

YAPAY SİNİR AĞLARI YÖNTEMİ İLE BANKALARIN TAHSİLİ GECİKMİŞ ALACAKLARININ TAHMİNİ

THE ESTIMATION OF NON-PERFORMING LOANS IN TURKISH BANKING SECTOR WITH ARTIFICIAL NEURAL NETWORK

Dr. İlhami KARAHANOĞLU¹

ÖZET

Gelişen teknoloji ile yüksek veri işleme kapasitesine sahip yeni yöntem ve metotlar bilgisayar sistemlerini de içerecek şekilde ortaya çıkmakta ve farklı bilim dalları arasındaki etkileşim ile de paylaşılmaktadır. Endüstri Mühendisliği ve Matematik Problemleri çözümünde kullanılan Yapay Sinir Ağlar (YSA)'lar son çeyrek asırda finansal problemler için de pratik ve esnek bir araç olarak tercih edilmektedir. Hem finansal politikaları belirleyen ve krizler için öncü bir gösterge; hem de bankaların kendi iç performanslarını belirleyen bir değişken olarak tahsili gecikmiş alacaklar finans dünyası için dikkatle takip edilen önemli bir değişkendir. Bu çalışmada tahsili gecikmiş alacaklar için yapay sinir ağı yapısı; açıklayıcı değişkenler olarak dolar ve avronun, BIST100 endeksinin ve sanayi üretim endeksinin aylık getirileri son 10 yıllık dönemdeki veriler kullanılarak oluşturulmuş ve oluşturulan farklı YSA yapıları verimlilik fonksiyonları perspektifinde karşılaştırılmıştır.

Anahtar Kelimeler: *Yapay Sinir Ağları, Tahsili Gecikmiş Alacaklar*

*Jel Kodu:*D53,G2

ABSTRACT

With the development of new technology, the new methods and applications are emerging which include the complex computer systems and they are shared by different science disciplines by means of the interactions between them. The Artificial Neural Networks which are used for the solutions of mathematical and industrial engineering problems have also

¹ Kalkınma Bankası

been used for the financial problems for 25 years. The non-performing loans that is not only a signal for crises and the variable for determination of financial politics but also an important indicator for the banks internal performance evaluation is an vital data for finance world which is followed and monitored carefully. In this research, ANN structure for the non-performing loans is constructed with the explanatory variables as the monthly return of USD vs TRL, EURO vs TRL, BİST100 and Industrial Production Index. The data for the last 10 years are used for each variable and the performance of the system is evaluated according to the performance indicator functions.

Key Words: *Artificial Neural Network, Non-Performing Loans*

Jel Classification: D53, G51

GİRİŞ

Takipteki alacaklar bankaların kendi verimliliklerini ölçmeleri, karlılıklarını karşılaştırmaları ve değerlendirmeleri, faaliyet planlamaları için oldukça önemli bir veridir. Bunun yanı sıra; aynı zamanda politika belirleyen organizasyonlar ile merkezi yönetimler ve kontrol ve izleme amaçlı oluşturulmuş olan kurullar ve mekanizmalar için de piyasaları izlemek adına kullanılan önemli bir değişkendir. Ayrıca; tahsili gecikmiş alacaklar; ekonominin gidişatı hakkında ciddi bir bilgi veren değerli bir veri, krizler için ise bir erken uyarı aracıdır (Reinhardt ve Rogoff,2010).

Geçmiş dönem araştırmalar, takipteki alacakları açıklamak için kullanılan değişkenleri içsel ve dışsal olarak ikiye ayırmışlardır. Bu ayırma göre firma içi verilere dayanan değişkenlere içsel (bilançodan gelen karlılık ya da aktif kalitesi gibi), firma dışından kaynaklanan makroekonomik veya finans dünyasından gelen dışsal değişkenler olarak adlandırılmaktadır (Louzis vd,2011; Podpeira ve Weill,2008). Takipteki alacaklar sadece firmanın kendi finansal performansından ya da karar alma mekanizmasından değil aynı zamanda makroekonomik değişkenlerden de etkilenen ilginç bir finansal veridir, bu özelliği ile de farklı araştırmalara konu olmuştur.

