



Ekoist: Journal of Econometrics and Statistics

ARAŞTIRMA MAKALESİ / RESEARCH ARTICLE

Ülke Kredi Notlarını Etkileyen Faktörlerin Çeşitli Sınıflandırma Analizleri ile İncelenmesi

Ayşe Mine Öreender¹, Selay Giray Yakut²

Öz

Kredi derecelendirmeleri, Standard and Poor's Corporation, Moody's Yatırımcı Servisi ve Fitch Ratings gibi uluslararası derecelendirme kuruluşları tarafından sağlanan kredi riskinin alfabetik göstergeleridir. Kredi notları hükümetlerin kamu borcunu zamanında geri ödeme kabiliyetinin ve istekliliğinin bir değerlendirmesi olduğundan, yatırımcılar, borç veren kuruluşlar ve ilgili piyasa katılımcıları, yayınlanan raporlar doğrultusunda yatırım kararları alabilmektedir. Bu nedenle verilen notlar oldukça önemlidir.

Bu çalışmada, 85 ülkenin 2017 yılına ait verisi için lojistik regresyon analizi ve yapay sinir ağları tekniklerinden yararlanılarak Moody's kredi derecelendirme kuruluşunun ülke kredi notlarını verirken baskın olarak hangi faktörleri ele aldığı belirlenmiş ve verilen kredi notlarına göre ülkeler yatırım yapılabilirlik durumuna göre sınıflara ayrılmıştır. Analiz sonucunda, kişi başına düşen gayrisafi yurtiçi hasıla (GSYİH), enflasyon, genel hükümet faiz dışı dengesi / GSYİH, devlet borcu, dış ödemeler ve resmi Forex rezervleri değişkenleri istatistiksel olarak anlamlı bulunmuş, lojistik regresyon modelinin doğru sınıflandırma oranının %90,6 ve yapay sinir ağları modelinin doğru sınıflandırma oranının %88 olduğu sonucuna varılmıştır.

Türkiye zaman zaman yatırım "yapılabilir ülkeler" kategorisinde yer alsa da, kredi derecelendirme kuruluşu Moody's, 2018 Ağustos ayında Türkiye'nin kredi notunu Ba2'den Ba3'e, 2019 Haziran ayında ise B1'e düşürerek not görünümünü durağandan negatife düşürmüştür. Analiz sonucunda da buna paralel olarak kredi notları açısından Türkiye'nin "yatırım yapılamaz" sınıfına dahil edildiği belirlenmiştir.

Anahtar Kelimeler

Ülke kredi notu, lojistik regresyon analizi, yapay sinir ağları

Investigation of Factors Affecting Sovereign Ratings by Various Classification Analyses

Abstract

Credit ratings are alphabetical indicators of credit risk provided by international rating agencies such as Standard and Poor's, Moody's, and Fitch. Since credit ratings are an assessment of a government's ability to repay the public debt on time, investors, lenders, and market participants can make investment decisions in line with published reports. Therefore, the scores given are very important.

In this study, the factors handled by Moody's as sovereign ratings were determined using Logistic Regression Analysis and Artificial Neural Networks for the data of 85 countries for 2017 and the countries were divided into classes according to investment grade. As a result of the analysis, per capita GDP, inflation, general government primary balance / GDP, government debt, external payments, official forex reserves were found to be statistically significant. The correct classification rate of the logistic regression model was found to be 90%, whereas the correct classification rate of the artificial neural network model was found to be 88%.

* Çalışma, Marmara Üniversitesi Sosyal Bilimler Enstitüsü Ekonometri Anabilim Dalı İstatistik Bilim Dalında 01.08.2019'da tamamlanmış olan "Sınıflandırma Analizleri ve Kredi Notları Üzerine Bir Uygulama" adlı yüksek lisans tezinden üretilmiştir.

1 **Sorumlu Yazar:** Ayşe Mine Öreender (YL Mezunu), Marmara Üniversitesi, Sosyal Bilimler Enstitüsü, İstatistik Tezli Yüksek Lisans Programı, İstanbul, Türkiye. E-posta: mineoreender@gmail.com ORCID: 0000-0003-2826-262X

2 Selay Giray Yakut Doç. Dr.), Marmara Üniversitesi, İktisat Fakültesi, Ekonometri Bölümü, İstatistik Anabilim Dalı, İstanbul, Türkiye. E-posta: selaygiray@marmara.edu.tr ORCID: 0000-0003-4002-7956

Atf: Öreender, A. M. ve Giray Yakut, S. (2019). Ülke kredi notlarını etkileyen faktörlerin çeşitli sınıflandırma analizleri ile incelenmesi. *EKOIST Journal of Econometrics and Statistics*, 30, 77–93. <https://doi.org/10.26650/ekoist.2019.30.0019>

In August 2018, Moody's downgraded Turkey's credit rating from "Ba2" to "Ba3" and in June 2019 to B1 so the rating outlook dropped from stable to negative. Similarly, the analysis concluded that Turkey had been placed onto the list of non-investable countries.

Keywords

Sovereign rating, logistic regression analysis, artificial neural networks

Extended Summary

In this study, using logistic regression analysis and artificial neural network techniques on the data of 85 countries for 2017, the factors that were taken into account by Moody's credit rating agency while determining a country's credit ratings were determined, and the countries were divided into classes according to investmentability based on the granted credit scores .

Within the scope of the study, the data set for year 2017 was taken from Moody's official website. Moody's had organized the data under four main headings, which included economic structure and performance, government financing, external payments and debt, monetary-external vulnerability and liquidity indicators. The data set, which included a total of 138 world countries, had been reorganized under the headings of economic structure and performance, state financing, external payments and debt to form the largest data set with common variables. Then, lost observations and extreme values were excluded from the analysis and a final data set consisting of 85 different countries was created . Here, it is also considered that the sample size should be at least five times the number of variables observed. According to studies in the literature 13 independent variables (Per capita GDP, Real GDP, Inflation, Gross Domestic Savings / GDP, Economic Gap, Government Revenue / GDP to Government Expenditures / GDP, General Government Primary Balance / GDP, General Government Debt, External Payments and Debt, Real Effective Exchange Rate, Current Account Balance / GDP, Net Foreign Direct Investment / GDP) are determined as Official Forex Reserves. For the dependent variable, a two category dependent variable was determined as $Y = 1$, meaning investment can be made, and $Y = 2$, meaning investment cannot be made , by making use of the investability level determined by Moody's for long-term credit rating. Missing observations were not included in the analysis and contradictory observations, namely Luxembourg, Ecuador and South Africa, were excluded from the data set. After this, logistic regression analysis and artificial neural network statistical analysis methods were applied to the data set.

