

CDS Primi Tahmini: Türkiye Üzerine Bir Uygulama¹ CDS Spreads Forecast: An Application on Türkiye

Ali Can DEMİREL^a Adalet HAZAR^b Şenol BABUŞÇU^c

^aBaşkent Üniversitesi, Sosyal Bilimler Enstitüsü, Bankacılık ve Finans, Ankara, Türkiye, alcndemirel@gmail.com

^bBaşkent Üniversitesi, Uluslararası Finans ve Bankacılık, Türkiye, ahazar@baskent.edu.tr

^cBaşkent Üniversitesi, Uluslararası Finans ve Bankacılık, Türkiye, babuscu@baskent.edu.tr

MAKALE BİLGİSİ

ÖZET

Anahtar Kelimeler:

Makine Öğrenmesi
Yapay Sinir Ağları
CDS primi

Gönderilme Tarihi 5 Ocak

2023

Revizyon Tarihi 13 Mart 2024

Kabul Tarihi 19 Mart 2024

Makale Kategorisi:

Araştırma Makalesi

Amaç – Bu araştırma, günlük CDS priminin tahmin edilmesi konusunda bir model geliştirmeyi hedeflemiştir. Bu çerçevede çalışmanın amacı yatırım kararları alırken bir gösterge olan CDS priminin tahminine katkı sağlamaktır. Özellikle finansal göstergelerdeki volatilitenin yüksek olduğu Türkiye’de, ekonomik istikrarın belirlenmesinde önemli bir gösterge olan CDS primi, finansal piyasalarda risk algısını yansıtan ve yatırım kararları konusunda gösterge olan bir metrik olarak öne çıkmaktadır.

Yöntem – Çalışmada, makine öğrenmesi disiplininin bir yöntemi olan yapay sinir ağları kullanılmıştır. Yapay sinir ağları ile 3 tahmin modeli oluşturulmuştur.

Bulgular – Çalışma sonucunda tüm modeller düşük ortalama mutlak hata (MAE) oranına sahip başarılı tahmin performansı gösterse de Model 2 en iyi performansı göstermiştir. Ayrıca karmaşıklık matrisi ile makine ezberleme problemi test edilmiştir.

Tartışma – Volatilitenin yüksek olduğu ülkelerde CDS primi tahmininde alternatif bir yöntem kullanılmıştır. Geleneksel finansal modeller genellikle bu tür piyasalarda istikrarlı tahminler sağlamakta zorlanırken, önerilen yöntem, belirsizlik ve dalgalanmanın daha doğru bir şekilde dikkate alınmasını sağlamaktadır. Bu alternatif yöntemin temelinde, volatilitiyi ve risk hareketlerini öğrenebilen algoritmanın çalışmasıdır.

ARTICLE INFO

ABSTRACT

Keywords:

Machine Learning
Artificial Neural Networks
CDS Spread

Received 5 January 2023

Revised 13 March 2024

Accepted 19 March 2024

Article Classification:

Research Article

Purpose – Development of a Model for Predicting Daily CDS Premiums: A Study on the Turkish Financial Market. This research aimed to develop a model for predicting daily Credit Default Swap (CDS) premiums. The primary goal of this study is to contribute to the prediction of CDS premiums, which serve as an indicator when making investment decisions. In the context of Turkey, where financial indicators exhibit high volatility, CDS premiums stand out as a crucial metric reflecting the perception of risk in financial markets and serving as an indicator for investment decisions, contributing significantly to the determination of economic stability.

Design/Methodology/Approach - In this study, artificial neural networks, a method within the discipline of machine learning, have been utilized. Three prediction models have been developed using artificial neural networks.

Findings – Although all models in the study exhibited successful prediction performance with low mean absolute error (MAE) rates, Model 2 demonstrated the best performance. Additionally, the machine memorization problem was tested using a confusion matrix.

Discussion – In countries with high volatility, an alternative method has been developed for predicting CDS premiums. While traditional financial models often struggle to provide stable forecasts in such markets, the proposed method ensures a more accurate consideration of uncertainty and fluctuations. At the core of this alternative approach lies the operation of an algorithm capable of learning volatility and risk movements.


¹“Kırılgan Ekonomilerdeki CDS primi Tahmini” adlı Tez çalışmasından türetilmiştir.

Önerilen Atıf/Suggested Citation

Demirel, A.C., Hazar, A., Babuşçu, Ş. (2024). CDS Primi Tahmini: Türkiye Üzerine Bir Uygulama, *İşletme Araştırmaları Dergisi*, 16 (1), 512-520.