Gerek içsel değişkenlere gerekse dışsal değişkenlere bağlı olarak yapılan araştırmaların ortak amacı tahsili gecikmiş alacakları daha iyi bir biçimde açıklamaktır. Ancak söz konusu araştırmalarda, değişkenler arasındaki ilişki her zaman doğrusal olmadığı gibi doğrusal sistemlerin çözümü de çoğu zaman belli kabullere dayanmaz (normal dağılım gibi) bu ise sadece araştırmayı planlarken değil aynı zamanda sonuçları değerlendirirken ciddi sorunlara yol açabilmektedir. Bu noktada değişkenler arasındaki sebep sonuç ilişkisini çözebilen daha esnek ve pratik bir metoda duyulan ihtiyaç

aşıkardır. Özellikle 2000'lerin başından beri finansal alanda uygulama alanı bulan yapay sinir ağları bu ihtiyacı karşılayan önemli bir yöntemdir.

Araştırmada; finansal ve ekonomik alanda çok önemli bir değişken olan tahsili gecikmiş alacaklar, dışsal faktörler olan BIST100 endeksi, yabancı para günlük getirisi (dolar ve avro) ve sanayi üretim endeksi ile açıklanmaya çalışılmıştır. Geçmiş dönemde gerçekleştirilen çalışmalara paralel olarak; söz konusu ilişki Yapay Sinir Ağları ile çözümlenerek yapının geçerliliği verimlilik ölçütlerinde değerlendirilmiştir.

1. TAHSİLİ GECİKMiŞ ALACAKLAR

Tahsili gecikmiş alacaklar finans literatüründe banka ile borçlu arasındaki ödeme ilişkisinde meydana gelen bozulma olarak tanımlanmaktadır. Farklı araştırmacılar tarafından bankacılık sektörünü takip ederken sıklıkla kullanılan ve değerlendirilen bir veri olarak tahsili gecikmiş alacaklar bir çok çalışmanın da ana konusu olmuştur. Louzis vd.(2011) çalışmalarında Yunanistan'daki farklı kredi sınıfları arasında karşılaştırma yapmışlardır. Tahsili gecikmiş alacaklar için oluşturdukları makroekonomik model ile hisse başına getiri, solvenci oranı, bilanço büyüklüğü ve kaldıraç oranını tahsili gecikmiş alacakların belirleyicisi olarak göstermişlerdir. Klein (2013) daha makroekonomik bir model kurmuş ve GDP ile işsizlik oranını tahsili gecikmiş alacakların en önemli belirleyicileri olarak savunmuştur. Benzer şekilde Pasha ve Kemraj (2013) da makroekonomik değişkenlerin firmaya özel değişkenlere göre tahsili gecikmiş alacakları daha iyi tahminleyebileceğini öne sürmüşlerdir. Messai (2013) tahsili gecikmiş alacakları firmaya özel ve makroekonomik olarak ikiye ayırmış bu çalışmasında büyüme hızlı, reel faiz ve işsizlik oranını makroekonomik veriler olarak, varlıkların getirisi, kredilerdeki artış ve rezerv krediler / toplam krediler oranını ise mikro ya da firmaya özel belirteçler olarak öne sürmüşlerdir.

Amediku (2006) çalışmasında tahsili gecikmiş alacaklar ile enflasyon arasındaki ilişkiyi incelemiş ve pozitif bir ilişki yapısını ortaya çıkarmıştır. Klein (2013) enflasyon ile tahsili gecikmiş alacaklar arasındaki ilişkiye dair tahmin denklemine, milli gelir ve işsizliği de eklemiştir. Skarica (2014) tahsili gecikmiş alacaklar üzerinde enflasyonun etkisinin kriz dönemleri öncesi ve sonrasında farklılaştığını göstermiş ve bunu Klein'in araştırmasında kullandığı değişkenlere bağlamıştır.

Abadi vd. (2014) tahsili gecikmiş alacakların dinamik özelliklerini incelemişlerdir. Araştırmalarında söz konusu alacakları etkileyebilen 6 önemli

faktörü; M2 para arzı, nominal döviz kuru, sanayi üretim endeksi, CPI, ihracat değerleri ve reel faiz olarak düşünmüşlerdir. Javinsloo (2013) tıpkı Abadi ve yukarıda adı geçen diğer araştırmacıları takip etmiş ve tahsili gecikmiş alacakların daha çok makroekonomik değişkenler yolu ile açıklanabileceğine dair inancını parasal şoklar ile tahsili gecikmiş alacaklar arasındaki ilişkiyi göstererek ortaya koymuştur.

Türkiye’de tahsili gecikmiş alacaklarla ilgili yapılan çalışmalara bakıldığında hem içsel hem de makroekonomik verilerin kullanıldığı görülmektedir. Yücemiş ve Sözel (2010) kriz dönemlerindeki tahsili gecikmiş alacaklarını incelemişler ve ekonominin genel durumunu ifade eden bir veri olarak tahsili gecikmiş alacaklar / toplam alacaklar oranını kullanmışlardır. Kriz dönemi sonrasındaki reformlarla Türkiye’deki reformlarla tahsili gecikmiş alacaklar / toplam alacaklar oranında göreceli bir azalma olduğu sonucuna ulaşmışlardır.

