



[itobiad], 2020, 9 (2): 1394/1418

Destek Vektör Makineleri ile Borsa Endekslerinin Tahmini

Predicting Stock-Exchange Indexes by Using Support Vector
Machines

Cem KARTAL

**Dr. Öğr. Üyesi / Zonguldak Bülent Ecevit Üniversitesi İktisadi ve İdari
Bilimler Fakültesi**

**Asst. Prof., Zonguldak Bulent Ecevit University Faculty of Economic and
Administrative Sciences**

cem.kartal@beun.edu.tr

Orcid ID: <https://orcid.org/0000-0002-8453-3300>

Makale Bilgisi / Article Information

Makale Türü / Article Type	: Araştırma Makalesi / Research Article
Geliş Tarihi / Received	: 10.01.2020
Kabul Tarihi / Accepted	: 26.04.2020
Yayın Tarihi / Published	: 21.06.2020
Yayın Sezonu	: Nisan-Mayıs-Haziran
Pub Date Season	: April-May-June

Atıf/Cite as: KARTAL, C . (2020). Destek Vektör Makineleri ile Borsa Endekslerinin Tahmini. İnsan ve Toplum Bilimleri Araştırmaları Dergisi , 9 (2) , 1394-1418 . Retrieved from <http://www.itobiad.com/tr/issue/54141/673015>

İntihal /Plagiarism: Bu makale, en az iki hakem tarafından incelenmiş ve intihal içermediği teyit edilmiştir. / This article has been reviewed by at least two referees and confirmed to include no plagiarism. <http://www.itobiad.com/>

Copyright © Published by Mustafa YİĞİTOĞLU Since 2012 - Karabuk University, Faculty of Theology, Karabuk, 78050 Turkey. All rights reserved.

Destek Vektör Makineleri ile Borsa Endekslerinin Tahmini

Öz

Destek Vektör Makineleri (DVM) en popüler makine öğrenme algoritmalarından birisidir. Bu çalışmada BIST100 endeksi ile birlikte dünyanın önde gelen borsa endekslerinden S&P 500, DAX ve NIKKEI 225 endekslerinin getiri yönlerinin sınıflandırılmasında bir makine öğrenme tekniği olan DVM'lerin kullanılması ve bu tekniklerin tahmin (sınıflandırma) performanslarının ortaya konulması amaçlanmıştır. Bu amaçla DVM'ler, borsa endekslerinin "yükseliş" ve "düşüş" trendlerinin modellenmesinde kullanılmıştır. Ayrıca çalışmada, makroekonomik değişkenlerin borsa endekslerine olan etkileri analiz edilmiştir. Çalışmanın veri seti, bağımlı ve bağımsız değişkenlerin 01.01.2013 – 30.11.2019 dönemleri arasındaki aylık olarak 82 adet gözlem değerini içermektedir. Bu gözlem değerlerinin 70 adedi (%85'i) algoritmanın modellenmesi (eğitim) için, 12 adedi (%15'i) ise sınıflandırma (test) için kullanılmıştır. Çalışma sonucunda modelin yükseliş yönlü tahminlerde sınıflandırma başarısının iyi olduğu, ancak düşüş yönlü tahminlerinde aynı başarıyı göstermediği ortaya çıkmıştır.

Özet

Makine öğrenmesi metodlarının büyük veri tabanlarına uygulanmasına veri madenciliği denir. Destek Vektör Makineleri (DVM) de Yapay Sinir Ağları ile yakından ilişkili olup çift katmanlı ve ileri beslemeli bir yapay sinir ağına sahiptirler. DVM'ler belki de en popüler makine öğrenme algoritmalarından biridir. Makine öğrenmesinde, DVM'ler verileri analiz eden ve regresyon analizi ve sınıflandırma amacıyla kullanılan kalıpları tanıyan, ilişkili öğrenme algoritmalarıyla denetlenen öğrenme modelleridir. 1990'larda geliştirildiklerinde son derece popüler olmuş ve yüksek performanslı bir algoritma için en iyi yöntemlerden biri haline gelmiştir. DVM'ler, ampirik veriler arasında tespit edilmesi zor olan fonksiyonel ilişkileri yakalama yeteneklerinden dolayı finansal zaman serilerini modellemek ve sınıflandırmak için yararlı teknikler olarak kullanılmaktadır. DVM'ler istatistiksel öğrenme teorisine dayanan yeni bir sinir ağı algoritmasıdır. Pratik uygulamalarda büyük potansiyele ve üstün performansa sahiptirler. Bu büyük ölçüde DVM'lerin geleneksel sinir ağları tarafından benimsenen ampirik risk minimizasyon ilkesinden daha üstün olan yapı risk minimizasyon prensiplerine sahip olmasından kaynaklanmaktadır. DVM'lerin finans alanında; borsa endeks hareketlerinin tahmin edilmesi, finansal bilgi manipülasyonları öngörüsü ya da finansal başarısızlıklara karşı erken uyarı sistemlerinin oluşturulması gibi birçok alanda istatistiksel yöntemlere göre daha başarılı oldukları gözlemlenmiştir. Destek Vektör



Makineleri (DVM) en popüler makine öğrenme algoritmalarından birisidir. Bu çalışmada BIST100 endeksi ile birlikte dünyanın önde gelen borsa endekslerinden S&P 500, DAX ve NIKKEI 225 endekslerinin getiri yönlerinin sınıflandırılmasında bir makine öğrenme tekniği olan DVM'lerin kullanılması ve bu tekniklerin tahmin (sınıflandırma) performanslarının ortaya konulması amaçlanmıştır. Bu amaçla DVM'ler, borsa endekslerinin "yükseliş" ve "düşüş" trendlerinin modellenmesinde kullanılmıştır. Çalışmada değişkenler, makroekonomik göstergeler, politik, ekonomik ve sosyal olaylar dikkate alınarak seçilmiştir. Ayrıca Dünyanın önde gelen borsa endekslerinin getiri yönünü tahmin etmek amacıyla literatürde yer alan çalışmaların bulguları da bağımsız değişken seçiminde etkili olmuştur. Çalışmanın veri seti, bağımlı ve bağımsız değişkenlerin 01.01.2013 – 30.11.2019 dönemleri arasındaki aylık olarak 82 adet gözlem değerini içermektedir. Bu gözlem değerlerinin 70 adedi (%85'i) algoritmanın modellenmesi (eğitim) için, 12 adedi (%15'i) ise sınıflandırma (test) için kullanılmıştır. Genel sınıflandırma başarı ortalamalarına baktığımızda modelin, DAX ve S&P 500 endeks yönlerinin tahmininde %75 ile en iyi performansı gösterdiği, NIKKEI 225 endeks yönü tahmininde ise %41,7 ile en kötü performansı gösterdiğini görmekteyiz. Bununla birlikte BIST100 endeks yönü tahmininde "yükseliş" trendinin test değerleri üzerinde %100 başarı gösterdiği (4/4), ancak "düşüş" trend tahmini başarısızlığı nedeniyle genel başarı ortalamasının %50 'de kaldığı gözlemlenmektedir. Bu analizler yapılırken modelin kullandığı test değerleri sayısının azlığı da göz önünde bulundurulmalıdır. Sonuç olarak DVM yöntemi yardımıyla BIST100 ve dünyanın önde gelen borsa endekslerinden S&P 500, DAX ve NIKKEI 225 endeks "yükseliş" ve "düşüş" trend yönü tahmininde bulunmaya çalıştığımız modelimizin genel başarı ortalaması %60,43 olmuştur. Doğruluk Oranı, F Ölçütünün büyüklüğü, ROC (Receiver Operating Characteristic) Alan Değeri ve Kappa İstatistik Değeri modelin başarı göstergelerindedir. ROC Alan Değeri ne kadar büyük ise sistemin güvenilirliği de artmaktadır. Birden fazla model kullanarak değerlendirme yapmak istendiğinde, bu ölçütlerden en iyi sonuçları veren modelin en iyi sınıflandırma tahmini yaptığını söylemek mümkündür. Modellerin genel başarısını değerlendirirken Doğruluk, F-Ölçütleri, ROC Alan Değerleri ve Kappa İstatistik Değerleri kullanılmaktadır. En iyi performansı gösteren DAX endeksinin getiri yönünün tahmin edilmeye çalışıldığı modelin doğruluk oranı %75, F-Ölçütü %74,4 ve ROC Eğrisi altında kalan alan değeri 0,743 bulunmuştur. En kötü performansı gösteren NIKKEI 225 endeksinin getiri yönünü tahmin etmeye çalışan modelin doğruluk oranı ise %41,7, F-Ölçütü %34,3 ve ROC Eğrisi altında kalan alan değeri 0,629 olarak bulunmuştur. Bu sonuçlara göre model, en iyi performansı DAX endeks getiri yönü sınıflandırma tahmininde, en kötü performansı ise NIKKEI endeks getiri yönü sınıflandırma tahmininde göstermiştir. Borsa endeksleri sınıf tahmin modellerinin Kappa İstatistik Değerleri incelendiğinde DAX'ın 0,4706 (orta düzeyde uyum olması), S&P 500'ün 0,25 (zayıf düzeyde uyum olması),



BIST100'ün 0,1818 (Önemsiz düzeyde uyum) ve NIKKEI 225'in ise -0,3125 (Şansa bağlı uyum) değerlerine sahip olduğunu görmekteyiz. Çalışmamız bu sonuçlarıyla literatüre katkı sağlamış olup, DVM modelinin içinde bulunduğu hibrit modeller oluşturularak ve veri setleri genişletilerek çeşitli varlık (döviz, altın, hisse senedi...) fiyat hareketlerinin tahmin performanslarının iyileştirilmesi mümkün olabilecek, bu da çeşitli piyasalarda yatırım yapmak isteyen yatırımcılara yol gösterecektir. Böylece yatırımcıların finansal kararlar vermesinde ve bu kararlar yardımıyla oluşturulan yatırım stratejileri sayesinde yüksek getiri elde etmeleri sağlanabilecektir.