1. Giriş

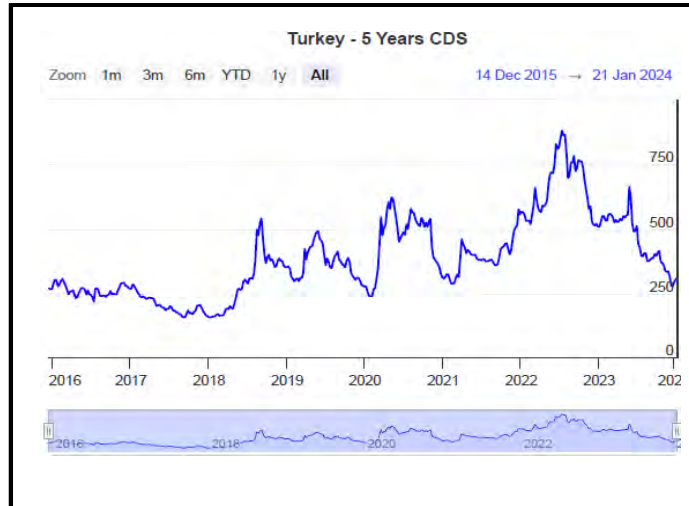
Finansal piyasalarda yaşanan belirsizlikler ve ekonomik dalgalanmalar, ülkelerin ve şirketlerin kredi temerrüt riskini değerlendirmek amacıyla kullanılan finansal göstergelerin önemini artırmıştır. Yatırımcılar, yatırım kararları alırken çeşitli finansal göstergelerden faydalanma eğiliminde bulunmaktadır. 2000' li yılların başlarında kredi temerrüt swapları yeni bir finansal enstrüman olarak kullanılmaya başlamış ve türev piyasalarda işlem hacmi olarak büyüme göstermiştir. Finansal enstrümanların, 2000' li yıllardan bu yana çeşitlenmesi türev ürün hacimlerinin derinleşmesine neden olmuştur. BIS (Uluslararası Ödemeler Bankası) 2021/2 dönem verilerine göre türev piyasaların toplam hacmi 600 trilyon dolar olduğu tahmin edilmektedir. İşlem türlerine göre faiz oranı türev işlemleri ise bu hacmin %81,3'lük (488 trilyon dolarlık) kısmını oluşturmaktadır.



Grafik 1: Kredi Türev Araçları ve Diğer Göstergelerin Yıllar İtibariyle İşlem hacmi Kaynak: BIS,2023

Kredi temerrüt swaplarının önemli bir unsuru olan kredi temerrüt swap primi, bir ülkenin veya kurumun borçlanma maliyetini ve kredi riskini belirlemede kritik bir role sahiptir. CDS primi, piyasa katılımcılarına, ilgili varlıkların veya ülkelerin finansal sağlığı hakkında önemli bilgiler sağlamaktadır. CDS her ne kadar bir türev araç olarak piyasada işlem görse de, CDS primi firmalar ve ülkeler için birer risk göstergesi olarak kullanılmaktadır. Kredi notu göstergelerine kıyasla daha dinamik ve her gün yenilenen değeri ile makroekonomik göstergelerin, ülke veya firmaların yönetim stratejilerinin, CDS primini ne yönde etkileyeceğinin öngörülüyor olması, yatırımcıların ülke riskini doğru şekilde yorumlamasına yardımcı olmaktadır.

Türkiye, gelişmekte olan bir ülke olması sebebiyle CDS priminin varlık sınıfları üzerindeki etkisi, finansal piyasalara doğrudan ve hızlı bir şekilde yansımaktadır. Risk primi ile yakından ilişkili olan tahviller, yatırımcıların risklerini korunma (hedge) için CDS sözleşmelerine yatırım yapabilirler. Risk primlerinin yükselmesi, hisse senedi piyasasında da olumsuz etki yaratabilir. İşletme kredilerindeki etkisi geri ödeme riskinin arttığını ve kredi maliyetlerin artacağı konusunda bilgi verebilir.



Grafik 2: Türkiye'nin Yıllara göre CDS primi Kaynak: World Government Bonds,2024

Son yıllarda Türkiye CDS primleri jeopolitik, ekonomik ve diğer çeşitli sebepler ile volatilitenin yüksek olduğu bir piyasa görünümündedir. Yatırım kararları alınırken CDS priminin dikkate alınması ve öngörülebilmesi proaktif analizlere katkı sağlamaktadır.

