

Makine Öğrenmesi Teknikleri ile Ülke Riski Tahmini

Country Risk Prediction with Machine Learning Techniques

Seyyide DOĞAN¹, Hasan TÜRE²

Öz

Ülke riski değerlendirmesi en genel anlamıyla bir ülkenin alabileceği dış yardımların ve yatırımcıların karşı karşıya kalacağı riskin bir ölçüsüdür. Bu sebeple ülke riskinin, ekonomik, finansal ve politik risk unsurlarının birlikte ele alındığı bir prosedürle oldukça hassas tahminler yapılarak ölçülmesi gerekmektedir. Tahmin yöntemi büyük bir titizlikle tercih edilmeli ve mutlaka farklı yöntemler ile desteklenmelidir. Bu amaçla çalışmada, iyi tahmin sonuçları üreten ve sıklıkla kullanılan LRA, KNN, CART ve DVM yöntemleri tercih edilmiştir. Tahmin modelini eğitmek için 2015-2019 yılları arasında 75 ülkenin farklı makroekonomik göstergeleri kullanılmıştır. Çalışmanın bulgularına göre tercih edilen tüm yöntemler ile oldukça başarılı tahmin sonuçlarının üretildiği söylenebilir. Farklı değerlendirme kriterlerinin ele alındığı ve her bir makine öğrenmesi algoritmasının 100 kez tekrar edildiği durumda, en iyi sonucu veren yöntem KNN algoritması olduğu görülmektedir. Takip eden yöntemler ise sırası ile DVM, LRA ve CART algoritması olarak sıralanabilir.

Jel Kodları: C45, C61, G24, G32

Anahtar Kelimeler: Ülke riski, Makine öğrenmesi, Destek vektör makinesi, K-yakın komşuluk, Lojistik regresyon, Karar ağaçları

¹ Dr, Karamanoğlu Mehmetbey Üniversitesi, İİBF, Uluslararası Ticaret ve İşletmecilik, dogans@kmu.edu.tr, ORCID: 0000-0001-7835-7905

² Doç. Dr, Ankara Hacı Bayram Veli Üniversitesi, İİBF, Ekonometri, hasan.ture@hbv.edu.tr, ORCID:0000-0002-1975-9063

Abstract

In a most general sense, country risk assessment is a measure of the foreign aid a country can receive and the risk the investors will face. Therefore, the related risk must be measured by making rather sensitive predictions with a procedure where economic, financial and political risks are taken into account. The prediction method must be chosen with great accuracy and supported with different methods. To that end, LRA, KNN, CART and DVM methods, which produce good estimation results and are frequently used, are preferred in country risk predictions. Different macroeconomic indicators of 75 countries between 2015 and 2019 are used to train the prediction model. According to the findings of the study, it can be said that quite successful prediction results are produced with all the chosen methods. When different assessment criteria are considered and each machine learning algorithm is repeated 100 times, it is seen that the KNN algorithm is the best method to produce results. The following methods can respectively be listed as DVM, LRA and CART.

Jel Codes: C45, C61, G24, G32

Keywords: Country risk, Machine learning, Support vector machine, K-nearest neighbor, Logistic regression, Decision trees

1. Giriş

Günümüzde hemen hemen hiçbir ekonominin dış yardım almadan kendi kendine yetemediği bilinmektedir. Otarşi olarak da adlandırılan bu durumun sağlanamamasının yanı sıra ülkelerin refah ve gelişmişlik açısından da gelişimlerini sürdürebilmeleri için dünyanın geri kalanı ile sağlıklı ilişkiler kurmaları gerektiği aşikardır. Küreselleşmenin de pozitif etkisiyle ekonomik, siyasi, askeri ya da kültürel olarak kurulan bu ilişkiler dünyanın en ücra köşesine kadar yayılabilmektedir. Kurulan bu ilişkilerin daha sağlam temellere dayanması için tarafların birbirlerine ne ölçüde güvenebileceklerini bilmeleri önem arz etmektedir. Bu bilgiler karar vericilerin ilişki kurulacak ülkenin sorumluluklarını yerine getirme noktasındaki kabiliyeti ya da istekliliği kısaca riski hakkında fikir sahibi olunmasına yardımcı olacaktır. Karşı karşıya kalınan bu risk ülke riski olarak tanımlanmakta ve uzun yıllardır farklı birçok yolla ölçülmeye çalışılmaktadır.

Literatürde ülke riski kavramının tanımlanması ve bu kavrama ilişkin ortak bir terminolojinin belirlenmesi noktasında henüz tam bir fikir birliği sağlanamamıştır. İlgili literatür incelendiğinde bu kavramı açıklamak için ülke riski (country risk) (Cooper, 1999; Oetzel vd., 2001; Yim & Mitchell, 2005), egemen risk (sovereign risk) (Hilscher & Nosbusch, 2010; Broner vd., 2010; Beirne & Fratzscher, 2013; Corsetti vd., 2013), politik risk (political risk) (Kobrin, 1979; Diamonte vd., 1996; Busse, 2007), sınır ötesi risk (cross-border risk) (Nikolov, 2016; Berg vd., 2015) gibi terimlerin sıklıkla kullanıldığı görülmektedir. Kimi zaman bu terimler aynı amaç için kullanılırken kimi zaman farklı durumları ifade etmek için tercih edilebilmektedir. Yapılan çalışmalar gözden geçirildiğinde sıklıkla ülke riski ve politik risk terimleriyle karşılaşılmaktadır.

Ülke riski kavramına ilişkin literatürde yapılmış çok fazla tanım olmakla birlikte bu tanımların bir özeti olarak; bir ülkenin veya belirli bir ülkeden borç alan kişinin, bir veya daha fazla yabancı borç verene ve/veya yatırımcıya karşı yükümlülüklerini yerine getirememesi ve/veya istememesi olasılığı olarak ifade edilmektedir (Krayenbuehl, 1985).

Son yıllarda özellikle gelişmekte olan ülkelerin ciddi borç krizlerine ve borç yeniden yapılandırılmalarına tanık olduğu; Dünya Bankası ve IMF gibi resmi kurumlardan alınan kredilerinin (1973 petrol krizi, 1994 Meksika Peso krizi, 1997-1998 yıllarında Asya krizi vb.) zamanında ve tam olarak ödenemediği gözlenmektedir (Sun vd., 2021). Bu yeni gelişmeler ışığında ülke riskinin ve onun ticari ve ekonomik faaliyetler aracılığı ile küresel ölçekli etkilerinin araştırılmasına duyulan ihtiyaç giderek artmakta ve ticari bankalar, politika yapıcılar ve araştırmacılar için ülke riski değerlendirmesi daha önemli bir konu haline gelmektedir. Ayrıca ülke riski derecelemelerinin bilgi asimetrisini azalttığı ve tahvil ihraçlarını ve sözleşmelerini etkilediği için dünya çapındaki finansal piyasalarda kullanılan en önemli göstergelerden biri olarak da kabul edilmektedir (Frascaroli & Olivere, 2017; Silva vd., 2019). Ülkenin dış borç yükümlüğünü zamanında yerine getirip getirmeyeceğinin önemli bir ölçüsü olarak da kabul edilen ülke kredi notu hem ilgili ülkeyi hem de bu ülke ile ekonomik, finansal ve politik faaliyetleri olan diğer pek çok ülkeyi etkileyebilmesinden dolayı çok boyutlu bir etkiye sahip olmaktadır (Hoti & McAleer, 2004; Amstad & Packer, 2015).

Bu amaçla yapılan ülke riski analizlerinin genel durumu yansıtan uluslararası iş risklerini ve bu risklerin ülkedeki yatırımların karlılığı ve getirileri üzerindeki kümülatif etkilerini tanımlayabilme kapasitesine sahip olduğu kabul edilmektedir (Asiri, 2014). Dereceleme kuruluşları tarafından geçmiş cari, nitel ve nicel değişkenlere dayanarak hazırlanan ve geleceğe yönelik bağımsız görüşler sunan kredi notları şirket, ülke ve finansal kurumlar gibi fon talep edenlerin kredi değerliliğinin, yatırım risklerinin ve temerrüt olasılığının bir ölçüsü olarak finansal piyasalarda yaygın olarak kullanılmaktadır (Moody's, 2021). Yalnızca bir değerlendirme olarak görülmemesi gereken ülke riski notunun yanlış tahmin edilmesinin ortaya çıkaracağı sonuçların, kurumların yönetiminin ve sermaye tercihlerinin, deniz aşırı yatırımların ve ticari iş birliklerinin üzerinde önemli bir etkiye sahip olacağı unutulmamalıdır (Öztürk vd., 2016; Sun vd., 2021).

Oldukça fazla sayıda kredi dereceleme kuruluşu (KDK) olmasına karşın Moody's ve Standard ve Poor's ve Fitch gibi üç büyük derecelendirme kuruluşu bu pazarın yaklaşık %80'ini elinde bulundurmaktadır. Frascaroli & Olivera (2017)'de ifade edildiği gibi bu oligopolistik yapı bazı yan etkileri de beraberinde getirmektedir. Birçok araştırmacı, yazar ve politikacı, KDK'larını şeffaf olmayan metodolojiler kullanmaları, siyasi kararlar vermeleri, finansal istikrarsızlığa sebep olabilecek ani kredi notu değişiklikleri yapmaları, krizleri tahmin edememeleri, krizlerin ekonomik etkilerini derinleştirmeleri ve kâr amacı gütmeleri gibi sebeplerden eleştirmektedir (Sy, 2009; Arezki vd., 2011; Belotti vd., 2011; Tichy vd., 2011; Doluca, 2014; Cunha vd., 2020). Ülke kredi notlarına olan güvensizliğin ve tartışmaların artması ile araştırmacılar kredi notlarının şeffaf ve objektif bir ortamda değerlendirildiği alternatif modellerin geliştirilmesi üzerinde çalışmaktadır. Ülke notlarının doğruluğu konusundaki argümanların artması, KDK'larına aşırı bağımlılıktan kaçınmak için daha fazla kredi puanlama sistemine ihtiyaç olduğunu vurgulamaktadır (Öztürk vd., 2016).

Literatürde bu amaçla yapılmış birçok ampirik çalışma bulunmaktadır. Bu çalışmaların bazılarında ilgili ülkeler risk durumlarına göre sıralandırılmakta (Doumpou & Zopounidis, 2002; Yim & Mitchell, 2005; Stankevičienė & Sviderskė, 2012; Lou & Kou, 2012; Stankevičienė vd., 2014; Svilokos & Rodić, 2015; Türe vd., 2017; Brauers & Lepkova, 2019), bazı çalışmalarda sınıflandırılmakta (Frank & Cline, 1971; Abassi & Taffler 1982; Cooper, 1999; Yim & Mitchell,



Doğan, S. & Türe, H. (2022). Makine Öğrenmesi Teknikleri ile Ülke Riski Tahmini. *Fiscaoeconomia*, 6(3), 1126-1151. Doi: 10.25295/fsecon. 1098493

2005), bazı çalışmalarda ise riskin belirleyicileri belirlenmeye (Feder & Just, 1977; Edwards, 1985; Brewer & Rivoli, 1990; Cosset & Roy, 1991; Oral vd., 1992; Lee, 1993a; Lee, 1993b; Rivoli & Brewer, 1997; Haque vd., 1998; Ramcharran, 1999; Easton & Rockerbie, 1999; Cooper, 1999; Oetzel vd., 2001; Yim & Mitchell, 2005; Vij, 2005) çalışılmaktadır.

