

BİREYSEL TÜKETİCİ İHTİYAÇ KREDİSİ TALEP TAHMİNLERİNİN VEKTÖR OTOREGRESYON VE YAPAY SİNİR AĞI MODELLERİ İLE KARŞILAŐTIRMALI ANALİZİ

İrfan ERTUĞRUL^[*]
Abdullah ÖZÇİL^[**]

Öz

Tüketici ihtiyaçlarının sınırsızlığı ve finansman olanaklarının artması sonucu bireysel ve endüstriyel alanda kredi talebi finansal hayatın vazgeçilmez unsurlarından biri haline gelmiştir. Bankalar açısından diğer finansal araçlara göre nispeten daha yüksek getiri olanağı sunan bireysel krediler daha cazip hale gelmiştir. Bu çalışmada Türkiye'deki tüketicilerin bireysel kredi ihtiyacının talebi konusu ele alınmıştır. Çalışmanın amacı hem tüketiciler hem de finansman sağlayıcılar açısından etkin kararlar alınmasını sağlayacak bireysel ihtiyaç kredisi tahmininin uygun şekilde modellenmesidir. Ocak 2005 - Kasım 2015 dönemini kapsayan 131 aylık veri ile Vektör Otoresyasyon (Vector Autoregression) modeli ve Yapay Sinir Ağı (Artificial Neural Network) modeli karşılaştırılmıştır. Yapılan analiz sonuçlarından Yapay Sinir Ağı modelinin Vektör Otoresyasyon modeline göre çok daha etkin sonuçlar verdiği elde edilmiştir.

Anahtar Kelimeler: Bireysel İhtiyaç Kredisi Talebi, VAR Modeli, Yapay Sinir Ağı Modeli, Talep Tahmini.

Jel Kodları: C13, C32, C45.

THE COMPARATIVE ANALYSIS OF PERSONAL LOAN DEMAND FORECAST WITH VECTOR AUTOREGRESSION AND ARTIFICIAL NEURAL NETWORK MODELS

Abstract

As a result of immensity of consumer needs and increased funding opportunities, credit demand has become one of the indispensable elements of financial life for individual and industrial areas. Offering the ability to relatively higher returns compared to other financial instruments in terms of banks personal loan

[*] Doç. Dr., Pamukkale Üniversitesi, iertugrul@pau.edu.tr

[**] Arş. Gör., Pamukkale Üniversitesi, aozcil@pau.edu.tr

have become more attractive. This study focuses on the issue of demand of personal loan needs in Turkey. The aim of this the study is modeled correctly forecast personal loans will enable effective decisions to be taken in terms of both consumers and providers of financing. Vector Autoregression and Artificial Neural Network models were compared with using the 131 monthly data covering January 2005 - November 2015. According to the results of analysis Artificial Neural Network model gave a much more effective results than Vector Autoregression model.

Keywords: Demand of Personal Loans, Vector Autoregression Model, Artificial Neural Network Model, Demand Forecasting.

Jel Codes: C13, C32, C45.

Giriş

Tüketici davranışları ile makro ekonomik göstergeler arasında var olduğu varsayılan ilişki, bireysel tüketici ihtiyaçlarını tahmin etmede ve ilgili planlamalar için karar almada önemli bir göstergedir. Makro ekonomik değişkenler ile tüketici davranışları veya ihtiyaçları tahmin edilerek tüketici davranışları veya ihtiyaçlarını yönlendirici kararlar alınabilir.