Literatür araştırmasında CDS primi tahmini ve makine öğrenmesi yöntemleri ile ele alınan bazı çalışmalar aşağıdaki şekilde sıralanmıştır. İncelenen çalışmalarda makine öğrenmesi yöntemlerinin başarılı performansı ve diğer yöntemler ile karşılaştırılması sonucunda tutarlı sonuçlara varıldığı sergilenmiştir.

Kim (2003), Deneysel hata ve yapısal riskin minimuma indirildiği destek vektör makineleri(SVM) yöntemi ile Güney Kore Bileşik Fiyat Endeksi'nin(KOSPI) günlük fiyat değişim yönünün öngörülmesi hedeflenmiştir. Belirlenen 12 teknik gösterge bağımsız değişken olarak seçilerek eğitim sürecinde kullanılmıştır. Çekirdek parametresi değeri incelenerek SVM tahmin performansının bu parametre değerine duyarlı olduğu sonucuna varılmış ve tahmin modellerinde optimizasyon sürecine vurgu yapılmıştır.

Nakamori ve Wang (2005), Tokyo Menkul Kıymetler Borsası'nda bulunan işlem gören 225 yüksek piyasa değerine sahip hissenin bileşik fiyat performansını ölçen ve Japon endüstrilerinin geniş bir kesimini temsil eden NIKKEI 225 endeksinin haftalık hareket yönü, destek vektör makineleri (SVM) ile kullanılarak tahmin performansı değerlendirilmiştir. Tahmin performansı karşılaştırılması için lineer yöntemler kullanılmıştır. Araştırma sonuçlarında SVM'nin diğer sınıflandırma yöntemlerini geride bıraktığını ve SVM'yi diğer sınıflandırma yöntemleriyle entegre ederek birleştiren bir model önerilmiştir. Bu entegre model en iyi performansı sergilemiştir.

Avino ve Nneji (2014), 2007'nin ortalarında başlayan finansal kriz döneminde iTraxx Europe endeksi üzerinde hem doğrusal hem de doğrusal olmayan modellerin CDS primlerini tahmin etme performansını araştırmaktadır. iTraxx Europe endeksinden günlük CDS primlerini alınırken daha likit olması sebebiyle 5 yıl vadeli CDS primleri kullanılmıştır. 2005-2010 yılları arasında 1235 değişken ile gelişmiş ekonometrik modeller uygulanmıştır. CDS primi tahmininde, ticaret stratejilerinin kullanıldığı ilk araştırmadır.

Li ve Tam (2017), destek vektör makineleri (SVM) ve uzun-kısa vadeli bellek (LSTM) modelleri kullanılarak farklı volatilitelere sahip hisse senetlerinin fiyat tahmin performansı ölçülmüştür. Shanghai Borsası'nda listelenen en büyük hacimli 50 firmanın endeksi olan SSE 50 endeksinin verileri kullanılmıştır. SVM modeli düşük volatilitelere sahip firmaların hisse senedi fiyat tahmininde başarılı olmuştur. LSTM modeli ise yüksek volatilitelere sahip hisse senedi fiyat tahmininde, düşük volatilitelere sahip firmalara göre daha yüksek bir tahmin performansı sergilemiştir.

Zhang (2018), Amerika'ya yerleşik ve verilerin bulunabilirliğine göre seçilen 17 şirketin 2010-2017 yılları arasında bulunan günlük 5 yıl vadeli CDS primleri ile veri seti oluşturulmuştur. 5 yıllık CDS sözleşmelerinin alım-satım amaçlı daha fazla kullanılmasından dolayı daha likit bir varlık olduğu vurgulanmıştır. Destek vektör makineleri yöntemi kullanılarak 4 model oluşturuldu (Naive, Base, New ve Combo). 5 günlük tahmin performansında "Combo" modelin daha yüksek performans gösterdiği gözlemlenmiştir. Hisse senedi getirileri, örtük oynaklık değişiklikleri ve tarihsel CDS zaman serisini içeren bir bileşik veri seti kullanarak bir destek vektör regresyonu ile başarılı gerçekleştiren bir model olduğunu öne sürülmüştür.