Anahtar Kelimeler: Finansal Tahmin, Destek Vektör Makineleri, Sınıflandırma, Makine Öğrenmesi, Yatırım Kararları.

Predicting Stock-Exchange Indexes by Using Support Vector Machines

Abstract

Support Vector Machines (SVM) is one of the most popular machine learning algorithms. In this study, it is aimed to use SVM, which is one of the leading stock indices of the world together with BIST100 index and a machine learning technique in the classification of return directions of S&P 500, DAX and NIKKEI 225 indices. Besides, it is aimed to reveal the estimation (classification) performances of these techniques. For this purpose, SVMs have been used to model the "upward" and "downward" trends of stock market indices. In addition, the effects of macroeconomic variables on stock market indices are analysed. The data set of the study includes 82 observational values of dependent and independent variables monthly between 01.01.2013- 30.11.2019. 70 (85%) of these observation values are used for modelling (training) and 12 (15%) for classification (test). As a result of the study, it is found that the model shows success in upward forecasts, but it does not show the same success in downward forecasts.

Structured Abstract

Application of machine learning methods to large databases is called data mining. There are many areas where data mining is used. Support Vector Machines (DVM) are also closely related to Artificial Neural Networks and have a double-layer and they feedforward artificial neural network. Support Vector Machines (DVM) is one of the most popular machine learning algorithms. In machine learning, DVMs are learning models that analyze data and recognize patterns used for regression analysis and classification, and they are controlled by associated learning algorithms. They were



extremely popular when they were developed in the 1990s and remain one of the best methods for a high-performance algorithm. DVMs are used as useful techniques to model and classify financial time series due to their ability to capture functional relationships that are difficult to detect among empirical data. DVMs are a new neural network algorithm based on statistical learning theory. They have great potential and superior performance in practical applications. This is largely due to the fact that DVMs have structure risk minimization principles that are superior to the empirical risk minimization principle adopted by traditional neural networks. In the field of finance, DVMs are used in many areas such as estimating stock market index movements, predicting financial information manipulations or creating early warning systems against financial failures. In this study, it is aimed to use DVM, which is one of the leading stock indices of the world together with BIST100 index and a machine learning technique in the classification of return directions of S&P 500, DAX and NIKKEI 225 indices. Besides, it is aimed to reveal the estimation (classification) performances of these techniques. For this purpose, DVMs have been used to model the "upward" and "downward" trends of stock market indices. In addition, the effects of macroeconomic variables on stock market indices are analyzed. In the study, variables are selected considering macroeconomic indicators, political, economic and social events. In addition, the findings of the studies in the literature have been influential in the selection of independent variables in order to estimate the return direction of the leading stock market indices. The data set of the study includes 82 observational values of dependent and independent variables monthly between 01.01.2013- 30.11.2019. 70 (85%) of these observation values are used for modelling (training) and 12 (15%) for classification (test). According to the general classification success averages, we see that the model shows the best performance with 75% in predicting the DAX and S&P 500 index directions, and the worst performance in the NIKKEI 225 index direction with 41.7%. In the BIST100 index direction estimation, however, it is observed that the "upward" trend shows 100% success on the test values (4/4), but the overall success average remains at 50% due to the "downward" trend prediction failure. While making these analyses, the number of test values used by the model should be taken into consideration. As a result of the study, it is found that the model shows success in "upward" forecasts, but it does not show the same success in "downward" forecasts. As a result, the overall success average of our model, which we are trying to predict on the "upward" and "downward" trend direction of the BIST100 and S&P 500, DAX and NIKKEI 225 index, which is among the leading stock market indices of the world, is 60.43%. Accuracy Rate, Size of the F Criterion, ROC (Receiver Operating Characteristic) Field Value and Kappa Statistical Value are the success indicators of the model. The greater the ROC Field Value, the more reliable the system is. When evaluating by using multiple models, it is possible to say that the model giving the best results from these criteria



makes the best classification estimation. When evaluating the overall success of the models, Accuracy, F-Criteria, ROC Field Values and Kappa Statistical Values are used. The accuracy of the model, where the best performing DAX index is tried to be estimated, is 75%, the F-Criterion is 74.4% and the area value under the ROC Curve is found to be 0.743. The accuracy of the model, which tries to estimate the return direction of the worst performing NIKKEI 225 index, is found to be 41.7%, F-Criterion is 34.3% and the area value under the ROC Curve is 0.629. According to these results, the model showed the best performance in the DAX index return direction classification estimate and the worst performance in the NIKKEI index return direction classification estimate. When the Kappa Statistical Values of stock indexes class prediction models are analyzed, DAX is found to be 0.4706 (moderate agreement), S&P500 0.25 (fair agreement), BIST100 0.1818 (slight agreement) and NIKKEI225 -0.3125 (less than chance agreement). Our study has contributed to the literature with these results, and by creating hybrid models containing the DVM model and expanding the datasets, it will be possible to improve the forecast performance of various asset (currency, gold, stock ...) price movements, which will guide investors who want to invest in various markets. Thus, investors will be able to make high returns through financial decisions and investment strategies created with the help of these decisions.


Keywords: Financial Forecasting, Support Vector Machines, Classification, Machine Learning, Investment Decisions.



1. Giriş

Makine öğrenmesi metotlarının büyük veritabanlarına uygulanmasına veri madenciliği denir. Veri madenciliğinde yüksek tahmine dayalı, kesinliğe sahip, değerli kullanımlı basit bir model oluşturmak amacıyla çok miktarda veri işlenmektedir (Bayramoğlu & Başarır, 2019, 257). Veri madenciliğinin kullanıldığı birçok alan vardır. Veri madenciliği özellikle bankacılık sektöründe (kredi uygulamalarında, dolandırıcılık tespitinde..) ve borsalarda (geçmiş veriler yardımıyla yeni modeller geliştirebilmek amacıyla) sınıflandırma problemlerinin çözümünde kullanılmaktadır. Ayrıca imalatta; öğrenme modelleri ile optimizasyon, kontrol ve sorun giderme için, tıp alanında; tıbbi teşhis için öğrenme modelleri kullanılmaktadır. Telekomünikasyon sektöründe; şebeke optimizasyonu ve servis kalitesini en üst seviyeye çıkarabilmek için çağrı kalıpları geliştirilmiştir. Bilimde; fizik, astronomi ve biyolojideki büyük miktardaki veriler ancak bilgisayarlar tarafından yeterince hızlı bir şekilde analiz edilebilmektedir. Makine öğrenmesi sadece bir veri tabanı problemi değildir; aynı zamanda yapay zekanın bir parçasıdır. Sistem meydana gelen değişiklikleri öğrenip uyarlayabiliyorsa, sistem tasarımcısının olası tüm durumlar için öngöründe bulunması ve çözüm üretmesi gerekmez. Makine öğrenimi, yaşam, konuşma, tanıma ve robotik alanındaki birçok soruna da çözüm bulunmasına yardımcı olmaktadır. Makine öğrenimi bilgisayarları, örnek verileri veya geçmiş deneyimleri kullanarak bir performans kriterini optimize etmek için programlamaktır. Makine öğrenmesi matematik modellerini oluştururken istatistiksel teorileri kullanır, çünkü temel görev bir örnekten çıkarımda bulunmaktır (Apaydın, 2014, s. 3).

Şekil 1: Biyolojik Nöron



Kaynak: Negnevitsky, 2005, s. 30.


Bir sinir ağı, bir hayvan beynindeki merkezi sinir sistemi olan biyolojik sinir ağlarından ilham alan bir akıl yürütme modelidir. İnsan beyni, nöron adı verilen çok sayıda birbirine bağlı sinir hücresinden oluşur (Şekil 1). Bir nöron; bir hücre gövdesi, soma ve dendrit adı verilen bir dizi lif ve akson olarak adlandırılan tek bir uzun liften oluşur. Biyolojik sinir sisteminin yapısı, işlevlerini nasıl yerine getirdiği ile birlikte Yapay Sinir Ağları (YSA) fikrine ilham vermiştir. İlk sinir ağı kavramsal modeli 1943'te Warren



McCulloch ve Walter Pitts tarafından geliştirilmiştir. Nöron kavramını, bir ağdaki diğer hücrelerle iletişim kuran ayrı bir hücre olarak tanımladılar. Bu hücre diğer hücrelerden veri alır, girdileri işler ve çıktıları diğer hücrelere geçirir. O zamandan beri, bilim insanları ve araştırmacılar YSA'ları geliştirmek için yoğun araştırmalar yapmışlardır. Günümüzde YSA'lar en etkili örüntü tanıma, regresyon ve sınıflandırma araçlarından biri olarak kabul edilmektedir (Negnevitsky, 2005, s. 30).

