

Ülke Kredi Notlarının Makine Öğrenme Algoritmaları ile Tahmini¹ (Estimating Sovereign Credit Rating by Using Machine Learning Algorithm)

Hakan PABUÇCU ^a

^aİktisadi ve İdari Bilimler Fakültesi, İşletme Bölümü, Bayburt Üniversitesi, Bayburt, Türkiye. hpabuccu@bayburt.edu.tr

MAKALE BİLGİSİ	ÖZET
Anahtar Kelimeler: Kredi derecelendirme Yapay Sinir Ağları Destek Vektör Makineleri Makine Öğrenme Gönderme Tarihi 1 Kasım 2018 Revizyon Tarihi 22 Ocak 2019 Kabul Tarihi 10 Şubat 2019 Makale Kategorisi: Araştırma Makalesi	Amaç – Bu çalışmanın temel amacı makine öğrenme algoritmalarından yapay sinir ağları, sinirsel bulanık mantık denetim ve destek vektör makinelerinin ülke kredi notu tahminindeki başarılarını araştırmaktır. Yöntem – Araştırma problemi ülkelerin kredi puanlarının tahminini bir sınıflandırma problemi olarak ele almaktadır. Seçilen değişkenler ilgili algoritmalar için girdi olarak kullanılmış ve bu algoritmaların sınıflandırma başarıları araştırılmıştır. Kullanılan veri seti ülkelere ait 2016-2018 dönemini kapsayan üç yıllık güncel verilerdir. Bulgular – Kullanılan algoritmaların parametre seçimi için çok sayıda deneme yapılmış ve uygun parametre kümeleri belirlenmeye çalışılmıştır. Araştırma sonuçlarına göre, her üç modelin de tahmin başarısı yüksek olmakla birlikte çok güçlü bir sınıflandırma algoritması olan destek vektör makineleri en iyi sonuçları üreten algoritma olmuştur. Tartışma – Tüm modellerin sınıflandırma başarısının kabul edilebilir olduğunu, kredi notu tayini için kullanılacak modeller olduklarını söylemek mümkündür. Örneğin Leshno ve Spector, (1996) çalışmasında YSA modelinin doğru tahmin yüzdesi %72 olarak, Mohapatra, De, ve Ratha, (2010) çalışmasında %75 olarak, Blanco ve diğerleri (2013) çalışmasında ise %92,4 olarak gerçekleşmiştir. Literatürdeki çalışmalarla karşılaştırıldığında analiz sonuçlarının başarılı olduğu görülmektedir.

ARTICLE INFO	ABSTRACT
Keywords: Sovereign Credit Rating Artificial Neural Network Support Vector Machine Machine Learning Received 1 November 2018 Revised 22 January 2019 Accepted 10 February 2019 Article Classification: Research Article	Purpose – The main objective of this study is to investigate the success of artificial neural networks, adaptive neuro fuzzy inference system and support vector machines in sovereign credit rating estimation. Design/methodology/approach – The research problem addresses the estimation of countries' credit scores as a classification problem. Selected variables were used as input for mentioned algorithms and classification success of these algorithms was investigated. The data set used is the current three-year data covering the 2016-2018 period of the countries. Numerous attempts were made to select the parameters of the algorithms used and the appropriate parameter sets were tried to be determined. Findings – According to the research results, although the predictive success of all three models is high, support vector machines was determined as the best classifier algorithm which produces the best results. Discussion – It is possible to say that the performance of the prediction of all models is acceptable and they are the models that can be used for sovereign credit rating prediction. For example, in the study of Leshno and Spector, (1996) the predicted performance of ANN model was 72%, in Mohapatra, De, and Ratha, (2010) was 75% and in Blanco et al. (2013) was 92.4%. It is seen that the results of the analysis are successful compared to the studies in the literature.

¹Bu çalışma 2015 yılında Karadeniz Teknik Üniversitesi SBE Ekonometri ABD'nda hazırlanmış olan doktora tezinden türetilmiş, güncel veri ve ilave analizler kullanılarak hazırlanmıştır.

Önerilen Atf/ Suggested Citation:

Pabuçcu, H. (2019). Ülke Kredi Notlarının Makine Öğrenme Algoritmaları ile Tahmini, *İşletme Araştırmaları Dergisi*, 11 (1), 42-51.

1. Giriş

Küresel durgunluk veya gerileme dönemlerinde ortaya çıkan yüksek faiz oranları gibi olumsuzluklar özellikle az gelişmiş ülkeler olmak üzere dünya ülkelerini etkilemektedir. Ülkeler borç ödeme yükümlülüklerini kaybetmekte ve hizmet verme konusunda büyük sıkıntılar yaşamaktadırlar. Bu gibi sorunları önceden öngörme noktasında bağımsız kredi derecelendirme kuruluşları hükümet tahvillerine yönelik olarak değerlendirmeler yapmakta ve ülkeler için kredi notları belirlemektedirler. Kredi derecelendirme kuruluşları borç alanların borç senetlerini geri ödeyememe ihtimalini değerlendirmektedirler. Ülkeler için kredi notu tayini istekleri doğrultusunda yani gönüllük esasına dayalı olarak yapılmaktadır. Kredi notu olan ülkelerin yabancı yatırımları alma konusunda notu olmayan ülkelere göre avantajlı oldukları herkes tarafından kabul görmektedir.

Derecelendirme kuruluşları değerlendirmelerini yaparken değişkenler için farklı ağırlıklar atayarak bir kredi skoru hesaplamaktadırlar. Her kuruluş kendine özgü değerlendirme ölçütleri ve ağırlıkları belirlemektedir. Bir ülkenin kredi notunun belirleyicileri olarak makroekonomik, siyasal, sosyal değişkenlerin yanında çok daha kapsamlı değerlendirmeler sunan; Küresel Rekabet Endeksi, Politik Kısıtlamalar Endeksi Ekonomik Özgürlük Endeksi gibi endeksler literatürde kullanılmaktadır. Bu çalışmada kapsamlı bir literatür araştırması sonucu belirlenen değişken havuzundan seçilen değişkenler kullanılarak uluslararası kredi derecelendirme kuruluşları tarafından yapılan değerlendirmelere alternatif olabilecek bir kredi derecelendirme modeli geliştirilmeye çalışılmıştır. Problemin çözümü için makine öğrenme algoritmaları kullanılmıştır.