Kim vd.(2020), veri işleme grup yöntemi (GMDH) kullanılarak CDS primi tahmin edilmiştir. Bu analiz, 2008 ile 2019 yılları arasındaki CDS vadeli yapı verileri üzerinden gerçekleştirilmiş olup, modellerin tahmin performansındaki değişimi değerlendirmek amacıyla bir alt dönem analizi uygulanmıştır. Alt dönem analizi, bir önceki dönem verileri üzerinden modellerin eğitildiği bir yöntemdir. Çalışma, 2008-2019 dönemini ve altı ay ile 1, 2, 3, 4, 5, 7, 10, 20 ve 30 yıl vadelerini kapsamaktadır. CDS primlerinin günlük kapanış fiyatları, makine öğrenme sürecinde kullanılmıştır. Elde edilen sonuçlara göre, SVR, RNN, LSTM ve GMDH gibi makine öğrenme yöntemleri, CDS primi tahmininde Nelson-Siegel modeline göre daha üstün bir performans sergilemiştir. Bu çalışma, gelecekteki risk tahmin etmek için etkili bir yöntem sunmaktadır. Yapılan analizler, makine öğrenme modellerinin, özellikle CDS primi tahmininde, geleneksel Nelson-Siegel modeline kıyasla daha güvenilir sonuçlar elde ettiğini göstermektedir.

Lei (2020), gelecekteki CDS primlerini tahmin etme sürecinde derin öğrenme metotları ile mevcut tahmin modellerinin performansı karşılaştırılmıştır. RNN (Recurrent Neural Network) ve LSTM (Long Short-Term Memory) yöntemlerinde bulunan dikkat mekanizması, modelin potansiyel piyasa dalgalanmasını beklenenden daha kararlı şekilde takip etmesini sağlamıştır. Amerika' da bulunan 125 firmanın, 5 yıllık CDS

primleri verileri kullanılarak toplam 2283 değişkenin %15'i test veri setinde eğitilmiştir. RNN tabanlı modeller ile oluşan sonuçlar diğer mevcut modellere göre artan bir tahmin performansı göstermiştir..

Kutuk ve Barokas (2021), Meksika, Endonezya ve Türkiye' nin günlük CDS primleri, bir derin öğrenme disiplini olan uzun-kısa vadeli bellek (LSTM) mimarisinde tahmin edilmiştir. Covid-19 etkisini önlemek amacıyla 2012-2019 verileri kullanılmıştır. Meksika modelinde en düşük ortalama mutlak hata (MAE) ve Ortalama hata karesi (MSE) değerlerine ulaşılmıştır. Alternatif kullanılan NARX modeli ise Türkiye ve Endonezya için daha iyi performans göstermiştir.

Vukovic vd (2022), Amerika' da bulunan 513 şirketin 2009-2020 yılları arasında günlük CDS primi verileri kullanılarak Covid-19 öncesi ve sırasında piyasa etkinliğinde değişiklik olup olmadığı test edilmiştir. Destek vektör makineleri (SVM), Veri İşleme Grup Yöntemi (GMDH), ve Markov geçişli otoregresyon (MSA) ile tahmin performanları araştırılmıştır. Daha önce yapılan çalışmalarda GMDH, SVM ve LSTM yöntemlerinin tahmin performansının kanıtlandığı fakat MSA yöntemi ile kıyaslanmadığı tartışılmış ve MSA yönteminin bu çalışma için diğer yöntemlerden daha iyi sonuç verdiği gözlemlenmiştir. Araştırmada kullanılan tüm makine öğrenmesi yöntemlerinin Covid-19 sırasında düşük performans gösterdiği fakat Covid-19 öncesinde daha yüksek performans gösterdiği sonucuna varılmıştır.

2. Yöntem

Türkiye'nin günlük CDS prim değerleri verileri Bloomberg L.P. terminalinden sağlanmıştır. 04.01.2008 ve 01.04.2022 tarih aralığından aktarılan ham veride kapanış değerleri dikkate alınmıştır. Kapanış değerleri bir sonraki günün CDS primi olarak kabul edilmiştir. Toplam 3.699 veriden oluşmaktadır. CDS primlerinin vade yapıları 1,2,3,4,5,7 ve 10 yıl vadeli. Çalışmada baz aldığımız vade yapısı 5 yıllıktır. Bunun nedeni ise diğer vade yapılarına göre Yurtdışında 5 yıl vadeli CDS primi kullanılmıştır. Bunun nedeni diğer vade yapılarına göre daha likit olmasıdır (Hull ve White, 2000).

Çalışmada kullanılan tahmin yöntemimiz makine öğrenmesi disipliniinde kullanılan ileri beslemeli yapay sinir ağları (Feedforward Artificial Neural Networks) yöntemidir. Eğitim için veri ayrılması, ağırlıklar ile çarpımı ve aktivasyon sürecinin uygulanması süreci aşağıdaki gibidir.

