

Kripto Para Değerlerine Dayanılarak BİST 100 Endeks Hareketi Tahmininde Destek Vektör Makineleri Uygulaması

Ali Can DEMİREL

Başkent Üniversitesi, Doktora Öğrencisi, Ankara, Türkiye
alcdemirel@gmail.com

Adalet HAZAR

Başkent Üniversitesi, Ticari Bilimler Fakültesi, Ankara, Türkiye
ahazar@baskent.edu.tr

Kabul Edilme Tarihi:
27.03.2021

Özet

Teknoloji gelişiminin hız kazanmasıyla sanal para birimleri takas işlemlerinde kullanılmaya başlamıştır. Yaklaşık on beş yıldır kullanımda olan kripto paralar, üçüncü taraflara olan ihtiyacı ortadan kaldıran blockchain teknolojisinin merkezileşmemiş sistemi sayesinde piyasada yeni bir yer yaratmıştır. Bir taraftan yüksek kazanç sağlamak isteyen yatırımcılar için çok cazipken, diğer taraftan fiyatlarındaki dalgalanmalar çok yüksektir. Bu nedenle riskli yatırım araçları olarak değerlendirilmektedir. Yatırımcılar piyasayı etkileyebilecek her faktörü risk unsuru olarak görebilmektedir. Dijital dönüşümün yaşandığı dünyamızda, Kripto paraların piyasa hareketlerinin, çeşitli ekonomik dengeleri etkileyeceği düşünülebilmektedir. Yatırımcılar bu belirsizliği aşmak için çeşitli tahmin yöntemlerine ihtiyaç duyabilirler. Bu çalışmada, yüksek piyasa değerine ve bunun yanında yüksek işlem hacmine sahip olan kripto para birimlerinin 2016-2020 yılları arası günlük piyasa değerleri alınarak, BIST 100 endeksinin hareket yönleri tahmin edilmiştir. Çalışmada girdi değişkeni olarak kabul edilen Bitcoin, Ethereum ve Ripple geçmiş piyasa değerleri destek vektör makinelerinin eğitiminde kullanılmıştır. Özellikle kripto paraların yaygınlaşması finans sistemlerinin bakış açısını değiştirmiştir. Çalışma sonucunda % 52 doğruluk başarıları elde edilmiştir.

Anahtar Kelimeler: Destek Vektör Makineleri, Makine Öğrenmesi, Kripto Para.

Support Vector Machines Application to Estimate BİST 100 Index Based on Cryptocurrency Values

Abstract

With the acceleration of development in the technology, crypto currencies have started to be used in transactions. Cryptocurrencies that have been in use for nearly eleven years have created a new area in the market thanks to the decentralized system of blockchain technology, which eliminates the need for third parties. It is very attractive for investors who want to make high profits, on the other hand, volatilities in prices are very dramatic. For this reason, it is considered as risky investment tools. Investors can utilize anything that may affect the market as a risk factor. In our world of digital transformation, it can be thought that the market movements of cryptocurrencies will affect various economic balances. Investors may need various forecasting methods to overcome this uncertainty. In this study, the movement of the BIST 100 index is estimated based on the daily market values of Bitcoin (BTC), ethereum (ETH) and Ripple (XRP) cryptocurrencies with high market value as well as high transaction volume. The past market values of Bitcoin, Ethereum and Ripple, which are accepted as input variables in the study, were used in the training of support vector machines. In particular, the widespread use of cryptographic money has changed the perspective of financial systems.

Keywords: Support Vector Machine, Machine Learning, Crypto Money.