Bu çalışma Pabuçcu, (2015) tarafından hazırlanan doktora tezinin devamı ve geliştirilmiş halidir. Oluşturulan değişken havuzundan elde edilen bağımsız değişkenlerle sistemin temsil kabiliyetinin güçlendirilmesi ve kredi notunu en iyi açıklayan değişkenlerin belirlenmesi amaçlanmaktadır. Literatürde kredi derecelendirme ile ilgili birçok çalışma yapılmıştır. Bu çalışmalarda lojistik regresyon analizi, diskriminant analizi, zaman serisi analizi ve panel veri analizi gibi istatistik ve ekonometrik yöntemler kullanılmıştır. Bu çalışmada ise, 2016-2018 yıllarını kapsayan veri seti ve makine öğrenme algoritmaları kullanılarak, ülkelerin temerrüde düşme durumlarının en iyi şekilde tahmin edilmesi amaçlanmıştır.

Kredi derecelendirme literatürü incelendiğinde genellikle mikro ölçekli yapılan çalışmalar dikkat çekmektedir. Ülke derecelendirmesi çalışmaları ise nispeten daha az ilgi görmüştür. Bu çalışmanın amacını da kapsayacak şekilde literatürü şu şekilde özetlemek mümkündür.

Kredi derecelendirme alanındaki her çalışmada dayanak noktası olarak gösterilen Cantor ve Packer, (1996), tarafından yapılan çalışmada kredi değerliliğini ölçmede kullanılacak temel değişkenlerin kişi başına gelir, GSYİH büyüme hızı, enflasyon, mali denge, dış denge, dış borç, temerrüt geçmişi ve ülkenin gelişmişlik sıralaması olması gerektiği üzerinde durulmuştur. Ülke notları ile notları belirleyen faktörler arasındaki ilişkinin hangi yönde ve büyüklükte olduğu regresyon analizi yardımıyla belirlenmeye çalışılmıştır. Bissoondoyal, (2005) kredi notlarının sayısal belirleyicilerini analiz etmek için S&P ve Moody's verilerini kullanmış, verileri yüksek notlu ve düşük notlu ülkeler olmak üzere ikiye ayırarak analiz etmiştir. Çalışmanın en önemli sonucu olarak notların sadece ekonomik ve finansal göstergeler tarafından açıklanamayacağı ifade edilmiştir. Bennel ve Diğ., (2006)'da kredi derecelendirme için sınıflandırma metodolojisi ile yapay sinir ağları ve sıralı probit analizinin kıyaslaması yapılmıştır. Kredi notları bağımlı değişken olarak, dış borç/ihracat, mali denge, dış denge, enflasyon oranı, kişi başı GSYİH, GSYİH büyüme oranı, ülkenin gelişmişlik durumu bağımsız değişkenler olarak kullanılmıştır. Butler ve Fauver, (2006) bir ülkenin resmi organlarının ve siyasi kuruluşlarının kredi notunu nasıl etkilediğini tespit etmek için politik istikrar, hükümet etkinliği, hukukun üstünlüğü yolsuzluk değişkenlerini kullanmışlar ve değişkenler arasında çok güçlü bir ilişki tespit etmişlerdir. Depken, Courtney ve Roger, (2006) ise yolsuzluk algı endeksi, temerrüt geçmişi, ticari açıklık, ülkenin dünya üzerindeki konumu, demokrasi endeksi, ticaret yasalarının kaynağı, nüfus ve petrol üretim durumu yanında makroekonomik değişkenleri de modellerine dâhil etmişler ve yolsuzluk algısı ile ülke notu arasında negatif yönlü bir ilişkinin varlığını tespit etmişlerdir. Politik şiddet, diplomatik baskı, yolsuzluk, askeri vesayet, dinsel eğilimler, kanunların etkinliği ve etkililiği, demokrasinin yapısı ve doğrudan yabancı sermaye yatırımları verilerinin kullanıldığı Busse ve Hefeker, (2007) çalışmalarında sadece makroekonomik değişkenlerin değil, aynı zamanda nitel değişkenlerin de yer aldığı model önerileri sunulmuştur. Bu çalışmada derecelendirme kuruluşlarının metodolojilerine