Logistic regression is one of the alternative techniques that can be used in cases where the dependent variable is categorical as in socio-economic issues. According to the results of the logistic regression application, while the total correct classification rate is 90.6%, according to the predicted results, the correct classification rate of non-investable countries is 87.9% and the correct classification rate of investable countries is 92.3%.

Artificial neural networks are computer-based systems that are developed with the inspiration of the neurons of the human brain and do not require traditional skills. In other words, artificial neural networks are computer networks that try to simulate the neural cell (neurons) networks of the biological central nervous system (Yegnanarayana, B. 2009), (Öztemel E., 2003). In the application of artificial neural networks, the data set containing a total of 85 observations was randomly divided into 2 sets as training data containing 69 observations and test data containing 16 observations. As a result of the application, the training data accuracy rate was found to be 0.88 and the test data accuracy rate was found to be 0.56. In addition, the area under the ROC curve for the training data was 0.90 and the area under the ROC curve for test data was 0.61. A value close to 1.00 indicates a good classification, while a value of 1.00 indicates an excellent classification.

In this study, two different methods were used with the most up-to-date data and a sample representing all world countries. Based on the literature review, it was observed that inflation, financial openness, per capita income, technological development, public income, public expenditure, borrowing, current account balance, democracy, adoption of laws and order and less corruption were most effective in granting country credit ratings. Parallel to previous studies and in addition to the application of logistic regression analysis, the most important factors determining whether countries can be invested in or not according to the 2017 country credit rating are GDP, Inflation, General Government Primary Balance / GDP, General Government Debt, Foreign Payments-Debt and Official Forex Reserves. According to the results of the analysis, it was observed that the correct classification rate of the logistic regression model is 90.6% and that of the artificial neural network model is 88%. Also in terms of credit scores it was concluded that Turkey was included in the list of non-investable countries.

Ülke Kredi Notlarını Etkileyen Faktörlerin Çeşitli Sınıflandırma Analizleri ile İncelenmesi

Kredi derecelendirme kuruluşları tarafından periyodik aralıklarla, bir ülkenin yatırım risk seviyesini belirleyen kredi notları verilir. Kredi notları hükümetlerin kamu borcunu zamanında geri ödeme kabiliyetinin ve istikrarının bir değerlendirmesi olduğundan, yatırımcılar, borç veren kuruluşlar ve ilgili piyasa katılımcıları yayınlanan raporlar doğrultusunda yatırım kararları alabilmektedir. Bu nedenle verilen notlar oldukça önemlidir.

Moody's resmi internet sitesinde kredi notlarının faydalarını; sermayeye daha geniş erişim, fonlama esnekliği ve piyasa istikrarı şeklinde özetlemektedir.

Son otuz yılda, kredi derecelendirme kuruluşları, gelişmekte olan ülkelerin uluslararası sermaye piyasaları üzerinde önemli bir etkiye sahip olmuştur. 60, 70 ve 80'li yılların aksine, günümüzde, gelişmekte olan bir ülkenin şu an beklediği en önemli vizitenin büyük yardım kuruluşlarından veya Uluslararası Para Fonu'ndan değil, büyük üç kredi derecelendirme kuruluşundan biri olduğunu ileri sürülmüştür (Bkz.: Reisen, 2002). Bunun nedeni, gelişmekte olan ülkelerdeki sınırlı bilgi ve şeffaflık eksikliği nedeniyle yatırımcıların yatırım kararlarını verirken derecelendirme kuruluşlarının uzman görüşlerine ihtiyaç duymasıdır (Tennant, D. F., & Tracey, M. R. 2016, s.2). Tennant ve Tracey'nin çalışmasına göre kişi başına düşen gayri safi milli hâsıla, yatırımlar, cari işlemler dengesi, ihracat, rezervler ve kurumsal kalitenin tümü ülkelerin borç kalitesi üzerinde beklenen etkiye sahiptir. Ayrıca yine bu çalışma sonucuna göre Standard and Poors (S&P), Moody's ve Fitch, fakir ülkelerin zengin ülkelere göre kredi notlarını yükseltmesinin daha zor olduğunu ve kredi derecesinde bakılmaksızın borçların geri ödeme kabiliyetinde daha zorlandığını göstermiştir.

Bir ülke için kredi riski analizi, doğası gereği karmaşık olup finansal oranlar, ekonomik, politik ve düzenleyici ortam ve endüstri eğilimleri dâhil olmak üzere çok çeşitli potansiyel etkilere dayanır. Nicel modeller bağlamında, kredi notuna ulaşmak için finansal, ekonomik ve işletme verilerinin kullanılması, farklı değişkenler arasındaki karmaşık ve doğrusal olmayan etkileşimler nedeniyle zorlu bir süreçtir (Bennell, J. A., Crabbe, D., Thomas, S., & Ap Gwilym, O., 2006).

Bu çalışmada, en güncel veriler ile 85 dünya ülkesi için kredi notunu etkileyen faktörler alternatif çok değişkenli analiz yöntemleri ile belirlenmiş ve ülkeler yatırım yapılabirlik düzeylerine göre sınıflandırılmıştır.

Literatür İncelemesi

Literatür incelendiğinde çalışmalarda genellikle kredi derecelendirme kuruluşlarının değerlendirmelerinin objektif olup olmadığı, kredi notlarının kriz öncesi-sonrası değerlendirmeleri, notların piyasa ve yatırım oranlarına etkileri, Türkiye ile aynı kredi notuna sahip ülkelerin makro ekonomik göstergelerinin karşılaştırılması konularına ağırlık verildiği görülmüştür.