1. Giriş

Finans alanında, çeşitli enstrümanlar ve piyasalar için geleceğe yönelik bilgilerinin tahmin edilebilmesi, yatırımcılar için dikkat edilmesi gereken bir konudur. Yatırımcılar oynaklığın yüksek olduğu pazarlarda, yüksek getiri sağlamak isteyebilmektedir. Fakat bu belirsizlik için en azından bazı göstergeleri öngörebilmek gerekmektedir. Yatırımların artması özellikle gelişmekte olan ülkeler için yabancı piyasalar arasında rekabet avantajı sağlamaktadır. Borsa endeksleri hisselerdeki fiyat hareketlerinden yola çıkılarak borsanın genel trendlerinin belirlenmesinde kullanılır.

Türk borsasında yer alan BIST 100 endeksi, yatırımcıların alım-satım işlemleri öncesinde takip ettikleri önemli endekslerden biridir. Bu sebeple yatırımcılar tarafından borsanın düşme ve yükselme yönleri BIST 100 endeksinde dikkate alınır. Yatırımcıların sermaye piyasasında beklentilerini şekillendirmek için birçok faktör bulunmaktadır. Son dönemlerde finansal piyasalarda alternatif yatırım aracı olarak kullanılan kripto paralar bu faktörlerden biridir. Yaklaşık on beş yıllık geçmişi olan güvenli işlem yapmaya ve sanal para arzına olanak sağlayan dijital ve alternatif para birimleridir. Herhangi bir devlet ya da merkezi otorite tarafından denetlenmemesi önemli niteliklerindedir. Berg ve diğerleri, (2017) enerjiye dayalı ve iktisadi değer taşıyan kripto para birimlerini endüstriyelleşme akımı olarak görmektedir. Merkez Bankaları'nın kendi dijital para üretimi çalışmaları çoğu ülkede uygulanmaktadır (Çin, Kanada, İsviçre). Para arzı tanımlarının ileriki dönemlerde değişeceği düşünülmektedir. Alternatif bir yatırım aracı olan kripto paralar yatırımcıların portföylerinde yerini almaya devam edecektir. Kripto paraların piyasa hareketlerinin, çeşitli ekonomik dengeleri etkileyeceği düşünülmektedir. Yatırımcılar bu belirsizliği aşmak için çeşitli tahmin yöntemlerine ihtiyaç duyabilirler. Bu çalışmada, yüksek piyasa değerine ve bunun yanında yüksek işlem hacmine sahip olan Bitcoin (BTC), ethereum (ETH) ve Ripple (XRP) kripto para birimlerinin 2016-2020 yılları arası günlük piyasa değerleri alınarak, BIST 100 endeksinin hareket yönleri tahmin edilmiştir. Çalışmada girdi değişkeni olarak kabul edilen Bitcoin, Ethereum ve Ripple'in geçmiş piyasa değerleri destek vektör makinelerinin eğitiminde kullanılmıştır.

2. Literatür

Literatür incelendiğinde, makine öğrenme yöntemleri kullanılarak, hisse senetleri getirileri tahminleri ve endeks tahminleri yapılan çalışmalar yabancı ve yerli literatür de bulunmaktadır.

Kryzanowski ve diğerleri (1993) seçtikleri şirketlerin mali performans oranlarını öğrenme sürecinde kullanarak, hisse getirilerinin artış ve azalış yönlerini öngörmeye çalışmıştır. Çalışmada kullanılan model ile %72 oranında başarı oranı elde edilmiştir.

İstanbul Menkul Kıymetler Borsası 100 endeksinin, bir sonraki gün artış ve azalış yönlerini, tahmin etmek amacıyla Diler (2003), toplamda 16 farklı model oluşturmuştur. En yüksek başarı oranı %60,81

olarak ortaya konulmuştur. S&P endeksinin günlük hareketlerini eğiten Zhang ve Wu (2009) çalışmalarında, yapay sinir ağıları metodu ile farklı modeller oluşturarak yöntemin başarısını göstermişlerdir.

Amerikan Borsasında yer alan, NASDAQ endeksinin günlük hareketlerini inceleyen Moghaddam ve diğerleri (2016) çalışmalarında endeksin son 29 günlük hareketini tahmin etmişlerdir.