Türkiye’de banka ve banka dışı kredi kurumları tarafından doğrudan kullanılan nakit krediler 2015 yılında yüzde 23,4 oranında artarak 1.773 milyar TL olarak kaydedilmiştir. Bankalar ve banka dışı kredi kurumları tarafından kullanılan bireysel krediler yüzde 9,5 oranında artarak 413 milyar TL olmuştur. 2015 yılı itibarıyla, bireysel kredilerin yüzde 38’ini ihtiyaç kredileri, yüzde 36’sını konut kredileri, yüzde 19’unu kredi kartları ve yüzde 7’sini taşıt kredileri oluşturmuştur. Bireysel kredi kullanan kişi sayısı 2 milyon artarak 25,8 milyon olurken, ortalama bireysel kredi miktarı ise 16 bin TL düzeyinde gerçekleşmiştir. Ortalama konut kredisi 67,6 bin TL, ihtiyaç kredisi ise 8,7 bin TL olmuştur (https://www.tbb.org.tr/Content/Upload/Dokuman/7340/TBB_Bilgi_Notu_RM_Bulten.pdf). 2015 yılı aralık ayı bireysel ihtiyaç kredisi kullanım miktarı ise 156.148.607.000 TL olarak gerçekleşmiştir (www.bddk.org.tr).

Bireysel tüketicilerin kullandıkları ihtiyaç, taşıt ve ev kredilerinden ihtiyaç kredisi çalışmanın konusunu oluşturmaktadır. Türkiye’de 2005 ve 2015 yılları arasında kullanılan aylık toplam bireysel ihtiyaç kredisi tutarı tahmin modelleri sunulmuştur.

Bu çalışmanın amacı hem tüketiciler hem de finansman sağlayıcılar açısından etkin kararlar alınmasını sağlayacak bireysel ihtiyaç kredisi tahmininin uygun şekilde modellenmesidir. Bu amaçla çalışmanın devamında etkin tahmin yönteminin tespiti için Vektör Otoregresyon (VAR) ve Yapay Sinir Ağı (YSA) modelleri tanıtılmıştır. Chen ve Minghua (2012) çalışmalarında benzer şekilde bireysel kredi ihtiyacını tahmin etmek için optimal Naive Bayes sınıflandırıcıyı araştırmışlardır. Literatürde bireysel kredi ihtiyacı tahmini için VAR ve YSA modellerini kullanan herhangi bir çalışmaya rastlanılmamıştır ve çalışma bu yönü ile bir ilk taşımaktadır. Çalışmanın uygulama kısmı, VAR modeli analizi için E-Views 8 ve YSA

modeli analizi iin de Visual Gene Developer 1.7 programları kullanılarak gerekleřtirilmiřtir. Sonu blmnde ise YSA modelinden elde edilen verilerin stnlğne, tahmin modellerinin gerek deęerlerden sapmasını deęerlendiren karřılařtırma yntemleri kullanılarak yer verilmiřtir.

I. Vektr Otoregresyon Modeli

Makroekonomik deęiřkenlerin devresel dalgalanmaları ve birbirleriyle iliřkili olduęu oęu ekonomist tarafından kabul edilmektedir. Gerek hayatı yansıtan makroekonomik teorileri gerektiren ve ok sayıda makroekonomik deęiřken ieren istatistiksel modeller neredeyse her daim doęru olan bir ifade olarak kabul grmektedir (Sims, 1980: 1).

Sims tarafından ortaya konulan VAR modelleri yapısal model zerinde herhangi bir kısıtlama gerektirmeksizin dinamik iliřkileri verebilmektedir. Ayrıca VAR modellerinde baęımlı deęiřkenlerin gecikmeli deęerlerinin yer alması, geleceęe ynelik gl tahminler yapılmasına olanak saęlamaktadır. VAR modeli, her bir deęiřkenin kendi gecikmeli deęerleri ve sistemdeki dięer tm deęiřkenlerin gecikmeli deęerleri ile aıklanan ok deęiřkenli bir modeldir (Tarı ve Bozkurt, 2005: 4).

VAR yntemi ile ilgili ilk nedensellik incelemesi 1978 yılında yapılan Kraft ve Kraft tarafından yapılan alıřmadır. Bu alıřmada Sims tarafından nedensellik testi kullanılarak 1950-1970 yılları arasında ABD iin enerji tketicimi ile Gayri Safi Yurtii Hasıla (GSYİH) arasındaki iliřki incelenmiřtir. alıřmada GSYİH'dan enerji tketicimine ynelik tek ynl pozitif bir nedensellięin bulunduęu belirlenmiřtir (Ayta, 2010: 484).