Ülke kredi notlarını belirleyen faktörlerle ilgili literatür incelendiğinde ise Bissoondoyal-Bheenick, Brooks ve Yip (2006) yapmış oldukları çalışmalarında kredi notunu belirleyen faktörlerin enflasyon, kişi başına düşen gelir ve teknolojik gelişme olduğunu saptamıştır. Montes, Oliveira ve Mendonça (2016) çalışmalarında, enflasyon hedeflemesinin, finansal açıklığın, demokrasinin, yasaların ve düzenin benimsenmesinin ve daha az yolsuzluğun, devlet notlarının iyileştirilmesinde önemli olduğunu vurgulamıştır. Balıkçioğlu ve Yılmaz (2013) yapmış oldukları çalışmalarında kamu geliri, kamu gideri ve borçlanmanın ülkelerin kredi notları üzerinde etkili olduğunu saptamıştır. Tennant ve Tracey'nin (2016) çalışmasına göre ise kişi başına düşen gayri safi milli hâsıla, yatırımlar, cari işlemler dengesi, ihracat, rezervler ve kurumsal kalitenin tümü ülkelerin borç kalitesi üzerinde beklenen etkiye sahip olduğunu ifade etmiştir.

Genç ve Başar (2019) yapmış oldukları çalışmalarında Piyasaya hâkim üç derecelendirme kuruluşu (S&P, Fitch ve Moody's) arasında Moody's'in, ülke derecelendirmesi açısından en iyimser tahminleri yaptığını saptamıştır.

Çalışma kapsamında, 2017 yılına ait veri seti Moodys'in resmi internet sitesinden alınmış ve literatür taramasında sayıca kısıtlı çalışmanın rastlandığı lojistik regresyon ve yapay sinir ağları teknikleri ile kredi derecelendirmesinde etkili olan değişkenler belirlenerek lojistik regresyon ve yapay sinir ağlarının sınıflandırma sonuçları karşılaştırılmıştır.

Araştırmada Kullanılan Yöntemler

Çalışma kapsamında temelde lojistik regresyon ve yapay sinir ağları analizlerinde çok değişkenli analiz teknikleri kullanılmıştır.

Lojistik Regresyon Analizi

Bağımlı değişken sayısal/metrik olduğunda basit veya çoklu doğrusal regresyon yardımıyla en küçük kareler yöntemini uygulayarak parametre tahminlemesi yapılabilir, bağımlı-bağımsız değişken/ler arasındaki neden-sonuç ilişkisi irdelenebilir. Fakat sosyo-ekonomik konularda olduğu gibi bağımlı değişkenin kategorik olduğu durumlar da oldukça yaygındır. Lojistik regresyon, 1960'ların sonları ve 1970'lerin başlarında doğrusal regresyon ve diskriminant analizlerine alternatif olarak önerilmiş ve 1980'lerin başlarında istatistiksel paket programlarında kullanılabilir hale gelmiştir (Peng, Lee ve Ingersoll, 2002, s.3).

Lojistik regresyon, bağımlı değişken tipinin esnek olması, bulguların kolay ve anlamlı bir şekilde yorumlanabilmesi, SPSS, SAS gibi birçok istatistiksel paket program ile analiz edilebilmesi, normal dağılıma uygunluk, eş varyansa sahiplik ve süreklilik varsayımı olmaması nedeniyle tercih edilmektedir (Alpar, 2003). Ayrıca son yıllarda istatistik dünyasında lojistik regresyonun popüler olmasının başlıca nedeni lojistik bir modelin tahmincilerin odds oranını değerlendirmek ve bağımsız değişkenlere dayanarak sonuç değerinin olasılığını belirlemek için kullanılmasıdır (Hilbe, J. M. 2016, s.4).

Doğrusal regresyonda artıklar sıfır ortalama ve sabit varyansla normal dağılım gösterirken, Lojistik regresyonda artıklar sıfır ortalama ve $\pi(1-\pi)$ varyansla binom dağılımı gösterir (Alpar, 2003, s. 645-647).

Lojistik regresyonda odds; bir olayın olma olasılığının, o olayın olmama olasılığına oranıdır, Bu oran sıfır (0) ile sonsuz (∞) arasında bir değer alır;

$$\text{Odds; } \frac{P}{(1-P)} = \frac{\text{Olayın gerçekleşmesi}}{\text{Olayın gerçekleşmemesi}} \quad (1)$$

Doğrusal olmayan lojistik regresyon fonksiyonu, odds'un doğal logaritması alınarak logit dönüşüm sayesinde doğrusallaştırılır. Logit $-\infty$ ile $+\infty$ arasında değer alabilir.

$$L = \ln\left(\frac{P}{1-P}\right) = \ln e^{(\beta_0 + \beta_1 X)} = \beta_0 + \beta_1 X \quad (2)$$


Tahmin edilen katsayılar (β_0, β_1), olasılıkların oranındaki değişikliklerin ölçümleridir. (Hair, Black, Babin, Anderson ve Tatham, 2006, s.278).

Doğrusal modelde bağımsız değişken, X'deki 1 birim değişimin bağımlı değişkende ne kadarlık bir değişime neden olduğunu gösterirken, lojistik modelde bağımsız değişken, X'deki 1 birim değişimin logit'te ne kadar değişime neden olduğunu gösterir.

Çalışmada bağımlı değişkenler 0-1 aralığında ikili değişkenlerden Moody's ülke kredi notuna göre yatırım yapılıp yapılamayacağı olasılığı için logit model kullanılmıştır.

Yapay Sinir Ağları

Yapay sinir ağları, insan beyninin nöronlarından ilham alınarak geliştirilen, geleneksel beceriler gerektirmeyip kendi kendine öğrenebilen bilgisayar sistemleridir. Bir diğer deyişle yapay sinir ağları, biyolojik merkezi sinir sisteminin sinir hücresi (nöronları) ağlarını simüle etmeye çalışan bilgisayar ağlarıdır (Yegnanarayana, B. 2009), (Öztemel E. ,2003).




Şekil 1. Biyolojik sinir hücresi (nöron) yapısı
Kaynak: (Öztemel, 2003)

Ağın temel ünitesine nöron veya sinir hücresi denir.

Bir biyolojik sinir hücresinin ana bileşenleri; hücre gövdesi, dendriteler, aksonlar ve snapslerdir.

Dendriteler, girdi kanalları gibi hareket eden hücre gövdesinin uzantılarıdır. Bu girdi kanalları, girişlerini diğer nöronların snapsleri aracılığıyla alır. Hücre gövdesi daha sonra bu gelen sinyalleri zaman içinde işler. Hücre gövdesi daha sonra bu işlenmiş değeri akson ve snapsler aracılığıyla diğer nöronlara gönderilen bir çıktıya dönüştürür. Temel olarak, bir biyolojik nöron başka kaynaklardan girdiler alır, bunları bir şekilde birleştirir, sonuçta genel olarak doğrusal olmayan bir işlem gerçekleştirir ve ardından nihai sonucu verir (Anderson, D., & McNeill, G. 1992).