Bu çalışma kapsamında ise bahse konu risk, ülke riski (country risk) olarak değerlendirilmiş ve bu kavram ile bir ülkeye yatırım yapmanın ya da borç vermenin ne derece riskli olacağı ölçülmeye çalışılmıştır. Bu noktada ölçülmek istenilen risk; borçlu ülkenin borçlarını ödeme noktasındaki istekliliği/isteksizliği, ya da yatırım yapılan (ev sahibi) bir ülkede yatırım yapan ülke, şirket ya da bireyin yatırımlarının ne derecede güvence altında olacağının değerlendirilebilmesi şeklinde olmaktadır. Bu riskin nicel olarak ölçülmesi noktasında ise ekonomik, finansal ve politik risk unsurlarının birlikte ele alındığı bir prosedür kullanılmıştır. Çalışmada, ülke kredi notlarını tahmin etmek için makine öğrenmesi yöntemlerden destek vektör makineleri (DVM), k-yakın komşuluk (KNN), sınıflandırma ve regresyon ağaçları (CART) ve geleneksel istatistiksel bir yöntem olan lojistik regresyon analizi (LRA)'nin ülke riski derecelenmede nasıl performans göstereceği araştırılmıştır.

Bu makale şu şekilde düzenlenmiştir: Bölüm 2'de, ampirik ve teorik literatürün bir tartışması yer almaktadır. Bölüm 3'te, ülke derecelendirmelerini sınıflandırmak için uygulanan DVM, CART, KNN sınıflandırma metodolojisi olan makine öğrenimi yöntemlerini ve geleneksel istatistiksel yöntemlerden LRA aktarılmaktadır. Bölüm 4'te ampirik sonuçları sunulmuş ve son olarak Bölüm 5'te ise sonuç tartışılmıştır.

2. Literatür

Ülke riski piyasa katılımcılarına önemli sinyaller verdiği için, bu konuda yapılacak analizlerin güvenilir ve yansız olması büyük önem arz etmektedir. Ülke riski potansiyel olarak ekonomik, sosyal, kültürel ve siyasi olmak üzere bir dizi karmaşık faktörü içermekle birlikte kabul görmüş net bir ülke riski modeli bulunmamaktadır. Araştırmacılar yeni ülke risk analizi ve değerlendirme modellerinin geliştirilmesine artan bir şekilde ilgi göstermektedir. Aşağıda bu çalışma için temel alınan öncü çalışmalardan bazıları kullanılan değişkenler (bağımlı ve bağımsız) ve elde edilen sonuçlar bakımından değerlendirilmesi verilmektedir.

Cosset & Roy (1991) çalışmasında, Euromoney ve Institutional Investor'ın sunduğu ülke riski derecelenmeleri ekonomik ve politik değişkenleri de dikkate alarak tekrar elde etmişlerdir. Çalışmada lojistik regresyon analizi kullanılıp açıklayıcı değişken olarak; kişi başına GSMH, yatırım eğilimi, rezervler/ithalat, cari işlemler dengesi/GSMH, ihracat büyüme oranı, ihracat değişkenliği, net dış borçlar/ihracat, borç servisi zorlukları ve politik istikrarsızlık göstergesi kullanılmıştır. Bağımlı değişken olarak ise Euromoney ve Institutional Investor'ün hesaplamış olduğu ülke riski skorları kullanılmıştır. Çalışmada kişi başına düşen gelir ve yatırım yapma eğilimi göstergelerinin ülke riski skorları üzerinde pozitif etkiye sahip olduğu sonucuna ulaşılmıştır.

Ülke riski alanında yapılmış bir diğer önemli çalışma olan Lee (1993a)'da ise, kredi dereceleme kuruluşları tarafından verilen kredi notları ile, borçluların (az gelişmiş ülkeler) borç yükümlülüklerini yerine getirme noktasındaki istekliliklerinin açıklanıp açıklanamayacağı doğrusal regresyon analizi ile araştırılmıştır. Çalışmada bağımlı değişken olarak kredi skorları



Doğan, S. & Türe, H. (2022). Makine Öğrenmesi Teknikleri ile Ülke Riski Tahmini. *Fiscaoeconomia*, 6(3), 1126-1151. Doi: 10.25295/fsecon. 1098493

kullanılırken, açıklayıcı değişken olarak; toplam dış borç/ihracat, kişi başına düşen GSYİH büyüme oranı, uluslararası borç verme faiz oranı, sanayileşmiş ülkelerin GSMH büyüme oranı, kişi başına düşen GSYİH'deki değişkenlik ve ortalama enflasyon oranı kullanılmıştır. Sonuç olarak kullanılan değişkenlerin kredi skorlarındaki değişimi açıklamada anlamlı sonuçlar verdiği görülmüştür.

Lee (1993b) çalışmasında ise lojistik regresyon analizi kullanılarak politik istikrarsızlığın ve ekonomik değişkenlerin algılanan ülke riski üzerindeki göreceli önemi araştırılmıştır. Bu amaçla 29 ülkeden oluşan veri seti için bağımlı değişken olarak Institutional Invest'in kredi derecelendirme skorları, açıklayıcı değişken olarak ise ekonomik göstergeler ve politik göstergeler kullanılmıştır. Ekonomik göstergeler; dış borç/GSMH, GSYİH büyümesi, yurtiçinde tutulan devlet borçları/GSYİH iken politik göstergeler; ilgili dönemdeki hükümet başkanı değişiklik sayısı, siyasi haklara ilişkin skorlar ve silahlı çatışma skorları olmuştur. Ayrıca siyasi istikrarsızlığı temsil eden rejim değişikliği ve silahlı çatışma sıklığının kredi notlarını etkilediği belirtilmiştir.

Bu alanda yapılmış bir diğer önemli çalışma olan Cantor & Packer (1996)'de regresyon analizi kullanılarak Standard ve Poor's ve Moody's gibi iki önemli kredi derecelendirme kuruluşu tarafından verilen kredi notlarının belirleyicileri ve etkileri değerlendirilmiştir. Çalışmada açıklayıcı değişken olarak kişi başına GSMH, GSYİH büyümesi, enflasyon, mali denge, dış denge, dış borç, ekonomik gelişmişlik göstergesi (IMF sınıflaması), döviz borcundaki temerrütler, devlet tahvili alınmışken bağımlı değişken olarak Moody's ve Standard and Poors derecelemeleri ve bu iki derecelemenin ortalaması kullanılmıştır. Ülke notlarının belirlenmesinde Standard ve Poor's ve Moody's in kullandıkları göstergelerden altısının önemli olduğu belirlenmiştir.

Haque vd. (1996) çalışmasında 60'tan fazla gelişmekte olan ülke için kredi notlarının belirleyicileri analiz edilmiştir. Ekonomik göstergelerden altın olmayan döviz rezervleri/ithalat, cari işlemler dengesi/GSYİH, büyüme ve enflasyonun kredi derecelendirmelerdeki değişimin büyük bir yüzdesini açıkladığı sonucuna ulaşılmıştır. Sonuç olarak tüm gelişmekte olan ülke derecelendirmelerinin uluslararası faiz oranlarındaki artıştan olumsuz etkilendikleri görülmüştür.

Haque vd. (1998) çalışmasında kredi derecelendirme kuruluşlarının yapmış oldukları derecelendirmelerin dayandığı ekonomik ve politik göstergelerin göreceli etkisi araştırılmaktadır. Modelde dış şokların ölçülebilmesi için; derecelendirmenin yapıldığı yıldan bir önceki yıldaki ticaret hadleri, 3 aylık ABD hazine bonusu oranı, dış sektör performansının ölçülmesi için; ihracat büyümesi, cari hesap/GSYİH, rezervler/ithalat, dış borç/GSYİH, derecelendirmenin yapıldığı yıldan bir önceki yıldaki reel döviz kuru, ekonomik performansın ölçülmesi için ise; büyüme ve enflasyon göstergeleri kullanılmıştır. Politik değişken olarak ise belirli bir yılda anayasaya aykırı olarak ya da zorla hükümet yönetimindeki değişiklik sayısı, üst düzey bir devlet görevlisinin veya politikacının siyasi olarak motive edilmiş herhangi bir cinayeti veya cinayete teşebbüsü, 1000 veya daha fazla sanayi veya hizmet işçisinin birden fazla işvereni içeren ve ulusal hükümet politikalarına veya otoritesine yönelik düzenlenen herhangi bir grev, bağımsız vatandaş grupları veya düzensiz güçler tarafından yürütülen ve mevcut rejimi devirmeyi amaçlayan herhangi bir silahlı faaliyet, sabotaj veya bombalama, mevcut rejimin çöküşünü tehdit eden herhangi bir hızla gelişen durum, rejim veya muhalefet

saflarında siyasi muhalefetin hapse atılması veya infaz edilmesi yoluyla sistematik olarak ortadan kaldırılması, fiziksel güç kullanımını da içeren 100'den fazla vatandaşın katıldığı herhangi bir şiddet gösterisi veya çatışması, üst düzey hükümet seçkinlerinin yasadışı zorla değişikliği, böyle bir değişiklik girişimi veya amacı merkezi hükümetten bağımsızlık olan başarılı veya başarısız herhangi bir silahlı isyan, hükümet politikaları veya otoritesine karşı olduklarını göstermek veya dile getirmek için en az 100 kişinin katıldığı herhangi bir barışçıl halk toplantısı ele alınmıştır.

Yim & Mitchell (2005) çalışmasında ise birçok ampirik yöntem birlikte kullanılarak sonuçların karşılaştırılmasına imkân sağlanmıştır. Çalışmanın örnekleme 20 yüksek riskli 32 düşük riskli ülkeye ait 31 göstergeden oluşmaktadır. Çalışmada diskriminant analizi, lojistik regresyon, yapay sinir ağları, kümeleme analizi, kohonen ağları ve melez (hibrit) yöntemler olmak üzere birçok farklı yöntem kullanılmıştır. Çalışmada melez yöntemin daha başarılı sonuçlar ortaya koyduğu sonucuna ulaşılmıştır.

Ülke riski alanında yapılan çalışmalara ilişkin literatür incelendiğinde ilk yıllarda istatistiksel yöntemler ve çok kriterli karar verme yöntemlerinin ele alındığı dikkat çekmektedir. Uzun vadeli tahminlerde çok kullanışlı olarak görülmesi de bir yıl gibi kısa vadeli ülke risk değerlendirmesinde diskriminant analizi sıklıkla kullanılmıştır. Ülke risk değerlendirmesinin bir sınıflandırma problemi olarak ele alındığı çalışmaların bazılarında (Frank & Cline, 1971; Abassi & Taffler 1982; Cooper, 1999; Yim & Mitchell, 2005) diskriminant analizi kullanılmıştır. Benzer şekilde çok değişkenli istatistiksel yöntemlerden temel bileşenler analizi de birçok ülke riski çalışmasında (Dhonte, 1974; Haque vd.,1996; Scherer & Avellaneda, 2002) tercih edilmiştir. İstatistiksel yöntemler ile elde edilen kayda değer başarının ardından diğer istatistiksel yöntemlerin uygulaması birbiri ardına birçok çalışmada önerilmiştir.