K deęiřkenleri olarak verilen $Y_t=(y_{1t}, y_{2t}, \dots, y_{kt})$ zaman serisi p gecikmeli VAR [VAR(p)] modeli (Sing vd., 2015: 2);

$$Y_t = c + \prod_1 Y_{t-1} + \prod_2 Y_{t-2} + \dots + \prod_p Y_{t-p} + \varepsilon_t$$

yle ki, $\prod_i = (n \times n)$ katsayı matrisi, c sabit vektr ve $\varepsilon_t = an(n \times 1)$ zamanla deęiřmeyen kovaryans matrisi ile gzlenemeyen sıfır ortalamalı beyaz grlt vektr srecini, modelin duraęan olması durumunda (Sing vd., 2015: 2);

$$|z| = 1 \text{ olması iin } \det \left(I_k - \prod_1 z_1 - \dots - \prod_p z_p \right) \neq 0$$

İki deęiřkenli VAR modeli ele alındıęında ařaęıdaki řekilde ifade edilebilir:

$$y_t = a_0 + \sum_{i=1}^k a_{1i} y_{t-i} + \sum_{i=1}^k a_{2i} x_{t-i} + u_{1t}$$

$$x_t = b_0 + \sum_{i=1}^k b_{1i} y_{t-i} + \sum_{i=1}^k b_{2i} x_{t-i} + u_{2t}$$

Eşitlik sisteminde u ortalaması sıfır, kendi gecikmeli değerleriyle olan kovaryansları sıfır ve varyansları sabit normal dağılıma sahip, rastsal hata terimlerini ve k ise gecikmelerin uzunluğunu göstermektedir. Buradaki varsayımlar aşağıda verilmiştir:

- y_t ve x_t serileri durağan olmalı,
- u_{1t} ve u_{2t} ak gürültü özelliğine sahip olmalı,
- u_{1t} ve u_{2t} birbirinden bağımsız olmalıdır.

Sistemde yer alan tüm değişkenlerin geçmiş değerlerinin yer aldığı bir eşitlikler sistemi olan VAR modelinin işleyişi şu adımları içermektedir (Bozkurt, 2007: 82):

- Verilerin Durağanlığının Sağlanması: Sistemde yer alan tüm değişkenlerin durağanlık sağlanacak şekilde dönüşümleri yapılır. Daha sonra A1 matrisinin özdeğerleri (eigen value) kontrol edilir. Eğer A1 matrisinin özdeğerleri 1'den küçük modüle sahipse, VAR (1) süreci durağan bir yapıya sahip olacaktır.
- Sistem İçin Uygun p Gecikme Seviyesinin Belirlenmesi: VAR modeli ile tahmin yapılırken gecikme seviyesinin belirlenmesi önemli bir yer tutar. Buradaki istatistiksel problem modelin derecesinin, yani modeldeki değişkenlerin gecikme sayılarının tespitinde ortaya çıkmaktadır. Modelin derecesi olması gerektiğinden daha küçük seçildiğinde parametrelerin tahmini tutarlı olmamakta, olması gerektiğinden daha büyük seçildiğinde ise parametrelerin tahminin varyansı büyük çıkmaktadır. Bu iki durumda da modelden elde edilen sonuçlar güvenilir olmamaktadır. Güvenilir, doğru sonuçlar veren bir model kurabilmek için muhakkak modeldeki değişkenlerin gecikme sayılarını hatasız bir şekilde belirlemek gerekmektedir. Modelin derecesinin seçiminde en çok olabilirlik yöntemine dayalı olan ve Akaike tarafından geliştirilen yöntem önerilmiştir. Bu yöntemde farklı sayıda parametreye sahip olan farklı modeller arasından seçim yapılmaktadır. Bu yöntem her modelin ayrı ayrı en çok olabilirlik fonksiyonunu bulup olabilirlik fonksiyonunun değeri en büyük olan modeli en uygun model olarak seçmektedir.
- Orthogonal Şoklarla Geleceğe İlişkin Tahminlerin Yapılması ve Bir Politika Analizinin Oluşturulması: VAR yöntemi modelde yer alan değişkenlerin sistemli bir şekilde birbirleriyle etkileşimlerini göstermesi açısından oldukça önemli bir ekonometri tekniğidir. Ancak sistemde iki zaman serisini gösteren VAR (1) modeli yerine VAR (p) modeline sahip d tane zaman serisi alınırsa, sistemde $(d^2p) + d$ tane bilinmeyen parametre olacağından elde edilen parametreleri yorumlamak zor olacaktır. Bu nedenle parametre tahmini yerine sistemin tahmini