değinilmiş ve kişi başı GSYİH değişkeninin bile tek başına kredi derecelendirmeyi %80 oranında açıklayabildiğine vurgu yapılmıştır. Elkhoury, (2008) çalışmasında kredi derecelendirme kuruluşları ve kuruluşların gelişmekte olan ülkeler üzerindeki etkisini tartışmıştır. Kuruluşları Basel 1-2 kriterleri çerçevesinde ele almış, metodolojilerini incelemiş kullandıkları nitel ve nicel yöntemleri ayrıntılı olarak açıklamaya çalışmıştır. Mohapatra, De, ve Ratha, (2010) Moody's Fitch ve S&P tarafından derecelendirmeye dâhil edilmeyen ülkeler için regresyon analizi kullanarak notlar belirlemiştir. Kredi notları bağımlı ve GSYİH büyüme oranı, kişi başı GSMH, rezerv oranları, GSYİH volatilitesi, enflasyon ve hukuk egemenliği açıklayıcı değişken olarak kullanılmıştır. Notu olmayan ülkeler için yapılan tahminlerin büyük bir kısmı "B" ve daha yukarısı olarak tahmin edilmiştir. Roychoudhury ve Lawson, (2010) ekonomik özgürlük, kredi notları ve ülkenin temerrüde düşme durumu arasındaki ilişkiyi incelemiştir. Bu çalışma için sıralı probit analizi, tobit analizi kullanılmıştır. Bundala, (2012) çalışmasında kredibilitenin belirleyicisi olan ekonomik büyüme, insani gelişim ve politik istikrar değişkenleri ile gelişmiş ve gelişmekte olan ülkeleri kıyaslama yoluna gitmiştir. Çoklu regresyon analizi uygulaması neticesinde; kişi başına GSYİH, iç borç, cari denge ve eşitsizliğe uyarlanmış insani gelişimin, borç ödeme yükümlülüklerini negatif yönde işsizlik, enflasyon ve politik istikrarın ise pozitif yönde etkilediği sonucuna ulaşılmıştır. Williams, Alsakka ve Owain, (2013) gelişmekte olan pazarlarda ülkelerin kredi notu değişimlerinin sebeplerini ve ülkelerin kredi notlarındaki değişimlerin o ülkede faaliyet gösteren bankaların kredibilitelerini nasıl etkilediğini araştırmışlardır. Kredi notu değişimleri bağımlı değişken olarak, ekonomik özgürlük endeksi, yolsuzluk algı endeksi, mülkiyet hakları kişi başı gelir, enflasyon cari denge, mali denge ve dış borç ise bağımsız değişken olarak kullanılmıştır. Reusens ve Croux, (2017)'de 2002-2015 yılları için 90 ülke örneğini kullanarak farklı ülke kredi derecelendirme belirleyicilerinin zaman içindeki önemini karşılaştırılmaktadır. Birleşik marjinal olasılık yaklaşımı uygulayarak, üç büyük kredi derecelendirme kuruluşunun her biri için çok yıllık bir probit modeli tahmin edilmiştir. 2009 yılında Avrupa borç krizinin başlamasından sonra, finansal dengenin, ekonomik kalkınmanın ve dış borçların önemi büyük ölçüde artmış ve avro bölgesi üyeliğinin etkisi olumludan negatife dönüşmüştür. Buna ek olarak, GSYİH büyümesi, yüksek borçlu devletler ve devlet borçlarının düşük GSYİH büyüme oranına sahip ülkeler için çok daha önemli hale gelmesi açısından büyük önem kazanmıştır. Bu bulgular, kredi derecelendirme kuruluşlarının Avrupa borç krizinin başlamasından sonra devlet kredi derecelendirme değerlendirmelerini değiştirdiğini gösteren ampirik kanıtlar sunmaktadır. Sangiorgi ve Spat, (2017) finansal kriz dönemlerinde kredi derecelendirme kuruluşlarının durumunu ve yapılan eleştirileri ayrıca, kararlarının ekonomik sistem üzerindeki etkilerini araştırmışlardır. Kuruluşların bağımsız durum tespiti yapıp yapamadıklarını ve sistematik risklerin ortaya çıkıp çıkmadığını tartışmışlar ve öneriler sunmuşlardır. Binici ve Hutchison, (2018)'de kredi notunun, CDS primleri ile ölçülen ülke riskinin piyasa fiyatlaması üzerindeki marjinal etkileri araştırılmıştır. Kredi derecelendirme değişikliklerinin etkisinin doğru bir şekilde değerlendirilmesinin, derecelendirme değişikliğinden önce bilinen bilgiler üzerinde koşullandırılması gerektiğini ifade etmişlerdir. Ampirik çalışmada, Ocak 2004'ten Ağustos 2012'ye kadar aylık verileri kullanan 56 ülkeyle dinamik bir panel makroekonomik model kullanılmaktadır. Bazı durumlarda not tahminleriyle, kredi notu değişikliklerinin bilgi değerini doğru bir şekilde belirlerken, izleme durumunun kritik bir rol oynadığı ifade edilmektedir. Yukarıda incelenen çalışmaların ortak yönleri ülke notları üzerinde sonuçlar ortaya koymaları ve genellikle ekonometrik modeller kullanmalarıdır. Bu noktadan hareketle, makine öğrenme algoritmalarının bu çalışmada kullanılmasının önemli olduğu düşünülmektedir.

Çalışma 4 bölümden oluşmaktadır. Birinci bölüm konuya ilişkin yazarın motivasyonunu, genel olarak çalışmanın teorik çerçevesini ve ilgili literatür araştırması sunulmuştur. İkinci bölümde kullanılan veri seti, yapay sinir ağları, ANFIS model ve destek vektör makineleri teorik olarak aktarılmıştır. Üçüncü bölümde araştırmanın bulgularına ve son bölümde ise tartışma ve araştırmanın sonuçlarına yer verilmiştir.

2. Veri seti ve yöntem

Bu çalışmada kredi derecelendirme kuruluşları tarafından yapılan kredi notu değerlendirmesine alternatif bir değerlendirme yaklaşımı olarak makine öğrenme algoritmaları kullanılmıştır.

2.1. Veri seti

Literatür araştırması sonucu kredi notunu, yani ülke riskini etkileyen faktörler için bir değişken havuzu oluşturulmuş, ilgili değişkenlere ve ülkelere ait 2016-2018 yıllarını kapsayan veri seti oluşturulmuştur. Üç

yıla ait veriler zaman faktörü göz önüne alınmaksızın ayrı birimler olarak yatay kesit veri şeklinde analizde kullanılmıştır. Buradaki amaç kullanılan modellerinin daha iyi öğrenmesini sağlayarak doğru tahmin oranını arttırmaktır. Bazı ülkelere ve değişkenlere ait verilerin eksik olması nedeniyle analizden çıkarılan birimler olmuştur. Toplamda analize dâhil edilebilecek 366 birime ait veriler eksiksiz olarak elde edilebilmiştir. Tablo 1’de kredi notu tahmini çalışmalarında kullanılan değişkenler ve elde edildikleri kaynaklarla ilgili bilgiler sunulmaktadır. Ayrıca; değişken seçimi değişken uzayının boyutlarını azalttığı için yöntem algoritmasının daha hızlı ve etkin çalışmasını sağlamakta ve daha tutarlı sonuçlar elde etmesine imkân tanımaktadır (Hajek ve Michalak, 2013, s. 75). Bu çalışmada kullanılan değişkenlerin seçimi için Pabuçcu’dan (2015) faydalanılmış ve kullanılan değişkenler * ile işaretlenmiştir.

