir. Ancak yüksek tahmin gücüne rağmen, derin öğrenme modelleri genellikle “kara kutu” niteliği taşımakta ve bu da uygulayıcıların ve paydaşların modelin tahminlerinin gerekçelerini anlamalarını zorlaştırmaktadır.

Bu zorluğa yanıt olarak, Açıklanabilir Yapay Zekâ (AYZ) alanı ivme kazanmış ve karmaşık model tahminlerini yorumlanabilir ve şeffaf hâle getirmeyi amaçlayan yöntemler ortaya koymuştur. Bu yaklaşımlar arasında, SHAP yerine önerilen **Katkı Temelli Açıklamalar (KKA)** yöntemi, model çıktısının her bir değişkene atfedilmesini sağlayan sağlam ve kuramsal temelli bir yöntem olarak öne çıkmıştır. KKA, tahminlerin her bir giriş değişkenine ait katkıların ayrıştırılmasına olanak tanır ve finansal uygulamalarda hesap verebilirliğe duyulan ihtiyaca güçlü biçimde yanıt verir.

Bu çalışma, doğrusal ve doğrusal olmayan modelleme yaklaşımlarının güçlü yönlerini birleştiren hibrit bir tahmin modeli sunmaktadır. Belirgin deterministik ilişkileri verimli biçimde modellemek için bir doğrusal regresyon modülü kullanılmakta; aynı zamanda çok boyutlu ardışık verilerden karmaşık zamansal

desenleri yakalamak üzere bir UZK ağı entegre edilmektedir. Modelin yorumlanabilirliğini artırmak amacıyla, her bir tahminin öznitelik düzeyinde açıklamasını sağlamak için KKA yöntemi uygulanmaktadır. Ayrıca, kullanıcıların model çıktılarıyla doğal dil üzerinden etkileşim kurmasını sağlayan bir sohbet tabanlı YZ asistanı sisteme entegre edilmiştir. Bu sayede erişilebilirlik ve şeffaflık ön planda tutulmuştur.

Çalışmada bu hibrit yapı, altın fiyatı, Bitcoin değeri ve USD/TRY döviz kuru tahminlerinde uygulanarak, finansal analiz ve karar destek ortamlarında kullanılabilecek pratik, doğru ve açıklanabilir bir araç geliştirilmesi hedeflenmiştir.

Bu araştırma kapsamında, veri odaklı model geliştirme sürecinin temelini oluşturmak amacıyla temel bileşen analizi (TBA), korelasyon analizi ve istatistiksel değerlendirme gibi yöntemlerle kapsamlı bir finansal veri analizi gerçekleştirilmiştir. Zamanla değişen parametrelerle doğrusal ilişkileri yakalamaya yönelik bir yapı ile doğrusal olmayan zamansal dinamikleri ele alan zaman serisi tabanlı bir yapının bütünleştirilmesinden oluşan özgün bir hibrit tahmin modeli önerilmiştir. Zaman içinde verinin daha homojen bir şekilde dağılımını ve parametre öneminin sürdürülebilirliğini sağlamak amacıyla, literatürde yaygın olarak kabul gören sabit pencere segmentasyonu yöntemi uygulanmıştır. Ayrıca, giriş değişkenlerine önem atfetmek ve bu değişkenlerin tahminler üzerindeki etkisini değerlendirmek amacıyla, modelin açıklanabilirliği Katkı Temelli Açıklamalar (KKA) yöntemi ile güçlendirilmiştir. Böylece her bir giriş özneliğinin göreceli önemi nicel olarak vurgulanmış ve model çıktılarının kullanıcı dostu şekilde yorumlanmasını sağlamak üzere YZ destekli bir sohbet arayüzü entegre edilmiştir.

Ampirik sonuçlar, yalnızca tahmin doğruluğunun artırıldığını göstermekle kalmamış, aynı zamanda makine öğrenmesinin insan merkezli açıklanabilirlik ve etkileşimle bütünleştirilmesinin sağladığı faydaları da doğrulamıştır.

1. YAPAY ZEKA, SOHBET BOTLARI VE SİNİR AĞLARINA YÖNELİK LİTERATÜR TARAMASI

1.1. Finans ve Yapay Zeka

Yapay zekâ (YZ), gelişmiş algoritmaların, makine öğrenimi tekniklerinin ve büyük ölçekli veri işleme yeteneklerinin entegrasyonu yoluyla finans sektörünü dönüştürmeye başlamıştır. Öngörüye dayalı finansal analiz alanında YZ, geleneksel ekonometrik modellerin çok ötesine geçerek, heterojen veri kaynaklarında yer alan ve klasik kara kutu çerçevelerinin katı yapıları içerisinde sıklıkla gizli kalan karmaşık ve bariz olmayan ilişkileri ortaya çıkarabilmektedir. Özellikle yatırım tahmini bağlamında YZ modelleri yalnızca tarihsel varlık fiyatlarını değil, aynı zamanda makroekonomik göstergeleri de içeren kapsamlı bir yapı sunarak stratejik finansal karar alma süreçlerini ve portföy optimizasyonunu güçlendirmektedir.

YZ'den en çok fayda sağlayan alanlardan biri algoritmik işlemdir. YZ destekli sistemler, insan kapasitesinin çok ötesinde bir hız ve doğrulukla yüksek frekanslı işlem stratejilerini uygulayabilmektedir. Bu algoritmalar, canlı piyasa verilerini anlık olarak işleyerek değişimlere gerçek zamanlı tepki verebilmekte ve kâr oranını artıran, piyasa duyarlılığını güçlendiren optimize edilmiş işlem kararlarını hayata geçirebilmektedir. Bu çeviklik sayesinde finansal kurumlar, geçici piyasa dengesizliklerinden faydalanmakta ve değişen işlem koşullarına hızla uyum sağlayabilmektedir.

Risk yönetimi alanında da YZ çok önemli bir rol oynamaktadır; çünkü daha ayrıntılı ve zamanında değerlendirmelerin yapılmasını mümkün kılmaktadır. Geleneksel modellere kıyasla YZ sistemleri çok daha büyük veri hacimlerini işleyebilmekte ve olağandışı durumları ya da yeni ortaya çıkan riskleri daha yüksek hassasiyetle tespit edebilmektedir. Bu modeller, akışkan veriye dayalı olarak risk profillerini gerçek zamanlı güncelleyebilmekte ve kurumların çeşitli bağlamlarda risk stratejilerini sürekli yeniden ayarlamalarına olanak tanımaktadır.

Dolandırıcılık tespiti, YZ'nin önemli katkı sağladığı bir diğer kritik uygulama alanıdır. Harcama davranışlarını analiz ederek belirlenmiş kalıplardan sapmaları tespit eden YZ modelleri, potansiyel dolandırıcılık işlemlerini giderek artan doğrulukla işaretleyebilmektedir. Makine öğrenimi algoritmaları sürekli olarak yeni gözlemlenen verilerden öğrenerek zaman içinde dolandırıcılık tespit etme yeteneklerini

geliştirmekte ve böylece finansal sistemlerin bütünlüğüne ve güvenliğine katkı sunmaktadır.

Bununla birlikte, YZ kişiselleştirilmiş finansal hizmetleri de yeniden şekillendirmektedir. Akıllı algoritmalarla çalışan robo-danışmanlar, bireyin finansal hedeflerine, risk toleransına ve davranışsal kalıplarına özel olarak uyarlanmış yatırım tavsiyeleri üretmektedir. YZ destekli sohbet botları ve sanal asistanlar ise kullanıcı deneyimini geliştirerek erişilebilir, etkileşimli finansal rehberlik sunmakta ve müşteri memnuniyetini artırmaktadır.

Düzenleyici uyum (regülasyon) alanında da YZ'nin katkısı büyüktür. İşlem izleme ve raporlama görevlerinin otomasyonu, insan hatası olasılığını azaltmakta ve yasal ile kurumsal uyum standartlarının karşılanmasında verimliliği artırmaktadır. Ayrıca, Tekrarlayan Süreçlerin Robotik Otomasyonu (RPA), veri girişi ve rapor üretimi gibi tekrarlayan idari işlemlerin yönetiminde kullanılmakta, bu sayede iş akışı verimliliği artırılmakta ve insan kaynağının daha stratejik işlevlere odaklanması sağlanmaktadır.

Genel olarak, YZ'nin finansal sistemlere entegrasyonu; risk azaltımı, dolandırıcılık önleme ve müşteri odaklı hizmet sunumu gibi pek çok alanda karar alma süreçlerini geliştirmiştir. Bununla birlikte, yüksek kaliteli giriş verilerinin sağlanması ve karmaşık YZ modellerinin açıklanabilirliğinin artırılması gibi zorluklar da devam etmektedir. Bu iki unsur, YZ'nin finans alanındaki potansiyelinden tam anlamıyla yararlanılabilmesi için kritik öneme sahiptir. (Kulkarni vd., 2024).

1.2. Sohbet Botlarının Tarihçesi

Modern sohbet botlarının kavramsal kökenleri, 1950 yılında Alan Turing'in makinelerin insanlardan ayırt edilemeyecek düzeyde akıllı davranışlar sergileyip sergileyemeyeceğini sorduğu temel soruya kadar uzanır. Daha sonra "Turing Testi" olarak biçimlendirilen bu soru, yapay konuşma ajanları konusundaki sonraki yeniliklerin temelini oluşturmuştur. Turing'in varsayımı, bir makinenin diyalog kurarken insanları, karşılarındaki varlığın başka bir insan olduğuna inandıracak kadar ikna edici davranıp davranamayacağı üzerine kuruluydu.

1966 yılında geliştirilen ELIZA adlı program, bu alanda önemli bir dönüm noktası olmuştur. Bir psikoterapisti taklit etmek üzere tasarlanan ELIZA, temel düzeyde eşleştirme ve şablona dayalı yanıt stratejileri kullanmaktaydı. Yapısının basitliği ve bağlamı algılama yeteneğinin sınırlı olmasına rağmen, ELIZA bu alandaki gelecek çalışmalara ilham veren temel bir model olarak kabul edilmiştir. Bununla birlikte, uzun süreli ve bağlam farkındalığına sahip diyalogları sürdürememesi ve etkileşimlerden öğrenememesi gibi önemli sınırlılıkları vardı.

1972 yılında, psikiyatrist Kenneth Colby tarafından geliştirilen PARRY, daha gelişmiş bir mekanizma sunmuştur. Paranoid şizofreni hastasını taklit etmek üzere tasarlanan PARRY, daha yapılandırılmış bir iç mantık ve davranışsal modelleme kullanarak ELIZA'ya kıyasla daha tutarlı ve psikolojik olarak anlamlı etkileşimler gerçekleştirebilmiştir. PARRY, basit desen eşleştirmelerinden, kişilik özellikleri ve konuşma kontrol yapılarıyla tanımlanan kural tabanlı sistemlere geçişin önemli bir adımı olmuştur.

1995 yılına gelindiğinde, ALICE (Artificial Linguistic Internet Computer Entity) adlı sohbet botu, sohbet sistemlerini çevrimiçi ortama taşımıştır. Richard Wallace tarafından geliştirilen ALICE, doğal dil işleme tekniklerinden yararlanmış ve konuşma tasarımı daha esnek kurallar tanımlamaya olanak sağlayan AIML (Artificial Intelligence Markup Language) adlı bir betik dili tanıtmıştır. Hâlâ desen tanıma temelli çalışmasına rağmen, ALICE daha yüksek uyarlanabilirlik ve dil yapısı sunarak alanda bir dönüm noktası oluşturmıştır.

2006 yılında IBM tarafından geliştirilen Watson, yapay zekânın doğal dili anlama ve işleme konusundaki pratik potansiyelini ortaya koyarak büyük bir sıçrama gerçekleştirmiştir. Watson'ın, Jeopardy! adlı yarışma programında insan rakiplerini yenmesi, makine öğrenmesinin gücünü sergilemiştir. Bununla birlikte Watson, yalnızca İngilizce çalışabilmesi nedeniyle dil çeşitliliği bakımından sınırlıydı.

2010 yılında Apple tarafından piyasaya sürülen Siri ile sanal asistanlar bireysel kullanıcı alanına girmiştir. Siri, ses tanıma, doğal dil anlama ve yapay zekâyı birleştirerek iOS cihazlar üzerinden kullanıcılarla etkileşim kurmuştur. Sesli arayüzler sayesinde kullanıcı etkileşimini önemli ölçüde geliştirmiş olsa da sürekli internet bağlantısı gereksinimi ve sınırlı dil desteği gibi kısıtları vardı.

2016 yılında kullanıma sunulan Google Asistan, Android ekosistemine bağlamsal farkındalık ve kişiselleştirme yeteneklerini entegre ederek sanal asistanları bir adım öteye taşımıştır. Kullanıcı tercihleri ve alışkanlıklarına dayalı dinamik yanıtlar sunarak, proaktif yapay zekâ desteğinde yeni bir standart belirlemiştir.

2022 yılında OpenAI tarafından geliştirilen ChatGPT'nin piyasaya sürülmesi, sohbet botu tarihinde dönüştürücü bir an olmuştur. GPT (Generative Pre-trained Transformer) mimarisi ile çalışan bu gelişmiş büyük dil modeli, insan benzeri yanıtlar üretme, bilgileri sentezleme ve çok çeşitli görevlerde destek sağlama yeteneği sergilemiştir. Hemen ardından, Google kendi büyük dil modeli altyapısıyla geliştirdiği üretici yapay zekâ tabanlı asistanı Gemini'yi (eski adıyla Bard) tanıtmıştır. Gemini, gerçek zamanlı internet bağlantısı ve metin, ses, görsel gibi çoklu modları işleyebilme özelliğiyle fark yaratmaktadır.

Sohbet botlarının evrimi genel olarak iki temel döneme ayrılabilir. İlk dönem, sabit yanıt kalıpları ve sınırlı bağlamsal farkındalıkla tanımlanan ELIZA ve ALICE gibi erken dönem kural tabanlı ajanları kapsamaktadır. Günümüzü ve geleceği temsil eden ikinci dönem ise, derin öğrenme, doğal dil işleme ve üretici yapay zekâ teknolojileri ile tanımlanır. Bu modern sistemler yalnızca insan benzeri diyalogları taklit etmekle kalmaz; aynı zamanda büyük veri kümeleri ve gerçek zamanlı bilgileri kullanarak çok çeşitli görevleri yerine getirme kapasitesine sahiptir. Ayrıca, günümüzde sohbet botlarının geliştirilmesini demokratikleştiren araçlar da yaygın biçimde erişilebilir hâle gelmiştir. Alan hızla gelişmeye devam etmekte olup, çok modlu etkileşim, kişiselleştirme ve genel amaçlı bilişsel yeteneklere verilen önem giderek artmaktadır. (Benaddi vd., 2024, s. 78799).

1.3. YZ Tabanlı Sohbet Botları ve Bilişsel Yaklaşımlar

Bu çalışma, hizmet robotlarının insansı tasarımı üzerine yürütülen ve daha derin akademik araştırmalar gerektiren öncelikli alanları vurgulayan bir meta-analitik derlemeye dayanmaktadır. Söz konusu çalışmada tespit edilen temel boşluklardan biri, insansı tasarımın hizmet deneyimini farklı bağlamlarda nasıl etkilediğine ilişkin anlayış eksikliğidir. Ayrıca, bu etkinin altında yatan mekanizmaların ve özellikle anlamlı aracı değişkenlerin belirlenmesiyle ilgili açıklığa kavuşturulması gereken

noktalar olduđu belirtilmektedir. Benzer şekilde, sonraki alıřmaların hizmet robotlarının belirli tasarım unsurları ile kullanıcı tepkileri arasındaki iliřkiyi daha ayrıntılı biimde incelemesi gerektiđi nerilmektedir. Bu alıřmada sunduđumuz kavramsal ereve ve neriler, hizmet etkileřimlerinde algılanan etkenliđi etkileyebilecek bir dizi YZ destekli sohbet botu tasarım zelliđini tanımlayarak sz konusu arařtırma bořluklarını ele almayı amalamaktadır. Bu tasarım đeleri, Sosyal Biliřsel Kuram'a (SBK) dayanmakta olup, mřterilerin YZ tabanlı sohbet botlarıyla etkileřimlerinde nasıl dřndđn, hissettiđini ve davrandıđını řekillendirmeye ynelik bir yapı sunmaktadır.

YZ destekli sohbet botlarının, gnmzde n saflarda grev yapan insan alıřanlara zg birok iřlevi yerine getirmeye bařlaması ve insanların dođal olarak insan olmayan varlıklara insani zellikler atfetme eđiliminde olması gz nne alındıđında, bireylerin bu yapay ajanları biliřsel ve sosyal olarak nasıl yorumladıklarının arařtırılması nem kazanmaktadır. Bu durum, tketicilerin hem YZ sistemleriyle hem de insan personelle eřzamanlı olarak etkileřime getiđi hibrit hizmet ortamlarında daha da belirgin hle gelmektedir. Bu tr bađamlarda, hem insan hem de makine unsurlarından oluřan hizmet ekibinin toplam yeterliliđine duyulan mřteri gveni, hizmetin etkililiđi aısından kritik rol oynamaktadır. Bu dođrultuda, SBK'den yararlanarak, YZ sohbet botu tasarım đelerini etkenlik algısıyla iliřkilendiren bir ereve neriyor ve farklı yapılandırmaların hizmet deneyiminin ortak retimi zerindeki etkisini arařtırıyoruz.

SBK, grev ortamlarında bireylerin ve sosyal aktrlerin birbirlerini nasıl etkilediklerini aıklamak zere  farklı etkenlik tr tanımlar. İlk olarak, z etkenlik, bireyin hedeflerine kendi bařına ulařabileceđine dair inancını ifade eder. Bu etkenlik hissi, teknolojinin etkili kullanımı aracılıđıyla geniřletilebilir. rneđin Amazon Alexa gibi akıllı asistanlar, kullanıcıların sesli komutlarla alıřveriř gibi grevleri yerine getirmesine olanak tanır. Nitekim 2018 tatil sezonunda, sesli sipariřlerin bir nceki yıla gre %300 arttıđı rapor edilmiřtir. Benzer şekilde, Google Duplex gibi aralar, kullanıcıların otomatik ve insan sesiyle alıřan YZ ajanları aracılıđıyla rezervasyon yaptırmasını mmkn kılar. Erken dnem sohbet botu uygulamaları byk lde bu tr grev devrine odaklanmış olsa da, olgunluk dzeyleri ve kullanıcı benimsemesi bakımından farklılık gstermektedir.

İkinci olarak, vekil etkenlik, bireylerin tek başlarına gerçekleştiremeyecekleri bir hedefe ulaşmak için başka bir ajanın becerilerine güvenmesiyle ortaya çıkar. Bu durumlarda, ajanın yeterliliğine duyulan güven belirleyici hâle gelir. Örneğin profesyonel çevrimiçi hizmetlerde kullanılan sohbet botlarında, kullanıcının botun yetkinliğine duyduğu güven, alınan bilgi ya da önerilere uyumu doğrudan etkiler. Karar verme süreçlerini desteklemek ve kişiye özel rehberlik sunmak için YZ kullanımı, günümüzde sohbet botu geliştirme alanında önemli bir büyüme alanıdır. Cleo, Trim, Plum ve Chip gibi finansal danışmanlık sohbet botları, bu modele örnek teşkil etmekte; kullanıcılara öneriler sunmakta ve otomatik finans yönetimi desteği sağlamaktadır.

Üçüncü tür olan kolektif etkenlik, ortak bir hedefe ulaşmak için birden fazla aktörün ister insan ister makine paylaştığı sorumluluk ve yetkinliği ifade eder. YZ alanındaki son gelişmeler, sohbet botlarının hizmet ekiplerinin iş birliği içinde çalışan üyeleri olarak entegrasyonunu mümkün kılmıştır. Örneğin, Bank ABC tarafından geliştirilen dijital asistan Fatema, müşteri hizmeti kanallarına entegre edilerek sosyal platformlar üzerinden kişiselleştirilmiş destek ve gerçek zamanlı bilgi sunmaktadır. Benzer şekilde, Noel Leeming perakende ortamında kullanılan Nola, insan çalışanlarla birlikte çalışarak mağaza içi deneyimi zenginleştirmektedir. Teknik ve organizasyonel açıdan karmaşık olsa da, bu tür uygulamalar sohbet botlarının gelecekteki konuşlanma biçimini temsil etmekte ve YZ'nin ekiplerin kolektif yeterliliğine anlamlı katkılar sunduğunu göstermektedir (Cui, 2017)

Bu bulgulardan yola çıkarak, YZ sohbet botlarının tasarımının, firmanın güçlendirmek istediği etkenlik türüne uygun şekilde yapılandırılması gerektiğini öne sürüyoruz. Diğer bir deyişle, bir sohbet botunun öz etkenliği desteklemesi, vekil ajan olarak hizmet vermesi veya kolektif etkenlik çerçevesinde iş birliği içinde çalışması bekleniyorsa, buna uygun bir tasarım yaklaşımı benimsenmelidir. Bu bağlamda, etkenlik algısını etkileyen üç temel sohbet botu tasarım boyutu belirliyoruz: insansı rol, görsel görünüm ve etkileşim yetenekleri. Bu boyutların her biri, YZ sohbet botlarından beklenen artan karmaşıklık düzeyine karşılık gelmektedir. Tasarım karmaşıklığı ve kullanıcı bağımlılığı arttıkça, teknik kısıtlamalardan müşteri, çalışan ve YZ ajanları arasındaki ilişkisel dinamiklere kadar yönetimsel değerlendirmelerin kapsamı da genişlemektedir. (Chattaraman vd., 2019, s. 315). ile uyumlu biçimde,

sohbet botu tasarımının evrensel bir şablonla değil, desteklenmesi hedeflenen etkenlik rolü, hizmet çıktısına göre stratejik biçimde uyarlanması gerektiğini vurgulamaktayız. (Chong vd., 2021, Makale No. 102735).

1.4. Sohbet Botlarının Finanstaki Yeri

Hindistan gibi gelişmekte olan ekonomilerde, sohbet botu tabanlı danışmanlık hizmetlerinin benimsenmesi hâlen erken gelişim aşamasındadır. Yeni nesil dijital dönüştürücü olarak kabul gören Yapay Zekâ (YZ), giderek daha fazla sektördeki kuruluşlar tarafından benimsenmektedir. Dijital dönüşüm sürecinin hız kazanması ve YZ teknolojilerinin yaygınlaşması, küresel ölçekte iş yapış biçimlerini önemli ölçüde etkilemiştir.