İslamoğlu (2015) kendi araştırmasında tahsili gecikmiş alacakları makroekonomik dünyada gerçekleşen değişiklikler ile açıklamaya çalışmıştır. İslamoğlu, ticari kredi faiz oranlarını, kamu borcu stoku / milli gelir oranını kullanmış ve bu değişkenlerin tahsili gecikmiş alacakları direk olarak etkilediğini göstermiştir.

Aslan ve Yapraklı (2008) araştırmalarında enflasyona odaklanmışlar ve enflasyon ile tahsili gecikmiş alacaklar arasında uzun dönemli negatif bir ilişki yakalamışlardır.

Tahsili gecikmiş alacakları açıklamaya çalışan yukarıda kurulmuş olan modeller ya zaman serileri temelli doğrusal çözümlerden ya da VAR modellemelerinden oluşmaktadır. Tahsili gecikmiş alacakları Yapay Sinir Ağları (YSA) ile açıklamaya çalışan araştırmalara son dönemlerde rastlanmaktadır. 19.yy ın formül asrı 20.yy ise algoritma ve süreç asrı olduğunu savunan görüşler göz önüne alındığında, doğrusal çözümlerinin yanısıra algoritmik bir çözüm olan YSA’nın da ciddiye alınması gerekliliği göz ardı edilemez.

Shaoet vd. (2012) kredi riskini araştırdıkları çalışmalarında bankalar için kredi riskini tahsili gecikmiş alacak oranı olduğunu belirtmişlerdir. Söz konusu çalışmada tahsili gecikmiş alacağı tahminleyen bir yapay sinir ağı modelini bilançooya bağlı oranları içeren 9 adet input ve yukarıda belirtildiği gibi tahsili gecikmiş alacakları içeren bir adet output ile kurmuşlardır.

Çifter vd.(2009) araştırmalarında, sektörel batık kredilerin ekonomik konjoktürden hangi faz aralığı ile etkilendiğini ölçen yapay sinir ağlarını

kurmuşlar ve batık ya da sorunlu kredileri tahsili gecikmiş alacaklar ile ölçmüşlerdir.

Harris (2013) çalışmasında, bir yapay sinir ağı yapısı olan destek vektör makinaları yardımı ile bankaların kredi risklerini ölçmeye çalışmış ve bankaların kredi risk göstergesi olarak tahsili gecikmiş alacakların kullanılabilceğini ifade etmiştir.

Geçmiş dönem çalışmalara bakıldığında, hem doğrusal modellerde hem de yapay sinir ağı modellerinde bağımlı değişken ya da output olarak tahsili gecikmiş alacakların (non-performing loans) kullanıldığını bununla beraber input olarak da hem makroekonomik verilerin hem de kuruma bağlı bilanço değerinden türetilen oranların kullanıldığı görülmektedir.


2. YAPAY SİNİR AĞLARI

Yapay sinir ağları (YSA),biyolojik sistemlerin yeni bir yapıyı keşfederek bu yapı üzerinden yeni bilgi üretme ve öğrenme algoritmalarının bilgisayar sistemlerine uygulanarak problem tanımlayan ve çözen sistemlerdir. Sistemde farklı elemanlar kendi belleklerine sahiptirler (Gupta,2003).YSA diğer problem çözme sistemlerine göre oldukça esnek ve aynı zamanda parametrik olmayan modelleme aracıdır (Tang ve Chi, 2005). Yapay sinir ağları, insan sinir sisteminin öğrenme süreci simülasyonu ile geliştirilmiş bir yöntemdir. Sadece basit matematiksel işlemleri ya da bağlantıları değil aynı zamanda karmaşık problemleri de oldukça etkili bir biçimde çözebilmektedir. Sadece ilişki ya da matematiksel hesaplamalarda değil aynı zamanda tahminleme, sınıflandırma, kümeleme gibi birçok problemin çözümünde tercih edilmektedir. Sinir ağlarının en önemli özelliği karmaşık sistemlerin geçmiş bilgilerinden yola çıkarak örnek üzerinde öğrenme yolu ile probleme çözüm getirebilmesidir (Efendigil vd., 2009)