Özçalıcı (2016), BİST 30 endeksinde yer alan hisse senetlerinin fiyatlarını 20 gün önceden %72,88'e varan başarı oranıyla tahmin edebilmiştir. Özellikle orta dönemli fiyatlamalarda potansiyelin fazla olduğu ve tahminlerin derinleşmesinin önemli olduğuna dikkat çekmiştir.

Kutlu ve Bodur (2009) yapay sinir ağıları metodu ile 3 farklı model oluşturarak, ileri besleme tabanlı yöntemle İMKB 100 endeksi günlük hareketlerini başarılı şekilde tahmin etmişlerdir.

Liu ve Wang (2012) Şangay borsasının endeks kapanış göstergelerini tahmin etmek amacıyla 3 katmanlı ileri beslemesi yapay sinir ağı mimarisi oluşturmuştur. Farklı örneklemeler alınarak tahminlerin duyarlılığı ölçülmüştür.

Selvamuthu ve diğerleri (2019) Hindistan firmalarının, hisse senedi getiri tahminlerini, 3 farklı algoritma kullanarak, %96 üzerinde doğruluk oranı sonucuyla ortaya koymuşlardır.

Yakut ve diğerleri (2014) BİST endeksinin geçmiş verilerini kullanarak yapay sinir ağı ve destek vektör makineleri metodları ile ileri beslemeli modeller oluşturmuştur. Modellerin, borsa endeks hareketleri tahminleri başarılı sonuçlar vermiştir.

BİST 30 endeksinde yer alan firmaların getirililerini öngörmeye çalışan Çalışkan ve Deniz (2015) çalışmalarının, fiyat yönleri başarısı %58 başarılı olarak gözlemlenmiştir. Bu çalışmada diğer çalışmalardan farklı olarak tahmin edilmek istenen günlük borsa değer değişimleri, kripto para birimlerinin artış azalış yönlerinden tahmin edilmeye çalışılmıştır.

3. Araştırma Yöntemi

Destek vektör makineleri, makine öğrenme disiplininin konularından olan bir öğrenme algoritmasıdır. Bu algoritmalar, genellikle belirli bir görev için geçmiş tecrübeleri kullanarak görevin başarısını yükseltmeyi amaçlayan, sınıflandırma problemlerinin çözümünde kullanılmaktadır. Boyut sayısının, örneklem sayısından fazla olduğu durumlarda farklı çekirdek fonksiyonları kullanılarak karar fonksiyonları oluşturulabilir. Sınıflandırma işlemi için iki ögeyi birbirinden ayıran bir hiper düzlem oluşturulur. Oluşturulan hiper düzlem istatistiksel öğrenme teorisini uygulayarak çalıştırır. Destek vektör makinelerinin görevi doğrusal olarak birbirinden ayrılabilen veri kümesini ayıran en uygun hiper düzlemi bulmaktır. Bazı problemler doğrusal olarak ayrılabilen noktalardan oluşmaktadır. Destek vektör makineleri metodu veri kümesindeki örüntüleri yeni bir uzaya geçirerek bu uzayda bir hiper düzlem aramaktır. En uygun düzlemi bulana kadar işlem devam

etmektedir. Borsa endeksleri volatilité ile birlikte birçok mikro ve makro deęişkenlerden etkilenebilir. Böyle piyasalarda tahmin yaparken doğrusal ve doğrusal olmayan düzlemde yöntemi belirlemek doğruluk oranı için önem arz eder. Sınıflandırma problemlerinde doğrusal olmayan düzlemde Destek vektör makineleri yönteminin kullanımı kolay ve yüksek başarı göstermektedir (Hajek, 2013).

$$w \cdot x + b = 0 \quad (1)$$

$$f(x) = \sum_{j=1}^n w_j \cdot x_j + b \quad (2)$$

Denklem 1’de w ağırlık vektörü, b ise sabit bir sayıyı ifade etmektedir. Sınıfı belirsiz bir nokta olarak x kullanılmaktadır. Birbirinden doğrusal olarak ayrılabilen verilerin karar fonksiyonu yine Denklem 2’de verilmiştir. Fonksiyona göre $f(x) \geq 0$ için bir sınıfa $f(x) < 0$ için ise dięer sınıfa ait olacaktır.