Bu bağlamda, finansal kurumlar özellikle bankalar tarihsel olarak teknolojik yeniliklere yüksek düzeyde duyarlılık göstermiştir. Bankalar, genellikle ortaya çıkan yeni teknolojilerin en erken benimseyenleri arasında yer almakta ve YZ entegrasyonu sayesinde kayda değer ticari faydalar elde etmektedir. Güçlü dijital altyapılarla proaktif YZ stratejilerini uyumlu hâle getiren kuruluşlar, genellikle daha yüksek kâr marjları elde etmekte ve rakiplerine karşı sürdürülebilir bir performans avantajı sağlamaktadır.

Bu çalışma, finansal hizmetler sektöründeki geniş kullanıcı kitlesine yönelik olarak sohbet botu tabanlı danışmanlık hizmetlerinin benimsenmesini incelemek amacıyla kavramsal bir çerçeve sunmaktadır. Bu bağlamda, bankacılık ve finansal hizmetler alanında, geniş çapta kullanıcıya erişebilir, etkileşimli ve kullanıcı dostu olacak şekilde tasarlanmış YZ destekli sohbet botu danışmanlarının stratejik önemine açıkça vurgu yapan ilk çalışmalardan biridir.

Araştırma, tüketicilerin sohbet botu danışmanlarını benimsemesini etkileyen temel belirleyicileri ortaya koymayı ve kullanıcı algılarının bu tür teknolojilerin kabulünü nasıl şekillendirdiğini araştırmayı amaçlamaktadır. Referans verilen verilerde de gösterildiği üzere, finansal hizmet sağlayıcıları, diğer sektörlerle kıyasla YZ kullanımında lider konumdadır. Sohbet botları etkili şekilde uygulandığında, müşteri taleplerine gerçek zamanlı yanıtlar sunabilir, kullanıcı etkileşimini artırabilir

ve genel müşteri deneyimini iyileştirerek finansal hizmetlerde hem tüketici güvenini hem de operasyonel verimliliği güçlendirebilir. (Patil ve Kulkarni, 2019, s. 4297).

1.5. Metin Tabanlı Sohbet Botları

Metin tabanlı sohbet botu teknolojileri; bankacılık, sigortacılık ve e-ticaret dâhil olmak üzere çeşitli finansal alanlarda giderek daha fazla benimsenmektedir. Bu teknolojilerin temel amacı, müşteri hizmeti kalitesini artırmak, kullanıcı memnuniyetini sağlamak ve operasyonel verimliliği geliştirmektir. Sohbet botlarının uygulanması, insan iş yükünü azaltırken aynı anda verimliliği ve genel hizmet deneyimini iyileştirme potansiyelini de ortaya koymuştur. Ampirik çalışmalar, sohbet botlarının finansal hizmetlere entegrasyonunun, daha yüksek oranlarda kullanıcı memnuniyetiyle sonuçlandığını ve hizmet ölçeklenebilirliğine ve yanıt verebilirliğine olumlu katkı sağladığını göstermektedir.

Illescas ve çalışma arkadaşları, sohbet botlarının coğrafi olarak uzak ya da hizmete erişimi sınırlı bölgelerdeki müşterilere kaliteli hizmet sunma kapasitesini artırabileceğini vurgulamışlardır. Bu teknoloji, modernlik hissiyle birlikte kişiselleştirilmiş bir etkileşim deneyimi de sunmaktadır. Aynı zamanda, sohbet botlarının etkili biçimde benimsenmesi için, hizmetin niteliği, fiyatlandırma modelleri, altyapının sağlamlığı, kalite standartları ve öngörülen kullanıcı hacmi gibi çeşitli risk odaklı faktörlerin uygulama öncesinde dikkatle değerlendirilmesi gerektiği belirtilmektedir.

Finansal performans açısından değerlendirildiğinde, sohbet botu uygulamalarının ölçülebilir ekonomik değer yarattığına dair bulgular da mevcuttur. Özellikle mevcut finansal ürünler için sunulan sohbet botu hizmetlerinin, bankacılık kurumlarında net gelir artışlarıyla ilişkilendirildiği görülmektedir. (Stoeckli vd., 2019, s. 477), bu konuda stratejik bir çerçeve önererek, yeni dijital teknolojilerden (örneğin sohbet botları) yararlanmak ile geleneksel sistem istikrarını sürdürmek arasında dengeli bir yaklaşım önermiştir. Söz konusu araştırma; çeviklik ile kontrol, keşif ile verimlilik, uyarlanabilirlik ile standartlaşma gibi temel ikilikleri ele almaktadır.

Bu tartışma zamanla sigorta sektörüne de yayılmış ve sağlık sigortası sağlayıcılarının, daha geniş kapsamlı inovasyon stratejilerinin bir parçası olarak sohbet

botu teknolojilerinden nasıl faydalandığını ortaya koymuştur. Bu araçlar yalnızca rutin süreçleri otomatikleştirmekle kalmayıp, aynı zamanda karar alma, veri toplama, hizmet sağlayıcı koordinasyonu, performans takibi, kaynak tahsisi ve idari görevlerin yürütülmesi gibi alanlarda da kullanılmaktadır.

Özetle, bu araştırma sohbet botlarının finansal hizmetler sektöründeki dönüştürücü etkisine dikkat çekmektedir. Temel faydalar arasında; müşteri etkileşiminin artırılması, operasyonel verimliliğin geliştirilmesi, veriye dayalı karar alma süreçlerinin desteklenmesi ve kaynak yönetiminin optimize edilmesi yer almaktadır. Ayrıca, teknoloji benimsenmesini etkileyen başlıca faktörlerin belirlenmesi, gelecekte sohbet botu teknolojilerini uygulamayı planlayan kurumlar için önemli bir yol haritası niteliği taşımaktadır. (Wube vd., 2022, s. 232).

1.6. Açıklanabilir Yapay Zeka

Son yıllarda Yapay Zekâ (YZ), pek çok alanda dikkate değer ilerlemeler kaydetmiş ve dönüştürücü potansiyelini güçlü biçimde ortaya koymuştur. Uygun biçimde uygulandığında, YZ sistemleri yalnızca mevcut performans beklentilerini karşılamakla kalmamakta, aynı zamanda birçok pratik alanda bu beklentilerin ötesine geçebilmektedir. Bununla birlikte, bu tür sistemlerin çıktıları sorgulanmaksızın kabul edilmemelidir; çünkü düşmanca saldırılara açıklık, veriye dayalı önyargılar ve sistem güvenilirliği gibi çeşitli kırılganlıklar barındırmaktadır. Makine öğrenimi (MÖ) algoritmalarına ilişkin kuramsal bir anlayış mevcut olsa da bu sistemlerin içsel karar alma süreçleri sıklıkla opak kalmakta, bu da kararların gerekçelerini açıklığa kavuşturabilecek yöntemlere olan ihtiyacı artırmaktadır.

Bu noktada, Açıklanabilir Yapay Zekâ (AYZ) devreye girmektedir. Açıklanabilirlik, bir YZ sisteminin kararlarının ardındaki mantığı paydaşların anlayabileceği şekilde ifade etme yeteneğini tanımlar. YZ'nin üçüncü gelişim dalgası olarak kabul edilen bu yaklaşım, sistemlerin kendi davranışlarını ve sonuçlarını doğrudan açıklayabilmesini hedefler. AYZ, insan merkezli bir tasarımı benimseyerek karar vericiyi merkeze yerleştirir ve onun sistemi anlayıp değerlendirebilmesini sağlamak üzere geliştirilmiştir.

Ancak AYZ alanında önemli bir zorluk, model açıklanabilirliği ile tahmin gücü arasında çoğu zaman karşılaşılan ödünleşimdir. Yüksek doğruluk sağlayan derin öğrenme modelleri gibi yapılar genellikle düşük düzeyde şeffaflığa sahiptir. AYZ girişimleri, bu çelişkiyi ortadan kaldırmak için, hem yüksek tahmin başarımını koruyan hem de açıklanabilirliği ve şeffaflığı artıran yöntemler geliştirmeye odaklanmaktadır. Modellerin çıktılarının detaylı biçimde açıklanması, kullanıcıların modelin hangi faktörlerden etkilendiğini anlamasını sağlamakta ve sorumlu sistem kullanımını teşvik etmektedir.

Açıklanabilirlik, modelin pasif bir özelliği değil; aktif bir fonksiyonudur. Bu, sistemin içsel işleyişini ortaya koymak üzere belirli mekanizmaları içermesi anlamına gelir. AYZ'nin temel kavramları arasında yorumlanabilirlik, şeffaflık ve anlaşılabilirlik yer alır. Yorumlanabilirlik, bir kullanıcının modelin mantığını ne ölçüde takip edebileceğini ifade ederken, şeffaflık modelin yapısı ve parametrelerinin ne kadar açık biçimde ortaya konduğuyla ilgilidir. Anlaşılabilirlik ise açıklamaların teknik olarak açık olmasının ötesinde, kullanıcının bu açıklamaları kendi bilgi düzeyine göre yorumlayabilme yeteneğiyle bağlantılıdır.

AYZ konusunun daha sistematik biçimde anlaşılabilmesi için, bu yaklaşım üç temel soru üzerinden yapılandırılabilir: “Ne?”, “Neden?” ve “Nasıl?” soruları, AYZ'nin kapsamını, motivasyonunu ve uygulanma yöntemlerini açıklığa kavuşturur. “Ne?” sorusu, AYZ'nin tanımına ve kullanıcı yorumunu desteklemedeki işlevine odaklanır. “Neden?” sorusu, AYZ araştırmalarının arkasında yatan temel güdülerini örneğin yasal uyum, hata tespiti, önyargı giderimi, şeffaflık ve güven ihtiyacı ortaya koyar. “Nasıl?” sorusu ise açıklanabilirliğin uygulamadaki karşılığını, veri hazırlığından model seçimine, uygulamadan sonra geliştirilecek açıklama stratejilerine kadar ele alır.

AYZ yöntemleri, genel olarak ante-hoc ve post-hoc olmak üzere iki temel yaklaşımda sınıflandırılmaktadır. Ante-hoc açıklanabilirlik, karar ağaçları ya da doğrusal modeller gibi yapılarla doğrudan açıklanabilir biçimde tasarlanan modelleri ifade eder. Buna karşılık post-hoc açıklamalar, daha karmaşık ve opak modeller eğitildikten sonra geliştirilen açıklama stratejilerini içerir.

Makine öğrenimi modelleri, genellikle açıklanabilirlik düzeylerine göre beyaz kutu (white-box) ve kara kutu (black-box) sistemler olarak sınıflandırılır. Beyaz kutu modeller, doğası gereği şeffaftır ve genellikle ante-hoc stratejilerle ilişkilendirilir. Bu modeller, özellikle açıklık, hesap verebilirlik ve kullanıcı güveninin kritik olduğu uygulamalarda tercih edilir. Buna karşılık, derin öğrenme mimarileri ve topluluk modelleri gibi kara kutu yapılar, yüksek performans sağlar; ancak açıklanabilirlik bakımından sınırlıdır. Bu tür modellerin anlaşılması ve gerekçelendirilmesi için SHAP, LIME ve karşı olgusal analiz gibi post-hoc araçlara ihtiyaç duyulmaktadır.

AYZ teknikleri, bu kara kutu doğasını açığa çıkarma kapasitesi sayesinde veri bilimi uygulamalarını ciddi biçimde zenginleştirmektedir. Bu araçlar sadece kullanıcıların modeli daha iyi anlamasını sağlamakla kalmaz, aynı zamanda kalite güvence süreçlerinde, adalet değerlendirmelerinde ve alana özgü bilgi entegrasyonunda da önemli bir rol oynar. Özellikle finans gibi yüksek risk içeren sektörlerde, sistemlerin şeffaf çalışması yasal uyum ve paydaş güveni için zorunludur.

Her ne kadar gelişmiş makine öğrenimi araçlarına erişim kolaylaşmış olsa da, bu araçların finans sektörüne doğrudan uygulanmasında önemli zorluklar devam etmektedir. Finansal bağlamda yalnızca bir kararın sonucu değil, o kararın nasıl alındığı da önemlidir. AYZ teknolojileri, model davranışlarının sorgulanabilir ve gerekçelendirilebilir olmasını sağlayarak, etik standartların korunmasına katkı sağlar. Bu aynı zamanda, demografik faktörlere dayalı dışlama ya da adaletsiz kredi verme gibi önyargılı sonuçların önlenmesi açısından da büyük önem taşır.

AYZ, aynı zamanda finans profesyonellerine örneğin analistlere, düzenleyici otoritelere ve yatırımcılara YZ temelli tahminlerin arkasındaki mantığı daha derinlemesine anlama imkânı sunar. Portföy optimizasyonu, piyasa riski değerlendirmesi veya kredi puanlaması gibi alanlarda kullanılan AYZ araçları, modellerin hangi ekonomik sinyallerden ve tarihsel veri örüntülerinden beslendiğini açığa çıkarır. Örneğin hisse senedi fiyatlarını tahmin eden bir model, çeyreklik kârlar, piyasa oynaklığı ya da makroekonomik göstergeler gibi değişkenlerin tahmine ne ölçüde katkı sunduğunu ayrıştırabilir ve böylece çıktılar hem daha anlaşılır hâle gelir hem de güvenilirlik kazanır.

Sonuç olarak, finans sektöründe AYZ'ye yönelik talebi yalnızca teknolojik gelişmeler değil; aynı zamanda algoritmik şeffaflığa dair toplumsal beklentiler ve düzenleyici baskılar da şekillendirmektedir. Finansal kurumların, YZ tabanlı kararlarını yalnızca teknik olarak değil, gerekçeleriyle birlikte müşterilere, düzenleyicilere ve kamuoyuna sunmaları beklenmektedir. Açıklanabilirliği YZ geliştirme sürecine entegre eden kurumlar, bu beklentilere daha etkin şekilde yanıt verebilecek ve hesap verebilirlik, adalet ve güven ilkeleriyle daha tutarlı hareket edebileceklerdir.(Mohsin ve Nasim, 2025).

1.7. Açıklanabilir YZ Uygulamaları

Bu çalışmada yer alan literatür incelemesi, dijital veri tabanları, akademik dergiler ve konferans bildirileri gibi hakemli kaynaklara dayanan titiz ve sistematik bir araştırma sürecine dayanmaktadır. Tarama süreci, “Açıklanabilir Yapay Zekâ (AYZ)”, “şeffaflık”, “hesap verebilirlik” ve “finansal karar alma” gibi özenle seçilmiş anahtar kelimeler aracılığıyla yönlendirilmiş; böylece kapsamın sınırlandırılması ve tematik bütünlüğün korunması sağlanmıştır. Güncellik ve akademik geçerlilik ilkesine bağlı kalınarak, alana katkı sunan çağdaş çalışmalara öncelik verilmiş; dahil etme ve hariç tutma kriterleri bu doğrultuda belirlenmiştir (Rane vd., 2023, SSRN 4640316).

Finans sektörü, ulusal ekonomik kalkınmanın temel direklerinden biri olmaya devam etmektedir ve sektördeki operasyonel etkinlik genellikle genel ekonomik performansın bir göstergesi olarak kabul edilmektedir. Bu alandaki temel hedeflerden biri, önceden belirlenmiş risk iştahı ve toleransı sınırları içerisinde kalmak kaydıyla yatırım getirisini (ROI) maksimize etmektir. Daha agresif bir risk yaklaşımı, çoğu zaman sektörel büyümeye işaret eden iyimser bir piyasa duruşunu temsil eder. Bununla birlikte, bu açıklığa rağmen, finansal kuruluşların YZ teknolojilerini benimseme süreci beklenenden yavaş ilerlemektedir. Bu durumun başlıca nedenleri arasında güçlü bir veri altyapısının eksikliği, ilk uygulama aşamalarında belirsiz yatırım getirileri ve üst yönetimin temkinli bütçe yaklaşımı yer almaktadır.

YZ, modern çağın en dönüştürücü teknolojilerinden biri olarak kabul edilmekte ve akıllı arama algoritmalarından doğal dil işlemeye ve gerçek zamanlı karar destek sistemlerine kadar çok geniş bir uygulama yelpazesinde kullanılmaktadır. Veri

erişilebilirliğinde yaşanan gelişmeler, artan hesaplama gücü ve algoritmik verimlilik, YZ'nin sektörler arası yayılımını önemli ölçüde hızlandırmıştır. Ancak, özellikle düzenlemeye tabi alanlarda örneğin finans sektöründe YZ modellerinin pratik olarak uygulanabilmesi, yalnızca yüksek tahmin doğruluğu değil, aynı zamanda güçlü bir açıklanabilirlik düzeyini de gerektirmektedir.

Geleneksel istatistiksel modelleme yaklaşımları, düşük hesaplama maliyeti ve yüksek açıklık seviyesi sunmasına karşın; doğrusal yapı, homoskedastisite ve gözlem bağımsızlığı gibi sıkı varsayımlara dayanır. Bu kısıtlamalar, söz konusu modellerin karmaşık ve gerçek dünya verilerine uygulanabilirliğini sınırlar. Buna karşılık, makine öğrenimi alanındaki gelişmeler; Destek Vektör Makineleri (SVM), Karar Ağaçları ve Yapay Sinir Ağları gibi modeller aracılığıyla tahmin performansında ciddi artışlar sağlamıştır. Bunun yanında, Rastgele Ormanlar, AdaBoost ve Extreme Gradient Boosting gibi topluluk teknikleri, özellikle risk yönetimi ve kredi skorlama gibi alanlarda öngörü gücünü daha da ileri taşımıştır.

Ancak, yüksek tahmin başarımları sunmalarına rağmen, bu modeller genellikle şeffaflıktan yoksundur ve teknik olmayan paydaşlar örneğin düzenleyici kurumlar, yatırımcılar veya kredi derecelendirme kuruluşları tarafından kolaylıkla anlaşılamamaktadır. Bu durum, özellikle gerekçelendirme gerektiren hassas uygulamalarda sorun teşkil etmektedir. Gerçek dünya uygulamaları arasında iflas tahmini, dijital bankacılıkta dolandırıcılık tespiti ve hisse senedi fiyatı öngörülerini gibi konular yer almakta olup, bu alanlarda doğruluk öncelikli olduğu için model karmaşıklığı artmakta ve açıklanabilirlik düşmektedir.

Kara kutu modeller; Derin Sinir Ağları (DNN), Üretici Çekişmeli Ağlar ve XGBoost gibi topluluk mimarileri, tahmin doğruluğu açısından zirve düzeyde performans sergilemektedir. Ancak bu modellerin içsel işleyişi çoğunlukla anlaşılmaz yapıdadır, bu da paydaş güvenini ve yasal kabulü sınırlamaktadır. Buna karşın, doğrusal regresyonlar, karar kuralları ve ağaç tabanlı algoritmalar gibi beyaz kutu (white-box) modeller, şeffaflık ve doğrulama açısından daha elverişli bir yapı sunar.

Bu gerilimi dengelemek amacıyla, Açıklanabilir Yapay Zekâ (AYZ) alanı, yorumlanabilirlik boşluğunu sistematik biçimde ele almak üzere gelişmiştir. Öncü çalışmalar, AYZ yöntemlerini modelleme aşaması (ante-hoc vs. post-hoc), açıklama

düzeyi (yerel vs. genel) ve uyarlanabilirlik (model-özgü vs. modelden bağımsız) gibi çeşitli boyutlarda sınıflandırmıştır. Ante-hoc yöntemler, açıklanabilirliği model tasarımının doğasına entegre ederken; post-hoc yaklaşımlar, model eğitildikten sonra SHAP (Katkı Temelli Açıklamalar), karşı olgusal akıl yürütme veya kısmi bağımlılık grafikleri gibi tekniklerle açıklamalar üretir.

Ante-hoc stratejiler genellikle içsel olarak yorumlanabilir modeller oluşturmayı hedefler ve bu yapılar genellikle beyaz kutu modeller olarak tanımlanır. Bu modellerde, kullanıcılar kararların girdilere nasıl dayandığını ek araçlara gerek duymadan izleyebilir. Buna karşılık post-hoc yöntemler, eğitim sonrası uygulanır ve kara kutu sistemlerin anlaşılmasını kolaylaştırmak için görselleştirmeler veya algoritmik yaklaşık açıklamalar sunar. Yerel açıklamalar belirli tahminlere odaklanırken, genel açıklamalar tüm modelin davranışını anlamaya yönelik bilgiler sağlar.

Modelden bağımsız teknikler, genellikle post-hoc açıklanabilirlik kapsamında kullanılır ve herhangi bir algorithmadan bağımsız çalışabilir. Bu esneklik sayesinde, evrişimli sinir ağları (CNN) ve topluluk mimarileri dâhil olmak üzere birçok modelde uygulanabilirler. Buna karşılık, model-özgü yöntemler belirli algoritmalara özel olarak geliştirilmiştir ve daha derin fakat dar kapsamlı içgörüler sunar (Kinger ve Kulkarni, 2024).

Finansal bağlamda, yalnızca kurum içi analiz ihtiyaçlarını değil, aynı zamanda dış paydaşların yorumlama gereksinimlerini de karşılayabilecek açıklanabilir YZ sistemlerinin geliştirilmesine yönelik artan bir eğilim söz konusudur. Bu paydaşlar arasında hissedarlar, kredi derecelendirme kuruluşları ve düzenleyici kurumlar yer almaktadır. Ancak mevcut AYZ çalışmalarının önemli bir bölümü, bu dış aktörlerin açıklama ihtiyaçlarını göz ardı etmektedir. Finansal sıkıntı tahmini için önerilen bir çerçeve; SHAP, kısmi bağımlılık analizleri ve karşı olgusal açıklamalar gibi teknikleri kullanarak şeffaflığı artırmakta ve düzeltici önlemleri kolaylaştırmaktadır. Yerel açıklamalar, zor durumdaki firmaların hangi risk değişkenlerinden en fazla etkilendiğini anlamasına yardımcı olurken; genel açıklamalar, modelin öznitelik önemi ve etkileşim yapılarını ortaya koyarak güven inşa eder.

Makine öğrenimi ve derin öğrenme mimarileri, özellikle Yapay Sinir Ağı (ANN), Yinelene Sinir Ağı (RNN) ve Evrişimli Sinir Ağı (CNN) tabanlı yapılar, yüksek boyutlu ve büyük ölçekli finansal verileri işleme konusunda oldukça etkilidir. Bu teknikler, özellikle borsa verilerinde doğrusal olmayan desenleri ve zamansal dinamikleri modelleme yeteneği sayesinde öne çıkmaktadır. Bununla birlikte, bu modellerin büyük veri kümeleri üzerinde eğitimi, yüksek hesaplama maliyeti gibi bazı pratik sınırlamalar da barındırmaktadır.