Farklı birçok istatistiksel yöntem kullanıldığı bu çalışmalardan bazılarında; regresyon analizi (Edwards, 1985; Lee, 1993a; Cantor & Packer, 1996; Haque vd., 1998; Ramcharran 1999), logit analizi (Feder & Just, 1977; Brewer & Rivoli, 1990; Kutty, 1990; Cosset & Roy, 1991; Oral vd., 1992; Lee, 1993b; Rivoli & Brewer, 1997; Easton & Rokerbie, 1999; Cooper, 1999; Oetzel vd., 2001; Yim & Mitchell, 2005; Vij 2005); probit analizi (Kharas, 1984; Rahnama-Moghadam vd., 1991; Balkan, 1992; Hernandez-Trillo, 1995; Cantor ve Packer, 1996a; Haan vd., 1997; Easton & Rokerbie, 1999; Cooper, 1999; Yim & Mitchell, 2005) ve tobit analizi (Lloyd-Ellis vd., 1990; Lanoie & Lemarbre, 1996) kullanılmıştır.

Logit analizinin diğer istatistiksel yöntemlere göre büyük avantajı katı varsayımlar gerektirmemesi ve istatistiksel varsayımlara tabi lineer denklemlerin sınırlamalarının üstesinden gelmesidir. Bununla birlikte, logit analizinde kullanılan hesaplama süreci karmaşık ve tahmin doğruluğunu kaçınılmaz olarak etkileyen birçok yaklaşıma sahiptir. Probit modeli fikir olarak Logit modeline benzese de birtakım hesaplama yöntemleri ve varsayımlarında bazı farklılıklar bulunmaktadır (Sun vd., 2021).

Bazı çalışmalar (Doupoulos & Zopounidis, 2002; Stankevičienė & Sviderskė, 2012; Lou & Kou, 2012; Stankevičienė vd., 2014; Svilokos, T., ve Rodić, 2015; Türe vd., 2017; Brauers & Lepkova, 2019) ülke risk analizi ve değerlendirmesinde istatistiksel modellerden daha esnek ve sağlam olan çok kriterli karar verme (MCDA) süreçlerini kullanarak mevcut ülke risk değerlendirme yöntemlerini genişletmişler ve bir dizi yeni yöntem önermişlerdir.

Denizaşırı yatırımların hızlı büyümesi nedeniyle, makroekonomik göstergelere dayalı ülke riskinin çok kriterli karar verme çerçevesi, artık işletmelerin optimal portföyelerine ulaşma ve küresel düzeyde bir risk primi elde etme ihtiyaçlarını karşılayamamaktadır. Bu durumda araştırmacılar, ülke risk analizi ve değerlendirmesinde yeni ilkeler ve yaklaşımları düşünmeye başlamışlardır (Scholtens, 2004). Makine öğrenimi algoritmalarının hızlı gelişimi ile ülkelerin borç riskini tahmin etmek için ilk olarak sinir ağı modeli kullanmıştır.

Cooper (1999), Yim & Mitchell (2005), Bennel vd. (2006), ve Caporale vd. (2011) gibi çalışmalarda ülke riskini değerlendirmek için yapay sinir ağı (YSA) önerilmiştir. Van Gestel vd. (2006), destek vektör makinesini (DVM) ile ülke risk analizi için genel bir derecelendirme süreci önermiştir. Takip eden yıllarda ANN'ye göre ülke riskinin çok boyutlu ve karmaşık doğasını daha iyi kavrama kabiliyetinden dolayı DVM'ye olan ilgi artmış ve yöntemin başarılı uygulamaları Bellotti vd. (2011), Chen vd. (2011) ve Li vd. (2012) tarafından genişletilmiştir. Erdal & Karakurt (2013) ve Ivkin (2018) ise ülke riski değerlendirmesini sınıflandırma ve regresyon ağaçları (CART) algoritmasını ile ele almışlardır.

Ülke kredi notlarını tahmin etmede Öztürk vd. (2016)'da CART, çok katmanlı algılayıcı (MLP), SVM, Bayes Net ve Naive Bayes kullanılarak çeşitli yapay zekâ tekniklerinin tahmin performansı araştırılmıştır. Benzer bir çalışma Silva vd. (2019) tarafından Rastgele Orman algoritması özelinde yine makine öğrenmesi algoritmaları ile yürütülmüştür. Türe & Başer (2015) çalışmasında ise ülke riski değerlendirmesi bir kümeleme problemi olarak ele alınıp bulanık C ortalama kümeleme yöntemi ile incelenmiştir.

3. Metot

3.1. Lojistik Regresyon

Lojistik Regresyon (LR), sınıflandırma algoritmaları türetmek için yaygın olarak kullanılan istatistiksel bir modelleme tekniği olarak görülmektedir. İkili çıktı ($Y = 0$ veya $Y = 1$) olasılığının bir dizi potansiyel tahmin değişkeniyle ilişkili olduğu, LR modeli denklem 1'de verildiği gibi gösterilmektedir:

$$P(Y = 1|X) = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots \quad 1$$

Burada $\beta_0, \beta_1, \beta_2$, model katsayıları iken X_0, X_1, X_2 ise bağımsız değişkenleri temsil etmektedir. Ancak bu yaklaşımda, lineer regresyon işlevi teorik olarak herhangi bir değeri verebilmektedir. Model katsayılarını değiştirilerek çıktı değişkeninin 0 ile 1 arasında değerler alması sağlanabilir olmasına karşın, daha sağlıklı bir yol olarak

$$P(X) = \frac{\exp^{\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots}}{1 + \exp^{\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots}} \quad 2$$

şeklinde verilen lojistik fonksiyonun çıktısı hesaplanarak X örneğine ait tahminin elde edilmesi şeklinde olmaktadır. Bu hesaplamayı yapabilmek için, model katsayılarının tahmin edilmesi gerekmektedir. Lojistik regresyon modelinin eğitim aşaması da bu kısımda gerçekleşmektedir. Regresyon katsayıları bir ilk çözümlerle somutlaştırılmakta ve daha sonra model çok küçük hale gelene kadar yinelemeli bir şekilde revize edilmektedir (Abdou, 2016). Bu süreç,

$$L(\beta_0, \beta_1, \beta_2) = \prod_{i:y_i=1} P(x_i) \prod_{i':y_{i'}=0} (1 - P(x_{i'})) \quad 3$$

şeklinde ifade edilen olabilirlik fonksiyonunun maksimize edilmesi ile gerçekleşmektedir. Bu modelde, olasılık değerinin 0.5'ten büyük ya da eşit olduğu durumlarda $Y=1$ ve küçük olduğu durumlarda 0 değerini almaktadır (Wagenmans, 2017). Basit Lojistik Regresyon yöntemi aşırı uyuma meyilli olduğundan literatürde birçok düzgünleştirme ve değişken seçme yöntemi tanıtılmıştır. Bunlardan bazıları, LASSO ve Ridge regresyon ve bu iki tekniğin bir bileşimi olan Elasticnet dir (Zou & Hastie, 2005).

3.2. K-Yakın Komşuluk

Fix & Hodges (1989) tarafından önerilen KNN algoritması, uygulaması ve anlaması kolay, hızlı ve iyi tahminleme performansına sahip parametrik olmayan gözetimli bir sınıflama algoritması olarak sunulmuştur. KNN algoritmasında her bir eğitim örneğinin en yakın k komşusu belirlenmekte ve bu komşuların ait olduğu sınıf referans alınarak sınıflama yapılmaktadır. En yakın komşu genellikle Pisagor temelli bir uzaklık fonksiyonu kullanılarak belirlenmektedir. KNN algoritması için sıklıkla kullanılan uzaklık fonksiyonları Öklid, Chebyshev ve Manhattan uzaklıklarıdır. Bu uzaklıklar ise,

$$d_{Euclidean}(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad 4$$

$$d_{Manhatta}(x, y) = \sum_{i=1}^n |x_i - y_i| \quad 5$$

$$d_{Chebyshe}(x, y) = \max_i (|x_i - y_i|) \quad 6$$

şeklinde verilmektedir. Burada x ve y girdi ve çıktı değişkeni temsil eden n boyutlu özellik uzaylarıdır. Hangi uzaklık fonksiyonun kullanılacağı ve k komşu sayısının ne olacağı, yöntemin performansının en önemli belirleyicileridir (Han & Kamber, 2006). En uygun K değerinin seçimi sapma ve varyans değerleri arasında denge kurularak yapılmaktadır. Küçük K değerleri sapmayı artırıp aşırı uyuma neden olurken, büyük K değerleri sınıf / küme sınırlarının belirsizleşmesine ve sapmanın çok fazla azalmasına neden olmaktadır.

3.3. Destek Vektör Makinesi

Destek vektör makinesi (DVM), temeli İstatistiksel Öğrenme Teorisi'ne dayanan (Vapnik & Chervonenkis, 1968) sınıflama (örüntü tanıma), regresyon ve yoğunluk tahmini yapabilen denetimli öğrenme algoritmasıdır. DVM'nin eğitim aşamasında, eğitim setlerini sınıflarına doğru bir şekilde ayıran optimal hiper-düzlemi belirlemek için bir model oluşturulmaktadır. En iyi sınıflandırma performansı, hiper-düzlem marjını maksimize ederek elde edilmektedir.

SVM eğitim veri setinde aynı sınıfa ait olan benzer noktaların dağılımına bir sınır uydurmaktadır. Bu eğitim örnekleri daha sonra test örnekleri içinde yer alan noktaların sınır içinde yer alıp almadığını karşılaştırmak için kullanılmaktadır. Bir sınır oluşturulduğunda, bu

sınır üzerinde yer alan eğitim verileri geri kalan eğitim verileri ile ilişkilendirilmekte ve destek vektör olarak ele alınmaktadır. Bu durumda geri kalan eğitim örnekleri gereksiz hale gelmektedir. DVM'nin avantajı hem doğrusal ayrılabilir hem de doğrusal ayrılamayan veriler için kullanılabilir olmasıdır. İlk durumda verileri maksimum marj ile ayıran bir sınır oluşturulmaktadır. İkinci durumda ise ayırma sınırını oluşturmak için bir çekirdek işleviyle $\Phi(x)$, $x \in MI \rightarrow \phi(x) \in MH$ olacak şekilde, girdi uzayından x verisini yüksek boyutlu bir H uzayına dönüştürmektedir (Tiwari, 2017).

Doğrusal olmayan DVM'de eğitim örnekleri için haritalama fonksiyonu ϕ kullanılmaktadır. İç çarpıma dayalı uygun bir çekirdek fonksiyonu tanımlamak, veriyi doğrusal olarak ayrılabilir yapmak için giriş uzayından, yüksek boyutlu (sonsuz da olabilir) öznitelik uzayına verinin doğrusal olmayan dönüşümünü yapmaktır.