Destek Vektör Makineleri yöntemi, doğrusal olarak ayrılan veri kümeleri için optimal hiper düzlemi bulabilirler. Fakat doğrusal olarak ayrılamayan veri kümeleri için Denklem 4’te gösterilen çekirdek fonksiyonu ile Denklem 3 güncellenebilir.

Çekirdek fonksiyonların amacı doğrusal olarak ayrılamayan veri kümelerini bulunduğu uzaydan doğrusal olarak ayrılabilen daha büyük boyutlu uzaylara taşımaktır. Veri setinin belirli bir hata ile doğrusal olarak ayrılma durumu, veri setinin parazitli veri içermesi, çok boyutlu olması veya karmaşık yapısından kaynaklanmaktadır. Belirli bir hata ile doğrusal ayrılma durumunda iki sınıflı veri setini ayırmak için gevşek sınır yaklaşımı kullanılmaktadır. Yanlış sınıflandırma olasılığını düşürmek için doğrusal ayrılma durumundaki dönüşümler yapılarak problem, Denklem 4’teki gibi optimizasyon problemine dönüşür. Modeldeki C katsayısı, Lagrange çarpanının alabileceęi üst sınır deęerini gösteren ceza parametresini ifade etmektedir. Lagrange çarpanı, C ceza parametresine eşit olması durumunda, destek vektörleri ayırma hiper düzlemi üzerinde yer almaktadır. Çekirdek fonksiyon ile güncellenmiş karar fonksiyonu aşağıdaki gibidir.

$$\text{Min } \frac{1}{2} (W)^2 + C \sum_{i=1}^n \vartheta_i \quad (3)$$

$$f(x) = \sum_{j=1}^n w_j \cdot x_j \cdot K(x_i, x) + b \quad (4)$$

Çalışmada ağırlık deęerlerinin saptanması için 2016-2020 Bitcoin (BTC), Ethereum (ETH) ve Ripple (XRP) kripto para birimlerinin günlük piyasa deęerleri eğitimde kullanılmıştır. Doğrusal olmayan dönüşümler ve verilerin yüksek boyutta doğrusal olarak imkan sağlanması için çekirdek fonksiyonu kullanılmıştır. Doğrusal çekirdek fonksiyonu kullanılarak eğitim gerçekleştirilmiştir. İki sınıflı bir sınıflandırma probleminde çözüm için doğrusal çekirdek fonksiyonu kullanılabilir. (Osuna vd., 1997). İşlem gerçekleştikten sonra toplam 3 farklı model oluşturulmuştur. En iyi sonucu alabilmek için C ceza katsayısı deęiştirilerek optimum hiper düzlem belirlenmeye çalışılmıştır. Çekirdek

fonksiyonda bulunan parametreler dışında C ceza parametresi, kullanıcı tarafından belirlenmesi gerekir (Kavzoğlu ve Çölkesen 2010).

Performans Süreci

Modellerin performanslarının değerlendirilmesinde sınıflandırma sonucu elde edilen hata matrisleri yardımıyla genel sınıflandırma doğrulukları hesaplanmaktadır. Tahminlerin ölçümünün doğruluğu hakkında anlaşılması kolay bilgiler sağlaması ve özellikle sınıflandırma algoritmalarında sıklıkla kullanılan karmaşıklık matrisi kullanılmıştır.