YSA, yapay zekâ araştırmasının popüler alanlarından biridir ve aynı zamanda insan beyninin organizasyonel yapısına dayanan soyut bir hesaplama modelidir. YSA'lar, Girdi, Gizli ve Çıktı tabakalarından oluşan 3 katmanlı bir yapıdan meydana gelmektedir (Snehashish C. ve Susmita M., 2017: 1-3).

Şekil 2: Yapay sinir Ağı Modeli



Kaynak: Snehashish & Susmita, 2017, s. 2.

Yukarıdaki şekilde, x_j giriş düğümleridir, w_{ij} , giriş katmanından gizli katmana kadar olan ağırlıklardır ve v_i ve y , sırasıyla gizli katmandan çıkış katmanına ve çıkış düğümüne kadar olan ağırlıkları belirtir.

Destek Vektör Makineleri (DVM) de Yapay Sinir Ağları ile yakından ilişkili olup çift katmanlı ve ileri beslemeli bir yapay sinir ağına sahiptirler. DVM'ler belki de en popüler makine öğrenme algoritmalarından biridir. 1990'larda geliştirildiklerinde son derece popüler olmuş ve yüksek performanslı bir algoritma için en iyi yöntemlerden biri haline gelmiştir. DVM, Vapnik ve grubu tarafından AT&T Bell Laboratuvarları'nda geliştirilen yeni ve çok umut verici bir sınıflandırma tekniğidir. Bu yeni öğrenme algoritması, Polinom, Radyal Temel Fonksiyon ve Çok Katmanlı Perceptron (Yapay sinir ağı) sınıflayıcıları için alternatif bir eğitim tekniği olarak görülebilmektedir (Vapnik, 1998, s. 30-32). Tekniğin arkasındaki ana fikir, verilerden oluşan sınıflar arasındaki marjı maksimize eden optimal bir hiper düzlem meydana getirmektir. DVM teorisi Yapısal Risk Minimizasyonu (SRM) fikrine dayanmaktadır (Suykens & Vandewalle, 1999, s. 293). DVM'ler, istatistiksel öğrenme teorisine dayanan parametrik olmayan bir sınıflandırma tekniğidir. DVM ikili sınıflandırmalar için geliştirilmiştir ve bu yöntem yardımıyla birkaç örnekleme verisi kullanılarak doğru sınıflandırma sonuçları elde etmek mümkündür. DVM'lerde veriler




doğrusal olarak ayrılabilir ya da doğrusal olarak ayrılamayan bir yapıda olabilir. Doğrusal olarak ayrılması mümkün olmayan veriler daha yüksek boyutlu uzayda gösterildiklerinde doğrusal olarak ayrılabilir. (Ayhan & Erdoğan, 2014, s.177).

Makine öğrenmesinde, DVM'ler verileri analiz eden ve regresyon analizi ve sınıflandırma amacıyla kullanılan kalıpları tanıyan, ilişkili öğrenme algoritmalarıyla denetlenen öğrenme modelleridir. Her biri iki kategoriden birine ait olarak işaretlenmiş bir dizi eğitim örneği göz önüne alındığında, bir DVM eğitim algoritması, bir örneği veya başka kategoriye yeni örnekler atayan bir model oluşturmakta ve bu onu olasılıksız bir ikili doğrusal sınıflandırıcı yapmaktadır. Bir DVM modeli, örneklerin uzaydaki noktalar olarak gösterilmesidir. Haritalama yaklaşımından yararlanır, bu sayede ayrı kategorilere ait örnekler mümkün olduğu kadar geniş ve açık bir aralıkla bölünmektedir. Daha sonra yeni örneklem verilerinin aralığın hangi tarafına dayanan bir kategoriye ait olduğu tahmin edilir (Şekil 3) (Jordan vd., 2008, s. 30-35)

X_j vektörleriyle verilen N vektörleri $\{x_1, x_2, \dots, x_N\}$, m $\{a_{j1}, a_{j2}, \dots, a_{jm}\}$ özelliklerine sahip ve C_1 veya C_2 sınıfından birine ait olsun. Belirtilen verinin, C_1 sınıfından örnekler ile C_2 sınıfından örnekler arasında ayrılabilen özellik alanında bir hiper düzlem bulmak mümkün olduğunda doğrusal olarak ayrılabilir olduğunu söyleyebiliriz. Şekil 3'de, iki boyutlu bir özellik alanında doğrusal olarak ayrılabilir veriler (daireler ve kareler) görülmektedir. Ayrık çizgi, iki boyutlu düz bir çizgi olan ayırıcı hiper düzlemi temsil eder (Mohammed vd. 2017, s. 115).

Şekil 3: İki Boyutlu Bir Özellik Uzayındaki Daire ve Karelerin Doğrusal Olarak Ayrılabilir Verileri




Kaynak: Mohammed vd., 2017, s. 115.

Doğrusal olarak ayrılabilir verilerden dolayı, verilen iki sınıfın örnekleri arasında bir boşluk olacaktır. Bu boşluk marj olarak adlandırılır. İki sınıfın örnekleri arasındaki boşluğun mümkün olduğunca geniş olması bir avantaj olacaktır (Şekil 4).



Şekil 4: Kareler ve Daireler Arasındaki Marj



Kaynak: Mohammed vd., 2017, s. 116.

Bir eğitim seti olarak, verilen N eğitim vektöründen n adet eğitim vektörünü rastgele seçtiğimizi varsayalım. DVM'nin asıl amacı, tüm eğitim vektörlerini iki sınıfta sınıflandıran bir hiper düzlem bulmaktır. İki sınıfın örneklerini ayıran birçok hiper düzlem olabilir, ancak seçilen hiper düzlemin iki sınıf arasındaki marjı maksimize etmesi istenir (Lin & Wang, 2002, s. 465).

$S(x)$, formun doğrusal diskriminant fonksiyonudur (Mohammed vd., 2017: s.116):

$$S(x) = w^t x + b$$


Burada x bir eğitim vektörüdür, w bir m boyutlu ağırlık vektörüdür ve b yönelim değeri (bias)'dir. Ağırlık vektörü, hiper düzleme ortogonaldır ve yönünü kontrol ederken, b pozisyonunu kontrol eder.

Eğer \tilde{x} bir eğitim vektörü olarak verilirse;

1. $S(\tilde{x}) = w^t \tilde{x} + b > 0$ eğer $\tilde{x} \in C_1$
2. $S(\tilde{x}) = w^t \tilde{x} + b < 0$ eğer $\tilde{x} \in C_2$

DVM'nin eğitim aşaması, ağırlığın ve yanlılığın ayarlanmasını içerir; böylece tüm C_1 örnekleri, hiper düzlemin bir tarafında, C_2 örnekleri ise hiper düzlemin diğer tarafında bulunur. Hiper düzlemin konumu için en uygun seçim hem C_1 hem de C_2 sınıflarından en yakın örneklerden mümkün olduğu kadar uzak olmasıdır. Her iki sınıftan da hiper düzleme en yakın mesafede olan özellik vektörleri destek vektörleri olarak adlandırılmaktadır (Şekil 5). DVM'nin temel amacı, hiper düzlem ile kendisine en yakın destek vektörler arasındaki mesafeyi yani marjı maksimize etmektir.

Şekil 5: Her İki Sınıftan Elde Edilen Destek Vektör Makineleri Arasındaki Mesafeyi Maksimum Yapan Ayırıcı Düzlem



Kaynak: Lin & Wang, 2002, s. 465.



Zaman serisi özelliği gösteren finansal fiyat/endekslerin doğru tahmin edilmesi yatırım kararı vermede önemli bir konu haline geldiğinden, fiyat/endeks hareketlerinin tahmini ve sınıflandırılması üzerine çok çeşitli çalışmalar yapılmaktadır. Ancak, bu hareketler doğal olarak rassal ve durağan değildir. Bu nedenle, finansal zaman serisi tahmini, zaman serisi tahminleri içerisinde tahmini en zor olan seriler olarak kabul edilmektedir. DVM'ler, ampirik veriler arasında tespit edilmesi zor olan fonksiyonel ilişkileri yakalama yeteneklerinden dolayı finansal zaman serilerini modellemek ve sınıflandırmak için yararlı teknikler olarak kullanılmaktadır. DVM'ler istatistiksel öğrenme teorisine dayanan yeni bir sinir ağı algoritmasıdır. Pratik uygulamalarda büyük potansiyele ve üstün performansa sahiptirler. Bu büyük ölçüde DVM'lerin geleneksel sinir ağları tarafından benimsenen ampirik risk minimizasyon ilkesinden daha üstün olan yapı risk minimizasyon prensiplerine sahip olmasından kaynaklanmaktadır. Genelleme yeteneğinin benzersiz bir çözüm elde etmedeki avantajları nedeniyle DVM'ler araştırmacıların dikkatini çekmiş ve doku sınıflandırması, görüntü tanıma, veri madenciliği, biyoinformatik gibi birçok alanda uygulama olanağı bulmuştur (Cao, 2003, s. 322). Vapnik'in duyarsızlık kaybı fonksiyonunun kullanılmaya başlanmasıyla, Destek Vektörü Regresyonu (DVR) olarak adlandırılan DVM'lerin regresyon modeli de doğrusal olmayan tahmin problemlerini çözmeye gittikçe ilgi görmeye başlamıştır (Burbidge, 2001, s. 8). Son zamanlarda YSA ve DVM yöntemleri tahmin amacıyla sıklıkla kullanılmaya başlanmıştır. YSA genellikle rassal verilerde tutarsız ve öngörülemez bir performans sergileyebilmektedir. DVM, sınıflandırma ve regresyon problemlerinin çözümünde ve aynı zamanda veri madenciliğinde kullanılabilen algoritmalar arasındaki en uygun ve doğru modellerden biridir.