Tablo 1. Sıklıkla kullanılan kredi notu belirleyicileri

Değişken	Kod	Kaynak
Demokrasi endeksi	DMKRS	The Economist
Dış borç yükü	DSBRC	Dünyabankası
Döviz kuru istikrarı	DVZIST	www.prsgroup.com
Ekonomik özgürlük endeksi	EKOZG	www.heritage.org
Eşitsizliğe uyarlanmış insani gelişim endeksi	EUİGE	www.tr.undp.org
GSYİH büyüme oranı	GSYHBY	Dünya bankası
GSYİH Deflatörü*	DEF	Dünya bankası
GSYİH yüzdesi olarak ithalat	ITH	Dünya bankası
GSYİH yüzdesi olarak ihracat	IHR	Dünya bankası
GSYİH yüzdesi olarak tasarruf oranı	TSRF	Dünya bankası
GSYİH yüzdesi olarak cari işlemler denge	CRDNGGSYH	Dünya bankası
İnsani gelişim endeksi	İGE	www.tr.undp.org
İhracat yüzdesi olarak cari işlemler denge*	CRDNGIHR	Dünya bankası
İhracat yüzdesi olarak borç servisi*	BRCSRVIHR	www.prsgroup.com
İstihdam oranı (%Toplam)	ISTHDM	Dünya bankası
İş yapma kolaylığı endeksi	ISKLY	Dünya bankası
Hukukun üstünlüğü (Rule of law)*	HKK	Dünya bankası
Kişi başı GSMH	GSMH	Dünya bankası
Küresel rekabet endeksi*	KRSLRK	www.weforum.org
Nüfus	NFS	Dünya bankası
Politik istikrar	PLTISTK	Dünya bankası
Tüketici fiyat endeksi	TUFE	Dünya bankası
Yasaların uygunluğu (Regulatory Quality)	YU	Dünya bankası

2.2. Yöntem

Bu araştırmada üç farklı makine öğrenme algoritmasının kredi derecelendirme problemi için kullanılabilirliği ve tahmin performansları araştırılmıştır. Yapay sinir ağları, uyarlanabilir sinirsel bulanık çıkarım sistemi ve destek vektör makineleri kredi derecelendirme probleminin çözümü için kullanılan algoritmalarıdır. Yapay sinir ağları tahmin problemlerinde çok sık kullanılan yöntemlerden bir tanesi olduğu için teorik olarak çok fazla detaya girilmemiştir.

2.2.1. Yapay Sinir Ağları

Yapay sinir ağı sosyal, fen ve mühendislik alanları başta olmak üzere birçok uygulama alanına sahip olan ve zeki öğrenme paradigmasını kullanan matematiksel bir modeldir (Yu, Wang ve Lai, 2008, s. 2626). Reel değerli n boyutlu girdi özel vektörleri şu şekilde ifade edilir. j gizli katman siniri, i girdisini, w_{ij} ($i=1,2,\dots,n, j=1,2,\dots$) ağırlığına göre alır. j birimi x girdi işaretinin ve w_{ij} ağırlıklarının bir fonksiyonunu hesaplayıp, sonucu sonraki komşu sinirlere aktarır. Gizli katmanlar birbirlerine ağırlıklarla tam bağlıdır. Bu sinirler de girdilerin ve girdilerin ağırlıklarının bir işlevini hesaplayıp sonucu sonraki aşamaya aktarır. Bu işlem, çıktı

katmanındaki sınırlar tarafından da yapıldığı zaman tamamlanır (Elmas, 2011, s.56). Sinir ağları ile ilgili detaylı bilgiye aşağıdaki kaynaklardan ulaşılabilir.¹

2.2.2. Uyarlanabilir Sinirsel Bulanık Çıkarım Sistemi (ANFIS)

Geleneksel yöntemlerle belirsizlik barındıran veya kaotik davranışlar sergileyen sistemleri modellemek oldukça güçtür. Bu tür sistemlerin modellenebilmesi için insan beyninin akıl yürütme sürecini de sisteme dâhil edebilen simülasyonlar kullanmak gerekmektedir. Bulanık çıkarım sistemleri bu şekilde tasarlanmıştır. Takagi ve Sugeno, (1985) tarafından geliştirilen, denetim ve tahmin gibi birçok alanda kullanılan bulanık çıkarım sistemleri, bulanık eğer-o halde kurallarını kullanmaktadır ANFIS model bulanık çıkarım sistemlerinin adaptif ağlara uyarlanarak Jang, (1993) tarafından geliştirilen ve doğrusal olmayan problemlerin çözümünde kullanılan bir yöntemdir (Pabuçcu, 2015).

Model için x ve y gibi iki girdi-iki bulanık kurallı Sugeno tip ANFIS mimarisi şu şekildedir.

$$R_1: \text{Eğer } x \text{ } A_1 \text{ ve } y \text{ } B_1 \text{ ise } o \text{ halde } f_1 = p_1x + q_1y + r_1 \quad (1)$$

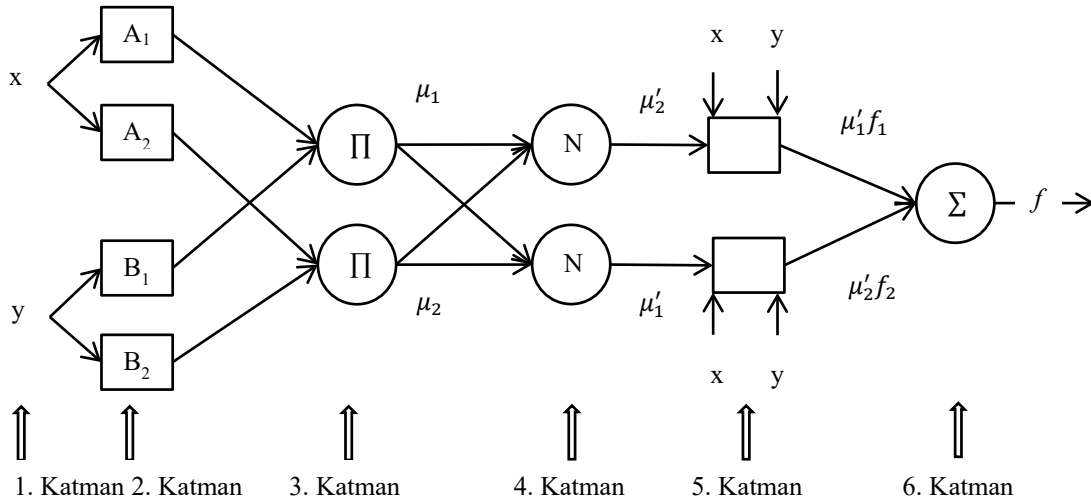
$$R_2: \text{Eğer } x \text{ } A_2 \text{ ve } y \text{ } B_2 \text{ ise } o \text{ halde } f_2 = p_2x + q_2y + r_2 \quad (2)$$

Şekil 1’de ANFIS mimarisi görülmektedir. Katmanların işlevleri sırasıyla şu şekilde ifade edilebilir (Elmas, 2011; Jang, 1991; Jang, 1993; Jang, 1996; Pabuçcu, 2015).

