



Finansal Verilere İlişkin Tahminleri Açıklamaya Yönelik Yeni Bir Model-Agnostik Yöntem ve Uygulaması

Samet Öztoprak¹, Zeynep Orman^{2*}

¹ İstanbul Üniversitesi-Cerrahpaşa, Lisansüstü Eğitim Enstitüsü, Bilgisayar Mühendisliği Bölümü, İstanbul, Türkiye, (ORCID: 0000-0002-0878-5979), sametoztoprak@hotmail.com

^{2*} İstanbul Üniversitesi-Cerrahpaşa, Bilgisayar Mühendisliği Bölümü, İstanbul, Türkiye (ORCID: 0000-0002-0205-4198), ormanz@istanbul.edu.tr

(İlk Geliş Tarihi 25 Şubat 2022 ve Kabul Tarihi 29 Haziran 2022)

(DOI: 10.31590/ejosat.1079145)

ATIF/REFERENCE Öztoprak, S., Orman Z., (2022). Finansal Verilere İlişkin Tahminleri Açıklamaya Yönelik Yeni Bir Model-Agnostik Yöntem Ve Uygulaması. Avrupa Bilim ve Teknoloji Dergisi, (38), 32-39,

Öz

Yapay sinir ağları, günümüzde insan hayatını doğrudan etkileyen sağlık, sürücüsüz araçlar ve ordu gibi kritik görev sistemlerinde ve bu sistemlerle ilgili verilere ilişkin tahminlerde yaygın olarak kullanılmaktadır. Bununla birlikte, yapay sinir ağı algoritmalarının kara-kutu yapıları, kritik görev uygulamalarında kullanımlarını zorlaştırırken güven eksikliğine yol açan etik ve adli kaygıları da gündeme getirmektedir. Yapay zeka kavramının günden güne gelişmesi ve hayatımızda daha fazla yer kazanması, bu algoritmalarından elde edilen sonuçların daha açıklanabilir ve anlaşılır olması gerektiğini ortaya çıkarmıştır. Açıklamalı Yapay Zeka, yapay zeka kararlarının yüksek kaliteli yorumlanabilir, sezgisel, insan tarafından anlaşılabilir açıklamalarını oluşturabilen bir dizi araç, teknik ve algoritmayı destekleyen bir yapay zeka alanıdır. Bu çalışmada, açıklanabilirlik için borsa verileri ele alınarak finans sektörü için kullanılacak yeni bir model-agnostik yöntem oluşturulmuştur. Geliştirilen bu yöntem, oluşturulan modele verilen girdiler ve modelden elde edilen çıktılar arasındaki ilişkiyi anlamamızı sağlamaktadır. Tüm girdiler tekli ve birleşik olarak değerlendirilmiş ve değerlendirme sonuçları tablo ve grafikler ile gösterilerek açıklanmıştır. Çalışmada önerilen bu model, farklı makine öğrenimi algoritmaları ve uygulama alanları için de açıklanabilir bir katman oluşturmaya yardımcı olmaktadır.

Anahtar Kelimeler: Açıklanabilir Yapay Zeka, Makine Öğrenmesi, Yapay Sinir Ağları, Finans, Borsa.

A New Model-Agnostic Method and Implementation for Explaining the Prediction on Finance Data

Abstract

Artificial neural networks are widely used in critical mission systems such as healthcare, self-driving vehicles and the army, which directly affect human life, and in predicting data related to these systems. However, the black-box nature of neural network algorithms makes their use in mission-critical applications difficult, while raising ethical and forensic concerns that lead to a lack of trust. The development of the Artificial Intelligence day by day and gaining more space in our lives have revealed that the results obtained from these algorithms should be more explainable and understandable. Explainable Artificial Intelligence is a field of AI that supports a set of tools, techniques, and algorithms that can create high-quality interpretable, intuitive, human-understandable explanations of artificial intelligence decisions. In this study, a new model-agnostic method that can be used for the financial sector has been developed by considering the stock market data for explainability. This method enables us to understand the relationship between the inputs given to the created model and the outputs obtained from the model. All inputs were evaluated individually and combined, and the evaluation results were shown with tables and graphics. This model will also help create an explainable layer for different machine learning algorithms and application areas.

Keywords: Explainable Artificial Intelligence, Machine Learning, Artificial Neural Networks, Finance, Stock Market.

* Sorumlu Yazar: ormanz@istanbul.edu.tr

1. Giriş

Yapay zeka (YZ), çok çeşitli alanlarda hayatımıza daha fazla girmeye başlamıştır. Bununla birlikte, yapay zekanın önerdiği kararlara dair kesin bir açıklama bulunmamaktadır. Özellikle finans, askeri, tıp ve otonom sürüş gibi kritik alanlarda bu kararların açıklanabilmesi oldukça önem hale gelmiştir. Açıklanabilirlik için modelden bağımsız yöntemler ön plana çıkmaktadır. Model-agnostik olarak adlandırılan bu yöntemlerin modele özgü yöntemlere göre en önemli avantajı esnek bir yapı sunabilmeleridir. Bu sayede, açıklanabilirlik yönteminin hangi makine öğrenimi modeline uygulandığı geliştiricinin tercihine bırakılmıştır. Bunun yanı sıra, bir grafik veya bazı kullanıcı arabirimleri ile makine öğrenimi modellerinin açıklamasına dayanan çıktılar, aynı zamanda temeldeki makine öğrenimini modelden bağımsız hale getirmektedir. Genellikle, bir görevi yerine getirmek için birden çok türde makine öğrenimi modeli kullanılır ve bu modelleri açıklanabilirlik açısından karşılaştırmak gerekir. Bu aşamada modelden bağımsız açıklama yapmak daha kolaydır; çünkü aynı yöntem herhangi bir model türü için de kullanılabilir.