Şekil 2. Yapay sinir hücresinin matematiksel işleyişi
Kaynak: (Budak, H., ve Erpolat, S. 2012)

Toplama fonksiyonunda her bir girdi değeri ile kendi ağırlıklarının çarpımı sonucu net girdiye ulaşılır.

$$\text{Net Girdi}_i = \sum_i^n X_i W_i$$

X_i =Girdiler

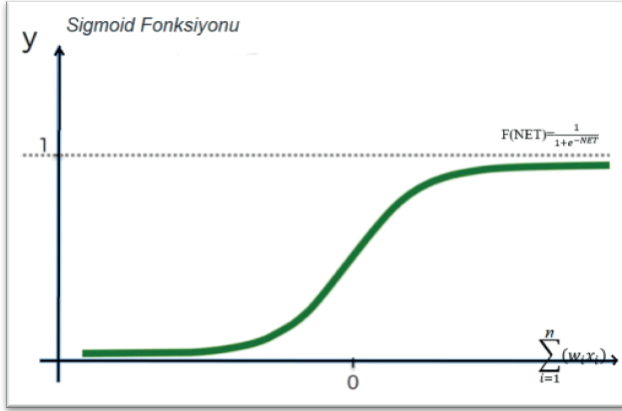
W_i =Ağırlıklar

Toplama fonksiyonunun sonucu, hemen hemen her zaman ağırlıklı toplam, aktivasyon fonksiyonu olarak bilinen algoritmik bir işlemle çalışan bir çıktıya dönüştürülür (Anderson, D., ve McNeill, G. 1992).

Aktivasyon fonksiyonu doğrusal olmayan sigmoid fonksiyonu ile Y çıktısını genellikle 0-1 aralığında sınırlar.

Sigmoid fonksiyonu;

$$F(\text{NET}) = \frac{1}{1 + e^{-\text{NET}}}$$

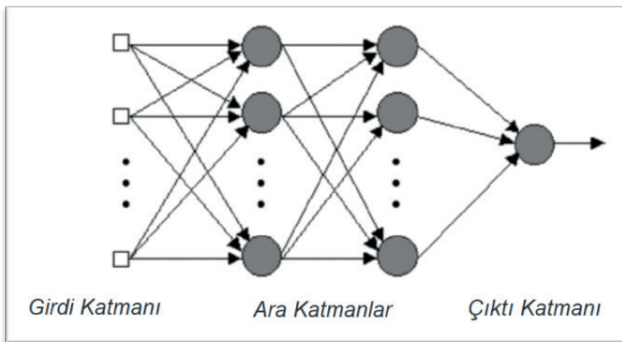


Şekil 3. Sigmoid fonksiyonu
Kaynak: (Menard, S. W. 1995)

Yapay sinir ağları içerisinde en popüler çok katmanlı yapay sinir ağıdır. Sistemde nöronların aynı doğrultu üzerinde bir araya gelmesiyle katmanlar oluşur (Avcılar, M. Y., ve Yakut, E., 2015). Çok katmanlı algılayıcı ağları genelleştirilmiş delta kuralı öğrenme yöntemi ile öğrenir. Genelleştirilmiş delta kuralı 2 aşamadan oluşur;

İleri doğru hesaplama; Girdi katmanı, dış ortamlardan aldığı bilgileri hiçbir değişikliğe uğratmadan ara katmana iletir. Bilgi, ara ve çıktı katmanında işlenerek ağıın çıktısı belirlenir.

Geriye doğru hesaplama; Bu hesaplamada, modelde üretilen çıktı ile beklenen çıktı karşılaştırılır. Aradaki farkın azalması için ara katman ile çıktı katmanı arasındaki ağırlıkların değiştirilmesi veya girdi katmanı ve ara katman arasındaki veya ara katmanların kendi arasındaki ağırlıklar değiştirilir (Öztemel, 2003).



Şekil 4. Çok katmanlı YSA örneği

Yapay sinir ağları ile sınıflandırma, tahmin, zaman serisi analizi, optimizasyon, veri sıkıştırma, veri ilişkilendirme, örüntü tanıma, doğrusal olmayan sistem modelleme, sinyal filtreleme fonksiyonları yerine getirilebilir (Tayyar, N. 2010).

Yapay sinir ağı modelleri, bağımsız ve bağımlı değişkenler arasındaki doğrusal olmayan ilişkileri algılayabilir. Yapay sinir ağları, hem sürekli hem de kategorik girdi ve çıktı değişkenleri kullanılarak eğitilebilir, ancak kullanılan yazılıma bağlı olarak veriler üzerinde bazı dönüşümler gerekebilir (Tu, J. V. 1996).

Yapay sinir ağlarının dezavantajlı yönlerini ele aldığımızda; bir yapay sinir ağının oluşturulmasına yönelik spesifik bir kural yoktur. Pek çok farklı eğitim algoritması mevcuttur ve şu anda belirli bir problem için en uygun eğitim algoritması yalnızca ampirik/deneysel olarak belirlenebilir. Çözümü ulaşmak için deneme yanılma yöntemi kullanıldığından çözümsüzlük veya iyi sonuç alamama yanında optimum bir değere ulaşıp ulaşılamadığını belirlenemeyebilir. Her problem için standardın olmaması dolayısıyla hep ayrı değerlendirme yapılması lazımdır. Ayrıca problem çözümlendiğinde ağın nasıl ve neden o şekilde hareket ettiği net değildir (Öztemel, 2003).

Bulguların yorumlanmasında sıkça yer verilen ROC eğrisi ise, karar eşiğinin gözlemlenen tüm sonuç aralığı boyunca sürekli olarak değiştirilmesinden kaynaklanan hassasiyet / özgüllük çiftlerinin bir grafiğidir. İyi sonuçlanan bir ROC eğrisinde gerçek pozitif değerlerin oranı (Hassasiyet) sol üst köşeden geçer ve 1'e yakın veya %100 oranındadır ve yanlış pozitif değerlerin oranı (Özgüllük) ise 0'a yakındır. Sınıflandırmanın doğruluk derecesi, ROC eğrisinin altında kalan alanın büyüklüğü ile ölçülebilir. Bu büyüklük 0.50 ve 1.00 arasında bir değer alır. 1.00'e yakın bir değer iyi bir sınıflandırmayı ifade ederken, 1.00 değeri ise mükemmel sınıflandırmayı gösterir (Zweig, ve Campbell, 1993).