1. *Katman*: Bu katmanda herhangi bir aritmetik işlem olmadan girdiler bir sonraki katmana aktarılır.

2. *Katman*: Bu katmandaki her bir düğüm birer bulanık kümedir. Hesaplanan düğüm çıktı değerleri, girdilerin üyelik fonksiyonları kullanılarak dönüştürülmüş üyelik dereceleridir ve Eşitlik (3) ile hesaplanmaktadır.

$$\begin{aligned} o_{i+2}^2 &= \mu_{A_i}(x) \\ o_{i+2}^2 &= \mu_{B_i}(y), \quad i = 1, 2 \end{aligned} \quad (3)$$



Şekil 1: İki Girdi-İki Kurallı Sugeno Tip ANFIS Mimarisi **Kaynak:** Elmas, 2011.

Burada x girdi düğümü ve A_i ise dilsel ifadeleri göstermektedir. Eşitlik (3)'de ağın x ve y girdilerine ait düğüm çıktıları görülmektedir. Her düğümde eşitlik (4)-(5)'te gösterilen çan eğrisi üyelik fonksiyonu kullanılır.

$$\mu_{A_i}(x) = \frac{1}{1 + \left| \frac{x - m_i}{\sigma_i} \right|^2} \quad (4)$$

$$\mu_{A_i}(x) = \exp \left[-\left(\frac{x - m_i}{\sigma_i} \right)^2 \right] \quad (5)$$

¹ *Elmas, Çetin (2011), Yapay Zeka Uygulamaları, 2. Baskı, Ankara: Seçkin Yayınevi.

**Fuller, Robert (1995), Neural Fuzzy Systems, Abo Akademi University, ISBN 951-650-624-0, ISSN 0358-5654

Bu iki eşitlikte m_i ve σ_i parametreleri çan eğrisi üyelik fonksiyonunun sırasıyla orta noktasını ve standart sapmasını göstermektedir. Bu parametreler, ağ eğitilirken ayarlanmaktadır. Bu katmandaki düğüm fonksiyonları için, sık kullanılan sürekli veya parçalı olmak üzere üçgen ve yamuk şekilli üyelik fonksiyonları da kullanılabilir.

3. *Katman*: Bu katmandaki düğümler, girdi sinyallerinin çarpımı olduğu için \prod sembolü ile gösterilmiştir. Düğüm çıktısı da Eşitlik (6) ile hesaplanmaktadır.

$$o_i^3 = \mu_i = \mu_{Ai}(x)\mu_{Bi}(y), i = 1, 2 \quad (6)$$

4. *Katman*: Bu katmandaki her düğüm "N" ile sembolize edilmiştir. Eşitlik (7) ile i . düğüm ve i . kurala ait normalize eşik değeri hesaplanır.

$$o_i^4 = \mu'_i = \frac{\mu_i}{\mu_1 + \mu_2}, i = 1, 2 \quad (7)$$

5. *Katman*: Düğüm çıktısı Eşitlik (8) yardımıyla hesaplanır.

$$o_i^5 = \mu'_i f_i = \mu'_i(p_i x + q_i y + r_i) \quad (8)$$

Eşitlikte μ'_i , dördüncü katmanın çıktısıdır ve normalleştirilmiş ateşleme seviyesini (*firing strenght*) gösterir. p_i, q_i, r_i parametre setidir.

6. *Katman*: Bu katmandaki düğüm \sum sembolü ile gösterilmektedir. Gelen sinyaller için toplam çıktı f Eşitlik (9) ile hesaplanmaktadır.

$$o^6 = f = \sum_i \mu'_i f_i = \frac{\sum_i \mu_i f_i}{\sum_i \mu_i} \quad (9)$$

2.2.3. Destek Vektör Makineleri

Destek vektör makineleri (SVM), tanıma, sınıflandırma, regresyon ve zaman serilerinde uygulanan bir algoritmadır. SVM, Vapnik'in (1995) ikili sınıflandırmalarda yapısal risk minimizasyonu ilkesinin bir uygulaması olarak ortaya çıkmıştır. SVM algoritması istatistiksel öğrenme kuramında genellemenin ve yapısal karmaşıklık ile deneysel risk arasındaki değiş tokuşun nasıl yapılacağı çalışmalarından doğmuştur. SVM, noktaları desen uzayında ya da daha yüksek boyutlu bir uzayda iki ayrık yarım uzaya atayarak sınıflandırır (Khemchandani ve Jayadeva Chandra, 2009). SVM'nin ana fikri, pozitif ve negatif örnekler arasındaki ayırım marjının maksimize edileceği şekilde karar yüzeyi olarak bir hiper düzlem oluşturmaktır (Xu, Zhou, ve Wang, 2009). Örneklerin bir eğitim kümesi için, $x_i \in R^d$ girdi vektörleri ve karşılığı olan $y_i \in \{1, -1\}$ görüntü kümesi ile nesnelere iki sınıfa dâhil ederek nasıl sınıflandıracağını öğrenir. İki sınıflı bir sınıflandırma problemi için; $x_i \in R^d (i = 1, 2, \dots, N)$ girdi vektörleri ve $y_i \in \{1, -1\} (i = 1, 2, \dots, N)$ karşılık kümesi olduğu varsayalım. Burada 1 ve -1 iki sınıfı ifade etsin. Burada amaç ikili bir sınıflandırıcı oluşturmak veya mevcut örneklerden, daha önce görülmemiş bir örnekteki birimleri yanlış sınıflandırma olasılığı düşük olan bir karar fonksiyonu üretmektir. SVM, girdi vektörlerini $x_i \in R^d$ yüksek boyutlu bir özellik alanına $\Phi(x_i) \in H$ haritalar ve en uygun ayırma hiper düzlemini oluşturur. Hiper düzlem ile H uzayındaki her bir sınıfın en yakın veri noktaları arasındaki mesafe maksimize edilir. Φ haritalaması H iç çarpım uzayında tanımlanan $K(x_i, x_j)$ çekirdek fonksiyonları tarafından gerçekleştirilir. Elde edilen sınıflandırıcı α_i katsayılarını belirlemek için eşitlik 10 da verilen karar fonksiyonu ve kuadratik programlama problemine dayalıdır (Hua ve Sun, 2001).