Modelden bağımsız açıklanabilirlik yöntemine bir alternatif, yalnızca açıklanabilir modelleri kullanmaktır; fakat bu genellikle diğer makine öğrenimi modellerine kıyasla daha az doğruluk sunması şeklinde bir dezavantaja sahiptir ve tek bir model tipine ve açıklanabilirliğe takılıp kalmaktadır. Diğer alternatif ise modele özgü açıklanabilirlik yöntemlerinin kullanılmasıdır. Buradaki dezavantaj ise tek bir algoritmaya bağlı kalınması ve başka algoritmaların denenmesinin oldukça zor olmasıdır. [Andreas Holzinger]

Açıklanabilir yapay zekayı çeşitli alanlarda kullanma isteği her geçen gün artmaktadır. Bu makalede, finans sektöründe önem arz eden borsa verilerine ilişkin tahminleri açıklamaya yönelik model-agnostik bir yöntem geliştirilmesi üzerine çalışılmıştır. Geliştirilen bu yöntem literatürde yeni bir yaklaşım olarak görülmektedir. Bu yöntem iki soruya cevap vermektedir. Bu cevaplar ile hangi parametrelerin daha önemli olduğu ve eğitim için hangi parametrelerin gereksiz olduğu belirlenmektedir. Çalışmanın temel amacı, önerilen model ile finans sektörü araştırmacılarının verileri hızlı ve etkili bir şekilde analiz etmelerine, ana yönler hakkında net bir fikre sahip olmalarına ve anlamalarına yardımcı olmaktır. Çalışmamızın literatüre katkıları şu şekilde ifade edilebilir: çalışmada önerilen yaklaşım, herhangi bir makine öğrenimi algoritmasında kullanılabilen modelden bağımsız bir yöntemdir. Ayrıca, bu yaklaşım, finasta herhangi bir finansal aracın fiyatını tahmin etmek için kullanılan parametreleri anlaşılır hale getirmektedir. Bu amaçla, model ilk olarak, kullanılan parametreler için en önemliden en önemsiz doğru bir sıra bulmaya çalışır. İkinci olarak, eğitimde hangi parametrelerin kullanılmasının gereksiz olduğuna önerilen bu model ile karar verilir. Model sonucu elde edilen veriler grafikler ile görsel olarak da analiz edilmiştir.

Makalenin ilerleyen bölümleri şu şekilde organize edilmiştir: Bölüm 2'de ilgili çalışmalar sunulmuştur. Materyal ve metod bilgileri Bölüm 3'de sunularak, açıklanabilir yapay zeka alanındaki en son gelişmeler ve kullanılan yaklaşımlar ile çalışmada kullanılan veri seti ele alınmaktadır. Bölüm 4'de, önerilen AYZ yöntemi anlatılmakta ve grafiklerle açıklanmaktadır. Bölüm 5'de, geliştirilen AYZ yönteminin sonuçları değerlendirilmektedir. Son olarak, Bölüm 6, çalışmamızın sonuç bölümünü oluşturmaktadır.

2. İlgili Çalışmalar

Son zamanlarda yapay zekadaki açıklanabilirlik isteğinin artışı ile birlikte bu alandaki yapılan çalışmaların sayısında da artış görülmektedir. Bu bölümde literatürde bulunan açıklanabilir yapay zeka (AYZ) ile ilgili çalışmalar hakkında bilgiler verilmektedir.

Samek ve arkadaşları, bu alandaki en son gelişmeleri özetlemek için bir çalışma yapmışlardır. Bu çalışma sonucunda yapay zeka uygulamalarında daha fazla yorumlanabilirliğin gerekliliği görülmektedir. Ayrıca, derin öğrenmenin tahminlerini açıklamak için iki yaklaşım sunulmaktadır. İlki girdideki değişikliklere göre tahminin hassasiyetini hesaplayan bir yöntem, ikinci olarak kararları girdi değişkenleri temelinde anlamlı bir şekilde ayrıştıran bir yaklaşım. Bu yöntemler görüntü sınıflandırması, metin belgesi sınıflandırması ve videolarda insan eylemi tanıma üzere üç tip sınıflandırma altında toplanmıştır.

Andreas Holzinger, olasılıklı öğrenme yöntemlerinin büyük bilgi gösterimleri ve mantıksal yaklaşımlar ile olan ilişkisini incelemiştir, böylece sonuçları geri işlenebilir, açıklanabilir ve istendiğinde anlaşılır hale getirmiştir.

Guo ve arkadaşları, çok değişkenli zaman serilerinde farklı dinamikleri yakalamak ve değişkenlerin tahmine katkısını ayırt etmek amacıyla ara katmandaki değişkenleri öğrenmek için uzun kısa süreli bellek (Long short-term memory-LSTM) mimarisinin tekrarlayan sinir ağlarının yapısını araştırmışlardır. Ara katmandaki değişkenler, hedefin üretici sürecini modellemek için bir karma dikkat mekanizması şeklinde önerilmiştir. Sonrasında, ağ parametresini, değişken ve zamansal önem ölçülerini aynı anda öğrenmeye yönelik olasılık tabanlı bir karışıma dayalı bir eğitim yöntemi belirlenmiştir. Gerçek veri kümeleri üzerinde yapılan kapsamlı deneyler, farklı değişkenlerin hareketliliklerini yakalayarak gelişmiş tahmin performansını gösterir böylece yorumlama sonuçları hem niteliksel hem de niceliksel olarak değerlendirilmektedir. Tahmin ve de bilgi çıkarımı uçtan uca bir çerçeve olarak sergilenmektedir. Çok değişkenli veriler üzerinden bilgi çıkarımı ve tahmin yapılabilmektedir.

Peng ve arkadaşları, elde ettikleri deneysel sonuçlar ile karmaşık modellerin basit olanlardan daha iyi performans sergilediğini göstermişlerdir. Geliştirilen Random Forest tabanlı yaklaşım, tüm modeller arasında en yüksek doğruluğu (%91,9) elde etmektedir. Genel ve yerel yorumlanabilir yöntemleri birleştiren bu yaklaşım karmaşık modellerin şeffaflığını geliştirir ve karmaşık modellerden alınan verilere ilişkin bir bakış açısı yakalamamızı sağlar; bu sayede önerilen model tedaviye rehberlik edebilir ve hepatit hastalarının ön tanısını iyileştirmede kullanılabilir. Ayrıca, önerilen yöntem, klinik veri bilimcilerin daha uygun bir bilgisayar destekli tanı koyabilmelerine de yardımcı olabilmektedir.

Howard ve Edwards, derin öğrenme ve diğer yapay sinir ağı tabanlı çözümlerin nadiren şeffaf olduğu ve genellikle beyaz kutu çözümleri istendiğini göz önüne alarak, Multirun Subtree Encapsulation'ın Açıklanabilir Yapay Zekayı kolaylaştırmak için beyaz kutu çözümlerini nasıl sağlayabileceğini açıklamışlardır.