Çalışmanın Amacı, Kapsamı ve Veri Yapısı

Bu çalışmanın amacı, çok değişkenli analiz tekniklerinden yararlanarak (literatürde en iyimser tahminleri saptanmış olan) Moody's kredi derecelendirme kuruluşunun ülke kredi notlarını verirken baskın olarak hangi faktörleri ele aldığını belirlemek ve verilen kredi notlarına göre ülkelere yatırım yapılabilir/yapılamaz sınıflandırmasını yapmaktır.

Çalışma kapsamında, 2017 yılına ait veri seti Moodys'in resmi internet sitesinden alınmıştır. Moody's, veri setini ekonomik yapı ve performans, devlet finansmanı, dış ödemeler ve borç, parasal-dış güvenlik açığı ve likidite göstergelerini içeren dört ana başlık altında düzenlemiştir. Toplamda 138 dünya ülkesi içeren veri seti, ortak değişkenlere sahip en geniş veri setini oluşturmak için ekonomik yapı ve performans, devlet finansmanı, dış ödemeler ve borç ana başlıkları altında yeniden düzenlenmiştir. Daha sonra kayıp gözlemler ve uç değerler analizden çıkarılarak 85 adet farklı ülkeden oluşan nihai veri seti oluşturulmuştur. Bu aşamada örneklem büyüklüğünün en az gözlenen değişken sayısının beş katı olması gerekliliği de göz önüne alınmıştır.

Çalışma kapsamındaki değişkenler literatürdeki çalışmalar göz önünde bulundurularak *Tablo.1'*deki gibi belirlenmiştir.

Tablo 1

Bağımsız Değişken Tanımları

Değ.	Tanım	Değ. (Devam)	Tanım (Devam)
X_{ep1}	Kişi başına düşen GSYİH (ABD \$)	X_{df4}	Genel Devlet Borcu (ABD \$)
X_{ep2}	Reel GSYİH (% değişim)	X_{df5}	Dış Ödemeler ve Borç
X_{ep3}	Enflasyon (TÜFE,% değişim)	X_{db1}	Reel Efektif Döviz Kuru (% değişim)
X_{ep4}	Gayri Safi Yurtiçi Tasarruf / GSYİH	X_{db2}	Cari İşlemler Dengesi / GSYİH
X_{ep5}	Ekonominin Açıklığı	X_{db3}	Net Doğrudan Yabancı Yatırım / GSYİH
$X_{df1/df2}$	Hükümet Geliri/GSYİH'nin Hükümet Harcamaları/GSYİH'ye oranı	X_{db4}	Resmi Forex Rezervleri (ABD \$)
X_{df3}	Genel Hükümet Faiz Dışı Dengesi / GSYİH		

Çoklu doğrusal bağıllık sorunu iki veya daha fazla bağımsız değişken arasında yüksek korelasyon olduğunda ortaya çıkar. Analizde bağımsız değişkenler arasında çoklu doğrusal bağıllığın olup olmadığını kontrolü yapılmıştır. Bu doğrultuda VIF değeri 5'den büyük olan değişkenler; Hükümet Geliri/GSYİH, Hükümet Harcamaları/GSYİH'ye oranlanmış ve VIF değerinin 5'in altında çıkması ile çoklu doğrusal bağlantı problemi elimine edilerek bu iki değişken tek bağımsız değişkene indirgenmiştir¹.

Kredi derecelendirmesinde her bir sembol, kredi özelliklerinin genel olarak aynı olduğu bir grubu temsil eder. Temelde kredi riskini gösteren dokuz sembol vardır. Bunlar; Aaa Aa A Baa Ba B Caa Ca C'dir. Analizde kredi dereceleri en düşükten en yükseğe doğru numaralandırılarak metrik hale getirilmiştir.

Uzun Dönem Kredi Notu	
Yatırım Yapılabilir Düzey	Aaa
	Aa1
	Aa2
	Aa3
	A1
	A2
	A3
	Baa1
	Baa2
Baa3	
Yatırım Yapılamaz Düzey	Ba1
	Ba2
	Ba3
	B1
	B2
	B3
	Caa1
	Caa2
	Caa3
Ca	
C	

Şekil 5. Moody's Kredi Derecelendirme Ölçeği

1 Bu aşamada Faktör analizi uygulamalarına da başvurulmuş ancak başarılı (yorumlanabilir) sonuçlara ulaşılamamıştır.

Daha sonra Moodys'in *Şekil 5*'de gösterilen uzun dönem kredi notu için belirlediği yatırım yapılabilirlik düzeyine göre, iki kategorili bağımlı değişken elde edilmiş ($y=1$: yatırım yapılabilir, 0 : yatırım yapılamaz) ve ikili lojistik regresyon analizi uygulanmıştır.

Ampirik Bulgular

Uygulama analiz sonuçları, SPSS istatistiksel paket programı ve R programındaki neuralnet paketi kullanılarak elde edilmiştir. Analize kayıp değerler içeren gözlemler dâhil edilmemiştir ve Mahalonobis D^2 uzaklıkları yardımıyla analizdeki aykırı gözlemler olarak saptanan Lüksemburg, Ekvador ve Güney Afrika birimleri veri setinden çıkarılmıştır.

Veri setine ikili lojistik regresyon analizi uygulanması sonucunda lojistik regresyonda enter yöntemi ile elde edilen bulgulara ilişkin açıklamalar aşağıda yer almaktadır.

Tablo 2

Model Katsayıları için Omnibus Testi

	Ki-Kare	df	Sig.
1. Adım	84,151	13	,000
Block	84,151	13	,000
Model	84,151	13	,000

“Yalnızca sabit terimin yer aldığı başlangıç modeli ile tüm bağımsız değişkenlerin analize dâhil edilmesiyle oluşan sonuç modeli arasında fark yoktur.” şeklinde ifade edilen sıfır hipotezi reddedilmiş ($\text{sig.} = 0,000$), ulaşılan modelin anlamlı olduğu sonucuna varılmıştır.