P adet niteliğe (özellik) sahip $(x_i, y_i), i = 1, 2, \dots, m$, $x_i \in \mathfrak{R}^n$ ve $y_i \in \{-1, 1\}$ girdi ve çıktı ikililerinden oluşan S eğitim kümesini ayıran en iyi hiper-düzlemin bulunması ikinci dereceden bir optimizasyon problemi formunda tanıtılmış ve Lagrange fonksiyonundan faydalanarak çözülmüştür. Lagrange değişkenlerinin maksimize edildiği dual model

$$\begin{aligned} \max_{\alpha} L_d(\alpha) &= \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i,j=1}^m y_i y_j \alpha_i \alpha_j K(x_i, x_j) \\ \text{kısıtlar: } \sum_{i=1}^m y_i \alpha_i &= 0 \quad 0 \leq \alpha_i \leq C, \quad i = 1, \dots, m \end{aligned} \quad 7$$

şekindedir (Cortes & Vapnik, 1995). Burada α_i her i örneği için bir Lagrange çarpanı ve $K(x_i, x_j)$, i 'inci ve j 'inci girdileri için çekirdek fonksiyonunun değerini belirtir. C , genel hatayı cezalandıran bir üst sınırdır. Herhangi bir x girdisi için DVM'nin çıktı tahmini

$$f(x) = \text{sig} \left(\sum_{i=1}^m \alpha_i^* y_i \langle K(x_i, x_j) \rangle + b^* \right) \quad 8$$

şekindedir. Burada sapma b ve α_i vektörü, 7 nolu eşitlikte verilen optimizasyon problemi tarafından belirlenen değişkenlerdir.

$$K(x_i, x_j) = \varphi(x_i)^T \varphi(x_j) \quad 9$$

Optimal sonucu bulmak için DVM'ye yardımcı olan birçok kernel fonksiyonu bulunmaktadır. Bunlardan en sık kullanılanları; polinomiyal kernel: $K(x_i, x_j) = (1 + x_i \cdot x_j)^d$, radyal tabanlı kernel: $K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2)$ ve sigmoid kernel: $K(x_i, x_j) = \tanh(K(x_i, x_j) - \delta)$ (Borges, 1998; Liao vd., 2004).

3.4. CART Algoritması

Yaygın olarak kullanılan sınıflandırma ve regresyon ağaçları (CART) Breiman vd. (1984) tarafından önerilmiş parametrik olmayan bir sınıflama algoritmasıdır. CART, sürekli veya kesikli olarak tanımlanabilen bir bağımlı (veya çıktı, sınıflayıcı) değişken ile özellikler olarak adlandırılan girdi değişkenleri arasında basit ikili ilişkilerin yinelemeli bir dizisini üretmektedir.

Bağımlı değişkenin tipik olarak sabit (sınıflandırma ağacı) ve bağımsız değişkenlerle doğrusal olarak ilişkili (regresyon ağacı) olduğu varsayılmaktadır. Her bir bağımsız değişken için olası tüm aday bölünmeler ile ilgilenen CART algoritması, bağımsız değişkenlerin çok boyutlu uzayını farklı bölgelere ayırıştırarak ağaca benzer bir yapı oluşturmaktadır. (Khandani vd., 2010; Song & Lu, 2015). Her bir değişken üzerinden iki ayrı fakat birbirini tamamlayan tüm olası aday bölünmeler ağacın karar düğümlerinde gerçekleşmektedir. Kök düğümünden başlanılan algoritmada, ağaç özelliklerin değerlerine göre homojen alt düğümlere ayrılmakta ve son olarak her bir gözleme bir sınıf etiketi atanıncaya (yaprak düğümüne ulaşıncaya) kadar harekete devam edilmektedir (Breiman vd., 1984).

Maksimum ağaç büyüklüğüne ulaşıldıktan sonra, ağacın boyutunun optimal olup olmadığı kontrol edilmelidir. Burada optimallikten kasıt; düğüm sayısı ve karmaşıklığı en az olan ağacın elde edilmesidir (Alpaydın, 2011). Ağaç karmaşıklığını önleyebilmek için öğrenmenin belirli süreçlerinde budama işlemi yapılmaktadır. Budama işlemi için en yaygın kullanılan kurallardan biri

$$G(\tau) = \sum_{k=1}^K P_{\tau}(k)(1 - P_{\tau}(k)) \quad 10$$

şeklinde ifade edilen Gini ölçüsüdür. Burada τ bir CART modelinin yaprak düğümünü ifade etmekte ve $P_{\tau}(K)$, τ yaprak düğümlerinde k sınıfına atanan eğitim verilerinin oranını ifade etmektedir. Daha sonra CART modelleri için budama kriteri

$$C(T) = \sum_{\tau=1}^{|T|} G(\tau) + \lambda|T| \quad 11$$

şeklinde tanımlanmaktadır. Burada $|T|$, CART model T 'de bir dizi yaprak düğümü ve λ çapraz doğrulama ile seçilen bir düzgünleştirme parametresini ifade etmektedir. Budama kriteri minimuma ulaştığında, CART algoritması ağacın büyümesini durdurmaktadır.

Artan bir popüleriteye sahip olan bu yöntemin önemli bir avantajı, bağımlı değişkenin tüm girdi alanı boyunca tek bir doğrusal modele uymaya zorlandığı logit ve probit gibi standart modellerin sınırlamalarının üstesinden gelmesidir. Bununla birlikte, CART, girdi değişkenleri arasındaki doğrusal olmayan etkileşimleri tespit etme yeteneğine sahiptir. CART modelleri, mantığı ağaçta açıkça ortaya konan, kolay yorumlanabilir karar kuralları üretmektedir (Khandani vd., 2010). Tüm bu avantajlarına rağmen karar ağaçlarının çoğu durumda aşırı uyum nedeni ile fazla dallanması sonucu test veri seti üzerindeki tahmin hatası yüksek olabilmektedir. Bu durum için budama yönteminin kullanılması önerilmektedir (Patel & Upadhyay, 2015; Osisanwo vd., 2017).

4. Uygulama

Çalışmanın uygulama kısmı için önerilen süreç araştırma tasarımı ve performans değerlendirme ana başlıkları altında takip eden kısımda ayrıntılı olarak açıklanmıştır. Çalışmanın kodları "MATLAB 9.4 (R2018a) The Language of Technical Computing" ortamında geliştirilmiş ve DVM için "libsvm" (Chang ve Lin, 2011); LRA için "lassoglm"; KNN için "fitcknn" ve CART algoritması için "fitctree" kütüphanesi tercih edilmiştir.



4.1. Araştırma Tasarımı

Analize geçmeden önce yapılması gereken adımlar bu kısmın alt başlıklarında açıklanmıştır. İlk olarak, çalışmada kullanacağımız veri seti tanıtılmış ve her veri madenciliği süreci için önemli bir adım olan veri ön-süreci açıklanmıştır. Ardından, analizde kullanılan her bir makine öğrenmesi yöntemi için en uygun parametreler belirlenmiştir.

4.1.1. Veri/Veri Ön süreç

Bu çalışma, ülke kredi notlarını tahmin etmek için ele alınan ve ekonomik, finansal, sosyal ve politik göstergelerden oluşan bağımsız değişkenler (özellikler) IMF ve Dünya Bankası'ndan derlenmiştir. Çalışmanın bağımlı değişkeni (sınıf etiketleri) olan ülke kredi notları OECD³'den (tanımlar ve kısa açıklamalar Tablo 1'de yer almaktadır) alınmıştır.

“Credit Risk” derecelendirme sınıflandırmasına göre, ülke riski 1 ile 8 arasında bulunmaktadır. 1 en yüksek notu temsil ederken, 8 notu yatırım yapılamaz spekülative nota karşılık gelmektedir. Çalışmada iki sınıflı bir problem olarak ele alındığından, kredi notları en yüksek notu ile spekülative notu ayıran 4 eşik notuna göre iki sınıfa ayrılmış ve “1” yatırım yapılabilir ve eşik değerin altında kalan ülkeler “2” yatırım yapılamaz olarak ele alınmıştır.

Sınıflandırılmaya tabii olmayan iki ülke grubu bulunmaktadır: Birinci grup, idari amaçlar için sınıflandırılmamıştır ve genellikle resmi ihracat kredisi desteği almayan çok küçük ülkelerden oluşmaktadır. İkinci grup, yüksek gelirli OECD ülkeleri ve diğer yüksek gelirli Euro bölgesi ülkelerinden oluşmaktadır. Çalışmada yer alan ülkelerin listesi Ek 1' de verilmiştir.

³ OECD, <https://www.oecd.org/trade/topics/export-credits/arrangement-and-sector-understandings/financing-terms-and-conditions/country-risk-classification/>

Tablo 1: Ülke Derecelenmede Kullanılan Makro-ekonomik Göstergeler

Kategori	Gösterge
Ekonomik	GSYİH Büyümesi (yıllık %)
	İşsizlik, toplam (% toplam işgücü) (modellenmiş Uluslararası Çalışma Örgütü tahmini)
	Kişi Başına Gayri Safi Yurtiçi Hasıla (2000 yılı sabit, ABD \$)
	Kişi Başına Gayri Safi Milli Gelir, Satın alma Gücü Paritesi (ABD \$)
	Mal ve Hizmet İthalatı (% GSYİH)
Ödemeler Dengesi	Cari İşlemler Dengesi (% GSYİH)
	Mal ve Hizmet İthalatı (% GSYİH)
	Mal ve Hizmetler Üzerindeki Dış Denge (% GSYİH)
	Yabancı Doğrudan Yatırımlar / GSYİH (%)
	Ticaret (% GSYİH)
Genel Yönetim	Enflasyon, GSYİH Deflatörü (Yıllık, %)
	Net borçlanma (+) / net borç verme (-) (% GSYİH)
	Gelir, hibeler hariç (% GSYİH)
Politik Risk (t-1)	Konuşma Yetkisi ve Denetlenebilme
	Politik İstikrar
	Hükümet Etkinliği
	Düzenleyicilik Kabiliyeti
	Hukukun Üstünlüğü
	Yolsuzluğu Kontrol Edebilme

Bu çalışmada incelenen dönem 2015–2019 yıllarını kapsamakta ve 75 ülkenin kredi notları hakkında bilgiler içermektedir. Genel olarak, uzun vadeli ülke kredi notlarına ilişkin yıllık olarak 349 gözleme ait 8 derecelendirme kategorisi bulunmaktadır. Kredi risk analizi üçer aylık dönemler için hazırlanıp yayınlanmıştır. Çalışmada yıl sonu için yayınlanan kredi dereceleri dikkate alınmıştır. Verilerin %70'i modeli eğitmek ve %30'u modelin doğruluk oranını test etmek için rassal olarak ikiye ayrılmıştır.

Veri ön süreçte, ham veri seti ya normalize edilmekte ya da farklı formüller ile ölçeklenmektedir. Bu ön süreç ile hesaplama sırasında sayısal zorluk yaşanmaması ve değişkenlerin aldığı büyük değerlerin küçük değerlerden etkilenmemesi amaçlanmaktadır. Bu çalışmada z-skore tekniği kullanılmıştır.

$$Z - score = \frac{x_i - x_{ort}}{S} \quad 11$$

Burada x_i her bir değişkenin aldığı ham değeri, x_{ort} değişken değerlerinin ortalamasını ve S ise standart sapmayı ifade etmektedir.