Pierrard ve arkadaşları, bulanık ilişkileri ve bulanık özellikleri öğrenmeye dayalı bir yaklaşım önermişlerdir. Açıklanmış bir karar oluşturmak için belirlenen veri kümesinden ilişkiler çıkarmışlardır. Yaklaşımları, sınıflandırma ve açıklama gibi farklı problemlerle ilgilidir. Oluşturulan bir yapay veri seti

üzerinde açıklamalı sınıflandırma yapmak için bir model oluşturmuşlardır. İkna edici açıklamalar sunarak örnekleri doğru bir şekilde sınıflandırmayı başarmışlardır. Bu çalışma ile gereksiz hesaplamalardan kaçınmak için ilişkileri ve özellikleri öğrenmeden önce veya öğrenirken filtreleme ihtiyacı gibi iyileştirilmesi gereken birkaç alan tespit edilmiştir.

Fernandez ve arkadaşları, evrimsel bulanık sistemler alanının kapsamlı analizini geliştiren bir çalışma amaçlamışlardır. Bu amaçla, bu konunun mevcut bağlamını ve önemini anlamak amacıyla "4W" soruları sorulup ele alınmaktadır. Özellikle, evrimsel bulanık sistemlerin açıklanabilir bir bakış açısıyla neden önemli olduğu, ne zaman başladıkları, ne için kullanıldığı ve yakın gelecekte bu alanda araştırmacıların dikkatlerinin nereye yönlendirilmesi gerektiği üzerinde durmaktadırlar. Verilerden öğrenmenin gelişen Açıklanabilir Yapay Zeka (AYZ) alanında önemli bir rol oynaması hedeflenmektedir.

Turek, çalışmasında daha akıllı, özerk ve simbiyotik sistemler gerektiren zorluklara değinmektedir. Açıklanabilir Yapay Zeka'nın, özellikle de Açıklanabilir Makine Öğrenimi'nin geleceğin savaşçılarında çok önemli hale geleceği vurgulanmaktadır. Akıllı savaş makinalarının birbirini anlaması, mantıksal şekilde güvenmesi ve etkin bir şekilde yönetilmesi için Açıklanabilir Yapay Zeka'nın gerekli olacağı öngörülmektedir.

Zhang ve arkadaşları, modelin yorumlanabilirliğini geliştirmek için Shapley ek açıklamaları, olgusal açıklamalar ve bağımlılık grafikleri kullanmışlardır. Çin borsasında işlem gören şirketlerin 2007'den 2020'ye kadar olan finansal verileri veri seti olarak alındığında, en yüksek AUC 0,92 değeri Light Gradient Boosting Machine tarafından sağlanmaktadır. Yerel açıklamalar, bireysel işletmelerin finansal sıkıntılarına yol açan temel özellikleri belirlemelerine yardımcı olur ve iyileştirme stratejileri sağlamak için açıklamalar üretilir. Küresel açıklamalar, özelliklerin önemini ve özellik etkileşiminin sonuçlar üzerindeki etkisini analiz ederek, "kara kutu" modellerinin şeffaflığını ve güvenilirliğini artırabilir.

Carta ve arkadaşları, amaçları S&P 500 endeksindeki bireysel şirketler için gelecekteki hisse senedi fiyat değişimlerinin büyüklüğünü (yüksek veya düşük) tahmin etmekte kullanılacak olan bir ikili sınıflandırma problemini çözmek için bir Makine Öğrenimi yaklaşımı önermişlerdir. Bunu yapmak için belirli bir zaman aralığında ve belirli bir iş sektörü içinde piyasadaki en etkili kelimeleri belirlemek amacıyla küresel olarak yayınlanan makalelerden sözlük setleri oluşturulur. Daha sonra oluşturulan sözlüklerden parametre süreci gerçekleştirilir ve elde edilen özellikler bir Karar Ağacı sınıflandırıcısı ile beslenir. Tahmini etiket (yüksek veya düşük), belirli bir eşğin üstünde veya altında olmak üzere, temel şirketin ertesi gün hisse senedi fiyat değişimini temsil eder. İleriye dönük bir strateji ile ve bir dizi sağlam temele dayalı olarak gerçekleştirdiğimiz performans değerlendirmesi, yaklaşımımızın açıkça rakiplerinden daha iyi performans olduğunu gösteriyor. Ayrıca, tasarlanan Yapay Zeka yaklaşımı, sınıflandırıcının arkasındaki beyaz kutuyu analiz eder ve elde edilen sonuçlar üzerinde bir dizi açıklama sunulmaktadır.

Yapay zeka modellerinin şeffaflığının olmaması, sosyal bilimlerde ve tıbbi teşhis gibi hassas alanlarda büyük bir endişe unsuru olmaktadır. Makine öğrenimi modellerinin ön açıklama başarısına rağmen, mevcut modellerin çoğu tüm gözlemlerin birbirinden bağımsız olduğunu varsaydığından, kümelenmiş verilerdeki herhangi bir tahminciye uygulanabilecek açıklama yöntemlerinin eksikliği bulunmaktadır. Zhou ve arkadaşları çalışmalarında bu eksikliği ele alarak kümelenmiş veriler

üzerinde herhangi bir karmaşık modelin yerel davranışını taklit etmek için doğrusal bir karma model kullanmayı önermişlerdir. Bu da açıklama yönteminin karmaşık modellere uygunluğunu iyileştirebilmektedir. Film tavsiyesi ve tıbbi kayıt teşhisi dahil olmak üzere iki görevde derin bir sinir ağı modeli de dahil olmak üzere çeşitli modelleri açıklamak için geliştirdikleri yöntemlerini uygulamışlardır. Deney sonuçları, modelin aslına uygunluk ve kesinlik gibi çeşitli metriklerde temel modellerden daha iyi performans gösterdiğini saptamıştır.

Bu çalışmada, finans alanında kullanılabilir açıklanabilir bir katman geliştirilmesi hedeflenmiştir. Bu katman sayesinde finansal araçların tahmininde daha yüksek bir doğruluk elde etmek amacı ile ilk olarak verilerdeki gereksiz parametreler ortadan kaldırılacak ve sonrasında sistem parametrelerinin önem sırası belirlenecektir.