Bu çalışmanın temel amacı, önemli makroekonomik değişkenlerin etkisi altında borsa endekslerinin hareket yönlerinin DVM ile tahmin edilebilirliğini araştırmaktır. Makalenin bundan sonraki ikinci bölümünde finans alanında DVM ve diğer makine öğrenmesi yöntemleri kullanılarak yapılmış tahmin (sınıflandırma) çalışmalarına yer verilmiş olup, üçüncü bölümde DVM modelinin teknik altyapısı hakkında bilgi verilmiştir. Dördüncü bölümde veri seti ve analizde kullanılan değişkenler açıklanarak, DVM yönteminin analiz sonuçları ve bu sonuçların yorumlarına değinilmiştir. Sonuç bölümünde, analiz bulguları karşılaştırılmış ve endeks getiri yönlerinin tahmin edilmesi amacıyla yapılan bu çalışmanın literatüre katkısına değinilmiştir.

2. Literatür Taraması

DVM'lerin finans alanında; borsa endeks hareketlerinin tahmin edilmesi, finansal bilgi manipülasyonları öngörüsü ya da finansal başarısızlıklara karşı erken uyarı sistemlerinin oluşturulması gibi birçok alanda istatistiki yöntemlere göre daha başarılı oldukları gözlemlenmiştir.



Kim (2003), Güney Kore kompozit hisse senedi fiyat endeksindeki (KOSPI) değişimin yönünü araştırmak amacıyla 1989-1998 yılları arasındaki 2628 veriden (2347 veri eğitim örneği, 581 veri ise test örneği olarak kullanılmıştır) faydalanmıştır. Hisse senedi fiyatı endeksindeki günlük fiyat değişim yönünü DVM metoduyla tahmin etmeye çalışmış ve deneysel sonuçlar, DVM'nin borsa tahminine umut verici bir alternatif sunduğunu göstermiştir.

Min ve Lee (2005) çalışmalarında iflas tahmin problemine DVM modelini uygulamıştır. Ek olarak, DVM'nin tahmin doğruluğunu değerlendirmek için performansını çoklu diskriminant analizi (MDA), lojistik regresyon analizi (Logit) ve üç katmanlı geri yayılım sinir ağları (BPN'ler) ile karşılaştırmışlardır. Çalışma sonuçları DVM'nin diğer yöntemlerden daha iyi performans gösterdiğini ortaya koymuştur.

Huang vd. (2005) 1 Ocak 1990- 31 Aralık 2002 yılları arasındaki 676 veriden oluşan NIKKEI 225 endeksinin haftalık finansal hareket yönünün DVM ile öngörülebilirliğini araştırmışlardır. DVM'nin tahmin yeteneğini değerlendirmek için, performansını Lineer Diskriminant Analizi, Kuadratik Diskriminant Analizi ve Elman Geri Yayılım Sinir Ağları ile karşılaştırmışlar ve analiz sonuçları DVM'nin diğer sınıflandırma yöntemlerinden daha iyi performans gösterdiğini ortaya koymuştur. Ayrıca DVM'nin içinde bulunduğu hibrit modellerin tüm öngörme yöntemleri arasında en iyi performansı gösterdiği sonucuna da ulaşılmıştır.

Min vd. (2006) çalışmalarında Güney Kore'de 1999-2002 yılları arasında faaliyette bulunan 614 firmanın mali tablolarından elde edilen finansal oranları yardımıyla iflas tahmini için DVM tabanlı yöntem, YSA ve lojistik regresyon gibi diğer yöntemlerle karşılaştırılmış ve DVM en iyi sonucu veren yöntem olmuştur.

Hua vd. (2007) çalışmalarında 1999-2004 yılları arasında Şangay Borsası'nda (SSE) işlem gören 120 şirketin denetimden geçmiş mali tabloları aracılığıyla DVM, YSA, lineer çoklu ayırıcı yaklaşımlar (IBDR) ve lojistik regresyon gibi makine öğrenmesi modelleri iflas tahmini probleminde kullanılmıştır. Çalışma sonucunda DVM sonuçları en iyi tahmin performanslarını gösteren makine öğrenme yöntemi olmuştur.

Öğüt vd. (2009) DVM ve olasılıksal sinir ağı (PNN) modelleri yardımıyla finansal tablolardan elde edilen bazı değişkenleri kullanarak finansal bilgi manipülasyonunu öngörmeye çalışmışlardır. Sınıflandırmanın performansını test etmek amacıyla PNN ve DVM metotları kullanılarak elde edilen doğruluk, duyarlılık ve özgüllük istatistikleri, diğer çalışmalarda kullanılan diskriminant analizi, lojistik regresyon (logit) ve probit sınıflandırıcılarının sonuçları ile karşılaştırılmıştır. DVM ve PNN performansının diğer sınıflandırıcılardan daha yüksek olduğu ortaya konmuştur.

Lu vd. (2009) çalışmalarında 4 Ekim 1999 ile 30 Eylül 2004 tarihleri arasındaki 1144 veriden oluşan (ilk 794 veri eğitim örneği sonraki 350 veri



ise test örneği olarak kullanılmıştır) Nikkei 225 endeksi açılış değeri ve 2 Ocak 2003 ile 27 Şubat 2006 tarihleri arasındaki 781 veriden oluşan (ilk 546 veri eğitim örneği sonraki 235 veri ise test örneği olarak kullanılmıştır) TAİEX (Taiwan Stock Exchange Capitalization Weighted Stock Index) endeksi kapanış değeri kullanılmıştır. Çalışmalarında finansal zaman serisi tahmininde bağımsız bileşen analizi (ICA) ve destek vektör regresyonunu kullanan iki aşamalı bir modelleme yaklaşımı önerilmiş ve DVM'ler finansal zaman serisi tahmininde daha başarılı olmuştur.

Ahn vd. (2011) çalışmalarında finansal krizlere karşı erken uyarı sistemi (EWS) oluşturmak için DVM tabanlı bir sınıflandırma yaklaşımı önermişlerdir. Bu sınıflandırma yaklaşımı temel olarak finansal piyasaların günlük anormal fiyat hareketlerini izlemek için geliştirilmiştir ve çalışma sonucunda DVM'lerin etkili bir sınıflandırıcı olduğu tespit edilmiştir.

Özdemir vd. (2011) çalışmalarında 1997-2010 dönemleri arasındaki 11 değişkenin (8 makroekonomik değişken, 3 borsa endeksi) aylık verilerinden faydalanarak İMKB100 endeksinin yönünü lojistik regresyon ve DVM yöntemi ile tahmin etmeye çalışmışlardır. Doğru sınıflandırma oranları sırasıyla yaklaşık %75 ve %86 olarak bulunmuştur. DVM metodunun yatırımcılar ve akademisyenler tarafından hisse senedi getirilerinin tahmin edilmesinde alternatif bir yöntem olarak etkili bir şekilde kullanılabileceği sonucu vurgulanmıştır.

Karagül (2013) çalışmasında İMKB100 içinde tekstil, gıda ve çimento sektörlerinde faaliyette bulunan 42 şirkete ait 10 adet mali oranın 2006-2011 yılları arasındaki ortalama değerlerini dikkate alarak DVM metodu yardımıyla yaptığı sınıflandırma başarısı %95,23 olarak bulunmuştur.

Yakut vd. (2014) çalışmalarında BIST100 endeksinin bir, iki ve üç gün öncesine ait değerleri ile birlikte 2005-2012 tarihleri arasındaki USD, gecelik faiz oranı, FTSE, CAC, DAX, NIKKEI, BOVESPA borsa endeks değerleri kullanılarak, BIST100 endeks değerleri ileri beslemeli YSA ve DVM yöntemleriyle tahmin edilmeye çalışılmıştır. Çalışma sonucunda YSA ve DVM yöntemlerinin borsa endeks tahmininde modellenebileceği tespit edilmiştir.

Altınırnak ve Karamaşa (2016) 30 özel sermayeli bankanın beş yıllık mali tablolarından elde ettikleri finansal oranlardan yararlandıkları çalışmalarında DVM ve YSA modellerini finansal başarısızlıklar konusunda erken uyarı sistemi olarak kullanmışlardır. Çalışma sonucuna göre DVM yönteminin, YSA metoduna göre bankalarda yaşanan finansal başarısızlıkların değerlendirilmesinde, sınıflandırıcı bir erken uyarı göstergesi olarak kullanılabileceği sonucu elde edilmiştir.

Henrique vd. (2018) çalışmalarında Brezilya, Amerika ve Çin borsalarında işlem gören 18 adet hisse senedinin 15 yıllık günlük kapanış fiyatlarını dikkate alarak DVM yardımıyla fiyat hareketlerini sınıflandırmaya



çalışmışlar ve sonuçta bu modelin başarılı bir sınıflandırma performansı gösterdiğini ortaya koymuşlardır.