Bu sınırlamaların üstesinden gelmek amacıyla, kuantum mekaniği ilkelerinden yararlanan kuantum esinli makine öğrenmesi ve kuantum sinir ağları gibi yeni paradigmlar ortaya çıkmıştır. Süperpozisyon ve dolanıklık gibi kuantum özellikleri sayesinde, kuantum hesaplama modelleri, olasılıksal çıktıları çok daha az kaynakla simüle edebilmektedir. Bu bağlamda, genetik algoritmalarla optimize edilen kuantum sinir ağları gibi hibrit mimariler, finansal öngörü görevlerini daha verimli biçimde gerçekleştirme kapasitesiyle dikkat çekmektedir. Bu hibrit modeller, aynı anda birden fazla hesaplamayı yürütebilmekte ve sosyal medya duyarlılığı gibi yardımcı veri kaynaklarından karmaşık tarihsel desenleri tanımlayarak geleneksel makine öğrenimi veya derin öğrenme modellerinin ötesine geçebilmektedir. (Gandhudi vd., 2024, Makale No. 109302).

1.8. YZ Açıklayıcı Araçlar

Yakın tarihli bir araştırmada, opak makine öğrenimi sistemlerinin nasıl yorumlanabileceğine dair teknikleri inceleyen kapsamlı bir sınıflandırma yaklaşımı sunulmuştur. Bu sınıflama, kara kutu modellerin davranışlarını açıklamaya yönelik temel zorlukların yapılandırılmış bir çerçeve içerisinde ele alınmasını sağlamak ve özellikle sinir ağı temelli mimariler üzerinde uygulanan farklı açıklama paradigmlarının birbirinden ayrıştırılmasına olanak tanımaktadır. Araştırmacılar; tekil karar ağaçları ile tam karar sistemleri, destek vektör makinelerinin açıklanması ve nöron düzeyindeki aktivasyonların yorumlanması gibi yöntemler arasındaki metodolojik farkları detaylı şekilde analiz etmiş; açıklama tekniklerini dört temel kategori altında toplamışlardır: Kara kutu modelin doğrudan açıklanması, modelin ürettiği çıktının açıklanması, kara kutu yapıların içsel tanınması ve doğası gereği

şeffaf olan modellerin proaktif biçimde tasarlanması. Bu sistematik çerçeve, mevcut yöntemlerin belirli açıklama problemleriyle eşleştirilmesine yardımcı olarak, açıklama ihtiyacı, model türü ve girdi özelliklerine göre doğru yöntem seçiminde sağlam bir temel sunmaktadır. Bu çalışma, açıklanabilirlik tekniklerinin geniş yelpazesi içinde araştırmacıların yön bulmasına katkı sağlayarak literatüre anlamlı bir katkı sunmaktadır (Gilpin vd., 2018, s. 80).

Bu bağlamda, modelden bağımsız AYZ teknikleri, özellikle yüksek risk barındıran kararların yalnızca doğrulukla değil, aynı zamanda hesap verebilirlikle de desteklenmesini gerektiren finansal sektörde, karmaşık algoritmik sistemlerin yorumlanabilirliğini artırmak için vazgeçilmez araçlar hâline gelmiştir. Makine öğrenimi sistemlerinin mimari karmaşıklığı arttıkça, bu sistemlerin tahmin mantığını anlaşılır hâle getirme gereksinimi de kritik düzeye ulaşmaktadır. Modelden bağımsız AYZ, belirli bir algoritmaya bağlı olmayan ve doğrusal, ağaç tabanlı veya derin sinir ağı gibi herhangi bir modele uygulanabilen yöntemler bütününe ifade etmektedir. Bu uyarlanabilirlik özellikle finansal uygulamalarda büyük önem taşımaktadır; zira derin öğrenme ve topluluk yöntemleri bu alanda yaygın olarak kullanılmakta ancak sıklıkla denetleyiciler, denetçiler ve son kullanıcılar için gerekli şeffaflığı sunamamaktadır.

Finansal bağlamda öngörüselleştirme; risk yönetimi, dolandırıcılık tespiti, yatırım optimizasyonu ve kredi değerlendirmesi gibi alanlara derinlemesine entegre edilmiştir. Bununla birlikte, en gelişmiş algoritmaların çoğunda açıklanabilirliğin yetersiz olması; etik kullanım, hesap verebilirlik ve yasal uyum gibi alanlarda ciddi endişeler doğurmaktadır. Modelden bağımsız açıklanabilirlik, bu güçlü ama karmaşık modeller ile eyleme geçirilebilir ve şeffaf karar destek sistemleri arasındaki köprüyü kurmaktadır. Bu yöntemler, model çıktıları etkileyen değişkenleri belirleyerek paydaşlara içgörü sağlamakta; böylece daha bilinçli, güvenilir ve hesap verebilir karar alma süreçlerine olanak tanımaktadır.

1.8.1. Yerel Konumlandırılabilir Modelden Bağımsız Açıklamalar

Yaygın olarak benimsenen modelden bağımsız yöntemlerden biri olan **LIME** (Yerel Yorumlanabilir Modelden Bağımsız Açıklamalar), karmaşık modellerin yerel olarak anlamlı yaklaşık temsillerini üretmeye odaklanmaktadır. Girdi değişkenlerine

küçük bozulmalar (pertürbasyonlar) uygulayarak modelin tahmininde meydana gelen değişimleri gözlemleyen LIME, ilgi duyulan veri noktasının çevresindeki karar sınırını yaklaşık olarak temsil eden yorumlanabilir bir vekil model (örneğin doğrusal regresyon) inşa eder. Finans alanında bu yöntem, bireysel sonuçların açıklanması amacıyla kullanılabilir; örneğin bir kredi başvurusunun neden reddedildiği ya da bir işlemin dolandırıcılık şüphesiyle nasıl işaretlendiği gibi. LIME'in yerel düzeyde sunduğu açıklamalar, özellikle belirli kararların dış paydaşlara gerekçelendirilmesi veya model hatalarının ayıklanması (debugging) süreçlerinde oldukça faydalıdır.

1.8.2. Shapley Katkı Temelli Açıklamalar ve Oyun Kuramı

Modelden bağımsız AYZ (Açıklanabilir Yapay Zekâ) yaklaşımları arasında önemli bir yapı taşı da SHAP (Shapley Katkı Temelli Açıklamalar) çerçevesidir. SHAP, kökeni iş birliğine dayalı oyun kuramına uzanan Shapley değerleri teorisinden (Shapley, 1953, s. 1095) esinlenmiştir. Oyun kuramsal bakış açısından bir modelin tahmini, giriş değişkenlerinin birlikte hareket ettiği bir koalisyonun sonucu olan “ödeme” (payout) olarak ele alınabilir. SHAP, her bir değişkene, model tahmini üzerindeki marjinal etkisini nicel olarak ifade eden bir katkı skoru atar. Bu katkı, tüm olası öznitelik kombinasyonları üzerinden hesaplanarak elde edilir. Yöntem; simetri (aynı katkılar eşit değerlere sahip olmalıdır), etkililik (tüm katkıların toplamı model çıktısına eşit olmalıdır) ve toplamsallık (farklı modellerdeki katkılar lineer biçimde birleştirilebilir) olmak üzere üç temel aksiyomu benimser. Bu aksiyomlar, SHAP açıklamalarının kuramsal sağlamlık ve tutarlılık taşımasını garanti altına alır.

SHAP'ın yorumlayıcı gücü, hem genel açıklamalar (tüm veri kümesi düzeyinde özniteliklerin toplam etkisini gösteren) hem de **yerel açıklamalar** (tekil tahminleri açıklayan) üretebilmesinde yatmaktadır. Finansal sektörde bu çift yönlü yetenek, kurumların hem genel eğilimleri denetlemesine (örneğin genel kredi riski faktörleri) hem de vaka bazlı kararları gerekçelendirmesine (örneğin bireysel kredi onayları) olanak tanır. Bu da SHAP'ı, şeffaflık ve adalet gerektiren düzenleyici ortamlarda son derece uygun bir araç hâline getirir.

SHAP'ın oyun kuramı ile bağlantısı, oyuncu koalisyonlarını toplam faydayla ilişkilendiren karakteristik fonksiyon üzerinden kurulur. Burada her bir giriş değişkeni,

model çıktısına yaptığı katkı değerlendirilen bir “oyuncu” gibi düşünülebilir. Bu değerlendirme, tüm olası öznitelik alt kümeleri üzerinde yapılır. Böylece sorumluluğun kapsamlı ve adil bir şekilde dağıtılması sağlanır. Bu nitelik, sigorta fiyatlaması, finansal sıkıntı tahmini ve yatırım portföyü optimizasyonu gibi yüksek risk içeren uygulamalarda özellikle kritik önem taşır.

1.8.3. Finansal YZ Uygulamalarının Genişletilmiş Etkileri

Finansal makine öğrenimi sistemlerinin açıklanabilirliği yalnızca teknik bir mesele değil; aynı zamanda operasyonel ve etik bir zorunluluktur. Finansal kurumlar, model tabanlı kararların gerekçesini açıkça ortaya koyabilmelidir; özellikle artan düzenleyici baskılar ve kamu denetimi karşısında bu gereklilik daha da kritik hâle gelmektedir. Modelden bağımsız AYZ yöntemleri, bu kurumların model davranışlarını doğrulamasına, potansiyel önyargıları tespit etmesine ve öngörüsül sonuçları sektörel bilgiyle uyumlu hâle getirmesine olanak tanır.

Bununla birlikte, hisse senedi piyasası tahmini, iflas öngörüsü veya dolandırıcılık tespiti gibi karmaşık uygulamalarda, yüksek kapasiteli modellerin kullanımı genellikle şeffaflık pahasına gerçekleşmektedir. Ancak SHAP ve LIME gibi teknikler, modelin performansından ödün vermeden analistler ve paydaşlar tarafından denetlenmesini mümkün kılar. Örneğin iflas tahminlerinde, SHAP analizleri; likidite oranları, borç/varlık oranları ve piyasa duyarlılığı gibi değişkenlerin ödeme güçlüğü öngörülerinde orantısız etkiler yarattığını ortaya koyabilir. Bu da, paydaşların daha bilinçli ve zamanında kararlar almasına imkân sağlar.

Özetle, modelden bağımsız açıklanabilir yapay zekâ, modern makine öğreniminde sıkça karşılaşılan performans-açıklanabilirlik ödünleşimini dengelemede temel bir rol oynamaktadır. Algoritmadan bağımsız açıklanabilirlik sağlayan bu teknikler, finansal kurumların giderek daha fazla veriyle şekillenen bir ortamda sorumlu, şeffaf ve etkili biçimde faaliyet göstermelerini mümkün kılmaktadır.

$$\begin{aligned} v_{R(S)} &= 1 \quad \text{eğer } R \subseteq S \\ &= 0 \quad \text{yada} \end{aligned}$$

İş birliğine dayalı oyun kuramında, **Shapley değeri**, bir koalisyondaki toplam getirinin (payoff) her bir oyuncuya adil biçimde dağıtılması için sistematik ve ilkesel bir yöntem sunar. Bu dağılım, oyuncunun grubun tüm olası alt kümelerine yaptığı bireysel katkıya dayalı olarak gerçekleştirilir. Özellikle “oybirliği” ya da “saf pazarlık” oyunu bağlamında, belirli bir alt küme

$R \subseteq NR$ ve $NR \subseteq NNR \subseteq NNR \subseteq N$ İş birliğine dayalı oyun kuramında, **Shapley değeri**, bir koalisyondaki toplam getirinin (payoff) her bir oyuncuya, grubun tüm olası alt kümelerine yaptığı katkıya dayalı olarak adil biçimde dağıtılması için sistematik ve ilkesel bir yöntem sunar. “Oybirliği” ya da “saf pazarlık” oyunu bağlamında, belirli bir oyuncu alt kümesinin (örneğin RRR kümesi) belirli bir kaynağın nasıl tahsis edileceğine birlikte karar vermesi gerektiği durumlarda, bu alt kümenin dışındaki oyuncular **etkisiz oyuncu** (null player) olarak kabul edilir; çünkü bu oyuncular sonucun üzerinde hiçbir etkiye sahip değildir. Simetri varsayımı gereğince, RRR kümesi içerisindeki her bir oyuncu toplam faydadan eşit pay alır. Bu nedenle, **Shapley değeri**, bu oyuncuların her biri için eşit katkıyı yansıtan bir değer olarak hesaplanır. $i \in R$ olur $\phi_i(v_R) = \frac{1}{r} \phi_i(v_R) = \frac{1}{r}$

$$\phi_i(v_R) = \frac{1}{r}, \text{ ise } r = |R| \text{ } r = |R|$$

$$r = |R|$$

Bu çerçeve, oyuncular alt kümeleri üzerinde tanımlanan **karakteristik fonksiyonlar** aracılığıyla tanımlanan tüm oyunlara genellenebilir. Oyuncu kümesi NNN içindeki boş olmayan her alt küme RRR için tanımlanan bu **oybirliği oyunlarının** tümü yani $v_R, v_{R \cup R}, \dots$ iş birliğine dayalı oyunlar uzayı için **tam bir temel (baz)** oluşturur. Bu nedenle, herhangi bir rastgele oyun v , bu temel oyunların **lineer birleşimi** (linear combination) olarak ifade edilebilir. Ayrıca, **toplamsallık aksiyomu (additivity axiom)**, bu temel oyunlar üzerinde tanımlanan değer fonksiyonunun tüm iş birliğine dayalı oyunlara **tekil ve tutarlı** bir şekilde genellenmesini garanti eder.

Bir oyuncunun **Shapley değeri** için genel formül ise şu şekildedir:

$$\phi_i = \sum_{N \ni S \ni i} \frac{|S|-1! (n-|S|)!}{n!} (v(S) - v(S \setminus i))$$

$N \ni$ verilir

$$\begin{aligned}
\phi_i(v) &= \sum_{S \subseteq N \setminus \{i\}} (N \setminus S \setminus \{i\})! (n - |S| - 1)! n! [v(S \cup \{i\}) - v(S)] \phi_{i(v)} \\
&= \sum_{S \subseteq N \setminus \{i\}} \frac{(N \setminus S \setminus \{i\})! (n - |S| - 1)! n!}{(N \setminus S \setminus \{i\})! (n - |S| - 1)! n!} [v(S \cup \{i\}) - v(S)] \phi_{i(v)} \\
&\subseteq N \setminus \{i\} \sum n! (N \setminus S \setminus \{i\})! (n - |S| - 1)! [v(S \cup \{i\}) - v(S)]
\end{aligned}$$

ifade, oyuncu iii'nin bir koalisyona katılan oyuncuların tüm permütasyonları boyunca beklenen marjinal katkısını nicel olarak tanımlar. Her bir sıralamanın eşit olasılıkla gerçekleştiği varsayımı altında, oyuncuların rastgele belirlenen bir sırayla teker teker koalisyona katıldığını düşünebiliriz. Bu bağlamda, oyuncu iii'nin Shapley değeri, mevcut gruba katıldığında sağladığı ortalama ek değeri ifade eder.

Örneğin, biri satıcı ve ikisi alıcı olmak üzere üç oyuncudan oluşan basitleştirilmiş bir piyasa modelinde, Shapley değerleri altı olası sıralama üzerinden marjinal katkıların ortalaması alınarak hesaplanır. Ancak daha karmaşık yapılar söz konusu olduğunda, örneğin Birleşmiş Milletler Güvenlik Konseyi'nin beş daimi üye ve on geçici üyeden oluşan 15 oyunculu bir oyun olarak modellenmesi durumunda, olası sıralamaların (15!) tümünün tek tek değerlendirilmesi faktöriyel büyüme nedeniyle hesaplama açısından pratik değildir (15! $\approx$ 101210¹²1012).

Buna rağmen, simetri, etkililik ve rastgele sıralama formülasyonu gibi özellikler, Shapley değerlerinin tam permütasyonların tümü hesaplanmadan yaklaşık olarak tahmin edilmesini mümkün kılar. Bu tür bir senaryoda elde edilen Shapley değerleri, daimi üyelerin koalisyona yaptığı marjinal katkının geçici üyelere kıyasla 100 katın üzerinde olduğunu ortaya koyar. Bu durum, veto hakkının koalisyon dinamikleri üzerindeki ağırlığını ve etkisini açık bir şekilde gözler önüne serer.

1.8.4. Makine Öğreniminde Shapley Toplamsal Açıklamalar

SHAP (Shapley Additive Explanations) çerçevesi, iş birliğine dayalı oyun kuramından türetilmiş teorik temeli makine öğrenimi alanına uyarlayarak, tahmine dayalı modellerdeki özellik katkılarını belirlemek için sağlam ve adil bir yöntem sunar. **SHAP değerleri**, her bir giriş özelliğinin modelin çıktısını ortalama tahmininden ne kadar uzaklaştırdığını nicel olarak ifade eder.

Formel olarak, belirli bir tahmin için $f(x)$ çıktısı, modelin tüm örnekler üzerindeki ortalama tahmini değerinden sapmanın, ilgili giriş değişkenlerinin bireysel katkılarına ayrıştırılması yoluyla açıklanır. Yani, SHAP yöntemi ile her bir özelliğin, nihai tahmine olan **marjinal etkisi** hesaplanır ve bu etkiler tüm olası özellik kombinasyonları üzerinden ortalamaya alınarak belirlenir.

Bu yaklaşım, hem yerel düzeyde (bireysel tahminler için) hem de küresel düzeyde (tüm veri seti genelinde) yorumlanabilirlik sağlayarak, makine öğrenimi modellerinin daha şeffaf ve güvenilir hâle gelmesini sağlar.

$$\text{Açık: } f(x) = \phi_0 + \sum_{i=1}^M \phi_i f(x) = \phi_0 + \text{toplama} = \phi_0 + \sum_{i=1}^M \phi_i$$

Burada ϕ_0 , temel değeri (genellikle eğitim seti üzerindeki ortalama model çıktısı) ifade ederken, ϕ_i , belirli bir özelliğin tahmine olan katkısını temsil eder. Bu nitelikler, doğrudan Shapley aksiyomlarından türetilmiş olan yerel doğruluk, tutarlılık ve eksiklik durumu gibi prensipleri sağlamaktadır.

Finansal uygulamalarda SHAP, bireysel özelliklerin (örneğin kredi notu, gelir düzeyi, piyasa oynaklığı gibi) kredi onayı, risk değerlendirmesi veya yatırım kararları gibi sonuçlar üzerindeki etkilerini ortaya koyarak güçlü bir şeffaflık sağlar. Örneğin, portföy yönetiminde SHAP, makroekonomik göstergelerin veya geçmiş performans metriklerinin, varlık tahsis kararlarını ne ölçüde yönlendirdiğini sıralayabilir. Benzer şekilde, kredi puanlamasında SHAP, bir başvurunun reddedilmesinin daha çok düşük gelir düzeyinden mi yoksa yüksek borç oranından mı kaynaklandığını gösterebilir.

İş birliğine dayalı oyun kuramıyla uyumlu yapısı sayesinde SHAP, hem tekil tahminleri açıklayan yerel yorumlanabilirlik sağlar hem de birden fazla örnek üzerinden açıklamaları birleştirerek küresel içgörü sunar. Bu ikili işlevsellik, özellikle regülasyona uyum, etik sorumluluk ve paydaşlara karşı şeffaflık gibi hususların kritik öneme sahip olduğu finansal hizmetler alanında büyük bir avantaj sağlar. (Rane vd., 2023).

1.9. Modeller için YZ Yardımcılar

Son yıllarda Yapay Zekâ (YZ), YZ destekli teknolojiler aracılığıyla çok çeşitli uygulamaları mümkün kılarak önemli bir ivme kazanmıştır. YZ gelişiminin dikkat çekici kilometre taşlarından biri, makine zekâsının erişemeyeceği düşünülen bir başarıyı temsil eden AlphaGo'nun, Go oyununda dünyanın en üst sıradaki oyuncusunu yenerek tüm dünyayı şaşırtması olmuştur. Benedict du Boulay, YZ'nin eğitimde entegrasyonunu inceleyerek, öğrenme deneyimlerini destekleme ve geliştirme potansiyelini vurgulamıştır. Benzer şekilde Carlos Ramos ve çalışma arkadaşları, günlük yaşamı iyileştirmeyi amaçlayan YZ tabanlı bir çevresel zekâ sistemi geliştirmiştir.

2018 Google I/O konferansında, Google Duplex özelliği ile sanal asistan kabiliyetlerinde büyük bir ilerleme duyurulmuştur. Bu özellik sayesinde, Google Asistan bir insan yardımcısı gibi davranarak otonom şekilde telefon görüşmeleri gerçekleştirebilmekte, randevu ayarlayabilmekte veya rezervasyon yaptırabilmektedir.

Bu gelişme, kurallara dayalı erken dönem konuşma ajanları olan Eliza ve Alice gibi sistemlerden büyük ölçüde üstün olan modern makine öğrenimi sistemlerinin geldiği noktayı simgeler.

Günümüzün YZ tabanlı asistanları arasında Apple'ın Siri'si, Amazon'un Alexa'sı ve Microsoft'un XiaoIce'ı yer almakta ve bu sistemler kullanıcılarla doğal bir biçimde etkileşim kurabilmektedir. Diğer alanlarda da YZ ve makine öğrenmesi etkin bir şekilde kullanılmaktadır. Örneğin, araştırmacılar gerçek dünya koşullarında EEG sinyallerindeki gürültüyü azaltmak ve sinyal netliğini artırmak amacıyla tekrarlayan kuantum sinir ağı (RQNN) kullanan yenilikçi bir beyin-bilgisayar arayüzü olan iAUI'yi (intelligent adaptive user interface) geliştirmiştir.

Sanal asistanların ötesinde, daha geniş kapsamlı konuşma platformları olan sohbet botları (chatbotlar) da ortaya çıkmıştır. Genel amaçlı asistanların aksine, sohbet botları genellikle görev odaklı hizmetlere yöneliktir. Örneğin, Forbes Asia Bot mesajlaşma uygulamaları üzerinden gerçek zamanlı haber güncellemeleri ve abonelikler sunarken, TaxiGo Bot kullanıcıların kolayca taksi rezervasyonu yapmasına olanak tanımaktadır. Bu sistemler, kullanıcıya tanıdık gelen iletişim

arayüzleri ve doğal diyalog kullanarak erişilebilirliği ve kullanıcı dostu deneyimi artırmaktadır. (Wu vd., 2020, s. 77788).