3. Materyal ve Metot

Açıklanabilir Yapay Zeka, yapay zeka sistemleri sonuçlarını insanlar için daha anlaşılır hale getirmeyi amaçlayan bir araştırma alanıdır. AYZ kavramı nispeten yeni olsa da, açıklanabilirlik sorunu, araştırmacıların uzman sistemlerin açıklanmasını inceledikleri 1970'li yılların ortalarından beri var olmuştur [Turek]. Bununla birlikte, açıklanabilirlik sorununu çözmeye yönelik yapılan çalışmaların ilerleme hızı, yapay zeka ve makine öğreniminde gerçekleşen olağanüstü ilerlemelerle bir dönüm noktasına ulaşana kadar yavaşladı. O zamandan beri, YZ araştırmalarının odak noktası, karar süreçlerini açıklama yeteneğini devre dışı bırakırken tahmin gücünü vurgulayan modellerin ve algoritmaların uygulanmasına kaymıştır.



Şekil 1. "Açıklanabilir Yapay Zeka" terimi araştırması için Google Trends sonucu (Figure. 1. Google Trends search result for the term "Explainable Artificial Intelligence")

Özellikle, son yıllarda AYZ konusu akademik dünyada yeniden ilgi görmeye başlamıştır. Şekil 1, google trendlerini kullanan AYZ terimi için arama oranında dikkate değer bir canlanmayı göstermektedir. Bu araştırma konusunun yeniden canlanması, yapay zeka ve makine öğrenmesinin çeşitli sektörler arasında artan etkisinin ve kritik karar verme süreçleri üzerindeki önemli etkisinin doğrudan bir sonucudur. Bu nedenle, sosyal, etik ve yasal kararları açıklanabilir ve anlaşılır hale getirebilecek yeni yapay zeka tekniklerine gereksinim artmaktadır.

Tablo 1. AYZ terimini arayan ilk 10 ülke Google Trends sonucu (Table 1. Google Trends result for the top 10 countries searching for the term XAI)

1 Vietnam	6 Yunanistan
2 Güney Kore	7 Japonya
3 Çin	8 Norveç

1 Vietnam	6 Yunanistan
4 Singapur	9 İsrail
5 Tayvan	10 İspanya

Tablo 1, XAI anahtar kelimesinin İnternette en çok araştırıldığı ilk 10 ülkeyi göstermektedir. Bu ülkeler dünyanın en büyük ekonomisi olmalarının yanı sıra Vietnam, İsrail gibi dünyanın yükselen ekonomilerinden oluşmaktadır. Makine öğrenimi alanında en çok kullanılan ve etkili algoritmalar yapay sinir ağlarına dayanmaktadır. Çalışmamızda modelden bağımsız bir yaklaşım belirlenmesinin nedeni, herhangi bir makine öğrenmesi algoritmasına bağımlı olmadan ortak bir açıklanabilirlik katmanı oluşturulabilmesidir.

3.1. Makine Öğrenmesi

Makine öğrenimi (MÖ), yazılım uygulamalarının açıkça programlanmadan sonuçları tahmin etmede daha hassas olmasını sağlayan bir yapay zeka alanıdır. Makine öğrenimi algoritmaları, geçmiş verilere dayalı olarak çalışır ve yeni çıktı değerlerini tahmin etmek için geçmiş verileri girdi olarak kullanmaktadır. Makine öğreniminin tahminlerinde kullanılacak dört temel yaklaşım bulunmaktadır:

Denetimli öğrenme: Bu tür makine öğreniminde, veri bilimcileri algoritmalara etiketlenmiş eğitim verileri sağlayarak algoritmanın korelasyonlar için değerlendirmesini istedikleri değişkenleri belirlemektedir. Algoritmanın hem girdisi hem de çıktısı belirtilmiştir.

Denetimsiz öğrenme: Bu tür makine öğrenimi, etiketlenmemiş veriler üzerinde eğitim veren algoritmalar içermektedir. Algoritma, anlamlı bir bağlantı arayan veri kümelerini tarayarak algoritmaların eğitildiği veriler ve çıktılarının tahminleri veya önerileri önceden belirlenmektedir.

Yarı denetimli öğrenme: Makine öğrenimine yönelik bu yaklaşım, önceki iki türün bir karışımını oluşturmaktadır. Veri bilimcileri genellikle eğitim verilerini etiketleyen bir algoritma kanalı ile beslemektedir, ancak model verileri kendi başına keşfetme ve veri kümesine ilişkin kendi anlayışını geliştirme yeteneğine sahiptir.

Pekiştirmeli öğrenme: Veri bilimcileri, bir makineye açıkça tanımlanmış kurallar aracılığıyla çok adımlı bir süreci tamamlamasını öğretmek için genellikle pekiştirmeli öğrenmeyi kullanmaktadır. Veri bilimcileri, bir görevi tamamlamak için bir algoritma kullanarak ve bir görevin nasıl tamamlanacağını araştırırken ona olumlu veya olumsuz ipuçları vermektedir. Ancak çoğunlukla, algoritma yol boyunca hangi adımların atılacağına kendi başına karar vermektedir.

3.2. Yapay Sinir Ağları

Yapay sinir ağları (YSA), makine öğreniminin bir alt alanıdır ve derin öğrenme algoritmalarının kalbinde yer almaktadır. Adı ve yapısı, biyolojik nöronların birbirine sinyal gönderme şeklini taklit ederek insan beyninden esinlenmiştir. YSA, bir girdi katmanı, bir veya daha fazla gizli katman ve bir çıktı katmanı içeren bir düğüm katmanından oluşmaktadır. Her düğüm veya yapay nöron diğerine bağlanır ve ilişkili bir ağırlık ve eşik değerine sahiptir. Herhangi bir düğümün çıkışı belirtilen eşik değerin üzerinde ise, o düğüm etkinleştirilir ve ağırlık bir sonraki katmanına veri gönderilmektedir. Eğer belirtilen eşik değerin altında ise, ağırlık bir sonraki katmanına hiçbir veri iletilmemektedir.

Yapay Sinir ağları, zaman içinde doğruluklarını öğrenmek ve geliştirmek için eğitim verilerine dayanmaktadır. Öte yandan, bu öğrenme algoritmaları, doğruluk için ince ayar yapılabilirlik, bilgisayar bilimi ve yapay zekada güçlü araçlardır ve verileri yüksek hızda sınıflandırmamızı ve kümelememizi sağlamaktadır. Konuşma tanıma veya görüntü tanımadaki görevler, insan uzmanlar tarafından yapılan tanımlamaya kıyasla günler yerine sadece dakikalar içinde yerine getirilmektedir. En iyi bilinen sinir ağlarından biri Google'ın arama algoritmasıdır.