4.1.2. Model Parametrelerinin Ayarlanması

Makine öğrenmesi yöntemlerinin başarısını önemli ölçüde etkileyen bir adım da modellerin hiper parametreleri için en iyi değerleri bulabilmektir. Hiper parametreler makine öğrenmesi kullanıcıları tarafından ayarlanabilir parametreler olup bir modeli eğitmeden önce

ayarlanmaları gerekmektedir. Söz konusu bu parametreleri kullanıcı farklı denemeler yaparak ya da meta-sezgisel optimizasyon algoritmalarını kullanarak belirleyebilmektedir. Birçok çalışmada, farklı denemelerin yapılabileceği kolay ve etkili bir yöntem olarak Grid aramaları tercih edilmektedir.

Grid arama yöntemi, belirli bir modelin parametrelerinin en iyi değerlerini bulmak için parametre değerlerinin belirtilen bir aralığında tüm olası kombinasyonları üzerinde kapsamlı bir arama yapma fikrine dayanmaktadır. Belirtilen aralıktaki olası tüm değerlerin bir kombinasyonu oluşturulmakta ve her bir kombinasyon için k-10 parçalı çapraz doğrulama oranı ile en uygun olanına karar verilmektedir. k-10 parçalı çapraz doğrulama veride aşırı uyum nedeniyle oluşan metodolojik hatayı önlemesinden dolayı avantajlı olarak kabul edilmektedir. k-10 parçalı çapraz doğrulamada veri rassal olarak 10 parçaya bölünmekte ve bir parça modeli test etmek için test veri seti olarak model dışı bırakılmaktadır. Geri kalan dokuz parça üzerinde model eğitildikten sonra test veri setinde modelin doğruluk oranı test edilmektedir. Bu adım k parça sayısınca tekrar edilmektedir. Test veri setleri üzerindeki doğruluk oranlarının ortalaması k-10 parçalı çapraz doğrulama olarak yorumlanmaktadır.


Tablo 2, tercih edilen yöntemler için Grid aramada kullanılacak uygun değer aralıkları ve kriterleri ile k-10 parçalı çapraz doğrulama ile bulunan hiper parametreleri içermektedir.

Tablo 2: Parametre aralıkları ve optimal parametreler

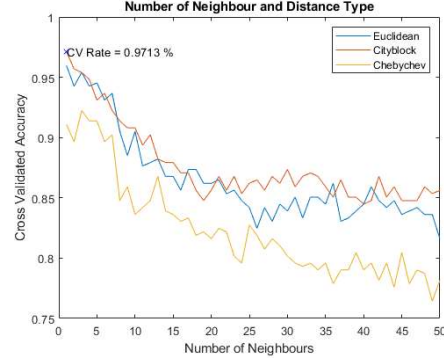
Metot	Parametreler	Seçilen aralık/kriter	Optimal Parametre
LRA	Lambda	$10^{-1,-2,\dots,-5}$	0.0041
	Ceza	Lasso	-
KNN	Komşu Sayısı	1, 2, ..., 50	1
	Uzaklık Ölçüsü	Euclidean, Cityblock, Chebychev	Cityblock
DVM	C	$2^{-5,-3,\dots,15}$	8
	Gamma	$2^{-15,-13,\dots,3}$	0.1250
CART	Min Yaprak Boyutu	10, 20, ...100	2
	Bölme Kriteri	Gini Endeks	-

Tablo 2' de yer alan optimal parametreler, en yüksek çapraz doğrulama oranına karşılık gelen değerlerdir. Parametre değerlerinin alabileceği her bir değer ve kriter ikilileri ile kurulan modellerin çapraz doğrulama oranları Şekil 1'de görselleştirilmiştir.

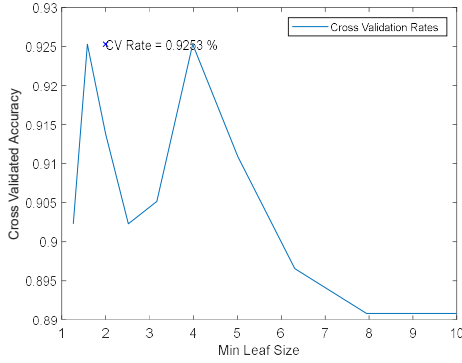
Şekil 1: Optimal Hiper Parametreler



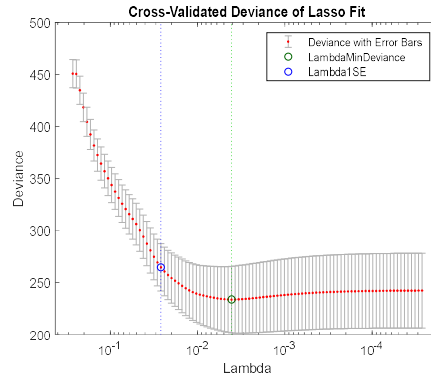
(a) SVM



(b) KNN



(c) CART



(d) LRA

DVM sınıflandırıcısının iki önemli parametresi (ceza parametresi C ve radyal tabanlı kernel parametresi gamma) için olası tüm kombinasyonlarda 110 farklı DVM modeli kurulmuştur. Kurulan her bir modelin çapraz doğrulama oranları Şekil 1(a)'da yer almaktadır. Burada en içte yer alan bölgede DVM modelleri %90 ve üzeri çapraz doğrulama oranlarına ulaşırken dışarıda yer alan eğrilerde modelin çapraz doğrulama oranlarının giderek %70'e doğru gerilediği görülmektedir. En yüksek çapraz doğrulama oranı %95,69 değeri C'nin 8 ve gamma'nın 0.125 değerine karşılık gelmiştir. Şekil 1(b)'de KNN için farklı uzaklık ölçü birimleri, her bir uzaklık ölçü birimi ve en yakın komşu sayısı ile denenen modellerin çapraz doğrulama oranları yer almaktadır. En yüksek çapraz doğruama oranınının uzaklık ölçü birimi "cityblok" ve en yakın komşu sayısının 1 olarak alındığı durumda elde edildiği görülmektedir. Cart algoritması için minimum yaprak boyutunun ne olması gerektiğine karar verilmiştir. Şekil 1(c)'de en küçük yaprak boyutunun 2 ve 4 alınması durumunda modelin en yüksek çapraz doğrulama oranına ulaşacağı görülmektedir.

Aşırı uyumunu önlemek ve model karmaşıklığını azaltmak için LRA analizinde Lasso düzgünleştirilmesi ele alınmıştır. Lasso düzgünleştirilmesi aslında LRA için optimal özelliklerin seçilmesi için kullanılmaktadır. Lasso regresyon modelinin maliyet fonksiyonunda yer alan lamda parametresinin 0 olması ve ele alınan bazı özelliklerin bağımlı değişkeni değerlendirmede kullanılmasının gereksiz olduğu anlamına gelmektedir (Tibshirani, 1996).

Ülke riski verisi için Lasso düzenleme parametresi lamda'nın 0.0041 olması durumunda model hatalarının minimuma olacağı görülmektedir.

4.2. Performans Değerlendirme

Modellerin tahmin doğruluk oranını ölçmek için tipik bir yol, doğru sınıflandırılan örnekler ile gözlemlerin tamamına oranından hesaplanan doğruluk oranı (accuracy rate)'dir. Ancak tek başına doğruluk oranını ile kıyaslama yapmak sağlıklı kabul edilmemektedir. Doğru sınıflandırılan pozitif örnekler ile doğru sınıflandırılan negatif örneklerin sayısı da modelin performansını daha ayrıntılı olarak ortaya koymaktadır. Bu sebeple, doğruluk oranı haricinde duyarlılık (sensitivity), özgüllük (specificity), kesinlik (precision) ve karmaşıklık matrisinin tüm elemanlarını dikkate alan, Matthews Korelasyon Katsayısı (MKK) değerlendirme ölçütleri ile de performanslar değerlendirilmiştir.

Sınıflandırılan çıktı örnekleri, çakışma matrisinin (confusion matrix) elemanlarını oluşturan 4 kategoride incelenmektedir. Bunlar; Doğru Pozitif (DP): Gerçekte riskli olan ülke kerdi notlarını riskli olarak tahmin etmek, Yanlış Negatif (YN): Gerçekte riskli olan ülke kredi notlarını risksiz olarak tahmin etmek, Doğru Negatif (DN): Gerçekte risksiz olan ülke kredi notlarını risksiz olarak tahmin etmek, Yanlış Pozitif (YP): Gerçekte risksiz olan ülke kredi notlarını riskli olarak tahmin etmek. Bu performans ölçülerine ilişkin formüller aşağıda verilmiştir.

$$\begin{aligned} \text{Doğruluk} &= \frac{DP + DN}{DP + YP + YN + DN} & \text{Duyarlılık} &= \frac{DP}{DP + YN} \\ \text{Özgüllük} &= \frac{TN}{TN + FP} & \text{Kesinlik} &= \frac{DP}{DP + YP} \\ \text{MKK} &= \frac{(DP \times YN) - (YP - YN)}{\sqrt{(DP + YP) \times (DP + YN) \times (DN + YP) \times (DN + YN)}} & & 12 \end{aligned}$$

4.3. Uygulama Sonuçları

Optimal parametrelerin belirlenmesinin ardından, bu parametreler kullanılarak her bir tahmin modeli 100 kez tekrar edilmiştir. Ülke riski veri setinin üzerindeki tahmin doğruluklarına ilişkin sonuçlar Tablo 3'te sunulmuştur. Tablo 3'te her bir modelden elde edilen uygunluk, duyarlılık, özgüllük, kesinlik ve MKK değerlerinin ortalama ve standart sapma değerleri rapor edilmiştir. Bu sonuçlara göre, 5 farklı değerlendirme kriterinin dördünde en iyi sonucu veren yöntem KNN algoritması olduğu görülmektedir. Doğruluk oranı sıralamasında birinci sırada yer alan KNN'nin tahmin doğruluk oranı %93,62 olarak elde edilmiştir. Bu yaklaşımının üstünlüğünün temelinde, KNN algoritmasının hem pozitif hem de negatif örneklerden oluşan eğitim veri setindeki bazı kalıpların, ilgilenilen gözlemin en yakın komşuluğundaki tekrar ortaya çıkma olasılığı ile ilgilenmesinden kaynaklanan sade ve basit bir yol izlemesi olarak düşünülebilir.

Doğruluk oranı dikkate alındığında DVM'nin %90,88'lik tahmin doğruluk oranı ile ikinci yöntem olduğu ve duyarlılık kriterinde en yüksek değeri aldığı gözlenmiştir. DVM'yi çok küçük bir fark ile takip eden takip eden üçüncü yöntem ise LRA'dır. LRA, özgüllük ve kesinlik kriterlerinde DVM ortalama değerlerinden daha yüksek sonuçlar verdiği ve standart sapmasının daha düşük

olduğu gözlenmiştir. CART algoritmasının tüm kriterlerde en düşük değeri aldığı görülmektedir.