Yapay sinir ağları yapısı, birbirine paralel olarak bağlı 3 temel elemandan oluşur. Bunlar nöron, bağlantılar ve öğrenme algoritmasıdır (Hamzaçebi,2011). Nöronlar; ana ve en önemli YSA elemanıdır. Tek katmanlı yapılarda, kurulan modele etki eden faktörlere göre birden çok sayıda nöron modelde yer alabilir ancak nöronlar modelde çıktı sayısı kadar sonuç verirler. Nöronların girdi ve çıktı arasında sonucu sağlamak için birbirleri ile etkileşimli olarak çalışması ile de yapay sinir ağlarının temel süreçleri ortaya çıkar.Yapay sinir ağları birbirleri ile etkileşim halindeki nöron katmanlarından oluşmaktadır. Bu katmanlar giriş katmanı, çıkış katmanı ve gizli katman olarak 3 kısımdır. Bu katmanlarda yer alacak nöron sayısı ve içerdeki toplam katman sayısı ile de YSA'nın mimarisi tamamlanmış olur.Girdi katmanı, sisteme dışardan verilerin aktarıldığı katmanı, gizli

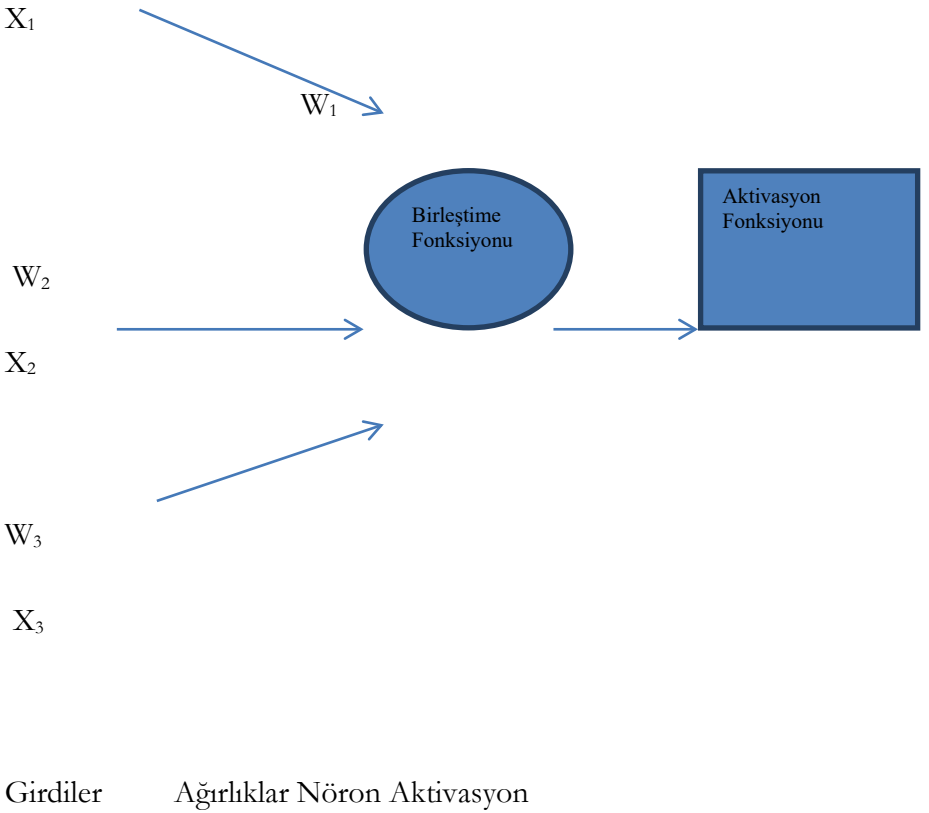
katman input ya da girdi verileri ile çıktı verileri arasındaki ilişkinin, söz konusu yapı ya da mimari esas alınarak çözüldüğü katmanı, çıktı ise output dediğimiz YSA nın ürettiği verilerin sistem dışına taşıdığı katmandır(Simon,1999).

Şekil 1 :Yapay Sinir Ağlarının Mimari Yapısı



Yapay sinir ağlarında yukarıdaki mimari yapıda da görüldüğü gibi her bir nöron bir başka nörondan ya da bağlantı noktasından bilgi almakta ve bu bilgileri ileriye doğru taşımaktadır .Nöronlar kendilerine gelen bilgiyi bir birleştirme fonksiyonu yardımı ile bir araya getirmektedirler Bu birleştirme fonksiyonları arasında en popüler olan ve çoğunlukla kullanılan ağırlıklandırılmış toplam fonksiyonudur. Bununla beraber girdiler arasındaki maksimumu tercih eden ağırlıklandırılmış maksimum ya da minimumu seçen ağırlıklandırılmış minimum ve ağırlıklandırılmış çarpım fonksiyonları da kullanılabilir. (Kaynar vd.2011)