YZ özellikli bir sistemin belirli bir çıktıya nasıl yol açtığını anlayarak açıklanabilirlik, geliştiricilerin sistemin beklendiği gibi çalışmasını sağlamalarına yardımcı olabilmektedir. Düzenleyici standartları karşılaması gerekebilir veya bir karardan etkilenenlerin bu sonucu sorgulamasına veya değiştirmesine izin vermede önemli olabilmektedir.

Her düğümü, girdi verileri, ağırlıklar, bir sapma (veya eşik) ve bir çıktıdan oluşan kendi doğrusal regresyon modeli olarak düşünüldüğünde. Formüller şu şekilde olacaktır:

$$\sum_{i=1}^m w_i x_i + b \quad (1)$$

Formül (1)'de sinir ağlarının toplam değerinin bulunması için uygulanan formül görülmektedir. Her bir düğümü, girdi verileri (x), ağırlıklar (w), bir sapma veya eşik (b) ve bir çıktıdan oluşan kendi doğrusal regresyon modeli olarak düşünülebilmektedir.

$$f(x) = \begin{cases} 1, & \text{if } \sum_{i=1}^m w_i x_i + b \geq 0, \\ 0 & \text{if } \sum_{i=1}^m w_i x_i + b < 0 \end{cases} \quad (2)$$

Formül (2)'de aktivasyon ile ilgili formülü göstermektedir. Bir girdi katmanı belirlendikten sonra ağırlıklar atanmaktadır. Bu ağırlıklar, herhangi bir değişkenin önemini belirlemeye yardımcı olur ve daha büyük olanlar diğer girdilere kıyasla çıktıya daha fazla katkıda bulunmaktadır. Tüm girdiler daha sonra ilgili ağırlıklarıyla çarpılır ve toplandıktan sonra çıktıyı belirleyen bir aktivasyon fonksiyonundan geçirilmektedir. Bu çıktı belirli bir eşik aşarsa, ağırlık bir sonraki katmana veri ileterek düğümü etkinleştirir. Bu bir düğümün çıktısının bir sonraki düğümün girdisi olması durumu ile gerçekleşir. Verileri bir katmandan sonraki katmana geçirme işlemi, bu sinir ağımları ile beslemeli bir ağırlık olarak tanımlanmaktadır.

3.3. Açıklanabilir Yapay Zeka (AYZ)

Açıklanabilir yapay zeka (AYZ), insan kullanıcılarının makine öğrenimi algoritmaları tarafından oluşturulan sonuçları ve çıktıları anlamasını ve bunlara güvenmesini sağlayan bir dizi süreç ve yöntemin tanımıdır. Açıklanabilir yapay zeka, bir yapay zeka modelini, beklenen etkisini ve potansiyel önyargıları tanımlama biçimidir. Yapay zeka destekli karar vermede model doğruluğunu, adaleti, şeffaflığı ve sonuçları tanımlamaya yardımcı olmaktadır. Açıklanabilir yapay zeka, yeni bir yapay zeka modeli kullanıma girildiğinde güven oluşturmak için çok önemlidir. Yapay zeka açıklanabilirliği ayrıca yeni modelin geliştirilmesinde sorumlu bir yaklaşım benimsenmesine yardımcı olmaktadır.

YZ daha karmaşık hale geldikçe, insanlar algoritmanın nasıl bir sonuca vardığını anlamak ve takip etmekte zorlanmaya başlamışlardır. Tüm hesaplama süreci, genellikle yorumlanması imkansız olan "kara kutu" olarak adlandırılan kavrama çevrilmektedir. Bu kara kutu modelleri doğrudan verilerden oluşturulmaktadır ve algoritmayı oluşturan mühendisler veya veri bilimcileri bile içlerinde tam olarak ne olduğunu veya yapay zeka algoritmasının belirli bir sonuca nasıl ulaştığını anlayamamakta ve açıklayamamaktadır.

Yapay zeka özellikli bir sistemin belirli bir çıktıya nasıl ulaştığını anlayarak geliştiricilerin sistemin beklendiği gibi çalışıp çalışmadığını anlamaya yardımcı olmaktadır. Belirli standartları karşılaması gerekebilir veya bir karardan etkilenenlerin bu sonucu sorgulamasına veya değiştirmesine izin vermede önemli rol oynayabilmektedir.

3.4. Veri Kümesi

Çalışmada kullanılan borsa verileri <https://finance.yahoo.com/> web adresinden .csv uzantılı veri dosyası olarak indirilmiştir. Hisse senedi adı BİZİM hisse senedir ve Türk borsa hisselerinden biridir. İndirilen dosyadaki parametre listesi sırasıyla (D) Date, (O) Open, (H) High, (L) Low, (C) Close, (A.C) Adj Close (Ayarlamalardan Sonra Fiyat) ve Volume sütunlarından oluşmaktadır; Date sütunu, hisse senedinin tarih bilgisini göstermektedir. Open sütunu, hisse senedinin başlangıç fiyatı anlamına gelir. High sütunu, hisse senedinin gün içindeki en yüksek fiyatını göstermektedir. Low sütunu, hisse senedinin gün içindeki en düşük fiyatını göstermektedir. Close sütunu, günün sonunda hisse senedinin Kapanış fiyatını göstermektedir. Adj Close sütunu, hisse senedinin son alım oturumundaki kapanış fiyatını yansıtır ve hisse senedinin doğru değerinin teknik olarak daha doğru yansımaları nedeniyle eğitim alanı olarak seçilmiştir. Volume sütunu, ticaretin (alış ve satış) toplamıdır.

Tablo 2. Veri Kümesinin Örnek Parçası (Table 2. Sample Fragment of the Dataset)

Date	Open	High	Low	Close	Adj.C lose	Volume
2016-08-29	9.126 666	9.1733 33	9.0000 00	9.000 000	8.7720 33	114538
2016-08-30	9.000 000	9.0000 00	9.0000 00	9.000 000	8.7720 33	0
2016-08-31	9.006 666	9.0666 66	8.9000 00	8.906 666	8.6810 62	133443
2016-09-01	8.926 666	8.9666 66	8.6666 66	8.666 666	8.4471 42	338652

Tablo 2, bu çalışmada kullanılan veri setinin küçük bir örneğini oluşturmaktadır. Bu veri seti 2016 ve 2021 yılları arasındaki verileri içermektedir.