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

$$f(x) = \frac{1}{1+e^{-x}} \quad (2)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (3)$$

- (1) Yapay eğitiminde, veri kümesinde eğitim veri kümesi sinir ağlarının olarak ayrılan küme, tasarlanan yapay sinir ağına girdi olarak verilir. İleri besleme aşamasında ilgili ağırlıklar(w_i) ile veriler(x_i) çarpılır, bias parametresiyle(b) toplanır aktivasyon fonksiyonu uygulanır son olarak sinir ağının sonunda çıktı elde edilir(y). Verilerin gerçek etiketleriyle yapay sinir ağının çıktısı karşılaştırılarak hata değeri belirlenir. Ortaya çıkan hata değerine göre ilgili ağırlıklar güncellenir(w_i).
- (2) Model eğitiminde aktivasyon fonksiyonu olarak sigmoid fonksiyonu($f(x)$) kullanılmıştır. Yapay sinir hücresinin çıktısı, aktivasyon fonksiyonu kullanılarak hesaplanan çıktı değeridir. Üretilen çıktı dış düzleme veya diğer bir hücreye gönderilir. Bunun yanında hücre, kendi çıktısını girdi olarak da gönderebilir. Sigmoid Fonksiyonu türevi alınabilir, sürekli ve doğrusal olmayan bir fonksiyon olması sebebiyle doğrusal olmayan problemlerin çözümünde kullanılabilir.
- (3) Hata fonksiyonlarında ise ortalama hataların karesi metodu kullanılmıştır(MSE).

Kullanılan yöntem Pycharm Community Edition 2022.3.1 ve Weka 3.8.4 programlarıyla çalıştırılmıştır. Yapay Sinir ağları modelinin Weka programında kullanılması işlem dosyası problemine yol açmıştır. Temel problem CSV dosyalarının ARFF dosyasına dönüşümüdür. Pycharm programı ile aşağıdaki adımlar izlenerek ARFF problemi çözülmüştür.

- CSV dosyasının adı girilir.
- CSV dosyasını açan komut çalıştırılır.
- CSV dosyasında bulunan satırları okur ve listeye aktarılır.

- Açılan dosya kapatılır.
- Açılış değerlerinin kopyalanacağı liste oluşturulur.
- CSV dosyasından okunan ve listeye dönüştürülen satırları okuyarak açılış değerleri alınır ve açılış isimli listeye kaydedilir.
- ARFF dosyası bu isimle açılır.
- Dosya ARFF dosyasının içine zorunlu ilk satır olan başlığı belli eden satır eklenir.
- Girilen gün sayısı kadar ARFF dosyasına aktarılır.
- İstenilen gün sayısı olan sınıf değeri ARFF dosyasında belirtilir
- ARFF dosyasına "@data" satırı eklenir.
- CSV dosyasından okunan açılış değerlerini gün sayısına göre arff dosyasına kod bloğu yazar.

Veri işleme süreci bittikten sonra tahmin uygulamasına geçilmiştir.


3. Bulgular

Eğitim sürecinde 3 farklı model test edilmiştir. Çalışmanın amacı tahmin başarısını optimize etmektir. Model 1 (3+1), tüm veri dizisi için ilk 3 günü eğiterek 4. günü tahmin etmektedir. Model 2 (7+1), tüm veri dizisi için ilk 7 günü eğiterek 8. günü tahmin etmektedir. Model 3 (14+1) ise tüm veri dizisi için ilk 14 günü eğiterek 15. günü tahmin etmektedir. Eğitime alınan gün sayıları (3,7 ve 14) önceden test edilerek en yüksek tahmin başarısını gösterdiği için kullanılmıştır.

Tablo 1: Model Sonuçları


Model	Correlation Coefficient	Mean Absolute Error
3+1	0.9947	9.4398
7+1	0.9914	9.0364
14+1	0.9893	10.3343

Tablo 1'de gösterildiği gibi, oluşturulan üç modelin sonuçları birbirine oldukça yakın ve tutarlıdır.