Tüm bulgular bütüncül olarak değerlendirildiğinde, bu çalışmada kullanılan tüm yöntemlerin oldukça iyi tahminler ürettiği görülmektedir. Ancak ülke riski gibi oldukça hassas tahminler yapılması gereken bir problemde ana tahmin yöntemi olarak tercih edilen yöntemin farklı yöntemler ile desteklenmesi gerekmektedir. Ayrıca farklı değerlendirme kriterlerinin de kullanılması yerinde olacaktır.

Tablo 3: Model Performansları

Metot	Sıra		Uygunluk	Duyarlılık	Özgüllük	Kesinlik	MKK
LRA	3	Ortalama s.sapma	0.9049 (0.0235)	0.8572 (0.0462)	0.9306 (0.0271)	0.8680 (0.0504)	0.7899 (0.0522)
KNN	1	Ortalama s.sapma	0.9362 (0.0272)	0.8778 (0.0717)	0.9726 (0.0277)	0.9498 (0.0539)	0.8650 (0.0555)
SVM	2	Ortalama s.sapma	0.9088 (0.0282)	0.8958 (0.0556)	0.9161 (0.0344)	0.8361 (0.0641)	0.7978 (0.0619)
CART	4	Ortalama s.sapma	0.8724 (0.0343)	0.8321 (0.0747)	0.8957 (0.0422)	0.7994 (0.0794)	0.7194 (0.0744)

5. Sonuç

Makine öğrenmesi alanında yaşanan gelişmeler finansal karar vermede önemli bir dönüm noktası oluşturmuştur. Makine öğrenmesinin finansal uygulamalarda bu denli ilgi uyandırması onun önemli bir avantajından kaynaklanmaktadır. Bu avantaj; makine öğrenmesi yöntemlerinin kurulacak model ve veriler üzerinde herhangi bir varsayım ile kısıtlanmadan sadece veriden öğrenerek tahmin yapabilme yeteneğine dayanmaktadır.

Bu çalışmada ülke riski tahmininde, literatürde sıklıkla kullanılan ve güçlü tahminler ürettiği kabul edilen yöntemlerden LRA, KNN, CART ve DVM yöntemleri kullanılmıştır. Tahmin modellerini eğitmek için 2015-2019 yılları arasında 75 ülkenin farklı makroekonomik göstergeleri kullanılmıştır. Önerilen model ülke riskinin ekonomik, mali ve ülkenin iç dinamikleri hakkında bilgi veren belli başlı temel göstergeler baz alınarak doğru bir şekilde tahmin edilebileceğini ortaya koymaktadır. Elde edilen sonuçlar ile, finansal başarısızlık ve kredi derecelendirme gibi finans alanının sıkça çalışılmış konularına nazaran nispeten daha az uygulama alanı bulmuş olan ülke riski tahmini konusunda literatüre katkı sağlanması amaçlanmıştır.

Bu çalışmanın temel bulgusu, makine öğrenmesi yöntemleri ve geleneksel istatistiksel teknikler kullanılarak ülke kredi notlarının başarılı ve objektif bir şekilde tahmin edilebileceğinin ortaya konulmasıdır. Politika yapıcılar ve uluslararası finansal piyasa katılımcıları için ön bilgi ve uzman deneyimine dayanan öznel değerlendirme olmaksızın, ülkelerin geçmiş makroekonomik göstergelerinin girdi olarak kullanıldığı makine öğrenmesi ve istatistiksel yöntemlere ilişkin modelleri eğitmek mümkün olmaktadır. Ayrıca sözü edilen modellerin kullanımının yaygınlaştırılması da içerisinde bulunduğumuz çağın bir gerekliliğidir.

Her ne kadar çalışmanın amacı doğrudan yöntem performanslarının karşılaştırması olmasa da ülke riski tahmininde en iyi sonucu veren yöntemin KNN olduğu görülmüştür. Dahası, KNN algoritması diğer yöntemlere nazaran teorik alt yapısı sade, anlaşılır ve uygulaması kolay bir yöntemdir. Diğer bir açıdan ayarlanması gereken fazla sayıda parametre içermemesi de önemli bir avantajdır.

Ülke riski dereceleme çalışmalarında kullanılmış yöntemler incelendiğinde her çalışmada öne çıkan yöntemin farklılık gösterdiği araştırmacıların dikkatini çekmiştir. Örneklemin ve kullanılan tahmin değişkenlerinin değişmesi ile en iyi tahmini üreten yöntemin de değişeceği aşikardır. Makine öğrenmesi yöntemlerinin ve geleneksel istatistiksel yöntemlerin kıyaslanmasına yönelik bir bakış açısından ziyade bu yöntemlerin birbirinin destekleyici olarak görülmesinde ve çalışmaların bu doğrultuda yapılmasında fayda bulunmaktadır.

Kaynakça

- Abassi, B. & Taffler, R. J. (1982). Country Risk: A Model of Economic Performance Related to Debt Servicing Capacity. *City University Business School*.
- Abdou, H., Abdallah, W., Mulkeen, J., Ntim, C. G. & Wang, Y. (2017). Prediction Of Financial Strength Ratings Using Machine Learning and Conventional Techniques. *Investment Management and Financial Innovation*, 14(4), 194-211.
- Alpaydın, E. (2011). *Yapay Öğrenme*. İstanbul: Boğaziçi Üniversitesi Yay. Birinci Basım.
- Amstad, M. & Packer, F., (2015). Sovereign Ratings of Advanced and Emerging Economies After the Crisis. *BIS Quarterly Review* (December), 77–91.
- Arezki, R., Candelon, B. & Sy, A. N. R. (2011). *Sovereign Rating News and Financial Markets Spillovers: Evidence from The European Debt Crisis*. IMF Working Papers, 68.
- Asiri, B. K. & Hubail, R. A. (2014). An Empirical Analysis of Country Risk Ratings. *Journal of Business Studies Quarterly*, 5(4), 52.
- Balkan, E. M. (1992). Political Instability, Country Risk and Probability of Default. *Applied Economics*, 24(9), 999-1008.
- Beirne, J. & Fratzscher, M. (2013). The Pricing of Sovereign Risk and Contagion During the European Sovereign Debt Crisis. *Journal Of International Money and Finance*, 34, 60-82.
- Bellotti, T., Matousek, R. & Stewart, C., (2011). A Note Comparing Support Vector Machines and Ordered Choice Models' Predictions of International Banks' Ratings. *Decision Support System*, 51(3), 682–687. <https://doi.org/10.1016/j.dss.2011.03.008>
- Bennell, J. A., Crabbe, D., Thomas, S. & Ap Gwilym, O. (2006). Modelling Sovereign Credit Ratings: Neural Networks Versus Ordered Probit. *Expert Systems with Applications*, 30(3), 415-425.
- Berg, J., Clerc, L., Garnier, O., Nielsen, E. F. & Valla, N. (2015). *From The Investment Plan to The Capital Markets Union: European Financial Structure and Cross Border Risk-Sharing*. CEPII, Centr' D'etudes Prospectives E' D'informations Internationales.



Doğan, S. & Türe, H. (2022). Makine Öğrenmesi Teknikleri ile Ülke Riski Tahmini. *Fiscaeconomia*, 6(3), 1126-1151. Doi: 10.25295/fsecon. 1098493

- Brauers, W. K. & Lepkova, N. (2019). Is Credit Rating Reserved Territory for Credit Rating Agencies? A Multimooora Approach for European Firms and Countries. *Technological And Economic Development of Economy*, 25(6), 1259-1281.
- Breiman, L., Friedman, J., Olshen, R. & Stone, C. (1984). *Classification and Regression Trees. 1984*. Wadsworth and Brooks.
- Brewer, T. L. & Rivoli, P. (1990). Politics and Perceived Country Creditworthiness in International Banking. *Journal Of Money, Credit and Banking*, 22(3), 357-369.
- Broner, F., Martin, A. & Ventura, J. (2010). Sovereign Risk and Secondary Markets. *American Economic Review*, 100(4), 1523-55.
- Burges, C. J. C. (1998). A Tutorial on Support Vector Machines for Pattern Recognition, *Data Mining and Knowledge Discovery: Kluwer Academic Publishers*, Boston.
- Busse, M. & Hefeker, C. (2007). Political Risk, Institutions and Foreign Direct Investment. *European Journal of Political Economy*, 23(2), 397-415.
- Cantor, R. & Packer, F. (1996). Determinants and Impact of Sovereign Credit Ratings. *Economic Policy Review*, 2(2).
- Cantor, R. & Packer, F. (1996a). *Multiple Ratings and Credit Standards: Differences of Opinion in The Credit Rating Industry* (No. 12). Nueva York: Federal Reserve Bank Of New York.
- Caporale, G. M., Matousek, R. & Stewart, C. (2011). EU Banks Rating Assignments: Is There Heterogeneity Between New and Old Member Countries?. *Review of International Economics*, 19(1), 189-206.
- Chen, S., Härdle, W. K. & Moro, R. A. (2011). Modeling Default Risk with Support Vector Machines. *Quantitative Finance*, 11(1), 135-154.
- Chang C. C. & Lin. C. J. (2011). LIBSVM: A Library for Support Vector Machines. *ACM Transactions on Intelligent Systems and Technology*, 2(3), 1-27. Software Available At <http://www.csie.ntu.edu.tw/~cjlin/libsvm>
- Cooper, J. C. (1999). Artificial Neural Networks Versus Multivariate Statistics: An Application from Economics. *Journal of Applied Statistics*, 26(8), 909-921.
- Corsetti, G., Kuester, K., Meier, A. & Müller, G. J. (2013). Sovereign Risk, Fiscal Policy, and Macroeconomic Stability. *The Economic Journal*, 123(566), 99-132.
- Cortes, C. & Vapnik, V. (1995). Support Vector Networks. *Machine Learning*, 20, 1-25.
- Cosset, J. C. & Roy, J. (1991). The Determinants of Country Risk Ratings. *Journal Of International Business Studies*, 22(1), 135-142.
- Cunha, I., Ferreira, M. A. & Silva, R. (2019). Do Credit Rating Agencies Influence Elections?. Available At SSRN 2748458.
- Dhonte, P. (1974). Quantitative Indicators and Analysis of External Debt Problems. *International Monetary Fund Mimeo, Washington, DC*.
- Diamonte, R. L., Liew, J. M. & Stevens, R. L. (1996). Political Risk in Emerging and Developed Markets. *Financial Analysts Journal*, 52(3), 71-76.