3.5. Ön İşleme

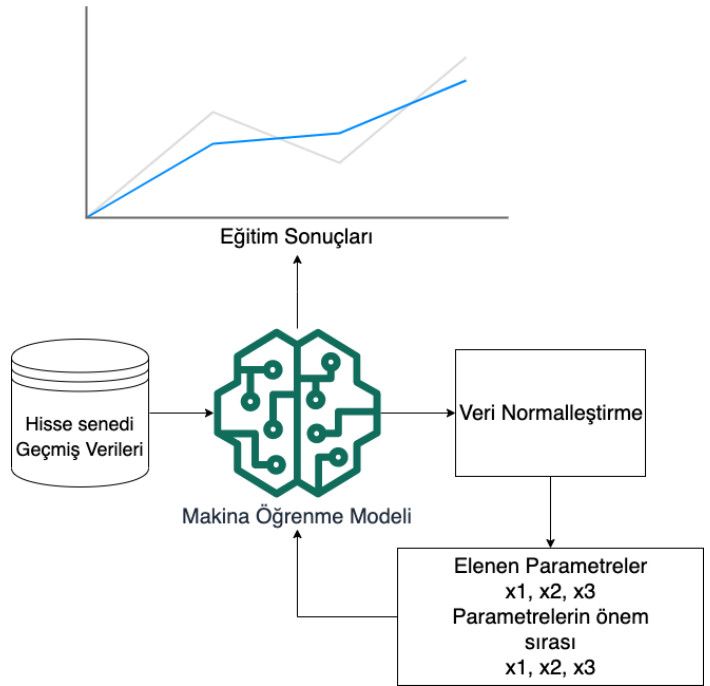
LSTM kullanarak hisse senedi fiyatını uygulamadan önce bu verileri önceden işlememiz gerekir. Phytonda bulunan MinMaxScaler() sınıfının fit_transform fonksiyonu yardımıyla veri değerleri dönüştürülür. Bu method yardımı ile giriş verileri

üzerinde tek seferde sıgdırma ve dönüştürme işlemleri gerçekleştirilir ve veri noktaları dönüştürülür. Her ikisine de ihtiyacımız olduğunda fit ve transform yöntemlerinin ayrı ayrı kullanılması modelin verimliliğini düşürür, bu nedenle her ikisini de gerçekleştirebilen fit_transform() methodu kullanılmıştır.

4. Önerilen AYZ Yöntemi

Şekil 2, Borsa Tahmin sistemi için önerilen AYZ'nın çerçevesini göstermektedir. Önerilen çerçeve, borsa tahmininin finansal anlayışını geliştirmek için açıklamalar sağlamaktadır. Hisse senedi kayıtları, veri toplama ve ön işleme ile elde edilmektedir. Ayrıca, riskin sonucunu tahmin etmek için model yüklenir. Daha sonra açıklamalara ulaşmak için model açıklama yöntemi uygulanır. Buradan sonra elimizdeki verilerin hangilerinin önemli olduğu ve hangilerinin gereksiz olduğu belirlenmektedir.

İlk önce, parametrelerin oryantasyon tablosu çıkartılır ve bu tablo daha sonrasında gereksiz parametrelerin elenmesinde ve parametrelerin değerlendirilmesinde kullanılacaktır. İlk olarak parametreler tek tek ele alınarak değerlendirmesi tamamlandıktan sonra parametreler ikili, üçlü ve dördü olarak değerlendirme sonuçları ile karşılaştırılır. Bu karşılaştırma sonucunda hangi parametrelerin daha önemli olduğu belirlenir ve bu veriler üzerinden algoritma eğitilmektedir.



Şekil 2. Finans Şeması AYZ Çerçevesi (Figure. 2. Finance Scheme XAI Framework)

4.1 Tek Parametre Analizi

Parametre oryantasyon türleri tablosu oluşturulurken 3 adet durum bulunmaktadır. İlk durum önceki değer mevcut değerle aynıysa 0 olur. İkinci durum önceki değer bir sonraki değerden büyükse (-) olacaktır. Üçüncü durum olarak önceki değer bir sonraki değerden küçükse (+) olacaktır. Bu şekilde oryantasyon türleri Tablo 3 de gösterilmiştir.

Tablo 3. Oryantasyon Türleri (Figure. 2. Finance Scheme XAI Framework)

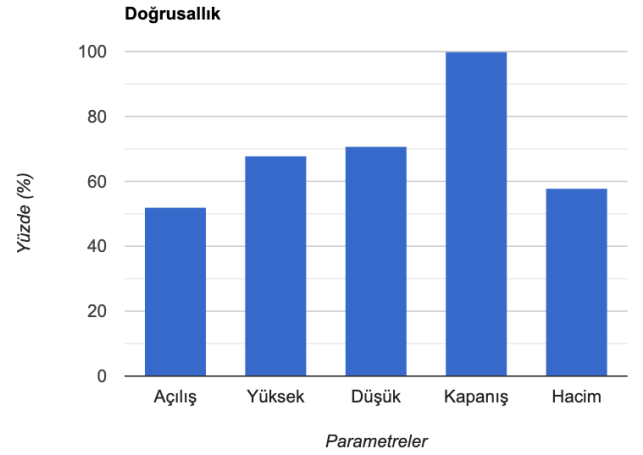
Oriyantasyon	Çıktı	Parametre
Doğrusal	+	+
Ters	+	-
Ters	+	0
Ters	-	+
Doğrusal	-	-
Ters	-	0
Ters	0	+
Ters	0	-
Doğrusal	0	0

Bu oryantasyon haritalarını birbirleriyle karşılaştıracağız ve parametreler arasındaki ilişkiyi bulacağız. Ters mi yoksa lineer mi olduğunu anlamaya çalışılacaktır. Parametreler sırasıyla Date, Open, High, low, Close, Adj. Close ve Volume sütunlarından oluşmaktadır. Tablo 3, doğrusal ve ters orantı için her bir parametrenin oranını göstermektedir.