Şekil 1: Model 1, Yapay Sinir Ağı Mimarisi

Model 1'in yapay sinir ağı mimarisi, 1 katman üzerinde 2 nöron ile işleme alınmıştır. Katman ve nöron sayısı değiştirilerek başarı performansı arttırılmak istenmiş fakat en iyi sonuç bu yapıda gözlemlenmiştir. Model 1, tek katman ve 2 nöron ile çalıştırılmıştır. Nöron sayılarında ve katman sayılarında değişim (+ ve -) makinenin ezberleme oranını arttırmıştır. Ezberleme süreci, karmaşıklık matrisi ile test edilmiştir. Tahminlerin doğruluğu hakkında bilgi vermek için karmaşıklık matrisi sık kullanılan bir yöntemdir. Matriste bulunan, gerçek pozitifler, gerçek değeri 1 ve tahmin ettiğimiz değerin de 1 olduğu örneklerdir. Gerçek negatifler, gerçek değeri 0 ve tahmin ettiğimiz değerin de 0 olduğu örneklerdir. Yanlış pozitifler, gerçek değeri 0 ancak tahmin edilen değerin 1 olduğu örneklerdir. Yanlış negatifler ise gerçek değeri 1 ancak tahmin edilen değerin 0 olduğu örneklerdir. Model 1' de doğru pozitif oranı 43, yanlış pozitif oranı 26, yanlış negatif değeri 14 ve doğru negatif değeri 15 performans göstermiştir.



Şekil 2: Model 2, Yapay Sinir Ağı Mimarisi

Model 2'in yapay sinir ağı mimarisi, 1 katman üzerinde 4 nöron ile işleme alınmıştır. Katman ve nöron sayısı değiştirilerek başarı performansı arttırılmak istenmiş fakat karmaşıklık matrisi sonuçları makine öğrenmesinin ezberleme sürecine girdiği görülmüştür. Model 2' de doğru pozitif oranı 42, yanlış pozitif oranı 25, yanlış negatif değeri 16 ve doğru negatif değeri 16 performans göstermiştir.



Şekil 3: Model 3, Yapay Sinir Ağı Mimarisi

Model 3'in yapay sinir ağı mimarisi, 1 katman üzerinde 4 nöron ile işleme alınmıştır. Katman ve nöron sayısı değiştirilerek başarı performansı arttırılmak istenmiş fakat en iyi sonuç bu yapıda gözlemlenmiştir. Model 3' de doğru pozitif oranı 39 yanlış pozitif oranı 42, yanlış negatif değeri 15 ve doğru negatif değeri 12 performans göstermiştir.

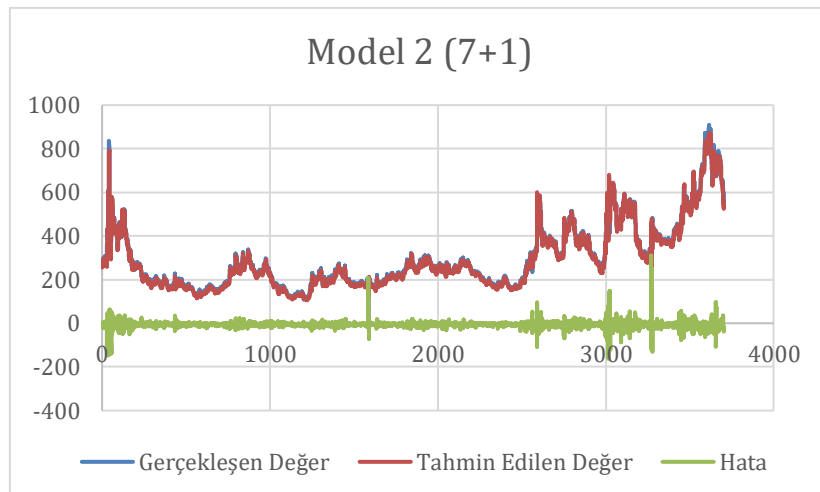

Oluşturulan modeller arasında en düşük ortalama mutlak değer hata değerini (MAE) Model 2 göstermiştir(9.0364). Fakat diğer modellerin tahmin başarısı önemsenerek düzeydedir. 3 modelde bağımsız değişkenler X,Y ve Z olarak adlandırılmıştır.


Tahmin performanslarında mutlak değer hata değerlerinin (MAE) düşük çıkması modelin başarılı olduğunu göstermiştir. Fakat başarı değeri tüm verilerin ortalaması alınarak bulunan bir sonuçtur. Veri içerisinde anomali günleri, ortalama başarı değeri içerisinde dikkat çekmeyebilir. Bu sebep ile anomali olan günlerde yoğunlaşma olup olmadığı konusunda test yapılmasına ihtiyaç duyulmuştur. Sapma gününün sadece finansal piyasalarda değil politik, hukuk ve yönetim gibi konuları özellikle kapsamaları istenmiştir. CDS finansal göstergeler dışında kantitatif olmayan yönetim, hukuk gibi alanlardan da etkilenmektedir. Bu sebep ile 15 Temmuz 2016 tarihi test edilmiş ve incelenmiştir.