Tablo 3

Modelin Özeti

-2LogLikelihood(-2LL)	Cox&Snell R ²	Nagelkerke R ²
29,401	,628	,853

Cox ve Snell R^2 ve Nagelkerke R^2 istatistikleri doğrusal regresyon analizindeki açıklama oranını veren R^2 istatistiğine benzemektedir. Fakat bu ölçütler R^2 gibi modelin uygunluğunun değerlendirilmesinde kullanılmamaktadır. Bu istatistikler lojistik regresyon analizinde bağımlı değişken ile bağımsız değişkenler arasındaki ilişkiyi ölçer. Örneğin, analizde Nagelkerke R^2 değeri, bağımlı değişken ile bağımsız değişkenler arasında yaklaşık %85'lik bir ilişki olduğunu göstermektedir (Özdamar, 2013).

-2LogL istatistiği n : gözlem sayısı, k :parametre sayısını ifade etmek üzere, $n-k$ serbestlik derecesiyle χ^2 dağılımına uymaktadır. Sadece sabit terimin olduğu, hiçbir bağımsız değişkenin olmadığı başlangıç modelinin serbestlik derecesi 84 (85-1), bağımsız değişkenlerin modele eklendiği sonuç modelinin serbestlik derecesi 72 (85-13)'dir.

Başlangıç modelinin -2LogL istatistiği(113,552), sonuç modelinin -2LogL istatistiği(29,401)'dir. Bu değerlerin farkı ise 84,151'dir. Yine model uyumunda oluşan değişme anlamlıdır (Özdamar, 2013).

Tablo 4
Sınıflandırma Tablosu

Adım	Tahmin Edilen Yi			
	Gözlenen Yi	Yatırım Yapılamaz	Yatırım Yapılabilir	Doğru Sınıflandırma Yüzdesi
Yatırım Yapılamaz	29	4	87,9	
Yatırım Yapılabilir	4	48	92,3	
Genel Sınıflandırma Yüzdesi			90,6	

Lojistik regresyon analizi ile birinci adımda bağımsız değişkenlerin modele dâhil edilmesi ile sonuç modeline ait toplam doğru sınıflandırma oranı % 90,6'ya yükselmektedir².

Tablo 5
Sonuç Modelinin Katsayı Tahminleri

1.Adım	B	Standart Hata	Wald	df	Sig.	Exp(B)
Xep1	0	0	6,384	1	0,012	1
Xep2	-0,016	0,324	0,002	1	0,961	0,984
Xep3	-0,743	0,324	5,253	1	0,022	0,476
Xep4	0,164	0,113	2,097	1	0,148	1,178
Xep5	0,011	0,02	0,298	1	0,585	1,011
orandf1df2	-26,056	15,564	2,803	1	0,094	0
Xdf3	1,451	0,731	3,935	1	0,047	4,267
Xdf4	0,006	0,003	5,034	1	0,025	1,006
Xdf5	-0,167	0,059	8,009	1	0,005	0,846
Xdb1	-0,127	0,121	1,092	1	0,296	0,881
Xdb2	-0,192	0,172	1,244	1	0,265	0,826
Xdb3	-0,368	0,232	2,523	1	0,112	0,692
Xdb4	-0,01	0,005	4,518	1	0,034	0,99
Sabit	26,52	15,083	3,091	1	0,079	3,29E+11

% 5 anlamlılık düzeyinde Kişi başına düşen GSYİH, Enflasyon, Genel Hükümet Faiz Dışı Dengesi / GSYİH, Devlet Borcu, Dış Ödemeler ve Resmi Forex Rezervleri değişkenlerinin istatistiksel olarak anlamlı bulunduğu saptanmıştır. Enflasyon değişkenindeki 1 birimlik artış, yatırım yapılabilirlik odds'unda %74 azalışa yol açmaktadır. Genel Hükümet Faiz Dışı Dengesi / GSYİH değişkenindeki 1 birimlik artış, yatırım yapılabilirlik odds'unda %145 artışa yol açmaktadır. Gayri Safi Yurtiçi Tasarruf / GSYİH değişkenindeki 1 birimlik artış, yatırım yapılabilirlik odds'unda %006 artışa yol açmaktadır. Ekonominin Açıklığı değişkenindeki 1 birimlik artışın, yatırım yapılabilirlik odds'unda %16 azalışa yol açmaktadır.

2 Başlangıç doğru sınıflandırma oranı % 61 olarak elde edilmiştir.

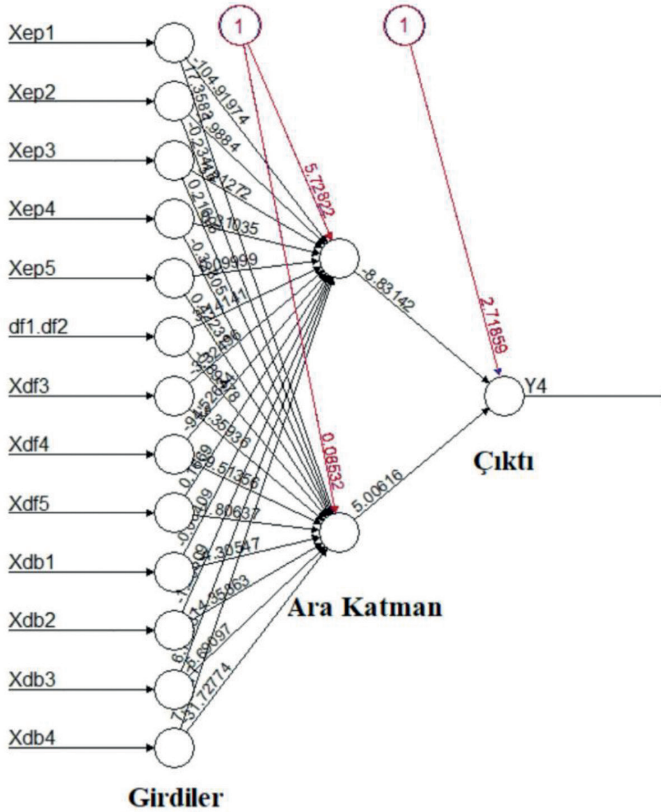
Tablo 6
Sonuç Özeti

Yi	Gözlem Sayısı
Pozitif	52
Negatif	33

Lojistik regresyon analizi sonucu 85 ülkeden 52'si pozitif (Yatırım Yapılabilir), 33'ü negatif (Yatırım Yapılamaz) olarak bulunmuştur.