Tablo 4. Parametrelerin Oryantasyon Oranı (Table 4. Orientation Ratio of Parameters)

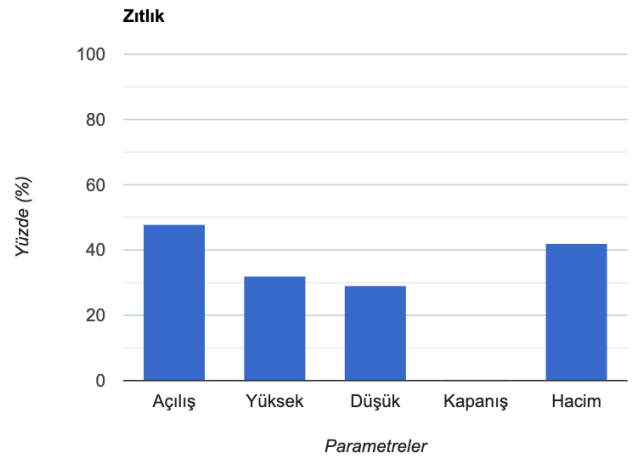
Parametre	Doğrusallık (%)	Terslik (%)
Open	52	48
High	68	32
Low	71	30
Close	100	0
Adj. Close	58	42

Tablo 4'ün 2 kategoride gösterilmesi gerekmektedir. Bunlardan biri, her bir parametrenin doğrusallık oranlarıdır. Diğeri ise her bir parametrenin ters oranlarıdır.



Şekil 3. Parametrelerin Doğrusallık Oranları (Figure. 3. Linearity Ratios of Parameters)

Şekil 3, parametrelerin doğrusallık oranını göstermekte ve bize bir parametrenin sonuca olumlu etkisi olup olmadığı hakkında fikir vermektedir. Bir parametredeki doğrusallık ne kadar fazlaysa, sonuç üzerinde o kadar olumlu etkisi vardır. Doğrusallık bizim çalışmamız için temel teşkil etmektedir.



Şekil 4. Parametrelerin Ters Oranları (Figure. 4. Inverse Ratios of Parameters)

Şekil 4, parametrelerin ters oranını gösterir. Bu durumda bir parametrenin sonuca ters etki yapıp yapmadığını anlamaya çalışıyoruz. Bu, sonucun bu parametreye göre ters gittiği anlamına gelir.

4.1.2 Parametre Eleme

Tablo 5'teki doğrusallık oranına dayanarak, eğitim için yararlı olmayan gereksiz parametrelere karar vermek mümkündür. Bu çalışmada, Tablo 4'te lineer %100 veya %0 olan parametreleri elenmiştir. Bu iki tip parametre, bias nedeniyle açıklanabilir katmanda herhangi bir yön vermemektedir. Bu nedenle artık Close parametresini dikkate almayacağız. Tablo 4'te gösterilmiştir.

Tablo 5. Elenen Parametre(ler) (Table 5. Eliminated Parameter(s))

Parametre	Doğrusallık (%)	Terslik (%)
Close	100	0

4.1.3 Birleşik Parametre Analizi

Bir önceki bölümde sonuç üzerinde tek parametre tutarlılığını gösterilmiştir. Bu bölümde, Kombine parametre tutarlılığını sonuç üzerinde anlamaya çalışılmaktadır. Parametreleri ikili, üçlü veya dördü olarak ele alacağız. Çıktı ve seçilen parametrelerin aynı işaretle olma durumunda doğrusal orantılı olarak sayılacaktır. Aksi takdirde Ters orantılı olarak alınmaktadır. Birleşik parametreler bu şekilde değerlendirilecektir.

4.1.3.1. Çift Kombinasyon

Tablo 6, oryantasyon haritalarındaki sonuçla parametre çiftlerini karşılaştırmayı ve parametreler arasındaki ilişkiyi bulmayı göstermektedir. High ve Low parametrelerinin kombinasyonu Tablo 6'da yüzde 57 ile en yüksek olasılığa sahiptir.

Tablo 6. Double Combination of Parameters (Table 6. Double Combination of Parameters)

Parametreler	Doğrusallık (%)
O, H	47
O, L	47
O, V	30
H, L	57
H, V	47
L, V	40

4.1.3.2. Üçlü Kombinasyon

Oryantasyon haritalarındaki sonuçla parametrelerin üçlülerini karşılaştırmının sonucu olarak Open, High ve Low parametrelerinin kombinasyonu Tablo 7'de yüzde 42 ile en yüksek olasılığa sahiptir.

Tablo 7. Parametrelerin Üçlü Kombinasyonu (Table 7. Triple Combination of Parameters)

Parametreler	Doğrusallık (%)
O, H, L	42
O, H, V	29
O, L, V	26
H, L, V	37

4.1.3.3. Dördü Kombinasyon

Dördü bir parametre kombinasyonu yalnızca birdir. Sadece 4 parametrenin dikkate alınması nedeniyle tüm parametrelerin doğrusallığı Tablo 8'de gösterilmiştir.

Tablo 8. Parametrelerin Dördü Kombinasyonu (Table 8. Parametrelerin Dördü Kombinasyonu)

Parametreler	Doğrusallık (%)
O, H, L, V	25

5. Araştırma Sonuçları ve Tartışma

Bu bölümde, tek parametre ile birleşik parametreler arasındaki veri tutarlılığı ele alınacaktır. Beklenen sonuç, birleşik parametrelerin tek parametre değerleriyle paralel olması gerektiğidir. Ancak, beklenen sonuç, birleştirilmiş parametre değerinden farklı olabilir. Bu durumda parametrelerin Tutarlılığının belirtilmesi gerekmektedir.

Tablo 9. Tekli Parametrelerin Azalan Değeri (Table 9. Decreased Value of Single Parameters)

Parametreler	Doğrusallık (%)
Low	71
High	68
Volume	58
Open	52

Parametrelerin doğrusallık yüzde değerleri Tablo 10'da azalan sırada sıralanmıştır. Beklenti, parametreler birbiriyle birleştirildiğinde, en yüksek doğrusallık yüzdesine sahip olan tek parametrelerin birleşik parametrelerde de en yüksek doğrusallık yüzdesi olması beklenmektedir.