neticesinde elde edilen artıkların analizi yapılarak, geleceęe yönelik yorumlar yapılabilir (Kardar, 2000: 51-52).

II. Yapay Sinir Ağları

Yapay sinir ağları, doğrusal ve doğrusal olmayan en küçük kareler regresyonuna benzemekte ve en küçük kareler problemlerinin çözümünde alternatif bir istatistiksel yaklaşımdır. Yapay sinir ağları ve klasik regresyon yöntemi hata karelerinin toplamını minimize etmek için çalışırlar. Yapay sinir ağlarındaki sapma, regresyondaki kesişim ile benzerlik göstermektedir. Girdi hücreleri regresyondaki bağımsız değişkenleri, çıktı ise regresyondaki bağımlı değişkeni temsil eder. Lineer regresyon modelleri ileri beslemeli gizli katmanı olmayan, bir çıktı hücresi ve lineer transfer fonksiyonu olan yapay sinir ağı gibi görülebilir. Yapay sinir ağlarındaki ağırlıklar regresyondaki bağımsız değişkenlerin katsayılarına benzerlik göstermektedir. Bir gizli katmanlı yapay sinir ağı doğrusal olmayan regresyona benzemektedir. Buradaki ağırlıklar ise regresyondaki eğri parametrelerini temsil etmektedir (Kaastra ve Boyd, 1996: 217).

Sinir ağları ile ilgili olarak üç farklı araştırma alanı mevcuttur. Bunlardan ilki fizyoloji ve moleküler biyolojiye dayalı deneysel alandır. Bu alan muntazam ve hızlı bir şekilde ilerlemektedir. İkinci alan, kaynağını beyin gibi hesaplamadan alan sinir ağlarının mühendislik uygulamalarıdır. Beyinde bilgi analog sinyallerde dağıtılmaktadır. Ayrıca beynin paralel hesaplaması güçlü basmaktadır. Öğrenme, esnekliği ve güçlü hesaplamayı garanti etmektedir. Bu alan desen tanıma, kontrol sistemleri, zaman serileri analizi, optimizasyon, hafıza v.b. gibi yeni pratik metotlar sunmaktadır. Üçüncü alan neurocomputing'in teorik veya matematiksel temelleri ile ilgilenmektedir. Neurocomputing, öğrenme kabiliyetli paralel çalışan dağıtık bilgi sistemlerinin temel prensiplerini arařtırmaktadır (Amari, 1994: 31).

Yapay sinir ağlarındaki sinaptik ağırlıklar ve regresyondaki katsayıların probleme göre ayarlanması gibi beyin de sinaptik bağlantıların gücünün ayarlanması ile öğrenir. Öğrenme ve eğitim bu ağırlık değerlerinin bulunması için tanımlanmış sürecin tanımı için kullanılan terimlerdir (Warner ve Misra, 1996: 287).