Şekil 2: Birleştirme ve Aktivasyon Fonksiyonları



Nöronların davranışlarını etkileyen bir başka aktivasyon fonksiyonudur. Birleştirme fonksiyonundan gelen veri, aktivasyon fonksiyonu ile çıktıya dönüşür. Söz konusu fonksiyon çıktıları sıkılaştırarak $[-1,1]$ aralığına almaktadır. Zaman serileri problemlerinde sıklıkla kullanılan aktivasyon fonksiyonu veriyi $[0,1]$ aralığına sıkıştıran sigmoid ($1 / (1 + e^{-x})$) ile $[-1,1]$ aralığına sıkıştıran hiperbolik tanjant ($(e^x - e^{-x}) / (e^x + e^{-x})$) fonksiyonlarıdır (Hamzaçebi,2011).

YSA sistemi sürekli olarak hedef hata fonksiyonunu minimize etmek için iterasyonlar yaparak çalışır. Bu kapsamda tespit edilen hata fonksiyonu da YSA sisteminin önemli bir parçasıdır. Ortalama hata kareleri (MSE), ve ortalama hata terimleri (MAPE) en çok kullanılan hata fonksiyonlarıdır (Takma vd 2012).

Yapay sinir ağları ile öngörü yapılırken ise şu adımlar takip edilmektedir ;

1:Verinin Normalleştirilmesi: Veri istatistiki yöntemlerden de bilindiği haliyle; $[0,1]$ aralığına sıkıştırılarak, lojistik ve diğer çok kullanılan aktıvasyon fonksiyonları tarafından işlenecek hale getirilir bu yapılırkende $X_{i(\text{yeni})} = (X_{i(\text{eski})} - X_{\min}) / ((X_{\max} - X_{\min}))$ formülü takip edilir.

2:Bu aşamada YSA'nın mantığı gereği verilerin bir kısmı eğitim amaçlı bir kısmı validasyon amaçlı bir kısmı ise uygulama amaçlı kullanılmak üzere gruplandırılmalıdır. Çalışmalarda eğitim için kullanılan verinin görel olarak validasyon ve test için kullanılan daha fazla olması gerektiği yönündedir. Verilerin %10-20 si arasının test ve validaysona ayrı ayrı ayrılması tavsiye edilmektedir(Erilli vd.2010).

3:Yukarıda açıklanmış olan YSA'nın elementleri bu aşamada tanımlanır. Girdi sayısı; çıktı sayısı, sistemi harekete geçirecek aktivasyon fonksiyonu, öğrenme tipinin tespiti, bu algoritmanın çıktılarını test edecek performans kriterlerinin ortaya konması bu aşamada kararlaştırılması gereken ve yapının ana iskeletinin oluşturan değişkenlerdir. Geçmiş dönem benzer araştırmalar özellikle öğrenme algoritmasını tespitinde önemli bir kaynak olarak kullanılabilir.

4: Zaman serileri için uygun model yapısı tespit edilmelidir. Eğer klasik zaman serileri kullanılacaksa, girdi tabakasındaki eleman sayısı gecikmeli zaman serisi değerlerini vermektedir.

5:Ağırlık değerleri, öğrenme algoritmasının yapısı (ileri veya geri beslemeli), öğrenme algoritması ve ara katmanlardaki nöron sayısı seçimi ile doğrudan ilişkilidir. YSA, hataları minimize edecek şekilde, tahmin yapacak

nöronlar arası veri aktarımına ağırlık veren YSA katsayılarını; yukarıda sayılı elemanlar vasıtasıyla tespit eder. Bu kapsamda uygun öğrenme algoritması seçilmelidir

6:Daha önce de belirtildiği gibi, YSA veri setini 3 ana gruba ayırarak eğitim, validasyon ve uygulama (test) işlemlerini gerçekleştirir. Bu aşamada çıktıların ya da sonuç değerlerinin gerçek değerleri ile YSA tarafından tahmin edilen değerler kullanılarak YSA yapısının performansı ölçülmektedir. MAPE (ortalama mutlak yüzde hata) ve MSE (ortalama hata kareleri farkı) en çok kullanılan performans ölçüm değerleridir. Bu değerler

$$MAPE = \frac{1}{N} * \sum (y_{Gözlem} - y_{tahmin}) / y_{gözlem} * 100$$

$$MSE = \frac{1}{N} * \sum (y_{Gözlem} - y_{tahmin})^2$$

7:Kurulmuş olan YSA sistemi gelecek dönemli tahminler yapabilmek için yeni veri setleri ile aktive edilebilir ve doğrudan öngörüler için kullanılabilir.