$$f(x) = \text{sgn}(\sum_{i=1}^N y_i \alpha_i \cdot K(x, x_i) + b) \quad (10)$$

Kuadratik problem ise aşağıdaki gibi tanımlanır:

$$\begin{aligned} \text{Maks. } \sum_{i=1}^N \alpha_i - 1/2 \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j \cdot y_i y_j \cdot K(x, x_i), 0 \leq \alpha_i \leq c \\ \sum_{i=1}^N \alpha_i y_i = 0 \quad i = 1, 2, \dots, N \end{aligned} \quad (11)$$

Burada c ; marjın ile sınıflandırma hataları arasındaki dengeyi kontrol eden düzenleme parametresidir. SVM'de yaygın kullanılan polinomial ve radyal tabanlı olmak üzere iki adet çekirdek fonksiyon vardır.

$$\text{Polinomial fonksiyon: } K(x_i, x_j) = (x_i \cdot x_j + 1)^d \quad (12)$$

$$\text{Radyal tabanlı fonksiyon: } K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (13)$$

Tahminin başarısı için çekirdek fonksiyonu seçimi oldukça önemlidir. İlgili fonksiyonların parametrelerinin belirlenmesi belli bir yöntem olmamakla birlikte çok sayıda deneme yapılarak en iyi parametre setleri belirlenmektedir.

3. Bulgular

Bu bölümde araştırma modellerine ilişkin bulgular detaylı olarak sunulacaktır. Makine öğrenme algoritmalarının öğrenme sürecinde veri seti eğitim (%66) ve test (%34) olmak üzere iki parçaya bölünmüştür. Tablo 2’de kullanılan göstergelere ilişkin özet istatistikler yer almaktadır.

Tablo 2. Göstergelere ilişkin özet istatistikler

Gösterge	Minimum	Maksimum	Ortalama	Standart sapma
KRSLREK	3,166	5,737	4,391	0,582
CRDNG	-65,59	62,564	-3,746	18,103
HKK	-1,686	1,956	0,267	0,969
BRCSR	0	325	14,227	26,734
DEF	-2,897	74,854	6,193	9,009

3.1. Yapay Sinir Ağı Tahmin Sonuçları

Oluşturulan yapay sinir ağı modelinde kullanılacak olan veriler derlendikten sonra yapılan çalışmalardan hareketle veri kümesi eğitim ve test olmak üzere iki parçaya bölünmüştür. YSA modelinde 366 adet verinin 242 tanesi (%66) eğitim, 124 tanesi (%34) test için ayrılmıştır. Test için ayrılan veriler modele önceden hiç gösterilmemiş olan tahmin verileridir. Bu verilere sinir ağının vereceği yanıtlar yani çıktı değerleri (kredi notu) bu çalışmada kullanılan diğer modellerle karşılaştırmak için kullanılmıştır. Veriler eğitim esnasında [0-1] arasında ölçeklendirilerek kullanılmış ve ağ eğitilmiştir. Sinir ağı eğitim sürecinde kullanılan parametre ayarları Tablo 3’te sunulmaktadır.

Tablo 3. Eğitim sürecinde kullanılan parametre ayarları

Parametre	Kullanılan düzey
Gizli katman nöron sayısı (n)	5,...,50
İterasyon (ep)	250, 500,...,2000
Momentum sabiti (mc)	0.1, 0.2,...,0.9
Öğrenme oranı (lr)	0.1, 0.2, 0.3

Yapay sinir ağı modeli olarak çok yaygın olarak kullanılan ve tahmin başarısı yüksek olan çok katmanlı algılayıcı (ÇKA) kullanılmıştır. ÇKA yapısında beş sinir hücresinden oluşan girdi katmanı, yedi sinir hücresinden oluşan bir gizli katman ve iki sinir hücresinden oluşan çıktı katmanı bulunmaktadır. Ağın iyi performans gösterebilmesi modelin mimarisine bağlı olduğu için çok önemli bir konudur. Net girdileri dönüştürmek üzere birçok aktivasyon fonksiyonu kullanılabilir. Bu çalışmada türevi alınabilir bir fonksiyon olan tanjant sigmoid fonksiyon tercih edilmiştir. Öğrenme oranı ve momentum sabiti sırasıyla 0,1 ve 0,3 olarak belirlenmiştir. Modellerin değerlendirilmesi için mutlak hata ortalaması (MAE) ve hata kare ortalama karekökü (RMSE) istatistikleri kullanılmıştır. Modelden elde edilen tahminler Tablo 4’te sunulmuştur.

Tablo 4. YSA Model Mimarisi ve Parametreleri

Ağın türü	ÇKA-MLP
Ağdaki Katman sayısı	4
Gizli katman sayısı	1 (7 nöron)
Girdi aktivasyon fonksiyonu	Tanjant sigmoid
Çıktı aktivasyon fonksiyonu	Doğrusal
İterasyon sayısı	500
Öğrenme oranı	0,1
Momentum sabiti	0,3

Eğitim mutlak hata ortalaması (EMAE)	0,0012
Eğitim hata kare ortalama karekökü (ERMSE)	0,0924
Test mutlak hata ortalaması (TMAE)	0,0173
Test hata kare ortalama karekökü (TRMSE)	0,1894

YSA modelinin test verisine ilişkin sınıflandırma performansı ise 0,9763 olarak gerçekleşmiştir.

3.2. ANFIS Model Sonuçları

ANFIS model Jang (1993)'e göre yapısı gereği dörtten fazla girdi değişkeni olduğu zaman kural tabanının çok genişlemesi dolayısı ile iyi sonuçlar üretmemektedir. Bu sebeple en yüksek hataya sebep olan değişkenin tespiti için dörtdü değişken grupları (beş grup) ile model denemeleri yapılmış ve "KRSLRK, CRDNGGSYH, HKK ve BRCSRVIHR" değişkenlerinin kullanılmasına karar verilmiştir. Tahminler için Sugeno tipi bulanık çıkarım sistemi yapısı kullanılmıştır.