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 ettiğimiz değerin 1 olduğu örneklerdir. Yanlış negatifler ise gerçek değeri 1 ancak tahmin ettiğimiz değerin 0 olduğu örneklerdir. Model A' da doğru pozitif oranı 459, yanlış pozitif oranı 441, yanlış negatif değeri 343 ve doğru negatif değeri 356 performans göstermiştir. Model B' de doğru pozitif oranı 511, yanlış pozitif oranı 412, yanlış negatif değeri 321 ve doğru negatif değeri 320 performans göstermiştir. Model C' da doğru pozitif oranı 454, yanlış pozitif oranı 423, yanlış negatif değeri 313 ve doğru negatif değeri 386 performans göstermiştir.

Tablo 1. Karmaşıklık Matrisi

		Gerçek	
		Pozitif	Negatif
Tahmin Edilen	Pozitif	Doğru Pozitif	Yanlış Pozitif
	Negatif	Yanlış Negatif	Doğru Negatif

Verinin eğitilmesinden sonra çekirdek fonksiyon seçilerek model çalıştırılmıştır. Ayrıca literatürde birçok çekirdek fonksiyonu tanımlanmıştır. Ancak her çekirdek fonksiyonu Destek Vektör Makinelerinde kullanımı uygun olmamaktadır (Ayhan ve Erdoğan 2014). Daha sonra çalıştırılan model üzerinden C ceza parametresi değiştirilerek, 3 farklı model elde edilmiştir. Parametre değişimindeki amaç en uygun başarı oranını bulmaktır. Tablo 2'de sırasıyla Model A performansı %49, Model B performansı %52 ve Model C performansı %50 gerçekleşmiştir parametreleri Model A için 500, Model B için 1000 ve Model C için 1500 seçilmiştir. Burada ceza parametresinin artış-azalış yönü başarı performansına etki etmediği gözlemlenmiştir. En yüksek performans Model B'de gerçekleşmiştir.

Tablo 2. Destek Vektör Makineleri Yöntemi İle Oluşturulan Modeller

MODEL	PERFORMANS (%)		C PARAMETRESİ
	EĞİTİM	TEST	
A	100	49%	500
B	100	52%	1000
C	100	50%	1500

4. Analiz ve Bulgular

Hacim ve kullanım sayıları dikkate alındığında, sıralamada ilk üçte yer alan ve 2016-2020 yılları arası Bitcoin (BTC), ethereum (ETH) ve Ripple (XRP) kripto para birimlerinin günlük değerleri investing.com 'un veri tabanından alınmıştır. Elde edilen verilerde açılış, kapanış, en yüksek değer, en düşük değer ve günlük değişim verisi bulunmaktadır. Çalışmada günlük değişimlerin artış azalış yönlerini kullanmak amaçlanmıştır. Problemi basitleştirmek için ikili sınıflandırma yöntemi gerçekleştirilmiştir. Bu sebeple endekslerin günlük hareket yönleri artmış ise 1 olarak etiketlenmiş, azalmış ise 0 olarak etiketlenmiştir (Tablo 3). Veri kümesinde toplamda 3825 adet örnek vardır. Test veri kümesinde 3025 adet veri eğitimde 800 adeti ise test veri kümesinde kullanılmıştır. Çalışmada kullanılan destek vektör makineleri modeli weka 3.8.4 programı ile çalıştırılmıştır.

Tablo 3. Örnek Veri Kümesi

Girdi			Çıktı
Bitcoin (BTC)	Ethereum (ETH)	Ripple (XRP)	BIST 100
1	1	0	1
0	0	0	0

Makine öğrenme yöntemlerinde performansı yükseltmek için katman ve nöron sayılarının aşırı artırılması öğrenme sürecini olumsuz yönde etkilemektedir. Model öğrenme yerine ezberlemeye yönelmektedir. Modeller çalıştırılırken eğitim sürecinde ezberlemenin önüne geçmek için karmaşıklık matrisi sonuçları ile test veri seti karşılaştırılarak kontrol sağlanmıştır.