3.UYGULAMA

Tahsili gecikmiş alacakları açıklamaya çalışan araştırmalar, firmaya özel değişkenleri kullananlar ile makroekonomik değişkenleri kullanan çalışmalar olarak iki ana kısımda ele alınmaktadır. Araştırmada, gelişmekte olan bir ülke olan Türkiye gerçekleri göz önüne alınarak, firmaların tahsili gecikmiş alacaklarının daha çok dış değişkenlerden etkilendiği perspektifi ile makroekonomik değişkenlere odaklanılmıştır. Araştırmada kullanılan veriler Türkiye bankacılık sektörüne ait tahsili gecikmiş alacak oranı ve aynı dönem de gerçekleşen USD, EUR getirileri, mevsimsellik etkisinden kurtarılmış sanayi üretim endeksi değerleri ve BİST100 endeksine ay sonu logaritmik getiri serilerinin son 10 yıllık değerleridir. Söz konusu verilere sırasıyla, BDDK, TCMB, Sanayi ve Ticaret Bakanlığı, TÜİK ve Borsa İstanbul'a ait internet sitelerinden ulaşılmıştır.

Çalışmada MATLAB 7.0 programının YSA lar için hazır bulunan NRX aracı kullanılmıştır. Söz konusu modelde kullanılan YSA yapısı farklı

alternatifler altında denenmiştir. Bir ve birden çok katmanlı YSA lar için 5 ile 10 arası farklı nöron sayısına sahip YSA yapısı yardımı ile çıktı olarak kullanılan tahsili gecikmiş alacakların yukarıda sayılan makroekonomik değişkenler ile açıklanmaya çalışılmıştır. Getiri verileri kullanıldığı yüzden normalleştirme işlemi yapılmamıştır. Çalışma sonucunda elde edilen tüm YSA yapıları, optimal YSA alternatifinin seçim kriteri olarak yukarıda sayılı performans kriterleri (MAPE ve MSE) göz önüne alınarak ayrı ayrı değerlendirilmiş ve sonuçlar aşağıda sunulmuştur. Geçmiş dönem çalışmalara bakılarak MAPE kriteri altında en uygun model seçilmiştir.

Tablo 1: Farklı YSA yapıları ile tahsili gecikmiş alacakların tahminleyen modellerin performansları

Girdi Sayısı	Çıktı Sayısı	Gecikme Sayısı	Nöron Sayısı	MAPE (%)	MSE	R
4	1	1	5	4,05	2,2273e-5	9,98592e-1
4	1	2	5	8,65	1,0134e-4	9,99239e-1
4	1	3	5	4,54	6,5572e-5	9,99533e-1
4	1	1	6	5,29	1,6476e-4	9,98267e-1
4	1	2	6	3,78	1,8472e-4	9,98669e-1
4	1	3	6	3,68	2,8598e-5	9,98641e-1
4	1	1	7	3,96	1,2481e-4	9,98770e-1
4	1	2	7	4,85	1,4118e-4	9,99222e-1
4	1	3	7	3,35	1,0812e-4	9,99283e-1
4	1	1	8	4,24	9,4227e-5	9,99299e-1
4	1	2	8	4,32	1,8925e-4	9,99076e-1
4	1	3	8	2,97	2,2009e-5	9,99756e-1
4	1	1	9	11,28	9,3178e-5	9,99433e-1
4	1	2	9	4,38	7,6733e-5	9,99499e-1
4	1	3	9	2,94	2,7353e-4	9,98110e-1
4	1	1	10	5,91	1,1350e-4	9,99130e-1
4	1	2	10	3,78	2,6736e-4	9,98561e-1
4	1	3	10	3,56	5,8447e-5	9,99598e-1

Performans ölçütlerine göre en iyi ANN yapıları (Nöron Sayısı Ve Gecikme Dönemi) arasında ilk üç aşağıdaki şekilde sıralanmıştır ;

MSE ilk 3 : 8-3 , 5-1 ,6-3

MAPE ilk 3 : 8-3, 7-3, 10-3

Araştırmada doğrusal olmayan dış değişkenli otoregresif model, farklı değişkenlerin zaman serilerini kullanılarak bağımlı değişkeni tahmin edebilmesi nedeniyle tercih edilmiştir. Bu modelde, Levenberg-Marquard fonksiyonu doğrusal olmayan zaman serilerinde eğri uydurma amacını başarı ile maksimize ettiği yüzden tercih edilmiştir (Çuhadar vd.,2009). Kurulan farklı YSA yapıları ve performans çıktıları yukarıda sunulmuştur