Veri setinde yapay sinir ağlarının geri yayılım algoritması ile elde edilen bulgulara ilişkin açıklamalar aşağıda yer almaktadır.

Makine öğrenmesinde denetimli öğrenmede model eğitilir. Eğitim modeli öğretilen model iken, Test verisi eğitim verisinden öğrendiklerini kullanarak sonuç verir. R programında belirlenen oranda (örn;%80) rastgele ayrıştırma yapılır. 85 gözlemden oluşan veri seti eğitim ve test verisine bölünür. Oluşan eğitim verisi 69, test verisi ise 16 gözlem içermektedir.



Şekil 6. Analiz sonucu oluşturulan yapay sinir ağı yapısı

Bir sinir ağı modelinin geliştiricisinin karşılaştığı kararlardan biri, gizli bir katmana konacak düğüm sayısıdır. Optimal sayıyı önceden belirlemek için hiçbir teori bulunmamakta, ağ geliştiricilerin optimal sayıyı bulmak için çeşitli gizli düğüm numaraları denemesi gerekmektedir. Çalışmada düğüm sayısını saptamak için çeşitli denemeler yapılmış, en iyi sonuca düğümüne önce 8 ve 6 değeri sonrasında da 2 değerini verildiğinde ulaşılmıştır.

Bulgulara göre, aşağıda gösterilen model, en iyi sonucu veren ağ yapısı 2 nöron içeren 1 ara katman ile oluşmuştur. Topolojik olarak ağ 13 girdi, 1 ara katman ve 1 çıktıdan oluşmuştur. Modelde bağımsız değişkenler girdilere karşılık gelir. Burada siyah çizgiler, her bir katman ve her bağlantıdaki ağırlıklar arasındaki bağlantıları gösterirken bordo çizgiler ise her adımda eklenen sabit terimi gösterir.

Aşağıda analiz uygulaması sonucunda ulaşılan sınıflandırma tabloları yer almaktadır.

Tablo 7

Eğitim Verisine Ait Sınıflandırma Tablosu

Gerçek Sınıf	Tahmini Sınıf	
	0	1
0	26	8
1	0	35

Tablo 8

Eğitim Verisine Ait Değerlendirme Sonuçları

Doğruluk=	0,88
Hata Oranı=	0,12
Gerçek Pozitif Değerlerin Oranı=	1
Gerçek Negatif Değerlerin Oranı=	0,76
Yanlış Pozitif Değerlerin Oranı=	0,23
Yanlış Negatif Değerlerin Oranı=	0
Kappa=	0,5017

Tablo 9

Test Verisine Ait Sınıflandırma Tablosu


Gerçek Sınıf	Tahmini Sınıf	
	0	1
0	7	7
1	0	2

Tablo 11

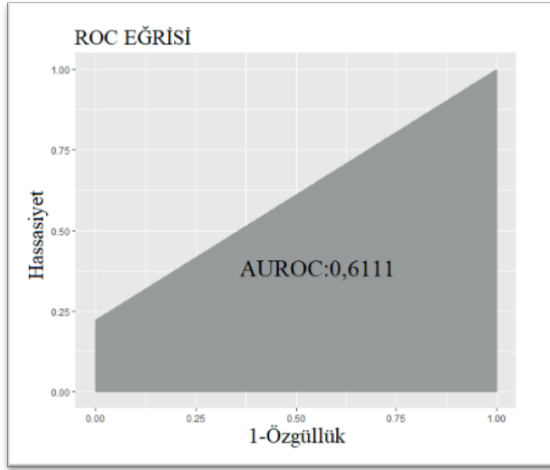
Test Verisine Ait Değerlendirme Sonuçları

Doğruluk=	0,56
Hata Oranı=	0,44
Gerçek Pozitif Değerlerin Oranı=	1
Gerçek Negatif Değerlerin Oranı=	0,5
Yanlış Pozitif Değerlerin Oranı=	0,5
Yanlış Negatif Değerlerin Oranı=	0
Kappa=	0,45

Kappa istatistiği; Cohen'in kappa katsayısı olarak bilinir ve iki değerleyici arasındaki karşılaştırmalı uyuşmanın güvenilirliğini ölçen bir istatistik yöntemidir. Cohen's Kappa istatistiği 0 ile 1 arasında değer alır. Kappa istatistiğinin 0,50 olması da modelin orta derecede gerçek değerlerle uyuştüğunun bir göstergesidir. Özetle, yapay sinir ağlarının eğitim verisini iyi şekilde öğrendiği söylenebilir.



Şekil 7. Eğitim verisi için ROC eğrisi



Şekil 8. Test verisi için ROC eğrisi

Daha önce de belirtildiği gibi, sınıflandırmanın doğruluk derecesi, ROC eğrisinin altında kalan alanın büyüklüğü ile ölçülebilir. Bu büyüklük 0,50 ve 1,00 arasında bir değer alır. 1,00'e yakın bir değer iyi bir sınıflandırmayı ifade ederken, 1,00 değeri ise mükemmel sınıflandırmayı gösterir. (Zweig, ve Campbell, 1993)

Eğitim verisi için Şekil 7'de görüleceği üzere ROC eğrisinin altında kalan alan AUC (area under curve) değeri 0,90'dır. Şekil 8'den görüleceği üzere ise AUC (area

under curve) değeri 0,61 olarak hesaplanmıştır. Burada değerlerin %50'nin üzerinde olması sınıflandırma performansının iyi olduğunu göstermektedir.

Sonuç

Ülke (Moody's) kredi notlarını etkileyen değişkenlerin saptanması ve ülkelerin sınıflandırılması amaçları doğrultusunda güncel ikincil verilerle (t = 2017, n= 85) ve alternatif çok değişkenli analiz teknikleri ile gerçekleştirilen bu çalışma sonucunda analiz bulgularının temelde literatürdeki diğer çalışmalar ile uyumlu olduğu söylenebilir.