Yürük ve Ekşi (2019) çalışmalarında BİST imalat sanayi şirketlerinin başarısızlığı tahmini için YSA ile DVM modellerini kullanmışlardır. Daha sonra sınıflandırma problemlerinde kullanılan bu iki modelin performansları karşılaştırılmıştır. Çalışmada başarısız işletmelerin başarısızlığı, 1., 2. ve 3. yıl öncesinden belirlenmeye çalışılmış ve çalışma sonucunda 3 yıl öncesinden bile %70 üzeri bir doğruluk oranı ile oluşturulan iki modelin iyi performans gösterdiği ortaya konmuştur.

Aksoy ve Boztosun (2019) çalışmalarında Borsa İstanbul'da işlem gören imalat sanayi sektöründe faaliyet gösteren 86 şirkete ait 2010-2012 dönemi arasındaki verileri kullanarak finansal başarısızlıklarından 1 ve 2 yıl öncesi için sınıflandırma tahmininde bulunmuşlardır. Çalışmada makine öğrenme yöntemlerinden; YSA, CART Sınıflandırma ve Regresyon Ağaçları, K En Yakın Komşular Algoritması ve Destek Vektör Makineleri olmak üzere 4 yöntemin sınıflandırma performanslarını karşılaştırmışlar ve DVM ile %74,17 doğru sınıflandırma başarıları elde edilmişlerdir.

Pabuçcu (2019) çalışmasında BIST 100 endeks hareketlerinin yönünü öngörmek amacıyla makine öğrenme yöntemlerinden olan YSA, DVM ve Naive Bayes algoritmasını kullanmış ve modellerin performanslarını karşılaştırmıştır. Veri seti olarak 2009-2018 dönemi arasındaki günlük kapanış değerleri kullanılmış ve her üç modelin de borsa endeks hareket yönünü tahmin etmede kullanılabilir olduğu sonucuna ulaşılmıştır.

Literatürdeki makine öğrenmesi modelleri kullanılarak yapılan çalışmalar incelendiğinde, DVM'lerin geleneksel makine öğrenme modellerinden daha yüksek performans sergilediği ve sınıflandırma problemlerini çözmek için güçlü araçlar oldukları görülmüştür.

3. Destek Vektör Makineleri

Bir DVM ilk önce giriş noktalarını yüksek boyutlu bir özellik alanına eşler ve bu alandaki iki sınıf arasındaki marjı maksimize eden bir ayırıcı hiper düzlem bulur. Marjı maksimuma çıkarmak, ikinci dereceden bir programlama (QP) problemidir ve Lagrangian çarpanları ile ikili probleminden çözülebilir. Herhangi bir haritalama bilgisi olmadan DVM, nokta ürün fonksiyonlarını çekirdek olarak adlandırılan özellik alanında kullanarak en uygun hiper düzlemi bulur. Optimal hiper düzlemin çözümü, destek vektörleri olarak adlandırılan birkaç giriş noktasının bir kombinasyonu olarak yazılabilir. DVM'de en temel sınıflandırma problemi, doğrusal olarak ayrılabilen "iki sınıflı" bir veri setinin sınıflandırılmasıdır (Lin & Wang, 2002, s. 465-466).

Verilen bir x_i eğitim vektörü için, $x_i \in C_1$ ise $w^t x_i + b$ pozitif ve $x_i \in C_2$ ise $w^t x_i + b$ olacaktır. Her x_i için bir y_i seçildiğinde (Mohammed vd., 2017, s. 115-128);



$$y_i = \begin{cases} 1, & x_i \in C_1 \\ 0, & x_i \in C_2 \end{cases} \quad (1)$$

y_i 'nin bu seçimi altında;

$$y_i(w^T x_i + b) > 0 \quad (2)$$

x , eğitim alanındaki herhangi bir nokta ise, hiper düzlemden uzaklığı aşağıdaki formülle bulunur;

$$z = \frac{|\omega^T x + b|}{\|\omega\|} \quad (3)$$

Eğer x ile hiper düzlem arasındaki mesafenin δ gibi bir pozitif değerden daha büyük olması istenirse, aşağıdaki eşitsizliğe sahip oluruz;

$$\frac{|\omega^T x + b|}{\|\omega\|} \geq \delta \quad (4)$$

Yukarıdaki denklemden $|w^T x + b| > \delta \|\omega\|$ eşitsizliğini elde ederiz. $\delta \|\omega\| = 1$ için aşağıdaki eşitsizliği elde ederiz;

$$w_T x + b \geq 1 \quad (5)$$

Yukarıdaki eşitsizlikten;

$$1. \quad w_T x + b \geq 1, \quad x \in C_1 \quad (6)$$

$$2. \quad w_T x + b \leq -1, \quad x \in C_2 \quad (7)$$

Hem C_1 hem de C_2 sınıflarından hiper düzleme en yakın özellik vektörleri destek vektörleri olarak adlandırılır ve DVM'lerin tasarımında ana rol oynarlar. Yukarıdaki denklemde eşitlik ancak x vektörü bir destek vektörü ise gerçekleşir. Bu nedenle, DVM yöntemindeki temel fikir, hiper düzlem ile destek vektörleri arasındaki mesafeyi maksimize ederek elde edilebilecek marjı maksimize etmektir. Hiper düzlem ve bir nokta arasındaki mesafe x tarafından verildiğinden x aşağıdaki formül yardımıyla bulunur;

$$z = \frac{|\omega^T x + b|}{\|\omega\|} \quad (8)$$

z , aynı anda $\|\omega\|$ 'nin minimize b 'nin maksimize edilmesiyle maksimum değer ulaşır. Optimal hiper düzlemi tasarlamak için öncelikle $\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$ eğitim setine sahip olduğumuzu varsayıyoruz. Bu durumda aşağıdaki Quadratic Programlama (QP) denklemini çözmeliyiz;

$$\min_{w \in \mathbb{R}^m} \frac{1}{2} \|w\|^2 \quad (9)$$

n eşitsizlik kısıtlarına tabi olmakla birlikte;

$$y_i(w^T x_i + b) \geq 1, \quad \forall i = 1, 2, \dots, n \quad (10)$$

Lagrangian çarpanları ile çözülebilir;



$$L(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^n \alpha_i [y_i (w^T x_i + b - 1)] \quad (11) \quad \alpha_i \text{ eşitsizliğe}$$

göre Lagrange çarpanıdır. $L(w, b, \alpha)$ 'nın w ve b 'ye göre diferansiyelini alarak sonuçları sıfıra eşitlersek, iki optimallik koşulu elde ederiz;

$$1. \frac{\partial L}{\partial b} = (\hat{w}, \hat{b}, \hat{\alpha}) = 0 \quad (12)$$

$$2. \frac{\partial L}{\partial w} = (\hat{w}, \hat{b}, \hat{\alpha}) = 0 \quad (13)$$

Lagrange çarpanını genişletirsek;

$$L(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^n \alpha_i y_i w^T x_i - \sum_{i=1}^n \alpha_i y_i b + \sum_{i=1}^n \alpha_i \quad (14)$$

aşağıdaki koşulları uygularsak;

$$\frac{\partial L}{\partial b} (\hat{w}, \hat{b}, \hat{\alpha}) = 0 \quad (15)$$

$$\sum_{i=1}^n \hat{\alpha}_i y_i = 0 \quad (16)$$

$$\frac{\partial L}{\partial w} (\hat{w}, \hat{b}, \hat{\alpha}) = 0 \quad (17)$$

aşağıdaki denklemleri elde ederiz;

$$\hat{w} = \sum_{i=1}^n \hat{\alpha}_i y_i x_i \quad (18)$$

Yukarıdaki \hat{w} denkleminde, optimal ağırlığın, $i = 1, \dots, n$ için eğitim setinin (x_i, y_i) doğrusal bir birleşimi olduğunu gösterir. Kuhn-Tucker teoremine göre, optimal çözümde, yalnızca eşitlik kısıtlamaları, sıfır olmayan Lagrange çarpanlarına sahip olabilir.

$$\hat{\alpha}_i (y_i (\hat{w}^T x_i + b) - 1) = 0 \quad (19)$$

Eğer $\hat{\alpha}_i \neq 0$ ise;

$$\hat{\alpha}_i (y_i (\hat{w}^T x_i + b) - 1) > 0 \quad (20)$$

$$\hat{\alpha}_i = 0, \quad (21)$$

S_v 'nin destek vektörleri kümesi olduğunu ve x_k nin S_v 'ye ait olmadığını varsayalım, ardından $y_k (\hat{w}^T x_k + b) > 1$, ve α_k katsayısının 0 olması istenir. Diğer yandan eğer $x_i \in S_v$ ise; $y_i (\hat{w}^T x_i + b) - 1 = 0$ ve α_i 'nin 0 olmaması istenir. Lagrange denkleminde (\hat{w}, \hat{b}) kullanılarak denklem yeniden düzenlenirse;

$$L(\hat{w}, \hat{b}, \alpha) = j(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) \quad (22)$$

Lagrange çarpanları için en uygun seçenek, Lagrange çarpanlarının negatif olmayan kısıtlamalarına bağlı olarak $J(\alpha)$ 'yı maksimize ederek elde edilir. QP problemini çözmek için;

$$\max \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) \quad (23)$$

Kısıtlamalara bağlı olarak;



$$\alpha_i \geq 0 \text{ ve } \sum_{i=1}^n \alpha_i y_i = 0 \quad (24)$$

Optimal Lagrange çarpanlarının hesaplanması sürecinde sadece destek vektörleri yer aldığından, yukarıdaki optimizasyon problemi;

$$\max \sum_{i: x_i \in S_v} \alpha_i - \frac{1}{2} \sum_{i,j: x_i, x_j \in S_v} \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) \quad (25)$$