5. Sonuç

Özellikle Bitcoin'in 2010 yılında işlem görmesinden sonra, kripto para birimleri çeşitlilik göstermeye başlamıştır. Yatırımcılar için alternatif bir enstrüman görülen kripto paraların piyasa sayısı ve yine bu piyasalarda işlem hacmi gün geçtikçe artış göstermektedir. Bir taraftan yüksek kazanç sağlamak isteyen yatırımcılar için çok cazipken, diğer taraftan risk sevmeyen yatırımcılar için ise dalgalanmaların yüksek olmasından dolayı çok riskli görülmektedir. Bu nedenle riskli yatırım

araçları olarak değerlendirilmektedir. BİST 100 endeksi Türkiye borsası için referans alınan önemli bir endekstir. Yatırımcılar için dikkat edilmesi gereken ve yatırım kararlarını direkt etkileyen bir unsurdur. Yatırımcılar piyasayı etkileyebilecek her faktörü risk unsuru olarak görebilmektedir. Küreselleşme etkisi ile birbirine geçmiş olan piyasalarda ve bir finansal ürünün diğer bir finansal ürünü doğrudan veya dolaylı olarak etkilemesi günümüzde olasıdır. Kripto para piyasaları da sisteme giren alternatif bir yatırım aracıdır. Bu çalışmada, yüksek piyasa değerine ve bunun yanında yüksek işlem hacmine sahip olan Bitcoin (BTC), ethereum (ETH) ve Ripple (XRP) kripto para birimlerinin 2016-2020 yılları arası günlük piyasa değerleri alınarak, BIST 100 endeksinin hareket yönleri tahmin edilmiştir. Liu ve Wang (2012) çalışmasında başarı skorunu arttırmak için modelde bulunan farklı parametleri değiştirerek, tahmin performansını arttırmıştır. Bu çalışmada 3 model oluşturularak, optimizasyon sağlanmaya çalışılmıştır. Model B performans skoru %52 bulunmuştur. Literatürde makine öğrenmesi yöntemleri kullanılarak tahmin ve ilişki çalışmaları az sayıda görülmektedir. İncelenen çalışmalarda daha çok yapay sinir ağları yönteminin kullanıldığı gözlemlenmiştir. Bu çalışmada, destek vektör makineleri yöntemi kullanarak ve örneklemdeki boyut sayısı artırılarak fark yaratılmak istenmiştir. Ekonometri tahmin yöntemlerine alternatif metot olarak makine öğrenmesi metotları özellikle sınıflandırma alanındaki başarısından dolayı kullanılabilir. Ekonometri ve makine öğrenmesi metotları kullanılarak performans başarıları anlamında katkı sağlanabilir.

Kaynakça

- Ayhan, S. ve Erdoğan, Ş. (2014). Destek Vektör Makineleriyle Sınıflandırma Problemlerinin Çözümü İçin Çekirdek Fonksiyonu Seçimi. *Eskişehir Osmangazi Üniversitesi İİBF Dergisi*, 9 (1), 175- 198.
- Berg, Chris., Davidson, Sinclair and Potts, Jason. (2017). *Blockchains Industrialise Trust*. <https://ssrn.com/abstract=3074070> or <http://dx.doi.org/10.2139/ssrn.3074070>.
- Çalışkan, M. M. T. ve Deniz, D. (2015). Yapay Sinir Ağlarıyla Hisse Senedi Fiyatları ve Yönlerinin Tahmini. *Eskişehir Osmangazi Üniversitesi İİBF Dergisi*, 10 (3), 177-194.
- Diler, A. İ. (2003). İmkb Ulusal-100 Endeksinin Yönünün Yapay Sinir Ağları Hata Geriye Yayma Yöntemi ile Tahmin Edilmesi Türkiye’de Bankalar, Sermaye Piyasası ve Ekonomik Büyüme: Koentegrasyon ve Nedensellik Analizi. *İMKB Dergisi*, 7 (25-26), 65-83.
- Kavzoğlu, T. ve Çölkesen, İ. (2010). Destek Vektör Makineleri ile Uydu Görüntülerinin Sınıflandırılmasında Kernel Fonksiyonlarının Etkilerinin İncelenmesi, *Harita Dergisi*, 144, 73-82.
- Kryzanowski. L., Galler. M. and Wright. W. D. (1993). Using Artificial Neural Networks to Pick Stocks, *Financial Analysts Journal*, 49 (4), 21-2.