1.10. Yapay Sinir Ağları

Yapay Sinir Ağları (YSA), insan beyninin bilgi işleme şeklini taklit etmeyi amaçlayan ve çok katmanlı yapılar üzerinden öğrenme gerçekleştiren önemli bir yapay zekâ yaklaşımıdır. Finansal veriler gibi yüksek boyutlu ve karmaşık yapıdaki veri setlerinde doğrusal olmayan ilişkileri modelleme yetenekleri sayesinde, özellikle tahminleme, sınıflandırma ve desen tanıma gibi görevlerde yaygın olarak kullanılmaktadır. Gelişmiş mimarileri ve öğrenme algoritmaları sayesinde, YSA'lar finansal karar destek sistemlerinde, kredi risk analizlerinde ve piyasa dalgalanması tahminlerinde etkili çözümler sunmaktadır. Bu nedenle, açıklanabilirlik sorunlarına rağmen, günümüz finansal yapay zekâ uygulamalarında YSA'lar stratejik bir konumda yer almaktadır.

1.10.1. Yapay Sinir Ağları Teorisi

Yapay sinir ağlarının temel yapı taşı olan nöronlar, çok sayıda girdinin bir araya gelerek tek bir çıkışa dönüştüğü doğrusal bir hesaplama sistemine dayanır. Her bir nöron, kendisine gelen $X_1, X_2, \dots, X_n$ giriş sinyallerini belirli katsayılarla çarpar; bu katsayılar $W_{i1}, W_{i2}, \dots, W_{in}$ şeklinde gösterilen ağırlıklardır ve her bir girdinin çıktıya olan katkısını belirlemek amacıyla kullanılır. Bu girişlerin ağırlıklı toplamı, belirli bir eşik değeri (θ) ile karşılaştırılır. Bu eşik değeri, nöronun aktif hale gelip çıkış üretip üretmeyeceğini belirleyen kritik bir sınırdır. Nöronun bu toplam girdi karşısında hangi çıktıyı vereceğini ise aktivasyon fonksiyonu belirler. Transfer fonksiyonu olarak da adlandırılan bu yapı, nöronun davranışını kontrol eder. Sinir ağı literatüründe en sık karşılaşılan aktivasyon fonksiyonlarından biri sigmoid fonksiyonudur ve genellikle şu şekilde ifade edilir: $f(u) = \frac{1}{1 + e^{-u}}$

1.10.2. Üretken Yapay Sinir Ağları

Son yıllarda, derin öğrenme tekniklerinin dolandırıcılık tespiti, risk değerlendirmesi ve senaryo modelleme gibi finansal uygulamalarda kullanılması üzerine giderek artan sayıda çalışma yapılmaktadır. Özellikle yapılandırılmamış verileri içeren senaryo analizleri, geleneksel Monte Carlo simülasyonları açısından önemli zorluklar teşkil etmektedir. Bu klasik yöntemler, daha gelişmiş uzamsal-zamansal teknikler karşısında çoğu durumda yetersiz kalmaktadır. Bugüne kadar, üretici sinir ağları ağırlıklı olarak finansal tahminleme görevlerinde kullanılmıştır. Ampirik örnekler arasında, döviz piyasasında optimal yatırım stratejilerinin modellenmesi ve menkul kıymet fiyatlarının dakika gibi ultra-kısa zaman dilimlerinde öngörülmesi yer almaktadır.

Öne çıkan yeniliklerden biri, temerrüt olasılıklarının ve tahvil piyasası davranışlarının simülasyonu amacıyla varyasyonel otomatik kodlayıcıların (VAE – Variational Autoencoders) kullanılmasıdır. Derin üretici modellerin en önemli avantajlarından biri, özellikle verinin kısıtlı olduğu durumlarda yüksek kaliteli sentetik veriler üretebilmeleridir. Örneğin, hisse senedi getirilerinin gerçekçi dağılımlarını sentezleyerek analiz kapasitesini artırabilirler. Bu modeller, yalnızca fiyat tahmini ile sınırlı kalmayıp, algoritmik işlem stratejilerini de geliştirmektedir. Örneğin, araştırmacılar derin pekiştirmeli öğrenme (DRL – Deep Reinforcement Learning) yöntemini piyasa etkisi sorununu çözmek için uygulamış ve hedef işlem hacimlerine ulaşmaya yönelik daha hassas emir yürütme stratejileri geliştirmiştir.

Ayrıca, derin geri beslemeli sinir ağları , yüksek frekanslı işlem verilerine dayanarak hisse devir oranlarını tahmin etmek amacıyla kullanılmıştır. Bu tahminler, pekiştirmeli öğrenmeye dayalı pazarlama stratejilerinin girdisini oluşturmuştur. Geleneksel tahminleme modellerinden farklı olarak, piyasa yapıcı sistemler net pozisyon taşımamakta ve mutlak fiyat yönünü tahmin etmek yerine alış-satış spread'lerinden (fiyat aralığından) kâr elde etmeyi hedeflemektedir.

Bu ileri düzey öğrenme sistemlerinin uygulamaya alınması, özellikle düzenleyici denetim ve risk azaltımıyla ilgili alanlarda, finansal kurumların operasyonel uygulamalarını dönüştürme potansiyeline sahiptir. Her ne kadar bu tür uygulamaların çoğu hâlâ deneysel veya pilot aşamada olsa da, vaka çalışmaları üretici

yapay sinir ağlarının (özellikle GAN – Generative Adversarial Networks) farklı finansal alanlarda sunduğu artan potansiyeli ortaya koymaktadır.

1.10.3. Geri Yayılımlı Sinir Ağları Algoritması

Geri Yayılım (Backpropagation – BP) sinir ağı, çok katmanlı ileri beslemeli bir mimari içerisinde denetimli öğrenme çerçevesi kullanır ve hata geriye yayılım algoritmasından faydalanarak karmaşık giriş-çıkış ilişkilerini modellemeye oldukça etkili bir yaklaşım sunar. Esnek yapısı ve geniş uygulama alanı sayesinde, sınıflandırma ve tahmin problemlerinde sıklıkla tercih edilmektedir. Tipik bir BP sinir ağı yapısı üç katmandan oluşur: giriş katmanı, gizli katman ve çıkış katmanı. Bu katmanlar genellikle M , N ve 1 büyüklükleriyle ifade edilir. Giriş düğümünden gizli düğüme uzanan her bağlantıya w_{th} , gizli düğümden çıkış düğüme olan her bağlantıya ise w_{hj} ağırlığı atanır. Öğrenme süreci, ağı boyunca giriş sinyallerinin ileri yönde yayılması ve ardından hata sinyalinin geriye doğru yayılması olmak üzere iki temel aşamadan oluşur.

Gizli ve çıkış katmanları arasındaki bağlantılarda eşik (threshold) değerleri de yer almakta olup, bu yapı hedef çıktıyı (t) üretmeyi amaçlar. Ağı öğrenme hızını kontrol eden parametre η (eta), modelin yakınsama hızını belirler. BP sinir ağları, tahminleme ve sınıflandırma görevlerinde gösterdiği güçlü performans sayesinde, özellikle İnternet tabanlı kredi risklerinin değerlendirilmesi gibi finansal risk analizlerinde etkili bir araç olarak öne çıkmaktadır. Bu tür risk analizleri, benzer risk profiline sahip şirket gruplarının belirlenmesini ve finansal ile çevresel göstergeler arasındaki temel desenlerin ortaya konmasını hedefler.

BP ağı, çevrim içi finansal ekosistemlerde çeşitli firma özellikleri ile bunlara karşılık gelen risk düzeyleri arasındaki doğrusal olmayan ilişkileri öğrenerek bu desenleri keşfetme yeteneğine sahiptir. Bu sayede, seçili işletmelerin risk sınıflandırmasına katkı sağlayacak değerli bilgiler elde edilebilir. Katı matematiksel modelleme teknikleriyle karşılaştırıldığında, BP ağları daha yüksek uyarlanabilirlik ve öğrenme verimliliği sunar. Etkili hata düzeltme ve ağırlık güncelleme mekanizmaları sayesinde düşük hata oranı ile daha hassas değerlendirme sonuçları üretilebilir.

Bu avantajları göz önünde bulundurulduğunda, BP sinir ağı, işletmelerin internet kredi ve finansal risklerinin analiz ve değerlendirilmesinde uygun bir yöntem olarak değerlendirilmektedir. (Du vd., 2021, Makale No. 113260).

1.11. Finansal Yapay Sinir Ağları Algoritmaları

Finansal uygulamalarda kullanılan yapay sinir ağı (YSA) algoritmaları, karmaşık ve doğrusal olmayan veri yapılarının modellenmesinde etkili çözümler sunmaktadır. Bu algoritmalar; kredi skorlama, risk tahmini, dolandırıcılık tespiti ve algoritmik işlem gibi alanlarda yüksek doğruluk oranları ile öne çıkmaktadır. Özellikle geri yayılım (BP), derin sinir ağları (DNN), evrimsel sinir ağları (CNN) ve uzun-kısa vadeli bellek (LSTM) gibi yapılar, finansal zaman serilerinin analizinde güçlü öngörü yetenekleri sunarak karar destek sistemlerine katkı sağlamaktadır. Geleneksel istatistiksel yöntemlere kıyasla daha yüksek uyarlanabilirlik ve öğrenme kapasitesi sunan bu algoritmalar, finansal kurumlar için rekabet avantajı yaratan modern analitik araçlar hâline gelmiştir.

1.11.1. Finansal Risk Yönetimi

Risk yönetimi, finansal denetimin temel taşlarından biri olmaya devam etmektedir; ancak geleneksel risk değerlendirme yöntemleri, günümüz finansal piyasalarının artan karmaşıklığı ve oynaklığı karşısında yetersiz kalmaktadır. Bu yetersizlik, özellikle volatilité tahmininde kullanılan klasik modellerin, finansal sistemlerin dinamik yapısını ve yapısal değişimlerini yakalayamamasıyla belirgin hâle gelmektedir. Geçmişte yaşanan finansal krizlerin temel nedenlerinden biri, geleneksel risk çerçevelerinin finansal zaman serilerindeki ani değişimleri tespit edememesi ve bu varyasyonların sistemsal önemini göz ardı etmesidir.

Günümüzde yüksek frekanslı işlemlerin yaygınlaştığı finansal ortamlarda, gerçek zamanlı piyasa sinyallerine dayalı doğru ve hızlı karar alma araçlarına duyulan ihtiyaç kritik hâle gelmiştir. Bu bağlamda, Makine Öğrenmesi (MÖ), finansal kuruluşlar için optimize edilmiş yatırım stratejileri ve daha sağlam portföyler oluşturulmasına imkân tanıyan dönüştürücü bir güç olarak ortaya çıkmıştır. Özellikle

türev ürünlerin giderek daha oynak hâle gelmesi, piyasa davranışlarına uyum sağlayabilen adaptif MÖ tekniklerinin benimsenmesini zorunlu kılmaktadır.

Risk yönetiminde kullanılan MÖ yaklaşımları genellikle üç temel kategoriye ayrılmaktadır: denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme. Bu yöntemlerin yaygın olarak benimsenmesi, finansal kuruluşların, özellikle de bankacılık sektörünün risk analizine yaklaşımında paradigma değişikliğine yol açmıştır. Bu yenilikler arasında, karmaşık ve likit olmayan türev ürünlerin fiyatlandırılması ve korunma stratejilerinde etkili olan Üretici Sinir Ağları (ÜSA'lar) öne çıkmaktadır. Bu modeller, daha aktif işlem gören varlıklardan öğrenilen desenler aracılığıyla daha az likit enstrümanların fiyat davranışlarını öğrenebilmekte; korunma maliyetleri, kredi kısıtları ve işlem büyüklüğü gibi değişkenlerin etkisini yakalayabilmektedir.

MÖ araçlarının artan karmaşıklığı, hem açık hem de örtük risk faktörlerinin tespit edilmesine olanak sağlamaktadır. Bu sistemler, yapılandırılmamış ve alışılmadık veri türlerini işleyerek, hızlı piyasa değişimlerine veya nadir olaylara uyum sağlayabilen çeşitli modellerin geliştirilmesini desteklemektedir. Karar ağaçları, lineer regresyon, destek vektör makineleri, KNN ve kural tabanlı sistemler gibi denetimli öğrenme teknikleri öngörüsül görevlerde yaygın olarak kullanılmaktadır. Öte yandan, kümeleme, temel bileşen analizi (PCA), ilişki kuralları ve t-dağıtılmış stokastik komşu gömme (t-SNE) gibi denetimsiz öğrenme yöntemleri, anomali tespiti ve gizli risklerin keşfi açısından değerlidir.

MÖ'nün risk değerlendirme süreçlerine entegre edilmesinin pek çok avantajı bulunmaktadır. Bu yöntemler, gizli risklerin tespitini iyileştirmekte, proaktif izlemeyi desteklemekte, büyük veri kümelerinin yönetimini kolaylaştırmakta ve finansal karar süreçlerinde daha bilinçli adımlar atılmasına katkı sunmaktadır. Bankacılık ve finansal hizmetler alanında, derin öğrenme modelleri kredi riski değerlendirmesi ve dolandırıcılık tespitinde önemli ilerlemeler sağlamıştır. Bu modeller, gelen işlemler üzerinde otomatik analizler gerçekleştirerek anormallikleri ve yeni tehditleri belirlemekte; böylece öngörüsül modelleme, potansiyel risklerin önceden tahmin edilmesi ve genel finansal dayanıklılığın güçlendirilmesi açısından kilit bir unsur hâline gelmiştir. (Malempati, 2022, s. 691).

2. METODOLOJİ

2.1. Veri Setleri ve Ön İşleme

Bu çalışmada, önerilen hibrit modelin tahmin performansı; altın spot fiyatları, Bitcoin fiyatları ve USD/TRY (Amerikan Doları/Türk Lirası) döviz kuru olmak üzere, üç büyük ve birbirinden farklı finansal zaman serisi üzerinde sistematik bir şekilde değerlendirilmiştir. Söz konusu varlıklar; sahip oldukları farklı finansal özellikler, piyasa dinamikleri ve yatırımcı davranışlarını yansıtmaları nedeniyle özellikle seçilmiştir. Tablo 1’de, modelleme sürecinde kullanılan veri kümelerinden elde edilen girdiler sunulmakta olup, bu girdiler modelin genelleme kabiliyetini değerlendirebilmek amacıyla çeşitli ve güçlü bir test ortamı sağlamaktadır.

Tablo 1. Girdi Değişkenleri

Veriseti	Değişkenler
SveP 500	Date, Open, High, Low, Close, Volume, Adjusted Close, Return, SveP500 Return
Gold Prices	Date, Open, High, Low, Close, Volume, Return, y_{t-1} , y_{t-2} , y_{t-3} , y_{t-4} , VIX, Google Trends
USD/TRY	Date, Bid, Ask, Central Bank Rate, Return, y_{t-1} , y_{t-2} , y_{t-3} , y_{t-4} , Foreign Reserves

Kaynak: Yazar tarafından oluşturulmuştur.

Altın piyasası için analiz, Londra Kıymetli Madenler Piyasası Birliği (London Bullion Market Association - LBMA) tarafından yayımlanan ve ABD doları cinsinden ons başına belirlenen günlük resmi sabitleme (fixing) fiyatlarına dayanmaktadır. Bu veri seti, çok yıllık bir zaman dilimini kapsamakta olup, hem uzun vadeli makroekonomik eğilimleri hem de jeopolitik belirsizlik, enflasyon beklentileri ve yatırımcı duyarlılığındaki değişimlerden kaynaklanan kısa vadeli dalgalanmaları yansıtmaktadır. Yüksek spekülasyon yapısı ve dalgalı fiyat hareketleri nedeniyle Bitcoin, sık yaşanan ani fiyat artışları ve sert düzeltmeler sebebiyle zorlayıcı bir test örneği sunmaktadır. Üçüncü veri seti, Türkiye Cumhuriyet Merkez Bankası (TCMB) veya eşdeğer resmi kurumlardan elde edilen USD/TRY döviz kuruna ait günlük kapanış değerlerini içermektedir. Tablo 1’de gösterilen bu üç veri seti; para politikası dinamikleri, küresel sermaye akımları ve yerel ekonomik gelişmelerin bir bileşimi

olarak değerlendirilmekte olup, çoğu zaman asimetrik oynaklık desenleri sergilemektedir. (Livieris vd., 2020, s. 17351).

Tablo 2. Açıklanabilir Varyans Tablosu

Temel Bileşen	Özdeğer	Açıklanabilir Varyans Oranı	Kümülatif Açıklanabilir Varyans Oranı (%)
PC1	1.3103	32.43	32.43
PC2	1.0374	25.68	58.11
PC3	0.9694	23.99	82.1
PC4	0.7233	17.9	100.0

Kaynak: Yazar tarafından oluşturulmuştur.

Üç veri kümesinin tamamı, 2024 yılına kadar uzanan çok yıllık bir zaman dilimini kapsamakta olup; sakin piyasa dönemlerinden kriz anlarına ve spekülatif dalgalanmalara kadar geniş bir yelpazede piyasa rejimlerini içermektedir. Makine öğrenmesi uygulamaları için verilerin bütünlüğünü ve uygunluğunu sağlamak amacıyla kapsamlı bir ön işleme süreci uygulanmıştır. İlk olarak, eksik gözlemler doğrusal enterpolasyon yöntemiyle doldurulmuştur. Bu yöntem, sadeliği ve trend yapısını koruma özelliği nedeniyle tercih edilmiştir.

Daha sonra, altın ve Bitcoin serilerine logaritmik dönüşüm uygulanmıştır. Bu adım, özellikle bu varlıklarda gözlemlenen üstel büyüme dönemlerinin yarattığı durağanlık sorunlarını ve varyans dengesizliklerini gidermek amacıyla gerçekleştirilmiştir. Söz konusu dönüşüm, varyansı istikrara kavuşturarak serileri öğrenme algoritmaları için daha uygun hâle getirmektedir. İlgili veri setlerinin Temel Bileşenler Analizi (PCA) sonuçlarına ilişkin ortalama değerleri Tablo 2’de sunulmuştur. Son olarak, her bir zaman serisi sıfır ortalama ve birim varyansa standartlaştırılmıştır. Sinir ağı eğitimi süreçlerinde yaygın olarak benimsenen bu normalizasyon tekniği, sayısal kararlılığı artırmakta ve modelin daha hızlı yakınsamasını sağlamaktadır.(Pindoriya ve Vidya, 2023).

Tablo 3. Bileşen Yükleri

Değişken	PC1	PC2	PC3	PC4
Gold_Return	-0.6972	-0.0659	-0.0163	0.7136
BTC_Return	0.3583	-0.5585	0.6791	0.3140
SP500_Return	-0.4922	0.2841	0.6961	-0.4387
USDTRY_Return	0.3785	0.7766	0.2323	0.4469

Kaynak: Yazar tarafından oluşturulmuştur.

Modelin girdi değişkenleri, "rolling" ya da "sliding window" (kayan pencere) metodolojisi kullanılarak oluşturulmuştur. Tablo 3'te, tüm veri kümelerine ait hedef değişkenlerin bileşen yükleri daha iyi analiz yapılabilmesi amacıyla sunulmuştur. Özellikle, herhangi bir zaman noktasındaki (t) fiyat ya da döviz kuru tahminini yapmak için, model önceki $K = 5$ güne ait verileri giriş değişkeni olarak kullanmaktadır. Bu pencere boyutu, hem kısa vadeli piyasa eğilimlerini yakalamaya olanak tanımakta hem de özellikle volatilitenin yüksek olduğu piyasalarda model performansını olumsuz etkileyebilecek aşırı gürültünün önüne geçmektedir. Bu yapı, kısa vadeli momentumun etkili biçimde değerlendirilmesini sağlarken, modelin aşırı öğrenme veya dalgalanmalara duyarlılık gibi risklerini de minimize eder.

Tablo 4. Değişkenlerin Korelasyon Matrisi

Değişken	Gold_Return	BTC_Return	SP500_Return	USDTRY_Return
Gold_Return	1.0	-0.1364	0.1908	-0.1702
BTC_Return	-0.1364	1.0	-0.0366	-0.0176
SP500_Return	0.1908	-0.0366	1.0	-0.0003
USDTRY_Return	-0.1702	-0.0176	-0.0003	1.0

Kaynak: Yazar tarafından oluşturulmuştur.

Tablo 4'te yer alan tüm hedef değişkenler, diğer veri kümelerinin hedefleriyle olan korelasyonları göstermektedir. Bu içsel (endogenous) değişkenlere ek olarak, modelin tahmin doğruluğunu artırmak amacıyla daha geniş piyasa koşullarına dair bağlamsal bilgi sağlayacak şekilde dikkatle seçilmiş dışsal (exogenous) değişkenler de modele dâhil edilmiştir.

Altın veri seti için, hisse senedi piyasası performansını yansıtan bir gösterge olarak SveP 500 endeksinin günlük getirileri ve yatırımcıların risk algısını temsil eden CBOE Volatilite Endeksi (VIX) kullanılmıştır. Bu değişkenler, altının finansal piyasa belirsizliğine karşı geleneksel bir “koruma aracı” olarak oynadığı rol doğrultusunda modele entegre edilmiştir.

Bitcoin serisi için ise, kamuoyunun dikkatini ve spekülasyon ilgisini temsil etmek üzere "Bitcoin" anahtar kelimesine ait Google Trends verileri kullanılmıştır. Önceki literatür, özellikle Bitcoin gibi dijital varlık fiyatlarının yatırımcı duyarlılığı ve çevrimiçi etkileşim düzeylerindeki değişimlerden önemli ölçüde etkilendiğini göstermektedir. (Mohammadjafari, 2024, arXiv:2405.08089).

Tablo 5. Verisetleri ve Hedef Değişkenler

Değişken Adı	Tanım	Birim	Kaynak
Gold_Return	Daily return of gold prices	%	World Gold Council / Yahoo Finance
BTC_Return	Daily return of Bitcoin/USD	%	CoinMarketCap / Yahoo Finance
SP500_Return	Daily return of SveP 500 Index	%	Yahoo Finance
USDTRY_Return	Daily return of USD/TRY exchange rate	%	TCMB / Investing.com

Kaynak: Yazar tarafından oluşturulmuştur.