Doğan, S. & Türe, H. (2022). Makine Öğrenmesi Teknikleri ile Ülke Riski Tahmini. *Fiscaeconomia*, 6(3), 1126-1151. Doi: 10.25295/fsecon. 1098493

- Doluca, H. (2014). Is There a Bias in Sovereign Ratings Due to Financial Reasons?. *The Empirical Economics Letters*, 13(7), 801 – 814.
- Doumpos, M. & Zopounidis, C. (2002). On the Use of a Multi-Criteria Hierarchical Discrimination Approach for Country Risk Assessment. *Journal of Multi-Criteria Decision Analysis*, 11(4-5), 279-289.
- Easton, S. T. & Rockerbie, D. W. (1999). What's in a Default? Lending To LDCs in The Face of Default Risk. *Journal Of Development Economics*, 58(2), 319-332.
- Edwards, S. (1985). The Pricing of Bonds and Bank Loans In International Markets: An Empirical Analysis Of Developing Countries And Apos; Foreign Borrowing. *NBER Working Paper*, (W1689).
- Erdal, H. I. & Karakurt, O. (2013). Advancing Monthly Streamflow Prediction Accuracy of Cart Models Using Ensemble Learning Paradigms. *Journal of Hydrology*, 477, 119-128.
- Feder, G. & Just, R. E. (1977). A Study of Debt Servicing Capacity Applying Logit Analysis. *Journal of Development Economics*, 4(1), 25-38.
- Fix, E. & Hodges, J. L. (1989). Discriminatory Analysis. Nonparametric Discrimination: Consistency Properties. *International Statistical Review/Revue Internationale De Statistique*, 57(3), 238-247.
- Frank Jr, C. R. & Cline, W. R. (1971). Measurement of Debt Servicing Capacity: An Application of Discriminant Analysis. *Journal of International Economics*, 1(3), 327-344.
- Frascaroli, B. F. & Oliveira, J. (2017). Sovereign Risk Ratings, Macroeconomic Fundamentals and Accountability: Evidence from Developing Countries. *Advances in Scientific and Applied Accounting*, 304-318.
- Haan, J. D., Siermann, C. L. & Lubek, E. V. (1997). Political Instability and Country Risk: New Evidence. *Applied Economics Letters*, 4(11), 703-707.
- Han, J. & Kamber, M. (2006). *Data Mining Concepts and Techniques (2nd Edition)*.
- Haque, N. U., Kumar, M. S., Mark, N. & Mathieson, D. J. (1996). The Economic Content of Indicators of Developing Country Creditworthiness. *Staff Papers*, 43(4), 688-724.
- Haque, N.U., Mark, N. C. & Mathieson, D. J. (1998). The Relative Importance of Political and Economic Variables in Creditworthiness Ratings.
- Hernández-Trillo, F. (1995). A Model-Based Estimation of the Probability of Default in Sovereign Credit Markets. *Journal Of Development Economics*, 46(1), 163-179.
- Hilscher, J. & Nosbusch, Y. (2010). Determinants of Sovereign Risk: Macroeconomics Fundamentals and the Pricing of Sovereign Debt. *Review of Finance*, 14(2), 235-262.
- Hoti, S. & McAleer, M. (2004). An Empirical Assessment of Country Risk Ratings and Associated Models. *Journal of Economic Surveys*, 18(4), 539-588.
- Ivkin, A. (2018). Country Risk in International Investment: Its' Structure and Methods of Estimation. *Review of Business and Economics Studies*, 6(1), 56-77.



Doğan, S. & Türe, H. (2022). Makine Öğrenmesi Teknikleri ile Ülke Riski Tahmini. *Fiscaeconomia*, 6(3), 1126-1151. Doi: 10.25295/fsecon. 1098493

- Khandani, A. E., Kim, A. J. & Lo, A. W. (2010). Consumer Credit-Risk Models via Machine-Learning Algorithms. *Journal of Banking and Finance*, 34(11), 2767-2787.
- Kharas, H. (1984). The Long-Run Creditworthiness of Developing Countries: Theory and Practice. *The Quarterly Journal of Economics*, 99(3), 415-439.
- Kobrin, S. J. (1979). Political Risk: A Review and Reconsideration. *Journal of International Business Studies*, 10(1), 67-80.
- Krayenbuehl, T. E. (1985) *Country Risk: Assessment and Monitoring*. Toronto: Lexington Books
- Kutty, G. (1990). Logistic Regression and Probability of Default of Developing Countries Debt. *Applied Economics*, 22(12), 1649-1660.
- Lanoie, P. & Lemarbre, S. (1996). Three Approaches to Predict the Timing and Quantity of LDC Debt Rescheduling. *Applied Economics*, 28(2), 241-246.
- Lee, S. H. (1993a). Relative Importance of Political Instability and Economic Variables on Perceived Country Creditworthiness. *Journal of International Business Studies*, 24(4), 801-812.
- Lee, S. H. (1993b). Are The Credit Ratings Assigned by Bankers Based on the Willingness of LDC Borrowers to Repay?. *Journal of Development Economics*, 40(2), 349-359.
- Li, J. P., Tang, L., Sun, X. L., He, W. & Yang, Y. Y. (2012). Country Risk Forecasting for Major Oil Exporting Countries: A Decomposition Hybrid Approach. *Computers and Industrial Engineering*, 63(3), 641-651.
- Liao, Y., Fang, S.-C. & Nuttle, H.L.W. (2004). A Neural Network Model with Bounded-Weights for Pattern Classification. *Computers and Operation Research*, 31, 1411-1426.
- Lloyd-Ellis, H., Mckenzie, G. W. & Thomas, S. H. (1990). Predicting the Quantity of LDC Debt Rescheduling. *Economics Letters*, 32(1), 67-73.
- Lou, C. & Kou, G. (2012). A Time Series Promethee Model for Sovereign Credit Default Risk Evaluation. *International Journal of Advancements in Computing Technology*, 4(17).
- Moody's. (2021). *Global Rating, Rating Symbols and Definitions*. 2.10.2021 https://www.moodys.com/researchdocumentcontentpage.aspx?docid=psc_79004
- Nikolov, P. (2016). Cross-Border Risk Sharing After Asymmetric Shocks: Evidence from the Euro Area and the United States. *Quarterly Report on The Euro Area (QREA)*, 15(2), 7-18.
- OECD. Country Risk Classifications of the Participants to the Arrangement on Officially Supported Export Credits. *Organization for Economic Co-Operation And Development*. <https://www.oecd.org/trade/topics/export-credits/arrangement-and-sector-understandings/financing-terms-and-conditions/country-risk-classification/>E.T. 5.12.2021.
- Oetzel, J. M., Bettis, R. A. & Zenner, M. (2001). Country Risk Measures: How Risky Are They?. *Journal Of World Business*, 36(2), 128-145.
- Oral, M., Kettani, O., Cosset, J. C. & Daouas, M. (1992). An Estimation Model for Country Risk Rating. *International Journal of Forecasting*, 8(4), 583-593.



Doğan, S. & Türe, H. (2022). Makine Öğrenmesi Teknikleri ile Ülke Riski Tahmini. *Fiscaeconomia*, 6(3), 1126-1151. Doi: 10.25295/fsecon. 1098493

- Osisanwo, F. Y., Akinsola, J. E. T., Awodele, O., Hinmikaiye, J. O., Olakanmi, O. & Akinjobi, J. (2017). Supervised Machine Learning Algorithms: Classification and Comparison. *International Journal of Computer Trends and Technology (IJCTT)*, 48(3), 128-138.
- Öztürk, H., Namli, E. & Erdal, H. I. (2016). Modelling Sovereign Credit Ratings: The Accuracy of Models in a Heterogeneous Sample. *Economic Modelling*, 54, 469-478.
- Patel, N. D. & Upadhyay, S. (2012). Study of Various Decision Tree Pruning Methods with Their Empirical Comparison in Weka. *International Journal of Computer Applications*, 60, 20-25.
- Rahnama-Moghadam, M., Samavati, H. & Haber, L. J. (1991). The Determinants of Debt Rescheduling: The Case of Latin America. *Southern Economic Journal*, 510-517.
- Ramcharran, H. (1999). Foreign Direct Investment and Country Risk: Further Empirical Evidence. *Global Economic Review*, 28(3), 49-59.
- Rivoli, P. & Brewer, T. L. (1997). Political Instability and Country Risk. *Global Finance Journal*, 8(2), 309-321.
- Scherer, K. P. & Avellaneda, M. (2002). All For One... One For All? A Principal Component Analysis of Latin American Brady Bond Debt From 1994 To 2000. *International Journal of Theoretical and Applied Finance*, 5(1), 79-106.
- Scholtens, B. (2004). Country Risk Analysis: Principles, Practices and Policies. In *Sovereign Risk and Financial Crises*, 3-27. Springer, Berlin, Heidelberg.
- Silva, D. R. B., Rêgo, T. G. D. & Frascaroli, B. F. (2019). Sovereign Risk Ratings' Country Classification Using Machine Learning.
- Song, Y.-Y. & Lu, Y. (2015). Decision Tree Methods: Applications for Classification and Prediction. *Shanghai Archives of Psychiatry*, 27, 130-135.
- Stankevičienė, J. & Sviderskė, T. (2012). Country Risk Assessment Based on Multimoora. In *7th International Scientific Conference "Business and Management 2012" May 10-11, 2012, Vilnius, Lithuania*.
- Stankevičienė, J., Sviderskė, T. & Miečinskienė, A. (2014). Dependence of Sustainability on Country Risk Indicators in EU Baltic Sea Region Countries. *Journal Of Business Economics and Management*, 15(4), 646-663.
- Sun, X., Feng, Q. & Li, J. (2021). Understanding Country Risk Assessment: A Historical Review. *Applied Economics*, 53(37), 4329-4341.
- Svilokos, T. & Rodić, M. (2015). Country Risk Analysis Based on Analytic Hierarchy Process. *Poslovna Izvrsnost*, 9(1).
- Sy, A. N. R. (2009). The Systemic Regulation of Credit Rating Agencies and Rated Markets. *World Economics Data Papers*, 10(4), 69-108.
- Tibshirani, R. (1996). Regression Shrinkage and Selection via the Lasso. *Journal of the Royal Statistical Society. Series B (Methodological)*, 58, 267-288.



Doğan, S. & Türe, H. (2022). Makine Öğrenmesi Teknikleri ile Ülke Riski Tahmini. *Fiscaeconomia*, 6(3), 1126-1151. Doi: 10.25295/fsecon. 1098493

- Tichy, G., Lannoo, K., Ap Gwilym, O., Alsakka, R., Masciandaro, D. & Paudyn, B. (2011). Credit Rating Agencies: Part of The Solution or Part of The Problem?. *Intereconomics*, 46(5), 232-262.
- Tiwari, A. K. (2017). Introduction to Machine Learning. Ubiquitous Mach. Learn. Its Appl. <https://doi.org/10.4018/978-1-5225-2545-5.ch001>.
- Türe, H. & Başer, F. (2015). Bulanık C-Ortalama Kümeleme Algoritması ile Ülke Risk Değerlendirmesi. *Ekonometri ve İstatistik Dergisi*, (23), 16-33.
- Türe, H., Koçak, D. & Doğan, S. (2017). MULTIMOORA Yöntemi ile Ülke Riski Değerlendirmesi. *Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 18(3), 824-844.
- Van Gestel, T., Baesens, B., Van Dijcke, P., Garcia, J., Suykens, J. A. & Vanthienen, J. (2006). A Process Model to Develop an Internal Rating System: Sovereign Credit Ratings. *Decision Support Systems*, 42(2), 1131-1151.
- Vapnik V. N. & Chervonenkis, A. V. (1968). *On the Uniform Convergence of Relative Frequencies of Events to Their Probabilities*, Soviet Math. Dokl. 9,915-918. İngilizce Çeviri: 2015. In Measures of Complexity (11-30). Springer, Cham.
- Vij, M. (2005). The Determinants of Country Risk Analysis. *Journal of Management Research*, 5(1), 20-31.
- Wagenmans, F. (2017). *Machine Learning in Bankruptcy Prediction* (Master's Thesis).
- Yim, J. & Mitchell, H. (2005). Comparison of Country Risk Models: Hybrid Neural Networks, Logit Models, Discriminant Analysis and Cluster Techniques. *Expert Systems with Applications*, 28(1), 137-148.
- Zou, H. And Hastie, T. (2005). Regularization and Variable Selection via the Elastic Net. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, 67(2), 301–320.