Yürütülen literatür taraması sonucunda ülke kredi notları verilirken en çok enflasyon, finansal açıklık, kişi başına düşen gelir, teknolojik gelişme, kamu geliri, kamu gideri, borçlanma, cari işlemler dengesi, demokrasi, yasaların ve düzenin benimsenmesinin ve daha az yolsuzluğun etkin olduğu görülmüştür.

Bu çalışma sonucunda daha önceki çalışmalara paralel ve ek olarak lojistik regresyon analizinin uygulanması sonucunda 2017 yılı ülke kredi derecelendirme notuna göre ülkelerin yatırım yapılabilir veya yatırım yapılamaz olduğunu belirleyen en önemli faktörlerin kişi başına düşen GSYİH, enflasyon, genel hükümet faiz dışı dengesi/GSYİH, genel devlet borcu, dış ödemeler-borç ve resmi forex rezervleri'nin olduğu saptanmıştır.

Analiz sonuçlarına göre yöntemlerin sınıflandırma başarıları incelendiğinde ise lojistik regresyon modelinin doğru sınıflandırma oranının % 90,6 ve yapay sinir ağırları modelinin doğru sınıflandırma oranının % 88 olduğu görülmüştür. Ayrıca kredi notları açısından Türkiye'nin yatırım yapılamaz sınıfına dahil edildiği sonucuna ulaşılmıştır.

Bu konuda çalışma yapmayı düşünen araştırmacılara kayıp gözlemlerin ilgili konuda geliştirilmiş metotlarla doldurularak uygulamanın tekrar gerçekleştirilmesi ve bulguların incelenmesi önerilebilir. Ayrıca gelişmişlik düzeyine göre farklı ülke grupları için de bulgular karşılaştırılabilir ve/veya alternatif yöntem sayısı artırılabilir.

Finansal Destek: Yazarlar bu çalışma için finansal destek almamışlardır.

Kaynakça/References

- Alpar, R. (2003). Uygulamalı çok değişkenli istatistiksel yöntemlere giriş. Ankara: 1. Nobel Yayın Dağıtım.
- Anderson, D., & McNeill, G. (1992). Artificial neural networks technology. *Kaman Sciences Corporation*, 258(6), 1–83.
- Avcılar, M. Y., & Yakut, E. (2015). Yapay sinir ağırları çoklu lojistik regresyon ve çoklu diskriminant analiz yöntemlerinden yararlanarak yerel seçimlerde seçmen tercihlerinin belirlenmesi: Osmaniye ili uygulaması. *Journal of Alanya Faculty of Business/Alanya İşletme Fakültesi Dergisi*, 7(2).
- Balıkçioğlu, E., & Yılmaz, H. H. (2013). Ülkelerin Finansal Açıdan Kredi Notlarını Etkileyen Faktörler ve Kredi Derecelendirme Kuruluşlarının Bu Faktörler Çerçevesinde Değerlendirilmesi. *Maliye Dergisi*, 165, 163–188.

- 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.
- Bissoondoyal-Bheenick, E., Brooks, R., & Yip, A. Y. (2006). Determinants of sovereign ratings: A comparison of case-based reasoning and ordered probit approaches. *Global Finance Journal*, 17(1), 136–154.
- Budak, H., & Erpolat, S. (2012). Kredi riski tahmininde yapay sinir ağları ve lojistik regresyon analizi karşılaştırılması. *AJIT-e: Online Academic Journal of Information Technology*, 3(9), 23–30.
- Disatnik, D., & Sivan, L. (2016). The multicollinearity illusion in moderated regression analysis. *Marketing Letters*, 27(2), 403–408.
- Ekelik, H., & Altaş, D. (2019). Dijital reklam verilerinden yararlanarak potansiyel konut alıcılarının rastgele orman yöntemiyle sınıflandırılması. *Journal Of Research In Economics*, 3(1), 28–45.
- Genç, E. G., & Başar, O. D. (2019). Comparison of country ratings of credit rating agencies with moora method. *Business and Economics Research Journal*, 10(2), 391–404.
- Hair, J. F., Black, W. C., Babin, B., Anderson, R. E., & Tatham, R. L. (2006). *Multivariate data analysis* (6th ed). Upper Saddle River, NJ: Prentice-Hall.
- Hilbe, J. M. (2016). *Practical guide to logistic regression*. Chapman and Hall/CRC.
- Kalaycı, Ş. (2010). *SPSS uygulamalı çok değişkenli istatistik teknikleri* (Vol. 5). Ankara: Asil Yayın Dağıtım.
- Özdamar, K. (2013). *Paket programlar ile istatistiksel veri analizi*. Eskişehir: Nisan Kitabevi,
- Peng, C. Y. J., Lee, K. L., & Ingersoll, G. M. (2002). An introduction to logistic regression analysis and reporting. *The journal of educational research*, 96(1), 3–14.
- Reisen, Helmut. 2002. "Ratings since the Asian Crisis." OECD Development Centre. Accessed October 9, 2015. <http://www.oecd.org/development/pgd/1934633.pdf>.
- Menard, S. W. (1995). *Applied logistic regression analysis*.
- Montes, G. C., Oliveira, D. S., & Mendonça, H. F. (2016). Sovereign Credit Ratings in Developing Economies: New Empirical Assessment. *International Journal of Finance & Economics*, 21(4), 382–397.
- Öztemel, E. (2003). *Yapay sinir ağları*. İstanbul: PapatyaYayincilik.
- Tabachnick, B. G., Fidell, L. S., & Ullman, J. B. (2012). *Using multivariate statistics* (Vol. 5). Boston, MA: Pearson.
- Tennant, D. F., & Tracey, M. R. (2016). *Sovereign debt and credit rating bias*. Palgrave Macmillan.
- Tayyar, N. (2010). Müşteri memnuniyeti tahmininde yapay sinir ağları, lojistik regresyon ve ayırma analizinin performanslarının karşılaştırılması. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 15(1), 339–355.
- Tu, J. V. (1996). Advantages and disadvantages of using artificial neural networks versus logistic regression for predicting medical outcomes. *Journal of clinical epidemiology*, 49(11), 1225–1231.
- Yegnanarayana, B. (2009). *Artificial neural networks*. PHI Learning Pvt. Ltd.
- Zweig, M. H., & Campbell, G. (1993). Receiver-operating characteristic (ROC) plots: a fundamental evaluation tool in clinical medicine. *Clinical chemistry*, 39(4), 561–577.