Kutlu. B. ve Badur. B. (2009). Yapay Sinir Ağları ile Borsa Endeksi Tahmini, *İstanbul Üniversitesi İşleme İktisadi Enstitüsü Yönetim Dergisi*, 63, 25-40.

Liu. F. ve Wang. J., (2012), Fluctuation prediction of stock market index by Legendre neural network with random time strength function, *Neurocomputing*, 83, 12-21.

Moghaddam. A. H., Moghaddam. M. H., and Esfandyari. M. (2016). Stock Market Index Prediction Using an Artificial Neural Network. *Journal of Economics, Finance and Administrative Science*, 21 (41), 89-93.

Osuna. E. E., Freund. R. and Girosi. F. (1997). *Support Vector Machines: Training and Applications*. Massachusetts Institute Of Technology And Artificial Intelligence Laboratory, Massachusetts. A.I. No. 1602, 44.

Ozalıcı. M. (2016). Yapay Sinir Ağları ile Çok Aşamalı Fiyat Tahmini: Bıst30 Senetleri Üzerine Bir Araştırma. *Dokuz Eylül Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 31 (2), 209-228.

P. Hajek. (2013). Forecasting Stock Market Trend Using Prototype Generation Classifiers, *WSEAS Transactions on Systems*, 4 (10), 671-680.

Selvamuthu. D., Kumar. V. and Mishra. A. (2019). Indian Stock Market Prediction Using Artificial Neural Networks on Tick Data, *Financial Innovation*, 5 (16), 6-14.

Yakut. E., Bekir. E., ve S. Yavuz. (2014). Yapay Sinir Ağları ve Destek Vektör Makineleri Yöntemleriyle Borsa Endeksi Tahmini. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 19 (1), 139-157.

Zhang, Y. and Wu. L. (2009). Stock Market Prediction Of S&P 500 via Combination of Improved Bco Approach And Bp Neural Network. *Expert Systems With Applications*, 36 (5), 8849-8854

Support Vector Machines Application To Estimate BİST 100 Index Based On Cryptocurrency Values

With the acceleration of development in the technology, cryptocurrencies have started to be used in transactions. Cryptocurrencies that have been in use for nearly eleven years have created a new area in the market thanks to the decentralized system of blockchain technology, which eliminates the need for third parties. It is very attractive for investors who want to make high profits, on the other hand, volatilities in prices are very dramatic. For this reason, it is considered as risky investment tools. Investors can utilize anything that may affect the market as a risk factor. In our world of digital transformation, it can be thought that the market movements of cryptocurrencies will affect various economic balances. Investors may need various forecasting methods to overcome this uncertainty. In this study, the movement of the BIST 100 index is estimated based on the daily market values of Bitcoin (BTC), ethereum (ETH) and Ripple (XRP) cryptocurrencies with high market value as well as high transaction volume. The past market values of Bitcoin, Ethereum and Ripple, which are accepted as input variables in the study, were used in the training of support vector machines. Support vector machines are a learning algorithm that is one of the topics of machine learning discipline. These algorithms are used to solve classification problems, aiming at our success by using past experience for a particular task to tackle it. 3 models created for the best success score and model B performance score was 52%. The complexity matrix, which is frequently used in classification algorithms, was used to provide easy-to-understand information about the accuracy of the estimation measurement.

In the literature, there are few studies on prediction and relationship using machine learning methods. Machine learning methods can be used as an alternative method to econometrics estimation methods, especially due to their success in the classification field. By using econometrics and machine learning methods, contribution can be made in terms of performance success.