Etik Beyanı: Bu çalışmanın tüm hazırlanma süreçlerinde etik kurallara uyulduğunu yazarlar beyan eder. Aksi bir durumun tespiti halinde Fiscaeconomia Dergisinin hiçbir sorumluluğu olmayıp, tüm sorumluluk çalışmanın yazarlarına aittir.

Ethics Statement: The authors declare that ethical rules are followed in all preparation processes of this study. In case of detection of a contrary situation, Fiscaeconomia has no responsibility, and all responsibility belongs to the authors of the study.



Country Risk Prediction with Learning Techniques

Seyyide Turan, Hasan Türe

Extended Abstract

Today, it is known that almost no economy is self-sufficient without getting foreign aid. With the positive effects of globalization, economic, political, martial, or cultural relations can expand even to the farthest corners of the world. For these relations to be based on a more solid basis, parties must know how much they can trust each other. This information will help to have an idea about the country's ability or willingness to fulfill the responsibilities, briefly its risk. Within the scope of this study, the risk in question was assessed as country risk and with this concept, it was tried to measure how risky it would be to invest or lend to a country. At this point, the desired risk to be measured is the willingness/unwillingness of the debtor country to pay its debts or how secure will be the investments of a country, company or individual in the invested (host) country.

Country risk should be measured by making very precise predictions with procedures in which economic, financial, and political risk factors are considered together. Three major assessment agencies, such as Moody's and Standard and Poor's and Fitch, which undertake this task, constitute approximately 80% of the market. This oligopolistic structure has brought along some side effects (Frascaroli & Olivera, 2017). Many authors criticized CAs for using non-transparent methodologies, making political decisions (Cunha et al., 2020; Tichy et al., 2011), making sudden changes in credit ratings, causing financial instability, not being able to predict crises, and even deepening the economic effects of these crises, seeking profit, and giving wrong ratings (Sy, 2009; Belotti et al., 2011; Arezki et al., 2011; Doluca, 2014).

With the increase in the lack of confidence in country-credit scores and debates, researchers have chosen the way to develop alternative models where credit scores are assessed in a transparent and objective environment. There are many empirical studies in the literature conducted with this purpose. Frank & Cline (1971), Abassi & Taffler (1982), Cooper (1999) and Yim & Mitchell (2005) have made the country risk assessment which was considered as a classification problem with Discriminant analysis. Dhonte (1974), Haque et al. (1996) and Scherer & Avellaneda (2002) preferred Principal Component Analysis among the multivariate statistical methods. After the remarkable success achieved with statistical methods, the application of other statistical methods has been suggested one after another; Regression Analysis (Edwards, 1985; Lee, 1993a; Cantor and Packer, 1996; Haque et al. 1998; Ramcharran 1999), Logit Analysis (Feder & Just, 1977; Brewer & Rivoli, 1990; Kutty, 1990; Cosset & Roy, 1991; Oral et al., 1992; Lee, 1993b Rivoli & Brewer, 1997; Easton & Rockerbie, 1999; Cooper, 1999; Oetzel et al., 2001, Yim & Mitchell, 2005, Vij 2005); Probit analysis (Kharas, 1984; Rahnama-Moghadam et al., 1991; Balkan, 1992; Hernandez-Trillo, 1995; Cantor & Packer, 1996a; Haan et al., 1997; Easton & Rockerbie, 1999; Cooper, 1999; Yim & Mitchell, 2005), Tobit analysis (Lloyd-Ellis et al., 1990; Lanoie & Lemarbre, 1996).

With the rapid development of machine learning algorithms, a neural network model was first used to predict the debt risk of countries: Cooper (1999), Yim & Mitchell (2005), Bennel et al. (2006) and Caporale et al. (2011) proposed an artificial neural network (ANN) to assess 2011 country risk. Van Gestel et al. (2006) introduced the support vector machine (SVM) to this

area and proposed an overall rating process for country risk analysis. In the following years, interest in SVM increased slightly due to its ability to grasp the multidimensional and complex nature of country risk compared to ANN, and a good application of the method was extended by Bellotti et al. (2011), Chen et al. (2011) and Li et al. (2012). Erdal & Karakurt (2013) and Ivkin (2018) considered the country risk assessment with the classification and regression trees (CART) algorithm. In estimating country credit ratings, Öztürk et al. (2016) investigated the prediction performance of various artificial intelligence techniques using CART, multilayer perceptron (MLP), SVM, Bayes Net and Naive Bayes. A similar study was carried out by Silva et al. (2019) with machine learning algorithms, particularly the Random Forest algorithm. In some studies, such as Türe & Başer (2015), the country risk assessment was handled as a clustering problem and examined using the Fuzzy C Means Clustering method.

At the point of quantitative measurement of this risk, a procedure in which economic, financial, and political risk factors are considered together was used. In the study, how will machine learning methods such as support vector machines (SVM), k-nearest neighbor (KNN), classification and regression trees (CART) and logistic regression analysis (LRA), a traditional statistical method, which are used to predict country credit ratings, perform in the ratings was investigated. The developments in the field of machine learning have created an important turning point in financial decision-making. The fact that machine learning arouses such interest in financial applications is due to one of its important advantages. This advantage is that machine learning methods can make predictions by learning from the data without being restricted by any assumptions on the model and data to be established.

In this study, different macroeconomic indicators of 75 countries between 2015 and 2019 were used to train the forecasting model. The 19 independent variables (features) of economic, financial, social and political indicators, which are considered to predict country credit ratings, were compiled from the IMF and the World Bank. Country credit ratings, which are the dependent variable (class labels) of the study, are taken from the OECD. According to the Credit Risk rating classification, country risk is between 1 and 8. 1 represents the highest grade, while 8 corresponds to the non-investable speculative grade. Since the study will be considered a two-class problem, the credit ratings are divided into two classes according to the 4 threshold grades that separate the highest and speculative grades, and the countries that are below the "1" are considered investment grades and "2" non-investment grades. In the study, the credit ratings published for the whole year were taken into account. After all the data were scaled, 70% were randomly divided into two for training the model and 30% for testing the accuracy of the model.

One step that significantly affects the success of machine learning methods is to find the best values for the hyperparameters of the models. Hyperparameters are machine learning user-adjustable parameters and must be set before training a model. An easy and effective method of setting these parameters is Grid search. Grid search performs a comprehensive search on all possible combinations of parameter values within a specified range to find the best values for the parameters of a given model. A combination of all possible values in the specified range is generated and the most suitable one is decided for each combination with a cross-validation rate of k fold. The advantage of k-fold cross-validation is that it prevents methodological error due to overfitting in the data. In k-fold cross-validation, the data is randomly divided into 10 folds and one piece is excluded from the model as the test data set to test the model. After

the model is trained on the remaining nine parts, the accuracy of the model is tested on the test dataset. This step is repeated for k pieces. The average of the accuracy rates over the test datasets is interpreted as k-fold cross-validation.

After determining the optimal parameters, each prediction model was repeated 100 times using these parameters. The results of the prediction accuracies on the country risk data set were evaluated by considering the mean and standard deviation values of the accuracy, sensitivity, specificity, precision, and Mathew's Correlation Coefficient values obtained from each model. According to these results, the method that gave the best results in four of the five different evaluation criteria was the KNN algorithm. The accuracy rate of KNN, which is in the first place in the accuracy rate ranking, was obtained as 93.62%. The underlying reason for the superiority of this approach is that the KNN algorithm follows a plain and simple path since some patterns in the training dataset, which consists of both positive and negative samples, are concerned with the probability of reoccurrence of the observation of interest in its nearest neighbor. Considering the accuracy rate, it was observed that SVM was the second method with a prediction accuracy of 90.88%, and it had the highest value in the sensitivity criterion. The third method that follows SVM with a very small difference is LRA. It was observed that LRA gave higher results than the mean values of SVM in the criteria of specificity and precision, and the standard deviation was lower. CART algorithm gave the lowest value in all criteria.

If all the findings are evaluated holistically, all the methods used in this study are methods that produce perfect estimates. However, in a problem where highly sensitive predictions are required, such as country risk, the preferred method as the main prediction method should be supported by different methods and measured with assessments and different assessment criteria.

The main finding of this study reveals that country credit ratings can be predicted quite successfully and objectively by using machine learning methods and traditional statistical techniques. For policymakers and international financial market participants, it is possible to train models of machine learning and statistical methods by using the past macroeconomic indicators of countries as input, without subjective evaluation based on prior knowledge and expert experience, and its widespread use is a necessity of the age. Although the aim of the study was not to directly compare method performances, KNN was found to give the best result from country risk estimation. When the methods used in country risk grading studies are examined, it has drawn the attention of researchers that the prominent method in each study differs. Changing the sample and the estimation variables used will change the method that produces the best estimation. It is useful to see machine learning methods and traditional statistical methods as supportive of each other rather than comparing them.



Dođan, S. & Türe, H. (2022). Makine Öğrenmesi Teknikleri ile Ülke Riski Tahmini. *Fiscaeconomia*, 6(3), 1126-1151. Doi: 10.25295/fsecon. 1098493

EKLER

Ek 1

Ülkeler: Arnavutluk, Angola, Arjantin, Ermenistan, Azerbaycan, Bahamalar, Bangladeş, Beyaz Rusya, Belize, Butan, Bosna Hersek, Botsvana, Brezilya, Bulgaristan, Burkina Faso, Kamboçya, Kamerun, Kolombiya, Kongo Cumhuriyeti, Fildişi Sahili, Hırvatistan, Dominik Cumhuriyet, Mısır Arap Cumhuriyeti, El Salvador, Fiji, Gabon, Gürcistan, Gana, Guatemala, Gine-Bissau, Hindistan, Endonezya, Irak, Jamaika, Ürdün, Kazakistan, Kenya, Kırgız Cumhuriyeti, Lübnan, Makao SAR, Çin, Madagaskar, Malavi, Malezya, Mali, Morityus, Meksika, Moldova, Moğolistan, Fas, Mozambik, Myanmar, Namibya, Nepal, Nikaragua, Kuzey Makedonya, Panama, Paraguay, Peru, Filipinler, Romanya, Rusya Federasyonu, Ruanda, Suudi Arabistan, Senegal, Sırbistan, Singapur, Güney Afrika, Sri Lanka, Tayland, Dođu Timor, Togo, Türkiye, Uganda, Ukrayna, Uruguay, Özbekistan, Zambiya, Zimbabve.