Kısıtlamalara bağlı olarak;

$$\alpha_i \geq 0 \quad (26)$$

$\alpha_i = 0$ olması ile birlikte, x_i bir destek vektör değilse,

$$\sum_{i: x_i \in S} \alpha_i y_i = 0 \quad (27)$$

Eğer $\hat{a} = (\hat{a}_1, \hat{a}_2, \dots, \hat{a}_n)$ optimal Lagrange çarpan vektörü ise,

$$\hat{w} = \sum_{i: x_i \in S_v} \hat{a}_i y_i x_i \quad (28)$$

x_i bir destek vektör ise,

$$\hat{b} = y_k - \hat{w}^T x_k \quad (29)$$

Son olarak, z herhangi bir sınıflandırılmamış eğitim vektörü ise, aşağıdaki sınıflandırma işlevi:

$$f(z) = \text{sign}(\sum_{i: x_i \in S_v} \hat{a}_i y_i x_i \cdot z + \hat{b}) \quad (30)$$

ve $K(x_i, x) = x_i \cdot x$, Doğrusal Kernel (Çekirdek) Fonksiyonu olarak adlandırılır. $|S| = s$ ve $\{x_1, x_2, \dots, x_s\}$, iki sınıf C_1 ve C_2 sınıflarından gelen destek vektörleri kümesidir. Açıkta ki;

$$\hat{w} \cdot x_k + b = y_k \quad (31)$$

veya eşdeğer olarak,

$$\sum_{j=1}^s \hat{a}_j \widehat{y}_j (x_j \cdot x_k) + b = y_k \quad (32)$$

$$\sum_{j=1}^s \hat{a}_j \widehat{y}_j K(x_j \cdot x_k) + b = y_k \quad (33)$$

s sayıda doğrusal denklem ile birlikte $s+1$ sayıda bilinmeyen ($\alpha_1, \alpha_2, \dots, \alpha_n$) ve b 'nin yukarıdaki denklemde formüle edildiğini görüyoruz. Buna ek olarak aşağıdaki denklemi de yazarız;

$$y_1 a_1 \dots + y_s a_s = 0 \quad (34)$$

Bununla beraber; optimal ağırlık \hat{w} ve optimal yönelim değeri \hat{b} lineer sistem çözülerek elde edilir;

$$Ma = b \quad (35)$$

$M \in R^{(s+1)(s+1)}$, $b \in R^{(s+1)}$ ve $a \in R^{(s+1)}$ aşağıdaki gibi tanımlanır;



$$M = \begin{bmatrix} y_1 K(x_1, x_1) & y_2 K(x_2, x_1) & \dots & \dots & y_s K(x_s, x_1) & 1 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ y_1 K(x_1, x_s) & y_2 K(x_2, x_s) & \dots & \dots & y_s K(x_s, x_s) & 1 \\ y_1 & y_2 & \dots & \dots & y_s & 0 \end{bmatrix} \quad (36)$$

$$a = \begin{bmatrix} \alpha_1 \\ \vdots \\ \alpha_s \\ b \end{bmatrix}, \quad b = \begin{bmatrix} y_1 \\ \vdots \\ y_s \\ 0 \end{bmatrix} \quad (37)$$

Optimum ağırlık \hat{w} ve optimal yönelim değeri \hat{b} aşağıdaki doğrusal sistemin çözülmesiyle elde edilebilir:

$$Ma = b \quad (38)$$

Doğrusal olmayan ve ayrıştırılamayan verilerin işlenmesinde çok verimli olan başka tür Kernel fonksiyonları da kullanılmaktadır.

4. Araştırmanın Amacı, Modeli ve Bulguları

Bu çalışmada BIST100 endeksi ile birlikte Dünyanın önde gelen borsa endekslerinden S&P 500, DAX ve NIKKEI 225 endekslerinin getiri yönlerinin sınıflandırılmasında makine öğrenme tekniklerinin kullanılması ve bu tekniklerin tahmin (sınıflandırma) performanslarının ortaya konulması amaçlanmıştır. Bu amaçla, bir makine öğrenme tekniği olan DVM, borsa endekslerinin yükseliş ve düşüş trendlerinin modellenmesinde kullanılmıştır. Ayrıca çalışmada, makroekonomik değişkenlerin borsa endekslerine olan etkileri analiz edilmiştir. Çalışmada değişkenler, makroekonomik göstergeler, politik, ekonomik ve sosyal olaylar dikkate alınarak seçilmiştir. Ayrıca Dünyanın önde gelen borsa endekslerinin getiri yönünü tahmin etmek amacıyla literatürde yer alan çalışmaların bulguları da bağımsız değişken seçiminde etkili olmuştur.

Çalışmada borsa endekslerinin getiri yönlerinin tahmini için ikili sınıflandırma kullanılmıştır. Bağımlı değişkenler, belirtildiği üzere borsa endekslerinin gün sonu kapanış değeri üzerinden bir önceki güne göre hesaplanan "yükseliş" ve "düşüş" sinyalleridir. Endeks getirisi bir önceki ay sonundaki değerine göre pozitif yönlü olduğunda "yukselecek", negatif yönlü olduğunda ise "dusecek" olarak kodlanmıştır. Dolayısıyla bağımlı değişken bir sayısal değişken olmayıp, sözel nitelikli bir değişkendir. Bu endekslerin getiri yönlerinin tahmininde uluslararası endekslerden (MSCI Dünya Endeksi, MSCI AC Küresel Öz sermaye Endeksi ve MSCI Avrupa Endeksi) ve makroekonomik göstergelerden (USD/YEN, EUR/USD, Ons Altın Fiyatı, Brent Ham Petrol Fiyatı ve ABD 10 Yıllık Tahvil Faizi) oluşan 8 bağımsız değişken kullanılmıştır. Çalışmada kullanılan bağımlı ve bağımsız değişkenler Tablo 1'de verilmiştir.



Tablo 1: Modelde Kullanılan Bağımlı ve Bağımsız Değişkenler

Bağımlı Değişkenler	Açıklama
BIST100	Borsa İstanbul'da işlem gören piyasa değeri ve işlem hacmi bakımından en büyük 100 şirketin hisse senetlerinden oluşan borsa endeksidir.
S&P 500	500 büyük Amerikan şirketin hisse senetlerinden oluşan borsa endeksidir. Amerikan hisse senedi piyasasının yaklaşık %75'ini kapsar
DAX	Frankfurt Menkul Kıymetler Borsası'nda işlem gören 30 büyük Alman şirketinin hisse senetlerinden oluşan borsa endeksidir.
NIKKEI 225	Tokyo Menkul Kıymetler Borsası'nda (TSE) işlem gören 225 yüksek sermayeli hisse senedinin bileşik fiyat performansını ölçmektedir.
Bağımsız Değişkenler	Açıklama
USD/YEN	Uluslararası piyasalardaki Dolar/Yen paritesini göstermektedir.
EUR/USD	Uluslararası piyasalardaki Avro/Dolar paritesini göstermektedir.
Ons	Uluslararası piyasalarda 1 ons altının (31,10 gram) Dolar cinsinden değerini göstermektedir.
Brent Petrol	Dünya piyasası için referans petrol türlerinden biri olan Brent Petrol'ün Dolar cinsinden değerini göstermektedir.
ABD 10 Yıllık Tahvil	ABD Hükümeti tarafından Dolar cinsinden ihraç edilen ve 10 yıl vadeli olan Amerikan tahvil faizlerini göstermektedir.
MSCI Dünya Endeksi (MSCI World Index)	23 gelişmiş ülke piyasası üzerinden hesaplanan geniş küresel sermaye endeksidir. Her bir ülkede halka açıklık oranlı serbest piyasa değerinin yaklaşık %85'ini kapsamaktadır (MSCI, 2019a).
MSCI AC Küresel Öz sermaye Endeksi (MSCI ACWI Index)	23 gelişmiş ve 26 gelişmekte olan piyasada büyük ve orta büyüklükteki hisse senetlerinin performansını temsil etmektedir. 11 sektör ve yaklaşık 2.700'den fazla bileşeni kapsar ve her bir ülkedeki halka açıklık oranlı serbest piyasa değerinin yaklaşık %85'ini kapsamaktadır (MSCI,2019b).
MSCI Avrupa Endeksi (MSCI Europe Index)	Avrupa'daki 15 gelişmiş ülkede büyük ve orta büyüklükteki hisse senetlerinin performansını temsil etmektedir. Her bir ülkede halka açıklık oranlı serbest piyasa değerinin yaklaşık %85'ini kapsamaktadır (MSCI, 2019c).

BIST100, S&P 500, DAX ve NIKKEI 225 borsa endeks değerleri, USD/YEN paritesi, EUR/USD paritesi, Ons altın USD değeri, Brent Ham Petrol fiyatları (USD) ve ABD 10 Yıllık Tahvil faiz oranları www.investing.com internet adresinden; MSCI Dünya Endeksi, MSCI AC Küresel Öz sermaye Endeksi



ve MSCI Avrupa Endeksi değerleri ise www.msci.com internet adresinden elde edilmiştir.