ANFIS model oluşturulurken veriler tıpkı YSA modelinde olduğu gibi eğitim ve test olmak üzere iki parçaya bölünmüştür. Girdiler için üçer üyelik fonksiyonu ve dolayısıyla 81 adet kural oluşturulmuştur. Girdi değişkenleri üyelik fonksiyonu olarak π üyelik fonksiyonu kullanılmıştır. Modelde çıktı fonksiyon tipi için sabit (sıfırıncı derece Sugeno bulanık model) ve doğrusal (birinci derece Sugeno bulanık model) olmak üzere iki fonksiyon seçeneği mevcuttur. Doğrusal fonksiyon seçildiği zaman eğitim hatası küçülmekte fakat test ve doğrulama hataları yüksek bir artış göstermektedir. Bu sebeple modelde çıktı için sabit fonksiyon kullanılmıştır. Tüm modellerin değerlendirilmesi için aynı hata istatistikleri kullanılmıştır. ANFIS model sınıflandırma başarısı 0,9527 olarak gerçekleşmiştir. Model mimarisi ve parametrelerine ilişkin istatistikler Tablo 5'te sunulmaktadır.

Tablo 5. ANFIS Model Mimarisi ve Parametreleri

Ağın türü	ANFIS (Sugeno tipi)
Ağdaki katman sayısı	6
Eğitim iterasyon sayısı	300
Girdi üyelik fonksiyonu	π şeklinde
Çıktı fonksiyonu	Sabit
Üyelik fonksiyon sayısı	3-3-3-3
Bulanık kural sayısı	81
Optimizasyon algoritması	Hibrit (Geri yayılım-EKK)
"ve" metodu	prod (çarpım)
"veya" metodu	probor (cebirsal toplam)
Durulaştırma metodu	wtaver (ağırlıklı ortalama)
Eğitim mutlak hata ortalaması (EMAE)	0,0011
Eğitim hata kare ortalama karekökü (ERMSE)	0,1189
Test mutlak hata ortalaması (TMAE)	0,0784
Test hata kare ortalama karekökü (TRMSE)	0,1963

3.3. Destek Vektör Makineleri

Model mimarisini belirleyen temel parametreler Tablo 6'da sunulmaktadır. En iyi modelin tahmini için tablodaki parametre değerlerinin tamamı denenmiştir.

Tablo 6. Eğitim sürecinde kullanılan parametre ayarları

Parametre	Düzey (polinomiyal)	Düzey (radial tabanlı)
Çekirdek fonksiyonu derecesi (d)	1,2,3,4	
Çekirdek fonksiyonu Gamma Katsayısı (γ)		0, 0.1, 0.2, ..., 5.0
Düzenleme parametresi (c)	1, 10, 100	1, 10, 100

Kredi notu tahmini için en iyi SVM modeline ilişkin parametreler Tablo 7'de sunulmaktadır. İkinci derece polinomiyal çekirdek fonksiyonlu SVM modeli en iyi sınıflandırıcı olarak tespit edilmiştir. SVM modelinin test seti üzerindeki sınıflandırma başarısı ise 0,9891 olarak gerçekleşmiştir.

Tablo 7. SVM modeline ilişkin parametreler

Parametre		d	γ	c	Perf.
Polinomial		2	-	100	0.9891
Hata istatistikleri	EMAE	0,0078			
	ERMSE	0,0623			
	TMAE	0,0109			
	TRMSE	0,1045			

4. Sonuç ve Tartışma

Sonuç olarak, Tüm modellerin sınıflandırma başarısının kabul edilebilir olduğunu, kredi notu tayini için kullanılacak modeller olduklarını söylemek mümkündür. Örneğin Leshno ve Spector, (1996) çalışmasında YSA modelinin doğru tahmin yüzdesi %72 olarak, Mohapatra, De, ve Ratha, (2010) çalışmasında %75 olarak, Blanco ve diğerleri (2013) çalışmasında ise %92,4 olarak gerçekleşmiştir. Daha eski çalışmalar ise çok daha düşük doğru tahmin oranlarıyla yayınlanmıştır. Modellerin arasında bir seçim yapmak gerekirse SVM modelinin en iyi sınıflandırıcı olduğu açıktır. Çalışmada modellerin inşa edilmesi ve analizi için, YSA-SVM için Weka 3.8, ANFIS model için ise Matlab 2017a programları kullanılmıştır.

İlgili literatür incelendiğinde birçok kredi derecelendirme çalışmasının olduğu, bu çalışmaların genellikle şirket ve tahvil derecelendirmesi gibi mikro anlamda derecelendirmeler olduğu görülmektedir. Yöntemsel olarak ise ekonometrik ve istatistiksel modellerin ağırlıkta olduğu görülmektedir. Bu çalışmada ise ülkelerin temerrüt durumları (sovereign credit rating) analiz edilmiştir. Problem bir sınıflandırma problemi olarak ele alınmış ve üç farklı makine öğrenme algoritması kullanılarak literatürle karşılaştırıldığında başarılı olarak değerlendirilecek model tahminleri gerçekleştirilmiştir. Bu çalışmada kullanılan modeller örnek olaylar üzerinden değişkenler arasındaki ilişkiyi öğrenen ve tahminler üreten modellerdir. Örnek sayısı arttıkça doğru tahmin oranları da artacaktır. Ayrıca, eldeki verilerin güvenilir veriler olması son derece önemlidir. Yanlış verilerle öğrenilen ilişkiler yanlış tahminlerin elde edilmesine sebep olacaktır. Makine öğrenme algoritmalarının uygulama esnasında gerek eğitim için gerekse parametrelerin belirlenmesi için fazla zamana ihtiyaç duymaları bu yöntemler için bir dezavantaj olarak düşünülebilir. Ancak, tahminlerdeki başarıları göz önünde bulundurulursa modellerin kullanışlı olduklarını söylemek mümkündür. Burada yöntemlerin her zaman en iyi sonuçları ürettiklerini söylemek doğru olmayacaktır. Modelin başarısı, kullanıcının tecrübesi ve seçilen parametrelerin başarısı ile doğru orantılıdır. Geleceğe yönelik yapılabilecek çalışmalar için ise; farklı değişken setleri ve zaman aralıkları kullanılarak yeni tahminler gerçekleştirilebilir. Ayrıca en iyi tahmin modelinin bir uzman sisteme dönüştürülüp ülkelerin geleceğe dönük temerrüt durumlarının tahminini gerçekleştirmek de mümkündür.