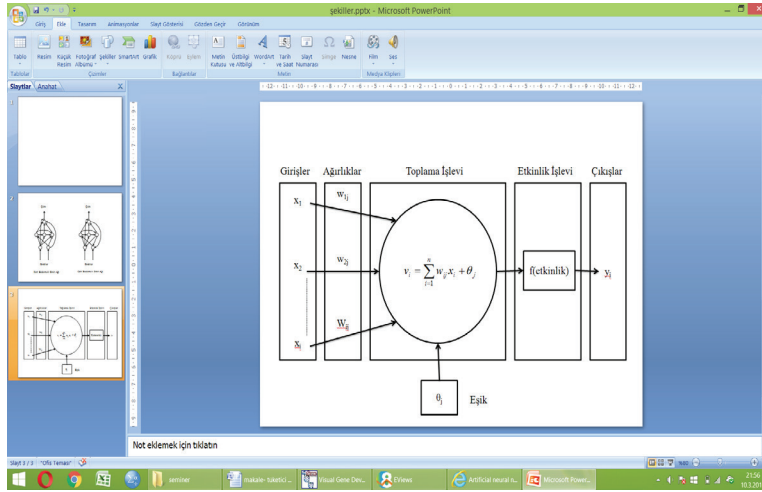
1940'lı yıllarda biyolojik sinir hücrelerinin yapısından esinlenerek tasarlanan yapay sinir hücre modeli, VE, VEYA veya DEĞİL gibi mantık işlemlerinin sayısal olarak modellenebileceğini göstermiştir. Bilgi işleme süreçleri olarak nitelendirilebileceğimiz YSA verilen girdilere karşı çıktılar üreten ayrıntılı bir kara kutu modeli olarak da nitelendirilebilir. YSA, bilgi akışını aksonlar yardımıyla sağlayan bir grup sinir hücresinden meydana gelen sinir sisteminin bir benzeri olarak tanımlanmakla birlikte basit elemanların yoğun bir şekilde paralel bağlanmasıyla ortaya çıkan yinelenebilir (adaptif) ağlar olarak da tanımlanmıştır (Şen, 2004: 9-10).

YSA alanında yapılan ilk çalışma, McClough ve Pitts (1943) tarafından yapılan yapay sinir hücresi modelinin mantıksal elemanlar olarak modellenmesidir. Hebb (1949) tarafından öğrenme kuralları açısından sinir ağı öğrenme kuralı sunulmuştur. Rosenblatt (1958) Tekli Doğrusal Algılayıcı (TDA) modeli öğrenme kuralını sunmuştur. Widrow ve Hoff (1960) tarafından

toplam hatayı minimize etmeyi amaçlayan ADALINE (Adaptive Linear Combiner) öğrenme kuralı modeli geliştirilmiştir. Hopfield (1982) tarafından çağrışımlı doğrusal olmayan YSA ağları mimarisi modeli sunulmuştur. Kohonen (1982) tarafından eğiticiyiz öğrenen YSA mimarisi modeli geliştirilmiştir.

Yapay sinir ağlarının temel birimi işlem elemanı ya da düğüm olarak adlandırılan yapay bir sinir hücresidir. Bir yapay sinir hücresi, biyolojik sınırlarla kıyaslandığında daha basit olmasına karşın, biyolojik sınırların 4 temel işlevini taklit eder. Şekil 1'de yapay bir sinir (düğüm) gösterilmiştir. Girişler x_i sembolüyle gösterilmiştir. Bu girişlerin her biri ağırlık (w) ile çarpılır. Basitçe, bu ürünler eşik değeri θ_j ile toplanır ve sonucu oluşturmak için etkinlik işlevi ile işlem yapılır ve y_i çıkışı alınır (Elmas, 2003: 32).