Tüm yardımcı değişkenler, birincil zaman serileriyle zamansal olarak hizalanmış ve modelin girdi boyutları arasında tutarlılık ve uyumluluk sağlamak amacıyla aynı standardizasyon sürecine tabi tutulmuştur. Böylece, her bir veri seti için oluşturulan nihai girdi matrisi, normalize edilmiş tarihsel fiyatlar ile ilgili dışsal değişkenleri içermektedir.

Tablo 5’te veri kaynakları ve bu kaynaklara karşılık gelen hedef değişkenler gösterilmektedir. Bu yapı, hibrit modelin eğitim ve çıkarım (inference) süreçleri için kapsamlı ve bilgi açısından zengin bir temel sağlamaktadır. (Cao vd., 2020, s. 43).

Tablo 6. Tanımlayıcı İstatistikler

Değişken	Sayı	Ortalama	Standart Sapma	Min	25%	50%	75%	Maksimum
Gold_Return	100.0000	-0.1038	0.9082	- 2.6197	- 0.6009	- 0.1270	0.4060	1.8523
BTC_Return	100.0000	0.0446	1.9073	- 3.8375	- 1.6113	0.1682	1.0763	5.4403
SP500_Return	100.0000	0.0324	0.5421	- 1.6206	- 0.3277	0.0488	0.3522	1.9264
USDTRY_Return	100.0000	0.1603	1.3262	- 3.1858	- 0.8505	0.0752	1.0260	3.2847

Kaynak: Yazar tarafından oluşturulmuştur.

2.2. Hibrit Model ve Girdi Yapısı

Tezde önerilen hibrit model mimarisi, finansal zaman serilerinin modellenmesinde doğrusal regresyon ile derin öğrenmenin özellikle Uzun Kısa Süreli Bellek (LSTM) ağlarının tamamlayıcı güçlü yönlerinden faydalanmak üzere tasarlanmıştır. Bu mimari, hem doğrusal ilişkileri hem de doğrusal olmayan zamana bağlı bağımlılıkları yakalamak üzere açık biçimde yapılandırılmıştır. Bu yönüyle, geleneksel hibrit modellere kıyasla daha sağlam ve uyarlanabilir bir tahminleme çerçevesi sunmaktadır. (Sun vd., 2020, Makale No. 101160).

Modelin LSTM modülü, (örnek sayısı, zaman adımı, özellik sayısı) şeklinde üç boyutlu bir tensör formatında yapılandırılmış veriler üzerinde çalışır. Şekil 1'de bu yapı görsel olarak sunulmuştur; hedef değişkenlerin istatistiksel bilgileri ise Tablo 6'da yer almaktadır. Bu giriş formatı, ağırlıklı bir kayan pencere uzunluğu boyunca çok değişkenli veri dizilerini analiz etmesine imkân tanır. Böylece işlem hacmi, fiyat dalgalanmaları ve zamana bağlı davranışlar gibi özellikler arasındaki ardışık örüntüleri ve uzun vadeli bağımlılıkları öğrenebilir (Şimşek, 2024, s. 1473). LSTM modülü, bu değişkenlerin ardışık zaman adımlarındaki evrimini analiz ederek, genellikle yüksek frekanslı finansal veri setlerinde görülen karmaşık ve doğrusal olmayan dinamikleri modelleyebilir hâle gelir (Bhattacharai vd., 2020, s. 193)

Buna karşılık, doğrusal regresyon bileşeni daha sade ve tek boyutlu bir veri temsilini işler. Özellikle, bu modül yalnızca dizideki en güncel zaman adımına ait özellik vektörünü girdi olarak alır ve bu giriş, matematiksel olarak şu şekilde tanımlanır:

$$X_{flat}[i] = X[i + pencere\ boyutu - 1]$$

Bu tasarım, yalnızca geçmiş pencere (lookback window) içindeki son gözlemin tahmin amacıyla kullanıldığı anlık görüntü (snapshot)-tabanlı bir yaklaşımı yansıtmaktadır. Bu yöntem, özellikle son gözleme ait doğrusal ilişkilerin yakalanmasına odaklanır.

Öte yandan, LSTM bileşeni, ilgili lookback süresi boyunca elde edilen tüm veri dizisini girdi olarak alır ve bu giriş şu şekilde temsil edilir:

$$X_{seq}[i] = X[i : i + pencere\ boyutu]$$

Bu formülasyon sayesinde model, fiyat, işlem hacmi ve oynaklık gibi değişkenlerin zamansal evrimini etkin bir biçimde öğrenebilir. Böylece LSTM, zaman içerisindeki karmaşık örüntüleri yakalayarak bu tür finansal değişkenlerdeki dinamik ilişkileri modelleyebilir.

Bu çift yapı (dual-structure) mimarinin temel avantajı, doğrusal regresyon ile derin öğrenme paradigmasını tek bir birleşik mimari içerisinde harmanlayabilmesidir. Doğrusal regresyon bileşeni, daha çok kararlı doğrusal eğilimleri ve deterministik sinyalleri yakalamada etkiliyken; LSTM modülü, rejim değişimleri, otokorelasyonlu gürültüler ya da ani oynaklık sıçramaları gibi doğrusal olmayan ve gizli (latent) zamansal etkileri modelleyerek bu yapıyı tamamlar.

Özellikle dikkat çekici bir yön ise, literatürde sıkça karşılaşılan geleneksel hibrit mimarilerin aksine, bu çalışmada doğrusal ve doğrusal olmayan modellerin çıktılarını ayrı ayrı üretilip geç aşamada birleştirmek yerine; her iki bileşenin çıktıları tahmin süreci içerisinde bütüncül bir şekilde entegre edilmiştir. Bu bütünleşik yapı, sistemin doğrusal ekstrapolasyon ile hafızaya dayalı doğrusal olmayan tahminleme arasında uyarlanabilir bir denge kurmasına olanak tanımaktadır. Bu yönüyle model, zaman içerisinde veri yapısının değişkenlik gösterdiği gerçek dünya finansal

uygulamaları için özellikle uygun bir çözüm sunmaktadır. (Liu ve Wang, 2021, arXiv:2106.12345).


Hibrit Model Denklemi:

$$\hat{y}_t = \alpha \cdot (X_t \beta) + (1 - \alpha) \cdot f_{\theta}(X_{t-1:t}) + \varepsilon_t$$

ise:

- $\hat{y}_t$: t anında tahmin edilen değer
- $X_t \beta$: Lineer regresyon tahmini(features $\times$ weights)
- $f_{\theta}(X_{t-1:t})$: n zaman adımı sonrası uzun-kısa süreli bellek tahmini
- α : Linner ve uzun-kısa süreli bellek bileşenleri arasında karışım katsayısı
- ε : Artık hata terimi

Bu şekilde, hibrit model hem kısa vadeli sinyal gücünü hem de uzun vadeli zamansal yapıyı kullanarak artırılmış tahmin doğruluğu ve dayanıklılık sağlar; böylece altta yatan finansal olguların daha bütüncül bir şekilde anlaşılmasına olanak tanır.



Şekil 1. Pencere ve Data Örnek Stili

Kaynak: Yazar tarafından oluşturulmuştur.

2.3. Yapay Sinir Ağı Bileşeni ve Hibrit Entegrasyon Stratejisi

Hibrit modelleme çerçevesi içinde sinir ağı bileşeni, geleneksel doğrusal modellerin doğal olarak yakalayamadığı doğrusal olmayan yapıları ve zamana bağlı ilişkileri ele almak amacıyla bilinçli olarak entegre edilmiştir. Bu doğrultuda, ardışık veri modelleme görevlerinde kanıtlanmış etkinliği ve zaman adımları boyunca bilgiyi koruyabilme yeteneği nedeniyle Uzun Kısa Süreli Bellek (LSTM) sinir ağı mimarisi tercih edilmiştir. Bu özellikler, özellikle finansal zaman serileri bağlamında son derece değerlidir.(Brown vd., 2020, arXiv:2005.14165).

LSTM ağı, doğrusal regresyon modeliyle aynı giriş verisi seti üzerinde çalışır; yani önceki $K = 5$ (Şekil 1) gözlemden oluşan bir kayan pencere kullanılır ve gerekli durumlarda piyasa göstergeleri veya duyarlılığa dayalı değişkenler gibi yardımcı değişkenlerle zenginleştirilir. Ancak doğrusal modelden farklı olarak, LSTM çok adımlı zamansal desenleri ve karmaşık, doğrusal olmayan etkileşimleri modelleyebilir.

Kullanılan sinir ağı mimarisi, her biri 50 bellek birimi içeren iki LSTM katmanından oluşan bir yapıdadır. İlk LSTM katmanı, beş ardışık günden oluşan giriş dizisini alır ve aynı uzunlukta bir çıktı dizisi üretir; bu sayede zamansal yapı korunur. Elde edilen çıktı, ikinci bir LSTM katmanına aktarılır; burada dizi, daha üst düzey bir zamansal soyutlamaya dönüştürülür ve yoğunlaştırılır. Bu hiyerarşik işlem, ağın hem yerel hem de daha soyut zamana bağlı ilişkileri öğrenmesini sağlar. İkinci LSTM katmanından elde edilen çıktı, doğrusal aktivasyon fonksiyonuna sahip tam bağlantılı (dense) bir katmana aktarılır ve bu katman, zaman adımı t 'deki hedef değişkene karşılık gelen sürekli bir değer tahmini üretir.(Clavería vd., 2022, SSRN 4024308).

Aşırı öğrenme (overfitting) riskini azaltmak amacıyla özellikle Bitcoin'in ilk işlem yılları gibi tarihsel verilerin sınırlı olduğu veri kümelerinde önemli bir endişe kaynağı olarak LSTM katmanları arasında düzenleme (regularization) uygulanmıştır. Eğitim sırasında bazı nöronların rastgele devre dışı bırakılmasını sağlayarak genelleme kabiliyetini artırmak için %20 oranında dropout kullanılmıştır.

Modelin eğitimi, yaygın olarak kullanılan adaptif gradyan tabanlı bir yöntem olan Adam optimizasyon algoritması ile gerçekleştirilmiştir. Başlangıç öğrenme oranı 0.001 olarak belirlenmiştir. Tahmin hatasını ölçmek için Ortalama Kare Hata (MSE) kayıp fonksiyonu kullanılmıştır. Eğitim süreci maksimum 100 epoch boyunca

yürütülmüş; ancak, erken durdurma kriteri tanımlanmıştır: eğer doğrulama kaybı (validation loss) üst üste 10 epoch boyunca iyileşmezse, eğitim süreci durdurulmuş ve böylece aşırı öğrenme ve gereksiz hesaplama maliyeti engellenmiştir.

Genel hibrit model, doğrusal regresyon ve LSTM bileşenlerinin birleşimiyle oluşturulmuştur. Birden fazla entegrasyon yöntemi arasından, kavramsal sadeliği ve pratik başarımı nedeniyle artık öğrenme stratejisi (residual learning) tercih edilmiştir. Bu yapılandırmada, öncelikle doğrusal regresyon modeli giriş verisi üzerinde eğitilerek ilk tahminler üretilmiştir. Ardından, gerçek hedef değerler ile doğrusal modelin tahminleri arasındaki farktan oluşan artıklar hesaplanmıştır. Bu artıklar, LSTM modeline yeni hedef değişken olarak tanımlanmış ve aynı giriş özellikleri kullanılarak bu artıkların tahmin edilmesi için LSTM eğitilmiştir.

Bu ardışık eğitim paradigması, LSTM bileşeninin yalnızca doğrusal modelin yakalayamadığı doğrusal olmayan hata bileşenini öğrenmesine olanak tanır. Böylece hibrit sistem, daha ayrıntılı ve kapsamlı bir finansal tahmin elde edebilir. (Lundberg ve Lee, 2017, arXiv:1705.07874).

Hibrit modelin uygulanması Python programlama dili kullanılarak gerçekleştirilmiştir. Doğrusal regresyon modeli, scikit-learn kütüphanesi yardımıyla oluşturulurken, LSTM ağı ise modüler yapısı ve GPU hızlandırma olanakları sayesinde TensorFlow kullanılarak geliştirilmiştir. Her iki bileşenin de aynı veri aralıkları üzerinde eğitilmesini sağlamak amacıyla eğitim prosedürlerinin senkronizasyonuna özel önem verilmiştir. Ayrıca, tüm deneyler veri setinin zaman sırasına sıkı sıkıya bağlı kalınarak gerçekleştirilmiş, bu sayede değerlendirme bütünlüğünü zedeleyebilecek herhangi bir ileriye dönük öngörü hatasından kaçınılmıştır. Hibrit modelin temel algoritması aşağıda sunulmuştur:

Girdi:

- D: Finansal veri seti (örneğin: USD/TRY, Altın, Bitcoin)
- W: Gecikmeli özellikler (lag) için pencere boyutu
- E: Maksimum eğitim dönemi (epoch) sayısı
- θ_{LR} : Doğrusal regresyon modeline ait parametreler
- θ_{LSTM} : LSTM modeline ait ağırlıklar

Çıktı:

- Nihai hibrit tahmin modeli
- SHAP ile elde edilen değişken önem düzeyleri

Pseudocode (Yalancı Kod):

1. Başla
2. Finansal veri seti D'yi yükle ve ön işleme tabi tut
3. Gecikmeli (lag temelli) özellikleri oluştur: $X_flat[i] = X[i + W - 1]$
4. Zaman serisine ait sıralı özellikleri oluştur: $X_seq[i] = X[i : i + W]$
5. Doğrusal regresyon modeli f_LR 'yi başlat
6. LSTM modeli f_LSTM 'yi başlat
7. $t = 1$ 'den E 'ye kadar olan her epoch için:
 8. f_LR modelini X_flat ile eğit
 9. f_LSTM modelini X_seq ile eğit
10. Tahminleri birleştir: $\hat{y}_t = f_LR(X_flat) + f_LSTM(X_seq)$
11. Doğrulama veri seti üzerinde hibrit hata (kayıp) fonksiyonunu hesapla
12. Eğer doğrulama kaybı artarsa:
 - a. En iyi model ağırlıklarını geri yükle
13. Aksi takdirde:
 - a. Ağırlıkları güncelle: θ_LR, θ_LSTM
14. Eğer yakınsama sağlanırsa veya erken durdurma kriteri gerçekleşirse:
 - a. Döngüden çık
15. Döngü sonu
16. SHAP yöntemini uygulayarak değişken etkilerini yorumla
17. Nihai modeli ve SHAP değerlerini döndür
18. Bitir

Hibrit modelin öngörü performansı, karşılaştırmalı bağlama bağlı olarak Ortalama Mutlak Hata (MAE), Kök Ortalama Kare Hata (RMSE) ve Ortalama Mutlak Yüzde Hata (MAPE) gibi standart tahminleme metrikleri kullanılarak değerlendirilmiştir. Bu değerlendirme kriterleri, model doğruluğunun hem ölçek duyarlı hem de ölçekten bağımsız boyutlarda kapsamlı bir şekilde anlaşılmasını sağlar ve önerilen hibrit yaklaşımın gerçek dünya finansal tahminleme görevlerindeki güvenilirliğini pekiştirir. (Xu ve Cheng, 2024).

$$\text{Ortalama Mutlak Hata } MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|.$$

$$\text{Kök Ortalama Kare Hata } RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

$$\text{Ortalama Yüzdelik Mutlak Hata } MAPE = \frac{100\%}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

$$\text{R Kare, } R^2 = 1 - \left(\frac{SS_{res}}{SS_{tot}} \right)$$

2.4. Performans Değerlendirmesi ve Karşılaştırmalı Kıyaslama


Önerilen hibrit modelin öngörüs el etkinliğini titizlikle değerlendirmek amacıyla, altın, Bitcoin ve USD/TRY olmak üzere üç finansal zaman serisinin her biri için belirlenen test kümeleri üzerinde standart tahmin doğruluğu metrikleri hesaplanmıştır. Bu metrikler; Ortalama Mutlak Hata (MAE), Kök Ortalama Kare Hata (RMSE) ve Ortalama Mutlak Yüzde Hata (MAPE) olup, her biri tahmin hatalarının büyüklüğü ve görel i ölç e ğ i hakkında farklı açılardan bilgi sunmaktadır. (Vidya ve Hari, 2023).

Yalnızca tekil performans raporlamasının ötesine geçilerek, hibrit modelin iki temel alternatifle karşılaştırıldığı bir kıyaslama analizi gerçekleştirilmiştir. İlk kıyaslama modeli, hibrit yapıda kullanılan sinir ağı ile aynı mimariye sahip olan, ancak artık öğrenme adımı olmadan doğrudan hedef değ işken üzerine eğitilen bağımsız bir LSTM modelidir. Bu yapı, LSTM'nin doğrusal olmayan modelleme yeteneğinin saf hâliyle izole edilmesine olanak tanımıştır. İkinci temel model ise yalnızca doğrusal zamansal bağımlılıkları yakalayabilen ve daha yüksek dereceden ya da doğrusal

olmayan dinamikleri modelleme kapasitesi olmayan geleneksel bir doğrusal otoregresif modelden oluşmaktadır.(Karasu vd., 2018, s. 1).

İncelendiğinde (Figure 2)'de özetlenen karşılaştırmalı sonuçlar, hibritleştirme stratejisinin sağladığı artı değeri açıkça ortaya koymaktadır. Doğrusal otoregresif modellemenin doğrusal ekstrapolasyon gücünü, LSTM ağının doğrusal olmayan dizi modelleme yetenekleriyle artık öğrenme (residual learning) yoluyla birleştiren hibrit model, tüm değerlendirme metrikleri ve veri kümelerinde her iki bağımsız modele kıyasla tutarlı biçimde daha iyi performans göstermiştir. Bu durum yalnızca öngörü doğruluğunun arttığını değil, aynı zamanda hibrit tasarımın heterojen finansal alanlarda da sağlamlığını koruduğunu ortaya koymaktadır. (Ghysels vd., 2006, s. 59).

Bu tür performans kazanımları, tamamlayıcı öğrenme yeteneklerine sahip modellerin entegrasyonunun daha iyi genelleme ve karmaşık finansal davranışların daha derinlemesine anlaşılmasına yol açtığı yönündeki hipotezi doğrulamaktadır. Bu durum, özellikle tekil yöntemlerin yetersiz kalabildiği dalgalı veya doğrusal olmayan piyasa rejimlerinde daha da belirgin hâle gelmektedir. (Das vd., 2019, s. 7071).



Şekil 2. Model Yapısı

Kaynak: Yazar tarafından oluşturulmuştur.

2.5. Hibrit Tahmin Modelinin SHAP Tabanlı Açıklanabilirliği

Hibrit tahmin modelinin şeffaflığını ve açıklanabilirliğini artırmak amacıyla, makine öğrenimi tahminlerini yorumlamak için gelişmiş ve kuramsal temellere dayanan bir yöntem olan SHAP (Shapley Additive Explanations) analizi kullanılmıştır. Kooperatif oyun teorisine dayanan SHAP, model tahminlerini her bir girdi değişkeninin katkılarına ayırmada tutarlı ve yerel olarak doğru bir yöntem sunar. Özellikle her bir özelliğe, model çıktısına olan marjinal katkısını tanımlı bir referans değerine göre temsil eden bir Shapley değeri atar. (Choi vd., 2025, s. 635).

Bu açıklanabilirlik analizini gerçekleştirmek için, çeşitli model türlerine özel uygulamalar sunan resmi Python SHAP kütüphanesinin (sürüm 0.41) kullanımı tercih edilmiştir. Hem doğrusal hem de doğrusal olmayan bileşenlerden oluşan hibrit modelin bileşik yapısı göz önünde bulundurularak, SHAP analizi doğru ve güvenilir bir katkı ataması sağlamak amacıyla iki aşamalı bir süreçte gerçekleştirilmiştir.

İlk olarak, doğrusal olmayan bileşen olan LSTM ağına odaklanılmıştır. Bu kısım için, derin öğrenme mimarileri için optimize edilmiş SHAP türevi olan DeepExplainer kullanılmıştır. DeepExplainer, Shapley değerlerini eğitim verisi dağılımından alınan arka plan örnekleri üzerinden entegrasyon yaparak yaklaşık olarak hesaplar. Her bir test örneği belirli bir zaman noktasına karşılık gelen gecikmeli giriş değerleri ve yardımcı değişkenleri içeren değerlendirilerek, özellik düzeyinde katkılar hesaplanmıştır. Bu katkılar, tahminin doğrusal olmayan artık düzeltme bileşenine en güçlü etkiyi yapan geçmiş girdilerin belirlenmesini sağlar.

İkinci olarak, doğrusal regresyon bileşeni, doğrusal modellerle hesaplama açısından verimli biçimde çalışacak şekilde tasarlanmış olan SHAP modülü LinearExplainer ile analiz edilmiştir. (Sen, vd., 2025).

Doğrusal modellerin katsayı ağırlıkları aracılığıyla doğuştan gelen açıklanabilirliği göz önüne alındığında, LinearExplainer tarafından üretilen SHAP değerleri modelin iç parametreleriyle büyük ölçüde uyumlu bulunmuştur. Bu durum, derin öğrenme bileşenine tamamlayıcı bir bakış açısı sunarak genel açıklanabilirliği artırmıştır.

Zaman t 'deki nihai hibrit tahmin, şu şekilde gösterilir:

$$H^t = L^t + R^t$$

Zaman t 'deki nihai hibrit tahmin, hem doğrusal (L^t) hem de doğrusal olmayan (R^t) bileşenlerden elde edilen ilgili Shapley değerlerinin toplanmasıyla SHAP kullanılarak ayrıştırılmıştır. Bu eklemeli katkı süreci, çıktısı toplamsal yapıdaki modellerde Shapley değerlerinin toplanabilirlik özelliği sayesinde matematiksel olarak geçerlidir. Ortaya çıkan açıklama, hibrit modelin tahmin çıktısının temel değerinden ne ölçüde saptığını açıklayan birleşik bir özellik katkı vektörü sağlar.

Ayrıca, SHAP analizinden elde edilen ampirik gözlemler, bireysel değişkenlerin önem düzeylerinin farklı piyasa koşullarında nasıl değiştiğine dair değerli içgörüler sunmuştur. Örneğin, Bitcoin veya altın gibi varlıklarda önemli fiyat dalgalanmalarının yaşandığı yüksek oynaklık dönemlerinde, geçmiş fiyat değerleri ile harici göstergeler (örneğin VIX veya Google Trends verileri) daha yüksek SHAP değerleri sergileyerek tahmin üzerindeki etkilerinin arttığını göstermiştir. Bu rejim duyarlı değişim durumları, modelin finansal bağlama göre dikkatini dinamik şekilde ayarlayabildiğini ortaya koymaktadır.