Yukarıdaki tablodan da görüleceği gibi, bir YSA'nın performansı (MSE yada MAPE ile ölçülmesinden bağımsız olarak) YSA ya giren nöron sayısının artması ile doğrusal ya da eğrisel olarak artmamakta aksine, parabolik bir yapı ile önce artmakta sonra azalmakta kısacası bu şekilde devam ederek çok farklı değerler alabilmektedir. Bu kapsamda, farklı yapıların denenmesi en iyi olanının bulunması için kaçınılmazdır. Bununla beraber hem MAPE hem de MSE kriterinden en verimli model 8 nöron ile kurulan, 3 gecikme dönemine sahip model olmuştur. MAPE modelleri içerisinde en verimli yapıları bakıldığında, gecikme sayısının 3 dönem olarak tahmin edildiği görülmüştür.

SONUÇ

Yapay sinir ağları birçok diğer model gibi sebep sonuç ilişkisini çözmeye çalışan esnek ve kendini gerçekleştirmiş veriler vasıtası ile geliştiren karmaşık ancak veri ile ilgili az önşarta sahip yapılardır. Bir çok finansal araştırmaya politik ve yönetsel sebeplerden dolayı konu olmuş olan tahsili gecikmiş alacakların böylesi bir yapı ile çözülmesi ise farklı değişkenler ışığında daha önceki araştırmalara da konu olmuştur. Ancak; bu araştırmada, Türkiye gibi gelişmekte olan bir ülkenin makroekonomik gerçeklerini gözetten bir açıklayıcı değişken seti oluşturularak (sanayi üretim endeksi ile borsa endeksinin yan yana kullanılması ve bunlara yabancı para cinsinin eşik etmesi gibi) geçmiş araştırmalara farklı bir yaklaşım getirmiş, farklı değişkenler üzerinde önceki yıllarda kullanılmış olan yapay sinir ağları da kullanılarak orijinal bir yaklaşım tercih edilmiştir. Söz konusu yapının tahsili gecikmiş alacakları başarı ile açıklayabildiği (MAPE değerlerinin %10 dan çok çok düşük olması) ve aralarından birkaç tanesinin diğerlerine göre daha verimli olduğu çalışmada ortaya konmuştur. Bu özellikleri itibarıyla araştırma tahsili gecikmiş alacaklarını tahmin etmek isteyen yönetici, bilim adamları ya da uzmanlara farklı bir perspektif sunmaktadır.

KAYNAKLAR

- AKSOY, A.Ş. (1998), Yeni Sağ, Kamu Yönetimi ve Yerel Yönetim: Eleştirel Bir Yaklaşım, *Çağdaş Yerel Yönetimler Dergisi*, 7(1), Ocak, 3-13.
- AKSOY, A.Ş. (2008), Kamu Yönetiminde Değişim Üzerine Düşünceler, Bölgesel Sorunlar ve Türkiye Sorunlar-Tehditler-Fırsatlar, Edt: A.H. Aydın, S. Taş ve S. Adıgüzel, *Kabramanmaraş Süüçü İmam Üniversitesi Yayını No:131*, Kahramanmaraş, 195-207.
- AMEDİKU, S. (2006), Stress Tests of The Ghanaian Banking Sector : A Var Approach. Working Paper. Bank of Ghana Wp/Bog-2006/02
- ARSLAN, İ., SEVDA Y. (2008), Banka Kredileri Ve Enflasyon Arasındaki İlişki: Türkiye Üzerine Ekonometrik Bir Analiz (1983-2007), *İstanbul Üniversitesi İktisat Fakültesi Ekonometri Ve İstatistik Dergisi. Ekonometri Ve İstatistik*, 7, 88-103
- ÇUHADAR, M., GÜNGÖR İ., GÖKSU A. (2009), Turizm Talebinin Yapay Sinir Ağları İle Tahmini Ve Zaman Serisi Yöntemleri İle Karşılaştırılmalı Analizi: Antalya İline Yönelik Bir Çalışma”, *Süleyman Demirel Üniversitesi İktisadi Ve İdari Bilimler Dergisi*, 14(1), 99-114
- ÇİFTER, A. YILMAZERS., ÇİFTER E.,” Analysis Of Sectoral Credit Default Cycle Dependency With Wavelet Networks: Evidence From Turkey, *Economic Modelling*, 26(6), 1382-1388
- EFENDİGİL, T., ÖNÜT, S., & KAHRAMAN, C. (2009), A Decision Support System For Demand Forecasting With Artificial Neural Networks And Neuro-Fuzzy Models: A Comparative Analysis, *Expert Systems With Applications* , 36, 6697-6707.
- ERİLLİ, N.A., EĞRİOĞLUE., YOLCUU., ALADAĞ Ç.H., USLU R.V. (2010), Türkiye’de Enflasyonun İleri Ve Geri Beslemeli Yapay Sinir Ağlarının Melez Yaklaşımı İle Öngörüsü”, *Doğuş Üniversitesi Dergisi*, 11(1), 42-55
- GUPTA, M.M. (2003), *Static and Dynamics Neural Networks: From Fundamentalsto Advanced Theory*, John Wiley&Sons, New Jersey
- HAMZAÇEBİ, C. (2011), Yapay Sinir Ağları, Tahmin Amaçlı Kullanımı Matlab Ve Neursosolutions Uygulamaları, Ekin, Bursa
- HARRİS, T. (2013), Quantitative Credit Risk Assessment Using Support Vector Machines: Broad Versus Narrow Default Definitions, *Expert Systems With Applications*, 40(11), 4404-4413