Kaynaklar

- Bennel, vd., (2006). "Modelling Sovereign Credit Ratings: Neural Networks Versus Ordered Probit", Expert Systems with Applications, Sayı: 30, 415–425, <https://doi.org/10.1016/j.eswa.2005.10.002>.
- Binici, M. ve Hutchison, M., (2018). "Do credit rating agencies provide valuable information in market evaluation of sovereign default Risk?", Journal of International Money and Finance, Sayı: 85, 58-75, <https://doi.org/10.1016/j.jimonfin.2018.04.001>.
- Bissoondoyal-Bheenick, E., (2005). "An Analysis of the Determinants of Sovereign Ratings". Global Finance Journal, Cilt: 15, Sayı: 3, 251-280, <https://doi.org/10.1016/j.gfj.2004.03.004>.
- Blanco, Antonio vd., (2013). "Credit scoring models for the microfinance industry using neural networks: Evidence from Peru", Expert Systems with applications, Cilt: 40, Sayı: (1), 356-364, <https://doi.org/10.1016/j.eswa.2012.07.051>.
- Bundala, N., (2012). "Do Economic Growth, Human Development and Political Stability Favour Sovereign Creditworthiness of a Country? A Cross Country Survey on Developed and Developing Countries". MPRA Paper, 47626, 1-16.
- Busse, M. ve Hefeker, C., (2007). "Political Risk, Institutions and Foreign Direct Investment". European Journal of Political Economy, Cilt: 23, 397–415, <https://doi.org/10.1016/j.ejpoleco.2006.02.003>.

- Butler, A. W., ve Fauver, L., (2006). "Institutional Environment and Sovereign Credit Ratings", *Financial Management*, Cilt: 35, Sayı: 3, 53-79, <https://doi.org/10.1111/j.1755-053X.2006.tb00147.x>.
- Cantor, R. ve Packer, F., (1996). "Determinants and Impact of Sovereign Credit Ratings". *Economic Policy Review*, Cilt: 2, Sayı:2, 37-54.
- Depken, C., (2006). "Corruption and Creditworthiness: Evidence from Sovereign Credit Ratings", *SSRN Working Paper Series* (<http://ssrn.com/abstract=899414>).
- Elkhoury, M., (2008). "Credit Rating Agencies and Their Potential Impact on Developing Countries". *United Nations Conference on Trade and Development*, Sayı: 186, 165-180.
- Elmas, Ç., (2011). *Yapay Zeka Uygulamaları*. Ankara: Seçkin Yayınevi.
- Fuller, R., (1995). *Neural Fuzzy Systems*. Abo Akademi University, ISBN 951-650-624-0, ISSN 0358-5654.
- Hajek, P., ve Krzysztof, M., (2013). "Feature Selection in Corporate Credit Rating Prediction", *Knowledge-Based Systems*, Cilt: 51, 72-84, <https://doi.org/10.1016/j.knosys.2013.07.008>.
- Jang, J. S. R., (1991). "Fuzzy Modeling Using Generalized Neural Networks and Kalman Filter Algorithm", *AAAI Proceeding*, Cilt: 91, Sayı: 2, 762-767.
- Jang, J. S. R., (1993). "ANFIS: Adaptive-Network-Based Fuzzy Inference System", *IEEE Transactions on Systems, Man and Cybernetics*, Cilt: 23, Sayı: 3, 665-685.
- Jang, J. S. R., (1996). "Input Selection for ANFIS Learning". *Proceedings of the Fifth IEEE International Conference on Fuzzy Systems*, Cilt: 2, Sayı: 1, 1493-1499.
- Khemchandani, R., ve Jayadeva, C. S., (2009). "Knowledge based proximal support vector machines", *European Journal of Operational Research*, Cilt: 195, 914-923, <https://doi.org/10.1016/j.ejor.2007.11.023>.
- Li, W. vd. (2012). "Evaluation of Driver Fatigue on Two Channels of EEG Data". *Neuroscience Letters*, Cilt: 506, Sayı: 2, 235-239, <https://doi.org/10.1016/j.neulet.2011.11.014>.
- Pabuçcu, H. (2015). *Uyarlanabilir Sinirsel Bulanık Çıkarım Sistemi Tabanlı Alternatif Bir Kredi Derecelendirme Yönteminin Geliştirilmesi*. Karadeniz Teknik Üniversitesi SBE- Yayınlanmamış Doktora Tezi.
- Mohapatra, S., vd., (2011). "Shadow Sovereign Ratings for Unrated Developing Countries", *World Development*, Cilt: 39, Sayı: 3, 295-307, <https://doi.org/10.1596/1813-9450-4269>.
- Reusens, P., ve Cristophe, C., (2017). "Sovereign credit rating determinants: A comparison before and after the European debt crisis", *Journal of Banking & Finance*, Cilt: 77, 108-121. <https://doi.org/10.1016/j.jbankfin.2017.01.006>.
- Roychoudhury, S., ve Lawson, R. A., (2010). "Economic Freedom and Sovereign Credit Ratings and Default Risk", *Journal of Financial Economic Policy*, Cilt: 2, Sayı: 2, 149-162, <https://doi.org/10.1108/1757638101107>.
- Takagi, T., ve Sugeno, M., (1985). "Fuzzy Identification of Systems and Its Applications to Modeling and Control", *IEEE Transactions on Systems, Man and Cybernetics*, Sayı: 1, 116-132.
- Williams, G., vd., (2013). "The Impact of Sovereign Rating Actions on Bank Rating in Emerging Markets", *Journal of Banking and Finance*, Cilt: 37, Sayı: 1, 563-577, <https://doi.org/10.1016/j.jbankfin.2012.09.021>.
- Xu, X., vd., (2009). "Credit scoring algorithm based on link analysis ranking with support vector machine", *Expert Systems with Applications*, Sayı: 36, 2625-2632, <https://doi.org/10.1016/j.eswa.2008.01.024>.
- Yu, L., vd., (2008). "Forecasting Crude Oil Price with an Emd-Based Neural Network Ensemble Learning Paradigm". *Energy Economics*, Cilt: 30, Sayı: 5, 2623-2635, <https://doi.org/10.1016/j.eneco.2008.05.003>.