Tablo 2: Model 3, Gerçekleşen ve Tahmin Değerleri

Sıra Num	Gerçekleşe	Tahmin Edile	Hata	Sıra Num	Gerçekleşe	Tahmin Edile	Hata
2012	264.450	253.467	-10.983	2032	239.140	242.023	2.883
2013	267.260	252.381	-14.879	2033	239.600	232.915	-6.685
2014	260.870	254.137	-6.733	2034	247.000	226.283	-20.717
2015	255.050	250.614	-4.436	2035	235.110	230.720	-4.390
2016	255.050	245.073	-9.977	2036	240.380	224.861	-15.519
2017	241.560	242.953	1.393	2037	241.450	226.121	-15.329
2018	237.670	232.926	-4.744	2038	233.180	226.830	-6.350
2019	237.670	227.257	-10.413	2039	227.880	222.054	-5.826
2020	252.170	224.208	-27.962	2040	217.720	218.588	0.868
2021	265.730	233.607	-32.123	2041	217.600	207.860	-9.740
2022	263.480	248.994	-14.486	2042	220.440	203.952	-16.488
2023	266.720	250.913	-15.807	2043	220.440	205.353	-15.087
2024	260.350	254.410	-5.940	2044	220.140	205.157	-14.983
2025	247.450	250.313	2.863	2045	245.940	207.000	-38.940
2026	246.900	238.881	-8.019	2046	265.680	224.976	-40.704
2027	241.550	233.858	-7.692	2047	281.010	245.614	-35.396
2028	242.170	226.843	-15.327	2048	281.010	264.093	-16.917
2029	256.840	227.540	-29.300	2049	281.010	269.161	-11.849
2030	259.640	239.835	-19.805	2050	268.420	268.966	0.546
2031	251.170	244.213	-6.957	2051	268.420	258.257	-10.163

Tablo 2’de baz alınan anomali günü Model 3’ te test edilmiştir. Model 3’ de test edilme nedeni başarı performansının en düşük çıkan model olmasıdır. Böylece algoritmanın optimizasyon uygulaması olmadan da gerçek değere yakınlığı gösterilmek istenmiştir. Bu test için eğitim amaçlı Pycharm programı aracılığıyla uygulanan veri işleme adımları tekrar çalıştırılmıştır. Daha sonra diğer modeller için bu süreç tekrarlanmıştır.





Grafik 3: Oluşturulan Model 1, Model 2, Model 3 Tahmin Edilen ve Gerçekleşen Değer Karşılaştırılması

Türkiye için oluşturulan 3 modelin Grafik 3'te gerçekleşen ve tahmin edilen değerleri alınarak aynı düzlemde gösterilmiştir. Grafikte gerçekleşen ve tahmin eğrilerinin birbirine çok yakın olduğu çoğu değer üzerinde üst üste geldiği görülmektedir.

4. Sonuç ve Tartışma

CDS primleri finansal piyasalarda risk algısını, ekonomik istikrarı ve yatırımcı güvenini gösteren önemli bir gösterge olarak kabul edilmektedir. Bu nedenle, yatırımcılar, risk analistleri ve kurumsal finansçılar genellikle CDS primlerini, yatırım öngörülerini için takip etmektedirler.

Bu çalışma günlük CDS primlerinin tahmin edilmesine, makine öğrenmesi disiplini içinde kullanılan yapay sinir ağları yöntemi kullanılarak başarılı tahmin performansları ortaya konulmaya çalışılmıştır.

Daha önce gerçekleştirilen araştırmalarda, ekonometrik modeller ve makine öğrenmesi yöntemleri arasındaki ilişki, firma bazında CDS primi tahminleri, makroekonomik verilerin CDS primini öngörmesi ve kredi derecelendirme notları ile CDS primi arasındaki ilişki gibi konular üzerine çeşitli çalışmalar yürütülmüştür. Bu çalışma, diğer araştırmalardan farklı olarak, ekonomik açıdan volatilitenin yüksek olduğu bir ülkede günlük CDS priminin tahmin edilmesinde kullanılan makine öğrenmesi yöntemine dayanan bir modelin oluşturulmasıyla öne çıkmaktadır. Bu sayede, modelin gücü, volatil piyasa koşullarında günlük CDS priminin etkili bir şekilde tahmin edilmesi yoluyla belirginleştirilmiştir.