- ISLAMOGLU, M. (2015),The Effect Of Macroeconomic Variables On Non-Performing Loan Ratio Of Publicly Traded Banks in Turkey, *Wseas Transactions On Business And Economics*, Volume 12, 2224-2899
- JANVISLOO, M. A.,JUNAINA M., TAUFIQ H. (2013),Macroeconomics Shocks And Stability in Malaysian Banking System; A Structural Var, *American Journal Of Economics 2013*, 3(5c): 22-28.
- KAYNAR, O, TASTAN S, DEMİRKOPARAN F. (2011),Yapay Sinir Ağları İle Doğalgaz Tüketim Tahmini”, *Atatürk Üniversitesi İktisadi Ve İdari Bilimler Fakültesi Dergisi*,25,463-474
- KHEMRAJ, T.,PASHA S. (2009),The Determinants Of Non-Performing Loans: An Econometric Case Study Of Guyana the caribbean Centre For Banking And Finance Biannual Conference On Banking And Finance, St. Augustine, Trinidad.
- KLEIN, N. (2013),Non-Performing Loans in Cese: Determinants And Macroeconomic Performance Imf WorkingPaper, Wp1372
- LOUZIS, D.P.,VOULDIS A.T.,VASILIOS L.M. (2011),Macroeconomicand Bank Spesific Determinant Of Non-Performing Loans in Greece: A Comparative Study of Mortgage , Business and Consumer Loan Portfolio”, *Journal Of Finance And Banking*, 36(4),1012-1024
- MESSAI, A.S. (2013), Micro And Macro Determinants Of No performing Loan, *International Journal Of Economics And Financial* ,3,(4),852-860
- PODPIERA, J.,WEILL, L. (2008),Bad Luck or Bad Management? Emerging Banking Market Experience”, *Journal Of Financial Stability*,4, 135–148
- REINHART, C., ROGOFF, K. (2010),American Economic Review, *American Economic Association*, 101(5), 1676-1706
- ŠKARICA, B.,(2014),Determinants 37 Of Non-Performing Loans in Central and Eastern European Countries. *Financial Theory And Practice*, 38 (1) 37-59

- TANG, T. C.,&CHI, L. C. (2005),Neural Networks Analysis in Business Failure Prediction Of Chinese Importers: A Between-Countries Approach, *Expert Systems With Applications*, 29, 244–255
- YÜCEMEMİS, B.,SOZER I.A.(2010),Türk Bankacılık Sektöründe Takipteki Krediler:Mukayeseli Kriz Performansı. *Avrupa Araştırmaları Dergisi*,18 (L-2),2010
- SIMON, H. (1994),*Neural Networks: A Comprehensive Foubdations*, Macmillian College, New York
- TAKMA, C., ATIL H., AKSAKAL V. (2012), Çoklu Doğrusal Regresyon Ve Yapay Sinir Ağı Modellerinin Laktasyon Süt Verimlerine Uyum Yeteneklerinin Karşılaştırılması, *Kafkas Üniversitesi Veterinerlik Fakültesi Dergisi*, 18(6), 941-944
- SHAO, H.H.JU H.F.,WU C., XU J.T., LIU M.Z. (2012), Research On Commercial Bank Credit Risk Evaluation Model Based On The Integration Of TheProbability Distribution Theory and The BpNeural Network Technology.”, *International Journal Of Advancements in Computing Technology* , 4(22),115-124