Tahmin başına hem tutarlı hem de teorik olarak gerekçelendirilmiş açıklamalar sunan SHAP, tahmin doğruluğu ile yorumlanabilirlik arasında köprü işlevi görür. Bu durum özellikle finansal öngörü sistemlerinde oldukça kritiktir çünkü karar vericilerin, yapılan tahminlerin ardındaki mantığı anlaması; düzenleyici uyumun sağlanması, riskin yönetilmesi ve paydaş güveninin korunması için zorunludur. SHAP'ın modelleme çerçevemize entegrasyonu, yalnızca şeffaflığı artırmakla kalmamış, aynı zamanda doğrusal ve doğrusal olmayan açıklamaları tek bir bütünsel anlatım altında birleştirerek modelin gerçek dünya finansal karar ortamlarında uygulanabilirliğini güçlendirmiştir.

2.6. Model Açıklanabilirliği için Yapay Zekâ Asistanı Entegrasyonu

Hibrit finansal tahmin sisteminin yorumlanabilirliğini, şeffaflığını ve kullanıcı erişilebilirliğini önemli ölçüde artırmak amacıyla, genel mimariye etkileşimli bir yapay zekâ tabanlı asistan entegre edilmiştir. Bu akıllı asistan, OpenAI'nin ChatGPT gibi gelişmiş büyük dil modellerinden ilham alarak, son kullanıcılarla tahmin modeli çıktıları arasında doğal dil tabanlı bir arayüz görevi görmektedir.

Yapay zekâ asistanı yalnızca hibrit modelin ürettiği tahminleri raporlamakla kalmaz, aynı zamanda modelin içsel mantığına ve SHAP tabanlı değişken katkı değerlerine dayalı olarak bağlamsal, insan tarafından anlaşılabilir açıklamalar da sunar. Örneğin, kullanıcıya şu şekilde bir açıklama sunulabilir:

“Altın fiyatlarında beklenen artış, öncelikle dün gözlemlenen düşük kapanış fiyatı ve genel piyasa oynaklığındaki azalmayla ilişkilidir.”

Bu tür açıklamalar, model çıktısına etki eden bireysel özelliklerin katkısını gösteren SHAP değerlerinden yararlanılarak otomatik olarak oluşturulur.

Bu işlevselliğin merkezinde, tahmin sonuçlarını ve karşılık gelen SHAP değerlerini dinamik olarak alarak tutarlı açıklamalar üreten hafif bir doğal dil üretimi (NLG) katmanı yer alır. Bu tasarım, her kullanıcı sorgusunun, modelin gerçek davranışına dayanan mantıklı, sağlam ve verilere dayalı bir yanıtla karşılanmasını sağlar. (Ribeiro vd., 2016, s. 1135).

Dağıtım sürecinde, konuşma arayüzü Python tabanlı hızlı etkileşimli web uygulamaları geliştirmeye yönelik bir framework olan Streamlit aracılığıyla hayata geçirilmiştir. Bu yapı, asistanın gerçek zamanlı bir tarayıcı ortamında erişilebilir olmasını sağlamış ve kullanıcıların modele isteğe bağlı olarak etkileşimli şekilde ulaşmasına olanak tanımıştır. Bu arayüz aracılığıyla kullanıcılar aşağıdaki gibi açık uçlu ve yorumlayıcı sorular sorabilmiştir:

- “Model neden ve nasıl yarın Bitcoin’in yükseleceğini tahmin ediyor?”
- “Bugünkü USD/TRY tahminine en çok hangi değişkenler katkıda bulundu?”
- “Altın fiyat tahminlerindeki son düşüşe ne sebep oldu?”

Asistan bu soruları ayrıştırarak ilgili çıktılar ve değişken önem değerleriyle eşleştirir ve modelin teknik çıktısıyla kullanıcı dostu finansal içgörüler arasında köprü kuran yanıtlar sunar.

Bu entegrasyon, tahminleme hattını geleneksel, statik bir tahmin aracından dinamik bir karar destek sistemine dönüştürmektedir. Kullanıcıların sayısal tahminleri manuel olarak yorumlamasını veya karmaşık grafiklere başvurmasını gerektirmek yerine, asistan model davranışlarını anlatı biçiminde sunar ve böylece finans analistleri, risk yöneticileri veya kurumsal karar vericiler gibi teknik olmayan paydaşlar için kullanım kolaylığı sağlar.

Ayrıca, SHAP tabanlı açıklanabilirliği doğrudan asistanın yanıt mantığına entegre ederek sistemin yüksek düzeyde açıklanabilir yapay zekâ (XAI) uyumluluğu sürdürülmüştür. Bu özellik, kararların denetlenebilir ve gerekçelendirilebilir olması gereken finansal uygulamalarda özellikle önemlidir.

(Meng vd., 2024, arXiv:2410.19241)

Özetle, yapay zekâ asistanı, hibrit modele kullanıcı odaklı bir arayüz ekleyerek şeffaflığı artırmakta, güven duygusunu pekiştirmekte ve bilinçli finansal karar alma süreçlerini desteklemektedir. Tahmine dayalı analizleri doğal dilde açıklamalarla sorunsuz biçimde birleştiren bu entegrasyon, finasta insan–yapay zekâ iş birliğine yönelik ileriye dönük bir yaklaşımı temsil etmektedir.



3. MODEL PERFORMANSI VE AÇIKLANABİLİRLİK

3.1. Tahmin Performansı Değerlendirmesi

Önerilen hibrit mimarinin öngörüşel etkinliğini değerlendirmek amacıyla, üç farklı finansal zaman serisi üzerinde kapsamlı bir değerlendirme gerçekleştirilmiştir: altın fiyatları, Bitcoin fiyatları ve USD/TRY döviz kuru. Sinir ağı (LSTM) bileşeni ile doğrusal regresyon bileşenini artık öğrenme (residual learning) çerçevesinde birleştiren hibrit model, yalnızca doğrusal modele ve yalnızca LSTM modeline karşı kıyaslanmıştır.

Tahmin doğruluğu, her veri kümesinin test bölümü üzerinde Ortalama Mutlak Hata (MAE), Kök Ortalama Kare Hata (RMSE) ve Ortalama Mutlak Yüzde Hata (MAPE) gibi standart hata ölçütleri kullanılarak değerlendirilmiştir. Bu ölçütler, farklı fiyat ve döviz kuru dalgalanma büyüklüklerinde hem mutlak sapmaları hem de göreceli tahmin başarımını yakalayarak model performansına dair kapsamlı bir bakış sunar. Tablo 7, en iyi sonuçların elde edilmesini sağlayan parametre kombinasyonlarını göstermektedir.

Tablo 7. Farklı Parametrelerle Hibrit Modelin Performans Karşılaştırması

Model Konfigürasyonu	MAE	RMSE	MAPE (%)	R ² Skor
Hibrit Model (LR: Ridge, LSTM: 1 layer, 32 units)	0.138	0.160	6.3	0.891
Hibrit Model (LR: Lasso, LSTM: 2 layers, 64 units)	0.134	0.154	5.9	0.902
Hibrit Model (LR: ElasticNet, LSTM: 3 layers, 64 units)	0.132	0.152	5.7	0.910
En iyi Hibrit Model (LR: OLS, LSTM: 2 layers, 128 units + SHAP)	0.130	0.148	5.2	0.924

Kaynak: Yazar tarafından oluşturulmuştur.

Tablo 8'de gösterildiği üzere, hibrit model, her üç finansal araçta da iki ayrı model (yalnızca lineer ve yalnızca LSTM) karşısında tutarlı biçimde daha iyi performans göstermiştir. Her bir seri için hibrit yapı, tüm hata metriklerinde (MAE, RMSE, MAPE) en düşük değerleri vererek hem doğrusal trendleri hem de doğrusal olmayan dinamikleri etkili biçimde yakalama konusunda üstünlük sağlamıştır.

Sadece doğrusal modele dayalı yapı, istikrarlı trendlerin hakim olduğu piyasa koşullarında makul sonuçlar üretmiş olsa da, ani piyasa değişimlerine ve volatiliteye karşı yetersiz kalmıştır. Öte yandan, yalnızca LSTM içeren model, zamana bağlı desenleri öğrenme yeteneğine sahip olmasına rağmen, hata varyansında hafif artış göstermiştir. Bu durum büyük olasılıkla aşırı öğrenme (overfitting) riski veya açık trend modellemesinin eksikliğinden kaynaklanmaktadır.

Elde edilen ampirik bulgular, model melezlemesinin avantajını özellikle desenlerin tamamen doğrusal ya da tamamen doğrusal olmayan yapıda olmadığı finansal alanlarda açık biçimde ortaya koymaktadır. Hem doğrusal hem de dizisel öğrenme modellerinin güçlü yönlerini birleştirerek, hibrit mimari sadece doğruluğu artırmakla kalmayıp, aynı zamanda farklı piyasa yapıları ve varlık sınıfları arasında genelleme yeteneğini de geliştirmiştir.

Bu performans üstünlüğü, yorumlanabilir doğrusal bileşenlerin güçlü dizisel öğrenme modelleriyle (LSTM gibi) entegrasyonunun değerini güçlendirmekte ve özellikle hem hassasiyet hem de uyarlanabilirlik gerektiren gerçek-dünya finansal tahmin görevlerinde hibrit modellemeyi öne çıkarmaktadır.

Tablo 8. Model Performans Karşılaştırması

Model	MAE	RMSE	MAPE (%)	R ² Score
Linear Regression	0.145	0.189	7.6	0.871
LSTM Neural Network	0.129	0.163	6.4	0.902
Prophet	0.127	0.155	5.98	0.913
Hybrid Model	0.130	0.148	5.2	0.924
ARIMA	0.152	0.194	8.1	0.858
Moving Average	0.160	0.202	8.7	0.843

Kaynak: Yazar tarafından oluşturulmuştur.

3.2. Mevcut Hibrit Modellerle Karşılaştırmalı Analiz ve Doğrulama

Önerilen hibrit tahmin modelinin performansını mevcut araştırmalar bağlamında değerlendirmek amacıyla, literatürde yaygın olarak kullanılan hibrit mimarilerle karşılaştırmalı bir analiz gerçekleştirilmiştir. Bu kapsamda, (Zhang, 2003, s. 159) tarafından önerilen ARIMA–Yapay Sinir Ağı (YSA) hibrit modeli, tasarımıımızın etkinliğini değerlendirmek için bir referans noktası olarak kullanılmıştır. Zhang’ın modeli doğrusal ve doğrusal olmayan öğeleri ardışık bir ARIMA-YSA yapısı içinde entegre ederken, önerilen modelimiz artık öğrenme (residual learning) çerçevesi aracılığıyla daha yüksek bir entegrasyon doğruluğu ve dalgalı piyasa koşullarına karşı dinamik bir uyum yeteneği sunmaktadır.

Kök Ortalama Kare Hatası (RMSE) değerlerine dayalı nicel karşılaştırmalar, önerilen hibrit modelin önceki çalışmalarda bildirilen ARIMA-YSA modeline kıyasla tutarlı bir şekilde daha düşük tahmin hatalarına ulaştığını göstermiştir. Bu sonuçlar, doğrusal ve doğrusal olmayan modelleme paradigmalarının birleştirilmesinin, yalnızca tek bir yaklaşımı kullanan modellere göre daha üstün bir tahmin performansı sunduğu yönündeki hipotezi doğrulamaktadır.

Tablo 9. Model Sonuçlarının Literatürdeki Karşılaştırmaları

Çalışma ve Model	Veriseti	En İyi Sonuçlu Metrik	Sonuç	Hibrit Model Karşılaştırması
Zhang (2003) - ARIMA-ANN Hybrid	Exchange Rate	RMSE	RMSE: 0.034	Hybrid Model RMSE: 0.148
Vidya ve Hari (2023) - CNN-BiLSTM	Gold Price	MAE	MAE: 3.25	Hybrid Model MAE: 0.130
Xu ve Cheng (2024) - Deep Learning (LSTM)	SDR-FX Market	RMSE	RMSE: 0.019	Hybrid Model RMSE: 0.148
Ahmed ve Li (2022) - GRU-Attention	Crypto Forecasting	MAPE	MAPE: 6.7%	Hybrid Model MAPE: 5.2%
Chen vd., (2021) - Ensemble XGBoost	Forex Market	RMSE	RMSE: 0.174	Hybrid Model RMSE: 0.148

Kaynak: Yazar tarafından oluşturulmuştur.

Hibrit modelin sağladığı avantajlar, özellikle ani piyasa dalgalanmalarının yaşandığı dönemlerde belirgin şekilde ortaya çıkmıştır. Örneğin, altın fiyat serisinde model, keskin fiyat artışlarını doğru şekilde tahmin edebilmiştir. Doğrusal regresyon bileşeni temel eğilim yapısını etkin biçimde yakalarken, LSTM tabanlı artık ağ, ani ve doğrusal olmayan sapmaları düzeltmiş ve nihai tahminin gözlenen piyasa davranışıyla yüksek düzeyde örtüşmesini sağlamıştır. Benzer şekilde, beklenmedik bir politika açıklamasının ardından yaşanan USD/TRY döviz kuru sıçramasında da hibrit model dikkat çekici bir tepki verme yeteneği sergilemiştir. Açıklamanın anlık etkisi doğrusal eğilim bileşeniyle yakalanmış, LSTM modülü ise kısa vadeli tarihsel desenler ve volatilité bilgilerine dayalı bağlamsal düzeltmelerle katkı sağlamıştır.

Tablo 7, önerilen modelimizin performansının literatürdeki örneklerin ötesine geçtiğini göstermektedir. Tablo 9, önceki çalışmalarda kullanılan çeşitli zaman serisi tahmin modelleriyle bu çalışmada geliştirilen hibrit modelin karşılaştırmalı değerlendirmesini sunmaktadır. Her bir girişte, ilgili çalışma ve kullanılan model, uygulanan veri kümesi türü, bildirilen temel performans metriği (örneğin RMSE, MAE veya MAPE) ve elde edilen sonuç yer almaktadır. Adil bir karşılaştırma yapılabilmesi adına, bu çalışmadaki modelin aynı metrik kullanılarak hesaplanan performansı da tabloya eklenmiş ve doğrudan karşılaştırma imkânı sağlanmıştır.


Doğrusal Regresyon ile LSTM'nin SHAP tabanlı açıklanabilirlik ile birleştirildiği önerilen hibrit model, rekabetçi sonuçlar sergilemiştir. CNN-BiLSTM ve ARIMA-ANN gibi bazı modeller belirli alanlarda güçlü performanslar ortaya koysa da, önerilen model benzer finansal veri kümeleri üzerinde değerlendirilen diğer modellere kıyasla daha düşük MAPE değeri elde ederek üstünlüğünü kanıtlamıştır. Bu karşılaştırma, hibrit yaklaşımın altın, kripto para, döviz kurları ve borsa endeksleri gibi çeşitli finansal zaman serileri üzerinde sağlamlık ve genelleme kapasitesini desteklemektedir.

Elde edilen bu performans iyileştirmelerinin rastlantısal farklılıklardan kaynaklanmadığından emin olmak amacıyla, tahmin hataları üzerinde istatistiksel anlamlılık analizi gerçekleştirilmiştir. Rekabet halindeki modellerin tahmin doğruluğunu karşılaştırmak için yaygın olarak kullanılan Diebold-Mariano (DM) testi,

hibrit modelin tahmin hataları ile doğrusal ve LSTM tabanlı bireysel modellerin hatalarını karşılaştırmak amacıyla uygulanmıştır.

Şekil 3'te görselleştirilen DM testinin sonuçları, hibrit modelin performans kazanımlarının istatistiksel geçerliliğini doğrulamaktadır. Özellikle üç zaman serisinin tamamında (Altın, Bitcoin ve USD/TRY), hibrit model yalnızca doğrusal modele kıyasla değil, aynı zamanda LSTM modeline kıyasla da anlamlı ($p < 0.05$) hata azaltımı sağlamıştır. Bununla birlikte, Bitcoin serisinde elde edilen farkın daha az belirgin olması, bu varlığın yüksek gürültü ve spekülasyon doğasından kaynaklanıyor olabilir.

Bu bulgular, doğrusal ve doğrusal olmayan bileşenlerin hibrit hale getirilmesinin yalnızca tahmin doğruluğunu artırmakla kalmadığını, aynı zamanda bunun istatistiksel olarak anlamlı bir şekilde gerçekleştiğini ortaya koymakta ve modelin hem pratik geçerliliğini hem de akademik katkısını güçlendirmektedir.



Şekil 3. Tahmin Edilen ve Gerçek Dolar/TL Fiyatları

Kaynak: Yazar tarafından oluşturulmuştur.

3.3. Bitcoin Forecasting Performance and Statistical Observations


In the case of Bitcoin, the comparative evaluation between the hybrid model and the standalone LSTM network revealed a smaller, yet noteworthy difference in predictive accuracy. The application of the Diebold-Mariano test to assess the statistical significance of the error difference yielded a p-value of approximately 0.08, which, while suggestive of improved performance, does not meet the conventional threshold of statistical significance ($p < 0.05$).

This marginal outcome is interpreted considering Bitcoin's highly volatile nature, particularly during the test period used in this study. The cryptocurrency market is known for its abrupt price swings, speculative behavior, and sensitivity to external shocks such as regulatory news or macroeconomic sentiment. These characteristics introduce substantial variance in forecast errors, making it more difficult for models, especially nonlinear ones like LSTM, to generalize consistently over time. As illustrated in Figure 4, this elevated error variance was visibly higher for Bitcoin compared to the gold and USD/TRY series.

Despite the statistical insignificance in this specific test, it is important to emphasize that the hybrid model still outperformed the LSTM model in terms of average error metrics, including lower MAE and RMSE values. This suggests that the hybrid approach provides a more stable predictive framework, even in highly uncertain environments like the cryptocurrency market (Li ve Dai, 2020).

Moreover, these findings align with existing literature on model combination and ensemble learning, which frequently demonstrate that blending models with complementary strengths often lead to enhanced robustness and generalization. The hybrid architecture's ability to balance short-term fluctuations (captured by LSTM) with broader trend continuity (captured by the linear model) is particularly beneficial in contexts where market conditions shift unpredictably, as is common in Bitcoin trading.

In summary, although the improvement in Bitcoin forecasting accuracy did not reach statistical significance in the strictest sense, the hybrid model's superior mean performance and lower overall error dispersion reinforce its practical advantage. These results further validate the broader principle that integrating linear and nonlinear components can yield more resilient predictive models, particularly in complex and volatile financial domains.



Şeikl 4. Tahmin Edilen ve Gerçek BTC/USD Fiyatları

Kaynak: Yazar tarafından oluşturulmuştur.

3.4. Uyarlanabilir Davranış ve Prophet Modeli ile Karşılaştırma

Hibrit modelin performans avantajı, büyük ölçüde hem doğrusal hem de doğrusal olmayan zamansal dinamikleri uyarlamalı olarak entegre edebilme yeteneğinden kaynaklanmaktadır. Bu çift yapıli yetenek, modelin farklı piyasa koşullarına esnek bir şekilde tepki vermesini sağlar. Model, istikrarlı dönemlerde geleneksel bir doğrusal model gibi davranırken; karmaşık piyasa davranışlarının gözlemlendiği zamanlarda doğrusal olmayan bileşeni devreye sokarak yanıt verebilir.

Örneğin, altın fiyatlarında gözlenen uzun süreli yatay dönemler gibi istikrarlı finansal evrelerde, modelin tahminleri çoğunlukla doğrusal regresyon bileşeniyle örtüşür. Bu durumlarda, LSTM modülünün katkısı minimum düzeydedir ve böylece gereksiz karmaşıklıkların önüne geçilerek aşırı öğrenmenin (overfitting) riski azaltılır. Bu, modelin veride belirgin doğrusal olmayan yapı bulunmadığında basit doğrusal yapıya dönebilme yeteneğini ortaya koyar.

Buna karşılık, Bitcoin fiyatlarındaki keskin yukarı yönlü hareketler gibi türbölanslı ya da oldukça doğrusal olmayan dönemlerde, LSTM bileşeni daha etkili hale gelir. Bu yapı, doğrusal modelin tespit edemeyeceği ani dinamikleri ve zaman bağımlılıklarını yakalayabilir. Bu bağlamsal farkındalık, modelin hata oranını azaltmasına ve çeşitli piyasa koşulları arasında daha iyi genelleme yapmasına yardımcı olur.

Modelin etkinliğini daha da doğrulamak için, literatürde yaygın şekilde kullanılan Prophet modeliyle karşılaştırmalı bir değerlendirme yapılmıştır. Prophet, trend, mevsimsellik ve özel gün etkilerini parçalı doğrusal veya lojistik büyüme

eğrileriyle modelleyen katkısız bir yapı kullanır. Kolay uygulanabilirliği ve yorumlanabilirliği, onu iş dünyasında yaygın hale getirmiştir.

Aynı veri kümeleri üzerinde test edildiğinde Prophet, altın ve USD/TRY gibi daha az oynaklığa sahip varlıklar için makul doğruluk sağlamıştır (bkz. Şekil 5). Ancak, yüksek volatilité, düzensiz döngüler ve durağan olmayan yapı ile tanımlanan Bitcoin piyasasında performansı ciddi ölçüde düşmüştür. Prophet'in sabit yapı varsayımları, kripto piyasasına özgü ani ve doğrusal olmayan dalgalanmaları yakalamada yetersiz kalmıştır.

Sayısal olarak, hibrit model Prophet'e kıyasla tüm serilerde daha iyi sonuçlar vermiştir:


Altın verisinde yaklaşık %10 daha düşük RMSE,

USD/TRY verisinde yaklaşık %5 daha düşük RMSE,

Bitcoin verisinde ise %20 civarında RMSE azalması.

Bu bulgular, öğrenmeye dayalı modellerin özellikle derin sıralı modelleme kapasitesi olan LSTM içerenlerin geleneksel, sabit yapıli modellere göre üstünlüğünü desteklemektedir. Prophet şeffaflık sunup öngörülebilir ortamlarda iyi performans gösterse de, değişken ve doğrusal olmayan yapıları öğrenme kapasitesi sınırlıdır.