Şekil 1: Yapay Sinir Ağı Düğümü (Elmas, 2003: 32)




YSA üç (veya daha çok) katman içerisinde ve her katmanda paralel olarak hücrelerin bir araya gelmesi ile oluşturulur. İlk katman girdi katmanı, ikincisi ara katman ve üçüncüsü de çıktı katmanıdır. Girdi katmanındaki düğümler dış dünyadan gelen verileri ara katmana iletir. Ara katmandakiler bu verileri işler. Çıktı katmanı ise ara katmandan gelen verileri işleyerek gereken çıktıyı üretir ve dış dünyaya getirir (Baykal ve Beyan, 2004: 29).

Öğrenme biçimine göre YSA Danışmanlı (supervised) veya “öğretmenli öğrenmede” ağa giriş-çıkış vektörleri şeklinde eğitim örnekleri verilmektedir. Danışmansız (unsupervised) öğrenmede ise ağırlık giriş bilgileri verilerek, problemin çözümü ağırlık istenmektedir. Mimarisine göre YSA belirli (deterministic) ve belirsiz (stochastic) olarak iki gruba ayrılır. Ayrıca, sinir ağlarının işaretin akış yönüne bağlı olarak, ileri beslemeli (feedforward) ve geri beslemeli (feedback) türleri de bulunmaktadır. Ara sinirlerden geçerek giriş katından çıkış katına doğru işaretlerin yalnız bir yönde ilerlediği ağa ileri beslemeli ağ, herhangi bir sinirin çıkışından girişine işaretin ulaştığı

ađlara geri beslemeli ađ denir ve Őekil 2'de gsterilmiřtir. Geri beslemeli ađ modelleri, gelecek durumlarına etki edebileceđinden danıřmansız đrenmeye dayalı bir model olmaktadır (Nabiyev, 2003: 582).

Őekil 2: Farklı Sinir Ađı Modelleri (Baykal ve Beyan, 2004: 28)



đrenme ile ilgili olarak Hebb kuralı bilinen en eski đrenme kuralıdır. Bu kurala gre bir hcre, diđer bir hcreden bilgi alırsa ve her iki hcre de aktifse her iki hcrenin arasında bađlantı kuvvetlendirilmelidir. Bir hcre kendisi aktif ise bađlı olduđu hcreyi aktif yapmaya, pasif ise pasif yapmaya alıřmaktadır. Hopfield kuralı da buna benzemektedir. Yapay sinir ađı elemanlarının bađlantı katsayıları 0-1 arasında kullanıcı tarafından atanan đrenme katsayısı ile sinir hcrelerinin sırasıyla aktif ya da pasif olmasına gre arttırılır ya da azaltılır. Delta kuralı Hebb kuralının modifiye Őeklidir. Yapay sinir ađı elemanlarının bađlantılarının ađrılık deđerleri deđiřtirilerek beklenen ıktı ile girdi arasındaki farklılık azaltılmaya alıřılır. Kohonen kuralında ise ađın elemanlarının ađrılıklarını deđiřtirmek iin birbirleri ile yarıřması sz konusudur. En byk ıktıyı reten hcre kazanan hcre olur ve bađlantı ađrılıkları deđiřerek bu hcre yakınındaki diđer hcrelere karřı daha gl hale gelir (Baykal ve Beyan, 2004: 31).

Yapay sinir ađlarının en byk stnlkleri, đrenme kabiliyeti olması ve farklı đrenme algoritmaları kullanabilmesidir. Ayrıca yapay sinir ađları matematiksel modele ihtiya duymazlar ve kural tabanlı kullanımı gerektirmezler. Bunların yanı sıra en sık belirtilen sakıncası ise sistemin alıřmasının analiz edilememesi, dolayısıyla sistem ierisinde ne olduđu bilinemez ve đrenme iřleminde bařarılı olunamama riski olmasıdır. Yapay sinir ađları sakıncalarına ek olarak bazı ađlar hari kararlılık analizlerinin yapılamaması ve farklı sistemlere uyarlanması zor olabilir (Elmas, 2003: 26-27).