Kim vd.(2020), çalışmasında CDS primi tahmini için geleneksel ve makine öğrenmesi yöntemleri kullanıp bu modelleri karşılaştırmıştır. Sonuç olarak makine öğrenmesi metotlarının verinin yoğun olduğu piyasalarda geleneksel yöntemlere karşın daha başarılı olduğunu ifade etmiştir. Çalışmamızda elde edilen bulguların, özellikle Türkiye gibi CDS priminin oynaklık seviyesinin yüksek olduğu bir piyasada başarılı sonuç vermesi modelin etkili tahmin yapma yeteneğini ortaya koymaktadır. Oluşturulan 3 modelin birbirine yakın ortalama mutlak hata (MAE) değerlerinin olması tutarlı bir algoritma oluşturduğumuzu göstermiştir.

Çalışmamızın amacı yatırımcılara ve finans profesyonellerine gelecekteki CDS prim değerini ve hareketleri konusunda bilgi sağlamaktır. Modelin tahmin yeteneği finansal planlamalarda ve risk yönetiminde etkin bir strateji oluşturulmasına katkıda bulunabilir. Fakat çalışmanın seçilen ülke kapsamında, bu alanda kullanılan yöntemlerin diğer ülkeler için test edilmesi bulguların genellenebilirliği ve model güveninin artması konusunda bir anlayış sağlayabilir. Sonuç olarak yapılan araştırmada CDS primi volatilitenin yüksek olduğu ve gelişmekte olan bir ülkenin verileri ile makine öğrenmesi disiplini kullanılarak tahmin etme yeteneği konusundaki başarıya dikkat çekmek istenmiştir. İleride yapılacak araştırmalarda farklı ülkeler modele dahil edilerek katkı sağlanabilir.

KAYNAKLAR

- Avino D., Nneji O. (2014). Are CDS spreads predictable? An analysis of linear and non-linear forecasting models, *International Review of Financial Analysis*, 34, 262-274.
- Chan, K.F., Marsden, A., (2014). Macro Risk Factors of Credit Default Swap Indices in a Regime-switching Framework, *International Financial Markets, Institutions and Money*, 29, 285-308.
- Diebold, F.X., Li C. (2006). Forecasting the term structure of government bond yields. *Journal of Econometrics*, 130, 337-364.
- Ferreira, M.A., Santa-Clara, P. (2011). Forecasting Stock Market Returns: The sum of the parts is more than the whole. *Journal of Financial Economics*, 100, 514-537.
- Huang W, Nakamori Y. ve Wang S.Y. (2005). Forecasting stock market movement direction with support vector machine. *Computers & operations research*, 32.10 (2005): 2513-2522.
- Hull, J. ve White A., (2000). Valuing Credit Default Swaps I: No Counterparty Default Risk. *Journal of Derivatives*, 8(1), 29-40.
- Kim K.J. (2003). Financial Time Series Forecasting Using Support Vector Machines, *Neurocomputing*, 55 (1), 307-319, ISSN 0925-2312, [https://doi.org/10.1016/S0925-2312\(03\)00372-2](https://doi.org/10.1016/S0925-2312(03)00372-2)
- Kim W.J, Jung G. ve Choi S.Y. (2020). Forecasting CDS Term Structure Based on Nelson-Siegel Model and Machine Learning. *Hindawi Complexity Article*, 2518283, 1-23. <https://doi.org/10.1155/2020/2518283>
- Kutuk, Y., Barokas, L. (2021). Multivariate CDS risk premium prediction with SOTA RNNs on MI[N]T countries. *Finance Research Letters*, 45, 102198.
- Lei W (2020)., Predicting CDS spreads with Deep Learning Architecture. An Application of Time- Series Forecasting, Stanford University fall projects, 1-11 http://cs230.stanford.edu/projects_fall_2020/reports/57222277.pdf
- Li Z., Tam V. (2017). A comparative study of a recurrent neural network and support vector machine for predicting price movements of stocks of different volatilities. *IEEE Symposium Series on Computational Intelligence (SSCI)*, Honolulu, HI, USA, 1-8, doi: 10.1109/SSCI.2017.8285319.
- Vukovic D.B., Romanyuk K., Ivashchenko S. ve Grigorieva E.M.(2022). Are CDS spreads predictable during the Covid-19 pandemic? Forecasting based on SVM, GMDH, LSTM and Markov switching autoregression. *Expert Systems Applications*, (194(15): 116553, doi: 10.1016/j.eswa.2022.116553
- Zhang T.Y. (2018). Predicting Credit Default Swap (CDS) Returns with Machine Learning. *Journal of Undergraduate Research*, 20(1), 1-15, <http://dx.doi.org/10.2139/ssrn.3152143>
<https://www.worldgovernmentbonds.com/cds-historical-data/turkey/5-years/>
https://www.bis.org/statistics/about_derivatives_stats.htm?m=200