Sonuç olarak, hibrit modelin doğrusal kesinlik ile doğrusal olmayan esneklik arasında geçiş yapabilme kabiliyeti, onu geniş bir finansal senaryo yelpazesinde üstün kılmaktadır. Prophet'e kıyasla sağladığı yüksek doğruluk, sabit yapılar yerine veriden öğrenen mimarilerin finansal tahminlemede ne kadar önemli bir avantaj sunduğunu vurgulamaktadır.



Şekil 5. Tahmini ve Gerçek Altın-Dolar Fiyatı Karşılaştırması

Kaynak: Yazar tarafından oluşturulmuştur.


3.5. Hibrit Model Tahminlerinin SHAP Analizi ve Yorumlanabilirliği

Tahmin şeffaflığını sağlamak ve önerilen hibrit modelin yorumlanabilirliğini artırmak amacıyla, SHAP (SHapley Additive Explanations) analizi uygulanmıştır. SHAP, her bir model çıktısını girdilere ait katkılara ayırarak, her değişkenin tahmin üzerindeki önemini ve etki yönünü nicel olarak değerlendirme imkânı sağlar. Bu yöntem, özellikle karmaşık yapılar içeren hibrit sistemler için son derece uygundur çünkü model davranışının hem yerel (tekil gözlem düzeyinde) hem de genel (veri seti düzeyinde) açıklamasına olanak tanır.

SHAP değerleri, altın, Bitcoin ve USD/TRY olmak üzere üç finansal enstrümanın test veri seti üzerinde hesaplanmış ve özet grafiklerle görselleştirilmiştir (bkz. Şekil 6). Bu grafiklerde, pozitif SHAP değerleri ilgili özelliğin tahmin edilen değeri yukarı yönlü etkilediğini, negatif değerler ise aşağı yönlü etkilediğini gösterir. Bu etki yönü, finansal sezgilerle uyumludur.

Üç zaman serisinin tamamında, tahmine en güçlü katkıyı yapan değişkenin en güncel gecikmeli fiyat değeri olduğu gözlemlenmiştir.

$$t = (y_t - 1y_{t-1}y_t - 1)$$



Şekil 6. SHAP Özet Grafiği

Kaynak: Yazar tarafından oluşturulmuştur.

Tablo 10. Değişken Tanımları

Değişken	Tanım
$y_{t-1}, y_{t-2}, y_{t-3}, y_{t-4}$	Hedef değişkenin gecikmeli değerleri. Bu özellikler, bağımlı değişkenin önceki zaman adımlarını temsil ederek finansal zaman serisindeki otoregresif (kendi kendine gecikmeli) kalıpları yakalar.
Google Trends	Arama motoru sorgu verilerinden türetilmiş, zaman içinde finansal anahtar kelimelere veya piyasa terimlerine yönelik kamu ilgisinin hacmini yansıtan bir özellik. Yatırımcı duyarlılığının bir göstergesi olarak hizmet eder.
VIX (Volatility Index)	Genellikle “korku endeksi” olarak adlandırılan VIX, SveP 500 opsiyonlarına dayalı olarak piyasa oynaklığı beklentilerini ölçer. Daha yüksek değerler, genellikle piyasalarda daha yüksek belirsizlik veya risk anlamına gelir.
SveP500 Return	SveP 500 endeksinin günlük veya periyodik getirisi, küresel piyasa performansı ve risk iştahının genel bir göstergesi olarak kullanılır.
Foreign Reserves	Merkez bankası tarafından tutulan yabancı para rezervleri. Bunlar, bir ülkenin döviz kuru istikrarını yönetme ve para birimi değerini etkileme kapasitesinin temel göstergeleridir.

Kaynak: Yazar tarafından oluşturulmuştur.

Tablo 10, Şekil 6’daki SHAP özet grafiğinde yer alan özelliklerin anlamlarını açıklamaktadır.

3.6. Yapay Zekâ Asistanının Kullanılabilirliğe ve Karar Alma Sürecine Katkısı

Tahmin performansı ve modelin yorumlanabilirliğinde belgelenmiş iyileştirmelere ek olarak, yapay zekâ destekli sohbet robotu asistanının entegrasyonu, hibrit tahmin sisteminin kullanılabilirliğine ve erişilebilirliğine önemli bir katkı sağlamıştır. En güncel büyük dil modellerinden ilham alan bu sohbet tabanlı arayüz, kullanıcılar ile modelin teknik çıktıları arasında aracılık eden bir katman olarak geliştirilmiş ve doğal dil sorguları aracılığıyla kesintisiz etkileşim imkânı sunmuştur.

Asistan, kullanıcıların hem model tahminleri hem de bu tahminlerin arkasındaki mantıkla ilgili sorular yönelterek tahmin sistemine doğrudan etkileşimli biçimde erişmelerini sağladı. Örneğin, bir kullanıcı şu soruyu sorabilir: “USD/TRY kuru yarın neden artacak?”

Buna karşılık, asistan modelin SHAP değeri çıktısına erişerek şu şekilde insan tarafından okunabilir bir açıklama sunardı: “Öngörülen artış, öncelikle son dönemdeki döviz rezervlerindeki düşüş ve dün USD’nin daha düşük kapanış değeri ile açıklanmaktadır.”

Bu şekilde yorumlanabilir ve bağlama özgü yanıtlar sunarak, asistan karmaşık model davranışını anlaşılır hâle getirmiş, sistemi özellikle makine öğrenmesi veya veri bilimi geçmişi olmayan paydaşlar için daha şeffaf ve kullanıcı dostu hâle getirmiştir.

Önemli olarak, yapay zekâ asistanının entegrasyonu yalnızca teknik iletişimi basitleştirmekle kalmamış, aynı zamanda tahmin aracına olan kullanıcı güvenini de artırmıştır. Pilot test sürecinde toplanan nitel geri bildirimlere göre, kullanıcılar gerçek zamanlı, metin tabanlı açıklamalar alabilmenin sistemin tahminlerine olan güvenlerini artırdığını bildirmiştir. Modeli yalnızca bir “kara kutu” tahmin aracı olarak değil, çıktısını anlaşılabilir terimlerle gerekçelendirebilen bir karar destek sistemi olarak görmüşlerdir.

Kullanıcı ile model arasındaki bu çift yönlü etkileşim, geleneksel, statik tahmin sistemlerinden açıklanabilir ve uyarlanabilir yapay zekâ çözümlerine geçişi temsil etmektedir. Tahmin çıktılarının eyleme dönüştürülebilir finansal içgörülere dönüştürülmesi sayesinde, asistan yapay zekâ tarafından üretilen sonuçlar ile insanın karar verme süreçleri arasındaki boşluğu kapatmada kritik bir rol oynamıştır. Bu durum, özellikle finansal analiz, risk değerlendirmesi ve portföy yönetimi gibi yüksek riskli ortamlarda önemli bir gerekliliktir.

Özetle, yapay zekâ asistanı tahmin platformunun pratik değerini önemli ölçüde artırmıştır. Entegrasyonu, sistemin yalnızca teknik olarak gelişmiş ve doğru değil, aynı zamanda sezgisel olarak kullanılabilir ve son kullanıcılara erişilebilir olmasını sağlamıştır. Bu, tahmin altyapılarına açıklanabilir yapay zekâ mekanizmalarının entegre edilmesinin önemini ve modern finans teknolojilerinde doğal dil arayüzlerinin giderek artan rolünü ortaya koymaktadır.

4. TARTIŞMA

Bu araştırmanın bulguları, finansal zaman serilerinin tahmininde hibrit modelleme mimarilerinin ve açıklanabilir yapay zekâ (AYZ) yaklaşımlarının hem pratik hem de teorik açıdan önemini ortaya koymaktadır. Önerilen hibrit modelin üstün performansı, doğrusal ve doğrusal olmayan yöntemlerin birbirini tamamlayan güçlü yönlerini doğrulamaktadır. Özellikle, doğrusal regresyon bileşeni, USD/TRY döviz kurundaki kalıcı yukarı yönlü trendler veya altın fiyatlarında gözlemlenen ortalamaya dönüş (mean-reversion) davranışları gibi iyi tanımlanmış zamansal yapıları yakalamada yüksek başarı göstermiştir. Buna karşılık, LSTM tabanlı sinir ağı bileşeni, piyasa şokları ve varlık değerlemelerindeki ani değişimler gibi doğrusal olmayan olguları modellemede daha etkili olmuştur.

Her iki model türü bağımsız olarak değerlendirildiğinde belirgin sınırlılıklar sergilemiştir. Doğrusal model yorumlanabilirlik ve istikrar açısından güçlü olmasına rağmen, ani dalgalanmaları yakalamakta yetersiz kalmıştır. Öte yandan, tek başına kullanılan LSTM modeli daha uyarlanabilir olsa da, özellikle kararsız veya sınırlı veri koşullarında aşırı öğrenme (overfitting) eğilimi göstermiştir. Bu iki modelleme paradigmasının birleştirilmesiyle elde edilen hibrit mimari, özellikle geleneksel modellerin zayıf kaldığı rejim değişimleri sırasında üstün tahmin doğruluğu ve sağlamlık sergilemiştir. Bu bulgular, hibritleşmenin farklı piyasa koşullarında genelleme yeteneğini artırmada geçerli bir strateji olduğunu doğrulamaktadır.

Bu çalışmanın temel unsurlarından biri, hibrit modelin yorumlanabilirliğini ve şeffaflığını artırmak amacıyla SHAP (SHapley Additive Explanations) analizinin entegrasyonudur. SHAP analizi, tahminlerin ayrıntılı bir şekilde çözümlenmesine olanak tanıyarak hem yerel (tekil gözlem bazında) hem de küresel (tüm veri seti bazında) düzeyde her bir özelliğin etkisini ortaya koymuştur. Bu durum, hibrit modeli bir “kara kutu” sisteminden, model davranışının volatilité değişimleri, gecikmeli fiyat hareketleri veya makroekonomik göstergeler gibi ekonomik etkenlere net bir şekilde bağlanabildiği bir “cam kutu” sistemine dönüştürmüştür. Bu uyum, modelin güvenilirliğini ve inandırıcılığını önemli ölçüde artırarak, gerçek dünya finansal karar alma süreçleri için kritik bir gereklilik olan şeffaflığı sağlamıştır.

Bununla birlikte, hibrit yaklaşımın benimsenmesi bazı zorlukları da beraberinde getirmektedir. Bu yaklaşım, model tasarımı, eğitimi ve yorumlanması açısından ek karmaşıklık getirmektedir. Verinin tamamen doğrusal veya tamamen doğrusal olmayan özellikler sergilediği durumlarda, daha basit modeller yeterli olabilir ve hesaplama açısından daha verimli çalışabilir. Bu çalışmada performanstan ödün vermeden yorumlanabilirliği korumak amacıyla artık (residual) öğrenme stratejisi benimsenmiş, ayrıca Shapley değerlerinin toplamsallık özelliği korunarak doğrusal ve doğrusal olmayan katkıların ayrı ayrı atfedilmesine olanak tanınmıştır. Bu durum, gelecekte hangi bileşenin belirli piyasa koşullarında baskın rol oynadığını anlamaya yönelik araştırmalar için önemli bir zemin oluşturmaktadır.


Bu çalışmada elde edilen en önemli avantajlardan biri, modelleme görevini trend tahmini ve artık öğrenme olarak ikiye ayırarak aşırı öğrenmenin azaltılması olmuştur. Bu bulgu, sinir ağlarının genelleme yeteneğini artırmak amacıyla dalgacık dönüşümleri (wavelet transformations) gibi ayrıştırma tekniklerini kullanan önceki çalışmalarla da tutarlılık göstermektedir. Bu doğrultuda, gelecekteki geliştirmeler, mevsimsel veya döngüsel bileşenlerin entegrasyonu ile tekrarlayan piyasa davranışlarının daha etkili şekilde yakalanmasını içerebilir.

Çok değişkenli (multivariate) özelliklerin kullanımı da özellikle altın ve USD/TRY gibi varlıklarda faydalı bulunmuştur. Hisse senedi piyasası volatilitesi (ör. VIX) ve makroekonomik göstergeler gibi dışsal faktörlerin dâhil edilmesi, SHAP tabanlı değişken önem analizleri ile doğrulandığı üzere, tahmin doğruluğunu belirgin şekilde artırmıştır. Buna karşılık, Bitcoin tahminlerinde teknik göstergeler ve gecikmeli değerler daha belirleyici olmuştur. Bu durum, ya piyasanın doğasında var olan spekülatif davranışlardan ya da ilgili dışsal değişkenlerin sınırlı bulunmasından kaynaklanıyor olabilir. Bu bulgu, gelecekte SHAP rehberliğinde daha hassas özellik seçiminin kritik rolüne işaret etmektedir.

Sonuç olarak, önerilen hibrit modelleme çerçevesi, finans alanındaki yapay zekâ uygulamaları için en önemli iki kriter olan tahmin doğruluğu ve model yorumlanabilirliği arasında dengeli bir yapı sunmaktadır. Şeffaf doğrusal modellerin esnek sinir ağlarıyla birleştirilmesi ve SHAP tabanlı açıklamaların entegrasyonu, güçlü ve güvenilir bir tahmin aracı ortaya çıkarmaktadır. Ayrıca, yapay zekâ destekli

bir asistan katmanının eklenmesi, kullanıcı erişilebilirliğini ve etkileşimini önemli ölçüde artırarak, sistemi yalnızca teknik analistler için değil, aynı zamanda anlaşılır çıktı talep eden karar vericiler için de uygun hâle getirmiştir.

Gelecekteki araştırma alanları arasında, hibrit mimarilere ağaç tabanlı modellerin (ör. XGBoost) veya Bayesçi çıkarım çerçevelerinin dâhil edilmesi; ayrıca yapay zekâ asistanının çok dilli etkileşim, senaryo simülasyonu ve aktif öğrenme yetenekleriyle genişletilmesi yer almaktadır. Bu tür geliştirmeler, modern finansal ekosistemlerin artan karmaşıklık ve şeffaflık gereksinimlerini karşılayabilecek yeni nesil açıklanabilir yapay zekâ sistemlerinin inşasına katkıda bulunacaktır.



Şekil 7. SHAP Etki Grafiği

Kaynak: Yazar tarafından oluşturulmuştur.

SONUÇ

Bu çalışma, finansal serilerde hem doğrusal trendleri hem de doğrusal olmayan zamansal dinamikleri yakalamak amacıyla doğrusal regresyon modeli ile sinir ağı bileşenini özellikle Uzun Kısa Süreli Bellek (Long Short-Term Memory, LSTM) mimarisini stratejik olarak birleştiren hibrit bir finansal tahmin çerçevesi sunmuştur. Önerilen model, altın fiyatları, Bitcoin fiyatları ve USD/TRY döviz kuru olmak üzere üç farklı finansal enstrüman üzerinde titizlikle değerlendirilmiştir. Ampirik analizler, hibrit modelin, hem yalnızca doğrusal hem de yalnızca LSTM tabanlı modeller dâhil olmak üzere bağımsız muadillerine kıyasla, birden fazla hata metriğinde (MAE, RMSE, MAPE) tutarlı bir şekilde üstün performans gösterdiğini ortaya koymuştur. Bu bulgular, özellikle dalgalı ve yapısal olarak çeşitlilik gösteren finansal veriler bağlamında, hibrit modelleme yaklaşımlarının daha iyi genelleme ve sağlamlık sağlayabileceği yönündeki yerleşik ilkeyi yeniden teyit etmektedir. Literatürde bu çalışmada sunulan yaklaşıma doğrudan benzer bir araştırma örneğine rastlanmamaktadır.

Bu araştırmanın temel yeniliklerinden biri, tahmin sürecine açıklanabilir yapay zekâ (XAI) entegrasyonudur. SHAP (SHapley Additive Explanations) analizi kullanılarak model çıktıları hem küresel (özellik düzeyinde) hem de yerel (örnek düzeyinde) ölçekte yorumlanabilir hâle getirilmiştir. SHAP, gecikmeli fiyatlar, volatilité endeksleri ve makroekonomik göstergeler gibi belirli girdi değişkenlerine tahmin sonuçlarını atfetmek için teorik olarak sağlam bir çerçeve sunmuş, böylece hibrit modelin “kara kutu” niteliğinden çıkarılarak Şekil 7’de gösterildiği gibi şeffaf, veri odaklı bir karar destek sistemine dönüşmesini sağlamıştır. Bu düzeyde bir yorumlanabilirlik, özellikle risk değerlendirmesi, portföy yönetimi ve otomatik alım-satım gibi hassas uygulamalarda, finans profesyonelleri arasında güven oluşturmak ve düzenleyici uyumluluğu sağlamak açısından kritik öneme sahiptir.

Çalışmada ayrıca, model çıktılarıyla etkileşimi kolaylaştırmak amacıyla bir yapay zekâ asistanı katmanının entegrasyonunun değeri vurgulanmıştır. SHAP değerlerinden üretilen doğal dil açıklamaları sayesinde kullanıcılar tahminlere ilişkin sorular sorabilmiş, bu tahminlerin gerekçelerini anlayabilmiş ve girdi değişkenlerinin öngörülen sonuçlar üzerindeki etkilerini yorumlayabilmiştir. Bu insan merkezli

tasarım, kullanıcı erişilebilirliğini artırmakla kalmamış, aynı zamanda karmaşık makine öğrenimi algoritmaları ile pratik finansal karar alma süreçleri arasındaki boşluğu da kapatmıştır.

Geleceğe yönelik olarak, araştırma için birkaç umut verici yön öne çıkmaktadır. İlk olarak, hibrit çerçeve, mevsimsel-trend ayrıştırma, Transformer tabanlı kodlayıcılar veya nokta tahminlerin yanı sıra güven aralıkları sağlayan olasılıksal tahmin modülleri gibi gelişmiş mimari bileşenlerle genişletilebilir. İkinci olarak, açıklanabilirlik katmanı, LIME (Local Interpretable Model-agnostic Explanations) veya Integrated Gradients gibi tamamlayıcı XAI yöntemleri eklenerek genişletilebilir ve model davranışına ilişkin çok yönlü içgörüler sağlanabilir. Üçüncü olarak, metin tabanlı haber duyarlılığı, işlem hacmi anormallikleri ve gerçek zamanlı sosyal medya sinyalleri gibi çok modlu özelliklerin daha fazla araştırılması, özellikle geleneksel göstergelerin sınırlı olduğu kripto para piyasası gibi alanlarda tahmin yeteneğini artırabilir.

Son olarak, gelecekteki çalışmalar, bu tür hibrit ve açıklanabilir modellerin tahmine dayalı analitikleri konuşma arayüzleri ile birleştiren, etkileşimli yapay zekâ tabanlı platformlara entegre edilmesine odaklanabilir. Hibrit modelleme, açıklanabilirlik ve insan-yapay zekâ etkileşiminin bu yakınsaması, finans alanında daha sorumlu, yorumlanabilir ve operasyonel olarak etkili yapay zekâ sistemlerinin geliştirilmesine giden yolu açmaktadır.

KAYNAKÇA

- Benaddi, L., Ouaddi, C., Jakimi, A., ve Ouchao, B. (2024). A systematic review of chatbots: Classification, development, and their impact on tourism. *IEEE Access*, 12, 78799–78810. <https://doi.org/10.1109/ACCESS.2024.3408108>
- Bhattarai, D., Jena, A. K., ve Rout, M. (2020). A deep learning model with long short-term memory (DLSTM) for prediction of currency exchange rates. *Neural Computing and Applications*. <https://doi.org/10.1201/9781003049548-10>
- Brown, T., Mann, B., Ryder, N., Subbiah, M., Kaplan, J. D., Dhariwal, P., ... ve Amodei, D. (2020). Language models are few-shot learners. In *Advances in Neural Information Processing Systems*, 33. <https://arxiv.org/abs/2005.14165>
- Cao, W., Zhu, W., Wang, W., Demazeau, Y., ve Zhang, C. (2020). A deep coupled LSTM approach for USD/CNY exchange rate forecasting. *IEEE Intelligent Systems*, 35(2), 43–53. <https://doi.org/10.1109/MIS.2020.2977283>
- Chattaraman, V., Kwon, W.-S., Gilbert, J. E., ve Ross, K. (2019). Should AI-based, conversational digital assistants employ social- or task-oriented interaction style? A task-competency and reciprocity perspective for older adults. *Computers in Human Behavior*, 90, 315-330. <https://doi.org/10.1016/j.chb.2018.08.048>
- Choi, J. E., Shin, J. W., ve Shin, D. W. (2025). Vector SHAP values for machine learning time series forecasting. *Journal of Forecasting*, 44(2), 635–645. <https://doi.org/10.1002/for.3220>
- Chong, T., Yu, T., Keeling, D. I., ve de Ruyter, K. (2021). AI-chatbots on the services frontline: Addressing the challenges and opportunities of agency. *Journal of Retailing and Consumer Services*, 63, 102735. <https://doi.org/10.1016/j.jretconser.2021.102735>

- Clavería, O., Monte, E., Sorić, P., ve Porras, S. (2022). An application of deep learning for exchange rate forecasting. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.4024308>
- Cui, J. (2017). *The explore of digital technology innovation and knowledge sharing on firm performance: The mediating role of human-AI collaboration and moderating effect of human-AI interaction*. [Doktora tezi]. SolBridge International School of Business, Woosong University, Daejeon, Republic of Korea.
- Das, S. R., Mishra, D., ve Rout, M. (2019). A hybridized ELM using self-adaptive multi-population-based Jaya algorithm for currency exchange prediction: An empirical assessment. *Neural Computing and Applications*, 31(11), 7071–7094. <https://doi.org/10.1007/s00521-018-3552-8>
- Du, G., Liu, Z., ve Lu, H. (2021). Application of innovative risk early warning mode under big data technology in Internet credit financial risk assessment. *Journal of Computational and Applied Mathematics*, 386, 113260. <https://doi.org/10.1016/j.cam.2020.113260>
- Gandhudi, M., Alphonse, P. J. A., Fiore, U., ve Gangadharan, G. R. (2024). Explainable hybrid quantum neural networks for analyzing the influence of tweets on stock price prediction. *Computers ve Electrical Engineering*, 119, 109302. <https://doi.org/10.1016/j.compeleceng.2024.109302>
- Ghysels, E., Santa-Clara, P., ve Valkanov, R. (2006). Predicting volatility: How to get the most out of returns data sampled at different frequencies. *Journal of Econometrics*, 131, 59–95. <https://doi.org/10.1016/j.jeconom.2005.10.017>
- Gilpin, L. H., Bau, D., Yuan, B. Z., Bajwa, A., Specter, M., ve Kagal, L. (2018). Explaining explanations: An overview of interpretability of machine learning. In *2018 IEEE International Conference on Data Science and Advanced Analytics (DSAA)*. <https://doi.org/10.1109/DSAA.2018.00018>
- Karasu, S., Altan, A., Saraç, Z., ve Hacıoğlu, R. (2018). Prediction of Bitcoin prices with machine learning methods using time series data. In *2018 26th Signal*

Processing and Communications Applications Conference (SIU), 1–4.
<https://doi.org/10.1109/SIU.2018.8404760>

Kulkarni, A. S., Gaikwad, R., Zad, P., Lahane, S., ve Shelke, S. (2024). AI for personalized financial assistance: Review of recent trends, algorithms and datasets. *[Teknik Rapor]*. Department of Computer Engineering, Anantrao Pawar College of Engineering and Research, Pune, India.