Çalışmanın veri seti, bağımlı ve bağımsız değişkenlerin 01.01.2013–30.11.2019 yılları arasındaki aylık 82 adet gözlem değerini içermektedir. Bu gözlemlerin 70 adedi (%85'i) algoritmanın modellenmesi (eğitim) için, 12 adedi (%15'i) ise sınıflandırma (test) için kullanılmıştır. Uygulama için dünyada yaygın bir şekilde kullanılan veri madenciliği ve makine öğrenimi yazılımı olan açık kaynak kodlu veri madenciliği yazılımlarından Weka 3.8 programı kullanılmış olup, elde edilen bulgular Tablo 2’de gösterildiği gibidir.

Tablo 2: Örnek Bulgular Tablosu

Endeksler	Karıştırma Matrisi			Doğru Sınıflandırma		Genel Sınıflandırma Başarısı		OMH *	OKH**
	Durum	Yükseliş	Düşüş						
DAX	Yükseliş	6	1	%85,71	6/7	9/12	%75	%40,67	%43,95
	Düşüş	2	3	%60	3/5				
S&P500	Yükseliş	8	1	%88,89	8/9	9/12	%75	%37,72	%41,89
	Düşüş	2	1	%33,33	1/3				
BIST100	Yükseliş	4	0	%100	4/4	6/12	%50	%49,52	%49,79
	Düşüş	6	2	%25	2/8				
NIKKEI225	Yükseliş	5	2	%71,42	5/7	5/12	%41,7	%47,04	%53,55
	Düşüş	5	0	%0	0/5				

* OMH (Ortalama Mutlak Hata) = $\sum_{i=1}^n |y - \hat{y}_t| / n$; y: Gerçek değeri, \hat{y}_t : Tahmin değerini, n: Gözlem sayısını ifade etmektedir.

** OKH (Ortalama Karekök Hatası) = $\sqrt{\sum_{i=1}^n |y - \hat{y}_t|^2 / n}$; y: Gerçek değeri, \hat{y}_t : Tahmin değerini, n: Gözlem sayısını ifade etmektedir.

Modelin başarısı, doğru sınıfa atanan örnek sayısı ve yanlış sınıfa atanan örnek sayılarıyla ilgilidir (Başarı & Bayramoğlu, 2018, s. 338). Tablo 2’ye göre getirilerin gelecek dönem “yükseliş” mi yoksa “düşüş” mü göstereceğine ilişkin sınıflandırma oranlarına bakıldığında DAX ve S&P 500 endekslerinin genel sınıflandırma başarısının %75 (9/12) ile en iyi, BIST100 endeksinin %50 (6/12) ile ikinci ve NIKKEI 225 endeksinin ise %41,7’lik başarı oranı ile en kötü sınıflandırma başarısına sahip olduğunu söyleyebiliriz. Modelin genel başarısına baktığımızda, yükseliş tahminlerinde daha başarılı olduğunu söylemek mümkündür. Model “yükseliş” ile ilgili sınıf tahmininde, DAX endeksi için 7 test değeri kullanmış olup, bu test değerlerinin 6’sı “yükseliş” trendi ile sonuçlanmışken sadece 1’i “düşüş” trendine girmiş (6/7), S&P 500 endeksi için 9 test değeri kullanmış olup 8 test değeri doğru sınıflandırılmış (8/9),



BIST100 endeksi için 4 test değeri kullanmış olup 4'ü de doğru sınıflandırılmış (4/4) ve son olarak NIKKEI 225 endeksi için 7 test değeri kullanmış olup 5'i de doğru sınıflandırılmıştır (5/7).

Model, "düşüş" ile ilgili sınıflandırma tahminlerine baktığımızda en iyi sınıflandırma performansını 5 test değerinin 3'ünün "düşüş" göstereceğini doğru sınıflandıran (3/5) DAX endeksinde, en kötü performansı ise "düşüş" yönünde sınıflandırdığı 5 test değerinden hiçbirinin bu trend yönünde hareket etmediği belirlenen (0/5) NIKKEI 225 endeks tahmininde göstermiştir.

Tablo 2'ye göre; modellerin Ortalama Mutlak Hata değerlerine bakıldığında S&P 500 endeks sınıf tahminin en düşük (%37,72), BIST100 endeks sınıf tahminin ise en yüksek değerlere (%49,52) sahip olduğu; Ortalama Karekök Hatası değerlerine baktığımızda ise yine S&P 500 endeks sınıf tahminin en düşük (%41,89), NIKKEI 225 endeks sınıf tahmininin ise en yüksek değerlere (%53,55) sahip olduğu görülmektedir.

Doğruluk Oranı, F Ölçütünün büyüklüğü, ROC (Receiver Operating Characteristic) Alan Değeri ve Kappa İstatistik Değeri modelin başarı göstergelerindedir. ROC Alan Değeri ne kadar büyük ise sistemin güvenilirliği de artmaktadır. Birden fazla model kullanarak değerlendirme yapmak istendiğinde, bu ölçütlerden en iyi sonuçları veren modelin en iyi sınıflandırma tahmini yaptığını söylemek mümkündür. Tablo 3'te gösterildiği üzere, modellerin genel başarısını değerlendirirken Doğruluk, F-Ölçütleri, ROC Alan Değerleri ve Kappa İstatistik Değerleri kullanılmaktadır. En iyi performansı gösteren DAX endeksinin getiri yönünün tahmin edilmeye çalışıldığı modelin doğruluk oranı %75, F-Ölçütü %74,4 ve ROC Eğrisi altında kalan alan değeri 0,743 bulunmuştur. En kötü performansı gösteren NIKKEI 225 endeksinin getiri yönünü tahmin etmeye çalışan modelin doğruluk oranı ise %41,7, F-Ölçütü %34,3 ve ROC Eğrisi altında kalan alan değeri 0,629 olarak bulunmuştur. Bu sonuçlara göre model, en iyi performansı DAX endeks getiri yönü sınıflandırma tahmininde, en kötü performansı ise NIKKEI endeks getiri yönü sınıflandırma tahmininde göstermiştir. Borsa endeksleri sınıf tahmin modellerinin Kappa İstatistik Değerleri incelendiğinde DAX'ın 0,4706 (orta düzeyde uyum olması), S&P 500'ün 0,25 (zayıf düzeyde uyum olması), BIST100'ün 0,1818 (Önemsiz düzeyde uyum) ve NIKKEI 225'in ise -0,3125 (Şansa bağlı uyum) değerlerine sahip olduğunu görmekteyiz.

Tablo 3: Model Başarım Ölçütleri

	Doğruluk	F Ölçütü	ROC Alan Değeri	KAPPA İstatistiği (k)*
DAX	%75	0,744	0,743	0,4706



S&P 500	%75	0,732	0,741	0,25
BIST100	%50	0,457	0,781	0,1818
NIKKEI 225	%41,7	0,343	0,629	-0,3125

* k istatistiği deęer aralıkları ve uyum durumları şöyledir; <0: Şansa baęlı uyum; 0.01-0.20: Önemsiz düzeyde uyum; 0.21-0.40: Zayıf düzeyde uyum; 0.41-0.60: Orta düzeyde uyum; 0.61-0.80: İyi düzeyde uyum; 0.81-1.00: Çok iyi düzeyde uyum.

Literatürde birden fazla Kernel fonksiyonu kullanılmaktadır. Ancak her Kernel fonksiyonunu DVM modelleri için uygun deęildir. Dolayısıyla, DVM'nin uygulanmasında Kernel fonksiyonunun seçimi oldukça önemlidir. Çalışmamızda Lineer Kernel fonksiyonu kullanılmış olup sonuçları Tablo 4'te gösterilmiştir.

Tablo 4: Kernel Fonksiyonlarına İlişkin Parametreler

	Kernel Sınıflandırma Performansı
DAX	919 (%81,57)
S&P 500	1269 (%81,52)
BIST100	794 (%62,86)
NIKKEI225	1040 (%79,48)

Bu çıktı her bir endeks yönü sınıflandırma tahmini için DVM modellerinin doğrusal karar sınırlarını göstermektedir. Lineer Kernel fonksiyonu çıktıları dikkate alındığında Model sırasıyla DAX endeksi için 919 (%81,579), S&P 500 endeksi için 1269 (%81,523), BIST100 için 794 (%62,86) ve NIKKEI 225 endeksi için 1040 (%79,483) sınıflandırma performansı göstermiştir.

5. Sonuç

DVM'ler en çok kullanılan makine öğrenme algoritmalarından birisidir. DVM'lerin finans alanında borsa endeks tahmini, finansal krizlere karşı erken uyarı sistemi, finansal başarısızlık tahmini gibi birçok alanda istatistiki yöntemlere göre daha başarılı sonuçlar ortaya koyduğu belirlenmiştir (Min ve Lee 2005; Huang vd. 2005; Hua vd. 2007; Öğüt vd. 2009; Lu vd. 2009). Borsa yatırımcılarının endekslerin "yükseliş" ve "düşüş" trendlerini doğru tahmin etmeleri (sınıflandırmaları), borsada doğru pozisyon almalarını sağlayacak ve böylece getirilerini arttırabileceklerdir.