Tablo 10. Parametrelerin Tutarlılığı (Table 10. Consistency of Parameters)

Kombinasyon	Çift	Üçlü
Beklenen	L, H	L, H, V
Gerçekleşen	L, H	L, H, O
Tutarlılık	Olumlu	V Olumsuz

Tablo 10, Low ve High parametre kombinasyonunun ikili kombinasyonda en yüksek yüzdeye sahip olduğunu ve bu sonucun gerçekleşen sonuçla uyumlu olduğunu göstermektedir. Üçüncü en yüksek doğrusallık yüzdesi Volume parametresine aittir ancak elde edilen sonuç farklıdır. Low, High ve Open kombinasyonu üçlü tabloda en yüksek değere sahiptir. Bu, Volume parametresinin gerçekleşen sonuçla tutarlı olmadığı anlamına gelir. Sonuç olarak gerçek parametre sıralamamız en

önemliden en az önemliye doğru L, H, O, V şeklindedir. Üçüncü parametre(V) değerleri en yüksek oranlara sahip diğer parametrelerle tutarlı değildir.

6. Sonuç

Açıklanabilirlik, makine öğreniminde daha fazla zemin kazanmaktadır. Bu çalışmada finans sektöründeki finansal araçlar için uygulanabilecek agnostik bir açıklama yöntemi ele alınmıştır. Parametreler arasındaki ilişkiyi anlamak için Borsa İstanbul'a ait olan bir hisse senedinin verileri kullanılarak bu veriler üzerinden çalışma yürütülmüştür. Çalışmanın amacı, parametreler ve sonuçlar arasındaki ilişkinin bulunması ve makine öğrenimi algoritmasını eğitmek için doğru parametrelerin seçilmesi konularında iyi bir karar verilmesine olanak sağlamaktır. Bunun için ilk yapılan adım oryantasyon tablosunun oluşturulmasıdır. Hisse senedi parametreleri bir önceki gün sonundaki değerleri ile karşılaştırılarak yükseliş(+) düşüş(-) yada sabit(0) durumları ile oryantasyon tablosu oluşturulur. Oryantasyon tablosu oluşturulduktan sonra, ikinci olarak parametreler gün sonundaki değer ile karşılaştırılır. Eğer parametre yükselişte ve hisse senedi de gün sonunda yükselişte ise bu doğru orantılı olduklarını göstermektedir. Her ikisi de düşüşte veya sabit ise doğrusallık durumu devam etmektedir. Parametrenin önemi bu doğrusallık ile doğru orantılı olarak artmaktadır. İlk önce tüm parametrelerin tek tek doğrusallık haritası çıkarılır. Bu aşamadan sonra parametrelerin kombinasyonlu doğrusallık oranları belirlenir. En yüksek doğrusallık oranına sahip olan parametre en önemli parametredir. Ancak, %100 yada %0 olan parametrelerin hesaba katılması eğitim setini bozacağı için bu parametreler çıkarılmaktadır. Bunlar ikili parametre kombinasyonu yani parametrelerin her ikisinin birden hisse senedinin gün sonu yükseliş, düşüş ya da sabit kalma gibi durumlar ile tutarlı olması durumudur. İkili parametre doğrusallık oranında en yüksek olan ikinci en önemli değerimizdir. Daha sonrasında bu üçlü durum için de geçerlidir. Bu şekilde en önemli parametre sıralaması bulunur ve algoritmanın doğru bir şekilde eğitilmesine yardımcı olabilecek bir yöntem izlenir.

Kaynakça

Samek, W., Wiegand, T., & Müller, K. R. (2017). Explainable artificial intelligence: Understanding, visualizing and interpreting deep learning models. arXiv preprint arXiv:1708.08296.

- Holzinger, A. (2018). From Machine Learning to Explainable AI, *World Symposium on Digital Intelligence for Systems and Machines, DISA*, 11(2), 55–66. <https://doi.org/10.1109/DISA.2018.8490530>
- Guo, T., Lin, T., & Antulov-Fantulin, N. (2019). Exploring interpretable lstm neural networks over multi-variable data. *International conference on machine learning*, 2494-2504.
- Peng, J., Zou K., Zhou, M., Teng, Y., Zhu, X., Zhang, F. & Xu J. (2021). An Explainable Artificial Intelligence Framework for the Deterioration Risk Prediction of Hepatitis Patients, *Journal of Medical Systems*, 45-61, <https://doi.org/10.1007/s10916-021-01736-5>
- Howard, D. & Edwards, M. A. (2018). Explainable A.I.: The promise of Genetic Programming Multi-run Subtree, Encapsulation *International Conference on Machine Learning and Data Engineering, ICMLDE*, 158–159. <https://doi.org/10.1109/iCMLDE.2018.00037>.
- Pierrard, R., Poli, J. & Hudelot, C. (2018). Learning Fuzzy Relations and Properties for Explainable Artificial Intelligence, *IEEE International Conference on Fuzzy Systems, FUZZ-IEEE*, 1–8. <https://doi.org/10.1109/FUZZ-IEEE.2018.8491538>
- Fernandez A., Herrera, F., Cordon, O., Jesus, M. J. & Marcelloni, F. (2019). Evolutionary Fuzzy Systems for Explainable Artificial Intelligence: Why, When, What for, and Where to?, *IEEE Computational Intelligence Magazine*, 14(1), 69–81. <https://doi.org/10.1109/MCI.2018.2881645>
- Zhou, Z., Sun, M. & Chen, J. (2019). Model-Agnostic Approach for Explaining the Predictions on Clustered Data, *2019 IEEE International Conference on Data Mining, (ICDM)*, 1528–1533. <https://doi.org/10.1109/ICDM.2019.00202>
- Turek, M. (2021), *Defense Advanced Research Projects Agency, (DARPA)*, 11 Augustos 2021 tarihinde <https://www.darpa.mil/program/explainable-artificial-intelligence>
- Zhang Z., Wu, C., Qu, S. & Chen X. (2022). *An explainable artificial intelligence approach for financial distress prediction*, *Information Processing and Management*, 59(4), <https://doi.org/10.1016/j.ipm.2022.102988>.
- Carta S. M., Consoli, S., Piras, L., Podda, A. S. & Recupero, D. R. (2021). *Explainable Machine Learning Exploiting News and Domain-Specific Lexicon for Stock Market Forecasting*, in *IEEE Access*, 9, 30193-30205, <https://doi.org/10.1109/ACCESS.2021.3059960>.