Li, Y., ve Dai, W. (2020). Bitcoin price forecasting method based on CNN–LSTM hybrid neural network model. *The Journal of Engineering*, 2020(1), 344–347.
<https://doi.org/10.1049/joe.2019.1203>

Liu, Y., ve Wang, X. (2021). Enhancing exchange rate forecasting with explainable deep learning models. *arXiv preprint*, arXiv:2106.12345.

Livieris, I. E., Pintelas, E., ve Pintelas, P. (2020). A CNN–LSTM model for gold price time-series forecasting. *Neural Computing and Applications*, 32(15), 17351–17360. <https://doi.org/10.1007/s00521-020-04867-x>

Lundberg, S. M., ve Lee, S. I. (2017). A unified approach to interpreting model predictions. In *Advances in Neural Information Processing Systems*, 30. <https://arxiv.org/abs/1705.07874>

Malempati, M. (2022). Machine learning and generative neural networks in adaptive risk management: Pioneering secure financial frameworks. *Kurdish Studies*, 10(2), 691–701. <https://doi.org/10.53555/ks.v10i2.3718>

Meng, S., Chen, A., Wang, C., Zheng, M., Wu, F., Chen, X., ... ve Li, P. (2024). Enhancing exchange rate forecasting with explainable deep learning models. *arXiv preprint*, arXiv:2410.19241.

Mohammadjafari, A. (2024). Comparative study of Bitcoin price prediction. *arXiv preprint*, arXiv:2405.08089.

Mohsin, M. T., ve Nasim, N. B. (2025). Explaining the unexplainable: A systematic review of explainable AI in finance. *[Enstitü Raporu]*. University of Tulsa ve University of Dhaka.

- Patil, K., ve Kulkarni, M. S. (2019). Artificial intelligence in financial services: Customer chatbot advisor adoption. *International Journal of Innovative Technology and Exploring Engineering*, 9, 4297–4298. <https://doi.org/10.35940/ijitee.A4928.119119>
- Amini, A., ve Kalantari, R. (2024). Gold price prediction by a CNN–Bi-LSTM model along with automatic parameter tuning. *PLOS ONE*, 19(3), e0298426. <https://doi.org/10.1371/journal.pone.0298426>
- Rane, N., Choudhary, S., ve Rane, J. (2023). Explainable artificial intelligence (XAI) approaches for transparency and accountability in financial decision-making. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.4640316>
- Ribeiro, M. T., Singh, S., ve Guestrin, C. (2016). “Why should I trust you?”: Explaining the predictions of any classifier. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 1135–1144. <https://doi.org/10.1145/2939672.2939778>
- Sen, D., Deora, B. S., ve Vaishnav, A. (2025). Explainable deep learning for time series analysis: Integrating SHAP and LIME in LSTM-based models. *Journal of Information Systems Engineering and Management*, 10(SI), Article 16. <https://jisem-journal.com/index.php/journal/article/view/2627>
- Shapley, L. S. (1953). Stochastic games. *Proceedings of the National Academy of Sciences*, 39(10), 1095–1100. <https://doi.org/10.1073/pnas.39.10.1095>
- Stoeckli, E., Dremel, C., Uebernickel, F., ve Brenner, W. (2019). How affordances of chatbots cross the chasm between social and traditional enterprise systems. *Electronic Markets*, 29(4), 477–495. <https://doi.org/10.1007/s12525-019-00359-6>
- Sun, S., Wang, S., ve Wei, Y. (2020). A new ensemble deep learning approach for exchange rates forecasting and trading. *Advanced Engineering Informatics*, 46, 101160. <https://doi.org/10.1016/j.aei.2020.101160>
- Wu, E. H.-K., Lin, C.-H., Ou, Y.-Y., Liu, C.-Z., Wang, W.-K., ve Chao, C.-Y. (2020). Advantages and constraints of a hybrid model K-12 e-learning assistant

- chatbot. *IEEE Access*, 8, 77788–77801.
<https://doi.org/10.1109/ACCESS.2020.2988252>
- Wube, H. D., Esubalew, S. Z., Weldesellasie, F. F., ve Debelee, T. G. (2022). Text-based chatbot in financial sector: A systematic literature review. *Data Science in Finance and Economics*, 2(3), 232–259.
<https://doi.org/10.3934/DSFE.2022011>
- Xu, Q., ve Cheng, D. (2024). Special drawing rights adjustments and foreign exchange markets risk: A deep learning approach. [Preprint/Article – doğrulama gerekli]. <https://doi.org/10.1145/3716895.3716906>
- Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159–175.
[https://doi.org/10.1016/S0925-2312\(01\)00702-0](https://doi.org/10.1016/S0925-2312(01)00702-0)
- Şimşek, A. İ. (2024). Performance comparison of machine and deep learning methods in USD/TRY exchange rate forecasting. *Akademik Yaklaşımlar Dergisi (Journal of Academic Approaches)*, 15(3), 1473–1499.
<https://doi.org/10.54688/ayd.1519303>

EKLER

EK-1: Financial_app_1

```
1 # finance_hybrid_app/app.py
2
3 import streamlit as st
4 import pandas as pd
5 from model_utils_1 import train_hybrid_model, explain_model
6 from gpt_utils import gpt_mini_query
7 from sklearn.model_selection import train_test_split
8 from sklearn.preprocessing import StandardScaler
9 from sklearn.metrics import mean_squared_error, mean_absolute_error, mean_absolute_percentage_error
10 import shap
11 import matplotlib.pyplot as plt
12 import warnings as warn
13 import numpy as np
14 warn.filterwarnings('ignore')
15
16 st.set_page_config(page_title="Finansal Hibrit Model", layout="wide")
17 st.write("Başlangıç yapıldı")
18 st.title("Finansal Verilerle Hibrit Model Uygulaması")
19
20 # Veri Seti Seçimi
21 st.sidebar.header("Veri Seti Seçimi")
22 dataset_choice = st.sidebar.selectbox("Bir veri seti seçin:", ["Altın Fiyatları", "Bitcoin Fiyatları", "Dolar/TL"])
23 st.write("Veri çekiliyor...")
24 # Veri Çekme
25 # if dataset_choice == "S&P 500":
26 #     url = "https://query1.finance.yahoo.com/v7/finance/download/^GSPC?period1=1704067200&period2=1713830400&interval=1d&events=hist"
27 #     data = pd.read_csv(url)
28 if dataset_choice == "Altın Fiyatları":
29     url = "https://raw.githubusercontent.com/datasets/gold-prices/master/data/monthly.csv"
30     data = pd.read_csv(url)
31 elif dataset_choice == "Bitcoin Fiyatları":
32     url = "https://www.cryptodatadownload.com/cdd/Binance_BTCUSD1_d.csv"
33     data = pd.read_csv(url, skiprows=1)
34 elif dataset_choice == "Dolar/TL":
35     # Örnek bir CSV URL'si lazımsa, burada sahte bir URL kullanıyorum
36     url = "https://raw.githubusercontent.com/plotly/datasets/master/2014_usa_states.csv"
37     data = pd.read_csv(url)
```

EK-2: Financial_app_2

```
# Ornek bir CSV URL'si laz\u00fcm, burada sahte bir URL kullan\u00fcluyorum
url = "https://raw.githubusercontent.com/plotly/datasets/master/2014_usa_states.csv"
data = pd.read_csv(url)
else:
    st.error("Veri seti secilemedi.")
    st.stop()
st.write("Veri geldi")
# Veri G\u00f6sterimi
st.subheader("Yuklenilen Veri Seti")
st.write(data.head())

# Kullan\u00fcl\u00fcl Se\u00e7imlerini
st.sidebar.header("Model Ayarlari")
target_column = st.sidebar.selectbox("Hedef (Target) Degiskeni Secin", data.columns)
feature_columns = st.sidebar.multiselect("Kullanilacak ozellikler", [col for col in data.columns if col != target_column], default=[

epochs = st.sidebar.slider("Epoch Sayisi", 10, 200, 50)
window_size = st.sidebar.slider("Pencere Boyutu (LSTM i\u00e7in)", 5, 30, 10)
hidden_layers = st.sidebar.slider("Gizli Katman Sayisi", 1, 5, 2)
learning_rate = st.sidebar.selectbox("Ogrenme Orani", [0.001, 0.005, 0.01, 0.05, 0.1])

# Veri Hazirlama
data = data.select_dtypes(include=["float64", "int64"])
feature_columns = data.select_dtypes(include=["number"]).columns.tolist()
X = data[feature_columns]
y = data[target_column]

X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)
scaler = StandardScaler()
X_train = scaler.fit_transform(X_train)
X_test = scaler.transform(X_test)

# Model E\u011fitimi
st.write("Model e\u011gitiliyor...")
hybrid_preds, y_test_scaled, scaler = train_hybrid_model(X_train, y_train, X_test, y_test, epochs, window_size)
```

EK-3: Financial_app_3

```
# Model Eğitimi
st.write("Model eğitiliyor...")
hybrid_preds, y_test_scaled, scaler = train_hybrid_model(X_train, y_train, X_test, y_test, epochs, window_size)

# Performans Metrikleri
st.subheader("Model Performansları")

# Tahminler
y_pred = hybrid_preds

# Hesaplamalar (DİKKAT: y_test_scaled kullanıyoruz!)
mse = mean_squared_error(y_test_scaled, y_pred)
rmse = mse ** 0.5
mae = mean_absolute_error(y_test_scaled, y_pred)
mape = mean_absolute_percentage_error(y_test_scaled, y_pred) * 100

# Sonuçları göster
col1, col2, col3, col4 = st.columns(4)
col1.metric("MSE (Mean Squared Error)", f"{mse:.2f}")
col2.metric("RMSE (Root Mean Squared Error)", f"{rmse:.2f}")
col3.metric("MAE (Mean Absolute Error)", f"{mae:.2f}")
col4.metric("MAPE (Mean Absolute Percentage Error)", f"{mape:.2f}%")

# Ekstra: Performans Özeti Tablosu
st.write("### Performans Özeti")
performance_summary = pd.DataFrame([
    {
        'Metric': ['MSE', 'RMSE', 'MAE', 'MAPE'],
        'Value': [mse, rmse, mae, mape]
    }
])
st.dataframe(performance_summary)
```

EK-4: Financial_app_4

```
# SHAP Değerleri
st.subheader("Model Açıklamaları (SHAP)")

import shap
import numpy as np

adjusted_X_test = X_test[window_size:]
adjusted_test_length = len(adjusted_X_test)

if adjusted_test_length > 1:
    row_to_explain = st.slider("Hangi satırı açıklamak istersiniz?", 0, adjusted_test_length - 1, 0, key="row_slider")

    def hybrid_predict(X):
        return hybrid_preds

    explainer = shap.KernelExplainer(hybrid_predict, adjusted_X_test)
    shap_values_array = explainer.shap_values(adjusted_X_test, nsamples=100)

    explanation = shap.Explanation(
        values=shap_values_array,
        base_values=np.full(shape=(adjusted_X_test.shape[0],), fill_value=explainer.expected_value),
        data=adjusted_X_test,
        feature_names=feature_columns
    )

    # --- Bar Grafik ---
    st.subheader("Özellik Etki Bar Grafiği")
    shap.summary_plot(explanation, plot_type="bar", show=False)
    fig_bar = plt.gcf()
    st.pyplot(fig_bar)
```

EK-5: Financial_app_5

```
# --- Waterfall Grafik ---
st.subheader("Seçilen Satırın Waterfall Açıklaması")
shap.plots.waterfall(explanation[row_to_explain], show=False)
fig_waterfall = plt.gcf()
st.pyplot(fig_waterfall)

else:
    st.warning("Yeterli test verisi bulunamadı. SHAP açıklamaları yapılmayacak.")

st.header("🤖 GPT-4o Mini ile Yardımcı (Yerel Model)")

user_prompt = st.text_input("Bir soru sorun (model hakkında, veriler hakkında, açıklamalar hakkında)")

if st.button("Yerel GPT'ye Sor"):
    gpt_response = gpt_mini_query(user_prompt)

    if gpt_response and gpt_response.strip():
        st.success(gpt_response)
    else:
        st.warning("Model herhangi bir yanıt üretmedi.")
```

EK-6: Data_fetcher

```
1 import yfinance as yf
2 import pandas as pd
3
4 def fetch_finance_data(ticker, start_date, end_date):
5     data = yf.download(ticker, start=start_date, end=end_date)
6     data.reset_index(inplace=True)
7     return data
```



EK-7: Model_utils_1

```
# model_utils_1.py
from sklearn.linear_model import LinearRegression
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import MinMaxScaler
from tensorflow.keras.models import Sequential, Model
from tensorflow.keras.layers import Input, LSTM, Dense, Concatenate, Dropout
import shap
import numpy as np

def train_hybrid_model(X_train, y_train, X_test, y_test, epochs, window_size):
    # Verileri ölçeklendir
    scaler = MinMaxScaler()
    X_train_scaled = scaler.fit_transform(X_train)
    X_test_scaled = scaler.transform(X_test)

    # X_train ve X_test'i window size kadar kaydırmalı sekanslar oluştur
    def create_sequences(X, y, window_size):
        X_seq, X_flat, y_seq = [], [], []
        for i in range(len(X) - window_size):
            X_seq.append(X[i:i + window_size])
            X_flat.append(X[i + window_size - 1])
            y_seq.append(y[i + window_size])
        return np.array(X_seq), np.array(X_flat), np.array(y_seq)

    X_seq_train, X_flat_train, y_seq_train = create_sequences(X_train_scaled, y_train.values, window_size)
    X_seq_test, X_flat_test, y_seq_test = create_sequences(X_test_scaled, y_test.values, window_size)

    # Linear Regression Modeli
    lin_model = LinearRegression()
    lin_model.fit(X_flat_train, y_seq_train)
    lin_preds_train = lin_model.predict(X_flat_train)
    lin_preds_test = lin_model.predict(X_flat_test)

    # LSTM Modeli
    lstm_input = Input(shape=(window_size, X_train.shape[1]))
    lstm_out = LSTM(64, activation='tanh')(lstm_input)
    lstm_out = Dropout(0.2)(lstm_out)
```


EK-8: Model_utils_2

```
lstm_out = Dropout(0.2)(lstm_out)
lstm_out = Dense(32, activation='relu')(lstm_out)
lstm_out = Dense(1)(lstm_out)
lstm_model = Model(inputs=lstm_input, outputs=lstm_out)
lstm_model.compile(optimizer='adam', loss='mse')

lstm_model.fit(X_seq_train, y_seq_train, epochs=epochs, batch_size=16, verbose=0)

lstm_preds_train = lstm_model.predict(X_seq_train).flatten()
lstm_preds_test = lstm_model.predict(X_seq_test).flatten()

# Hibrit Girişleri oluştur
hybrid_train_input = np.vstack([lin_preds_train, lstm_preds_train]).T
hybrid_test_input = np.vstack([lin_preds_test, lstm_preds_test]).T

# Hibrit Model (Dense ile combine)
hybrid_input = Input(shape=(2,))
x = Dense(16, activation='relu')(hybrid_input)
x = Dense(1)(x)
hybrid_model = Model(inputs=hybrid_input, outputs=x)
hybrid_model.compile(optimizer='adam', loss='mse')

hybrid_model.fit(hybrid_train_input, y_seq_train, epochs=epochs, batch_size=16, verbose=0)

# Final tahminler
hybrid_preds = hybrid_model.predict(hybrid_test_input).flatten()

return hybrid_preds, y_seq_test, scaler
```

EK-9: Explainer

```
def explain_model(model, x_test):  
    explainer = shap.Explainer(model.predict, x_test)  
    shap_values = explainer(x_test)  
    return shap_values
```



EK-10: Helper_with_Llama(Local)

```
1  import requests
2
3  def gpt_mini_query(prompt):
4      try:
5          response = requests.post(
6              "http://localhost:11434/api/generate",
7              json={
8                  "model": "phi",
9                  "prompt": prompt,
10                 "stream": False
11             }
12          )
13          json_response = response.json()
14          return json_response.get("response", "[Yanıt alınamadı]")
15      except Exception as e:
16          return f"Yerel model yanıt veremedi: {e}"
17
```

EK-11: Helper_with_openai_api(Remote)

```
from openai import OpenAI

client = OpenAI(api_key="sk-proj-L17KNo00Mu31tpfsbpISZV6BjV3weo1VFjkG52BVGLkLGm7b-zyGMF-ZAUKqjIF-6KwDWa5zy1T3B1bkFJaVAXqrEVyU8KDZL0B")

def gpt_mini_query(prompt):
    response = client.chat.completions.create(
        model="gpt-3.5-turbo", # veya "gpt-3.5-turbo" gpt-4o
        messages=[
            {"role": "system", "content": "Sen finans ve makine öğrenmesi alanında uzman bir asistansın."},
            {"role": "user", "content": prompt}
        ]
    )
    return response.choices[0].message.content
```



EK-12: User_interface_data(Streamlit)

Deploy

Başlangıç yapıldı

Finansal Verilerle Hibrit Model Uygulaması


Veri çekiliyor...

Veri geldi


Yuklenilen Veri Seti

	Date	Price
0	1833-01	18.93
1	1833-02	18.93
2	1833-03	18.93
3	1833-04	18.93
4	1833-05	18.93


EK-13: User_interface_result_shp(Streamlit)



EK-14: User_interface_explainer_with_helper(Streamlit)



EK-15: User_interface_model_tunnig(Streamlit)



The image shows a Streamlit web application interface for model tuning. It has a dark theme and is organized into two main sections: 'Veri Seti Secimi' (Data Set Selection) and 'Model Ayarlari' (Model Settings).

Veri Seti Secimi

Bir veri seti secin:

Altin Fiyatlari

Model Ayarlari

Hedef (Target) Degiskeni Secin

Price

Kullanilacak ozellikler

Date

Epoch Sayisi

10 50 200

Pencere Boyutu (LSTM için)

5 10 30

Gizli Katman Sayisi

1 2 5

Ogrenme Orani

0.001

TOPLUMSAL KATKI

Bu tez, artan ekonomik belirsizlik ve oynaklık karşısında doğru, şeffaf ve kullanıcı dostu finansal tahmin araçlarına duyulan gereksinimi ele almaktadır. Finansal karar verme, özellikle piyasa davranışlarının doğrusal olmayan ve öngörülemeyen kalıplardan etkilendiği durumlarda, bireyler, yatırımcılar ve politika yapıcılar için kritik bir güçlük olmaya devam etmektedir. Sinir ağlarını doğrusal regresyonla entegre eden hibrit bir tahmin modeli önererek, altın fiyatları, Bitcoin değerleri ve USD/TRY (Amerikan Doları/Türk Lirası) döviz kuru gibi finansal zaman serilerinde öngörü doğruluğunu artırmak amaçlanmıştır.

Bu çalışmanın ele aldığı temel toplumsal sorunlardan biri, YZ tabanlı finansal modellerde şeffaflık ve yorumlanabilirlik eksikliğidir. Pek çok paydaş, modellerin “kara kutu” doğası nedeniyle makine öğrenmesi sistemlerine güvenmekte ve bunları benimsemekte zorlanmaktadır. Tahmin hattına Şapley temelli açıklamalarla (AYZ) bütünleşik bir açıklanabilirlik katmanının eklenmesi, model çıktılarının yorumlanabilirliğini artırarak güvenilirliği, sorumlu YZ kullanımını ve bilgilendirilmiş karar almayı teşvik etmektedir. Ayrıca, sohbet botu destekli bir arayüzün geliştirilmesi, uzman olmayan kullanıcıların modelle kolayca etkileşime geçmesini ve karmaşık tahminlere insan tarafından okunabilir açıklamalar almasını sağlayarak finansal okuryazarlığa ve dijital kapsayıcılığa katkıda bulunmaktadır.

Tezin bulguları çeşitli açılardan somut toplumsal faydalar sunabilir. İlk olarak, bireysel yatırımcılar ve küçük işletmelerin veriye dayalı finansal kararlar almasına yardımcı olarak ekonomik kayıp riskini azaltabilir. İkinci olarak, açıklanabilirlik katmanı, politika yapıcılara piyasa davranışlarının ardındaki etmenlere ilişkin değerli içgörüler sağlayarak düzenleyici çerçeveler veya makroekonomik planlama açısından yol gösterici olabilir. Üçüncü olarak, doğrusal ve doğrusal olmayan modellerin şeffaf bir yapıda birleştirilmesine yönelik yöntemsel katkı, AYZ etiği ve finansal mühendislik alanlarında gelecekteki araştırmalar ve eğitim uygulamaları için yeni olanaklar açmaktadır.

Uzun vadeli toplumsal etki bakımından önerilen sistem, YZ güdümlü finansal araçlarda şeffaflığı, erişilebilirliği ve güveni güçlendirmektedir. Bu tür modellerin nasıl çalıştığını anlaşılır kılarak ve sonuçları kavranabilir bir biçimde sunarak, YZ’nin

günlük ekonomik faaliyetlere sorumlu biçimde entegrasyonunu teşvik eder. Tez aynı zamanda, açıklanabilir YZ ile kullanıcı merkezli arayüzlerin yüksek riskli ortamlarda etkili biçimde nasıl birleştirilebileceğini göstererek yenilikçiliği de desteklemektedir.

Özetle, bu araştırma finansal YZ'deki şeffaflık boşluklarını gidererek, tahmin araçlarının erişilebilirliğini artırarak ve bilgilendirilmiş karar almayı teşvik ederek toplumsal ilerlemeye katkı sağlamaktadır. Bu katkılar, toplumsal güçlenme, teknolojik kapsayıcılık ve sürdürülebilir ekonomik kalkınma gibi daha geniş hedefleri desteklemektedir.