Literatürde yapılan çalışmalara bakıldığında DVM'lerin etkili bir sınıflandırıcı olduğu ve borsa endeks tahmininde modellenebileceği tespit edilmiştir. Modelin genel başarısına baktığımızda yükseliş tahminlerinde daha başarılı olduğunu söylemek mümkündür. Modelin "yükseliş" yönlü başarı tahmininin diğer çalışma sonuçları (Huang vd. 2005; Min vd. 2006; Hua vd. 2007; Öğüt vd. 2009; Özdemir vd. 2011; Karagül 2013; Henrique vd. 2018; Yürük ve Ekşi 2019; Aksoy ve Boztosun 2019) ile uyumlu olduğu,



ancak “düşüş” yönlü tahminlerinde aynı başarıyı göstermediğini söyleyebiliriz. Genel sınıflandırma başarı ortalamalarına baktığımızda modelin, DAX ve S&P 500 endeks yönlerinin tahmininde %75 ile en iyi performansı gösterdiği, NIKKEI 225 endeks yönü tahmininde ise %41,7 ile en kötü performansı gösterdiğini görmekteyiz. Bununla birlikte BIST100 endeks yönü tahmininde “yükseliş” trendinin test değerleri üzerinde %100 başarı gösterdiği (4/4), ancak “düşüş” trend tahmini başarısızlığı nedeniyle genel başarı ortalamasının %50 ‘de kaldığı gözlemlenmektedir. Bu analizler yapılırken modelin kullandığı test değerleri sayısının azlığı da göz önünde bulundurulmalıdır.

Sonuç olarak DVM yöntemi yardımıyla BIST100 ve dünyanın önde gelen borsa endekslerinden S&P 500, DAX ve NIKKEI 225 endeks “yükseliş” ve “düşüş” trend yönü tahmininde bulunmaya çalıştığımız modelimizin genel başarı ortalaması %60,43 olmuştur. Literatürde DVM modelleri kullanılarak yapılan çalışmalara baktığımızda sınıflandırma başarısının %70 ‘in üzerinde çıkmasının (Özdemir vd., 2011; Yürük ve Ekşi, 2019; Karagül, 2013) modelin başarılı bir performans gösterdiği sonucunu ortaya koymaktadır. DAX ve S&P 500 endeks yönü genel başarı performanslarının %75 çıkması modelin, bu endekslerin trend yönü tahmininde başarılı olduğu ancak BIST100 ve NIKKEI 225 endeks yönü tahmin performanslarının genel başarı ortalamalarının %50 ve altında çıkması nedeniyle bu endekslerin trend yönü tahminlerinde ise başarısız olduğu söylenebilir.

Çalışmamız bu sonuçlarıyla literatüre katkı sağlamış olup, DVM modelinin içinde bulunduğu hibrit modeller oluşturularak ve veri setleri genişletilerek çeşitli varlık (döviz, altın, hisse senedi...) fiyat hareketlerinin tahmin performanslarının iyileştirilmesi mümkün olabilecek, bu da çeşitli piyasalarda yatırım yapmak isteyen yatırımcılara yol gösterecektir. Böylece yatırımcıların finansal kararlar vermesinde ve bu kararlar yardımıyla oluşturulan yatırım stratejileri sayesinde yüksek getiri elde etmeleri sağlanabilecektir.

Kaynakça / Reference

Ahn, J. J., Oh, K. J., Kim, T. Y., & Kim, D. H. (2011). Usefulness of Support Vector Machine to Develop An Early Warning System for Financial Crisis. *Expert Systems with Applications*, 38(4), 2966-2973.

Aksoy, B., & Boztosun, D. İmalat İşletmelerinde Makine Öğrenmesi Yöntemleri Kullanılarak Finansal Başarısızlık Tahmini ve Sınıflandırma Performansının Karşılaştırılması: Borsa İstanbul Örneği. 2. Uluslararası Bankacılık Kongresi, Hitit Üniversitesi, 19-20 Nisan 2019, Çorum, 11-18.



- Altınırnak, S., & Karamaşa, Ç. (2016). Bankaların Finansal Başarısızlıklarının İncelenmesinde Makine Öğrenme Tekniklerinin Karşılaştırılması. *Balıkesir Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 19(36), 291-304.
- Apaydın, E. (2014). *Introduction to Machine Learning*. Third Edition, The MIT Press Cambridge, Massachusetts London, England.
- Ayhan, S., & Erdoğan, Ş. (2014). Destek Vektör Makineleriyle Sınıflandırma Problemlerinin Çözümü İçin Çekirdek Fonksiyonu Seçimi. *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 9(1), 175-201.
- Bayramoğlu, A.T., & Başarır, Ç. (2019). *Blockchain Economics and Financial Market Innovation Financial Innovations in the Digital Age: The Linkage Between Cryptocurrencies and Macro-Financial Parameters: A Data Mining Approach*. Springer Nature Switzerland, 249-269.
- Basarir, C., & Bayramoglu, M. F. (2018). *Global Approaches in Financial Economics, Banking, and Finance: Global Macroeconomic Determinants of the Domestic Commodity Derivatives*. Springer, Cham, 331-349.
- Burbidge, R., Trotter, M., Buxton, B., & Holden, S. (2001). Drug Design by Machines Learning: Support Vector Machines for Pharmaceutical Data Analysis. *Computer and Chemistry* 26, 5-14.
- Cao, L. J. (2003). Support Vector Machines Experts for Time Series Forecasting. *Neurocomputing*, 51, 321-339.
- Henrique, B. M., Sobreiro, V. A., & Kimura, H. (2018). Stock Price Prediction Using Support Vector Regression on Daily and up to The Minute Prices. *The Journal of finance and data science*, 4(3), 183-201.
- <https://www.investing.com>, (Erişim Tarihi: 15.12.2019).
- Hua, Z., Wang, Y., Xu, X., Zhang, B., & Liang, L. (2007). Predicting Corporate Financial Distress Based on Integration of Support Vector Machine and Logistic Regression. *Expert Systems with Applications*, 33(2), 434-440.
- Huang, W., Nakamori, Y., & Wang, S. Y. (2005). Forecasting Stock Market Movement Direction with Support Vector Machine. *Computers and Operations Research*, 32(10), 2513-2522.
- Jordan, M., Kleinberg, J., & Scholkopf, B. (2008). *Support Vector Machines*. Information Science and Statistics. New York: Springer.
- Karagül, K. (2014). İstanbul Menkul Kıymetler Borsası'nda İşlem Gören Firmaların Destek Vektör Makineleri Kullanılarak Sınıflandırılması. *Pamukkale University Journal of Engineering Sciences*. 20(6), 174-178.
- Kim, K. J. (2003). Financial Time Series Forecasting Using Support Vector Machines. *Neurocomputing*, 55(1-2), 307-319.



- Lin, C. F., & Wang, S. D. (2002). Fuzzy Support Vector Machines. *IEEE Transactions on Neural Networks*, 13(2), 464-471.
- Lu, C. J., Lee, T. S., & Chiu, C. C. (2009). Financial Time Series Forecasting Using Independent Component Analysis and Support Vector Regression. *Decision Support Systems*, 47(2), 115-125.
- Min, J. H., & Lee, Y. C. (2005). Bankruptcy Prediction Using Support Vector Machine with Optimal Choice of Kernel Function Parameters. *Expert Systems with Applications*, 28(4), 603-614.
- Min, S. H., Lee, J., & Han, I. (2006). Hybrid Genetic Algorithms and Support Vector Machines For Bankruptcy Prediction. *Expert Systems With Applications*, 31(3), 652-660.
- Mohammed, M., Khan, M. B., & B., E. B. M. (2017). *Machine Learning Algorithms and Applications*. Taylor & Francis Group, FL., U.S.A.
- MSCI, 2019a, <https://www.msci.com/acwi>, (Erişim Tarihi: 15.12.2019).
- MSCI, 2019b, <https://www.msci.com/developed-markets>, (Erişim Tarihi: 15.12.2019).
- MSCI, 2019c, <https://www.msci.com/developed-markets>, (Erişim Tarihi: 15.12.2019).
- Negnevitsky, M., (2005). *Artificial Intelligence: A Guide to Intelligent Systems*. 2nd Ed., London: Pearson Education Limited.
- Öğüt, H., Aktaş, R., Alp, A., & Doğanay, M. M. (2009). Prediction of Financial Information Manipulation By Using Support Vector Machine And Probabilistic Neural Network. *Expert Systems with Applications*, 36(3), 5419-5423.
- Özdemir, A. K., Tolun, S., & Demirci, E. (2011). Endeks Getirisi Yönünün İkili Sınıflandırma Yöntemiyle Tahmin Edilmesi: İMKB-100 Endeksi Örneği. *Niğde Üniversitesi İİBF Dergisi*, 4 (2), 45-59.
- Pabuççu, H. (2019). Borsa Endeksi Hareketlerinin Makine Öğrenme Algoritmaları ile Tahmini. *Uluslararası İktisadi ve İdari İncelemeler Dergisi*, (23), 179-190.
- Suykens, J. A., & Vandewalle, J. (1999). Least Squares Support Vector Machine Classifiers. *Neural processing letters*, 9(3), 293-300.
- Vapnik, V. (1998). *Statistical Learning Theory*. New York: Springer.
- Yakut, E., Elmas, B. ve Yavuz, S. (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.
- Yürük, M., F. & Ekşi, İ. H. (2019). Yapay Zeka Yöntemleri ile İşletmelerin Finansal Başarısızlığının Tahmin Edilmesi: BİST İmalat Sektörü Uygulaması. *Mukaddime*, 10(1), 393-422.