Dalan (2015) yapay sinir ađı modelini kullanarak oluřabilecek hırsızlık vakalarının miktarının ve oluřabilecek kořullar iin hırsızlık suunun oluřup oluřmama durumunun tahminini

yapmıştır. Hırsızlık suçlarının gerçekleşip gerçekleşmeyeceği ile ilgili % 91 başarı oranına sahip YSA modelinin regresyon modelinden % 32,6 daha iyi sonuçlar verdiğini elde etmiştir. Kayaççı (2014) elektronik ortamda doğru bilgiye en kısa zamanda ulaşılmasını sağlamak amacı ile web sayfalarını YSA modeli kullanılarak sınıflandırmıştır. Yapılan uygulama ile sanal ortamda akıllı yazılımlar gerçekleştirilmesi hedeflenmiştir. Helhel (2009) döviz kurunu on bir adet makroekonomik değişken ile VAR ve YSA modellerini karşılaştırmalı olarak kullanarak tahminde bulunmuştur. Zhao vd. (2015) uluslararası ham petrol fiyatına etki eden faktörleri Genetik algoritma modeli ile analiz etmişlerdir. VAR-Svm (Support Vector Machine), CGarch ve YSA modellerini karşılaştırarak uygun ve verimli model önerisinde bulunmuşlardır. Gupta ve Kashyap (2015) G-7 ülkelerindeki enflasyon tahmini için farklı YSA modeli kombinasyonlarını kullanmışlardır. Nazemi vd. (2015) karmaşık optimizasyon teorilerine ve bazı sıradan diferansiyel eşitliklere dayalı YSA modelini, doğrusal programlama problemlerinden portföy seçimine uygulamışlardır. Dauji vd. (2015) Kuzey Atlantik ve Kuzey Pasifik okyanusundaki 24 saatlik güneyden gelen ve bölgesel akıntıları tahmin etmek için YSA modeli kullanmışlardır. Santos vd. (2015) iklim değişikliği ile ilgili olarak Güney Amerika'daki yağmur tahmini için YSA modeli ve çoklu doğrusal regresyon modelini karşılaştırmışlardır. Domingo vd. (2015) tren yolu dizaynı için parça özellikleri, oluşacak yükseklik ve dolgu oluşturmak için kullanılan malzeme kalitesi değişkenlerini kullanarak YSA modeli ile optimizasyon önerisinde bulunmuşlardır. Komyakov vd. (2015) Rusya'daki demiryolu taşımacılığı elektrik tüketimi tahmini için F-Fisher testine dayalı YSA modeli önermişlerdir. Gani vd. (2015) solar enerji sistemleri için günlük güneş enerjisi radyasyon miktarı tahmininde otoregresif YSA modeli kullanmışlardır. Sonuçlar adaptif sinirsel bulanık çıkarım mekanizması (Adaptive neuro-fuzzy inference system, ANFIS) modeli sonuçları ile karşılaştırılmıştır. Günay (2016) Türkiye'deki yıllık elektrik talebi için 1975 - 2013 yıllarını kapsayan nüfus, Gayri Safi Milli Hasıla, enflasyon ve ortalama yaz sıcaklığı değişkenlerini kullanan YSA tahmin modeli sunmuştur. Şentürk (2014) Türkiye'de cari işlemler açığını etkileyen faktörleri ve derecelerini VAR ve MS-VAR (Markov Switching Vektör Otoregresif) modelleri ile incelenmiş ve nedensellik analizleri gerçekleştirmiştir. Gürel (2012) iktisadi büyümeyi etkileyen dış dinamikleri ve etkilerini açıklamak amacıyla Yapısal VAR ve Markov-Switching VAR modellerini kullanmıştır. Zhang ve Zheng (2015) uzun dönemli Çin karbon verimliliği ile sosyal elektrik tüketimi arasındaki ilişkiyi VAR modeli Granger nedensellik analizi ile araştırmışlardır ve karbon emisyon miktarı hakkında önerilerde bulunmuşlardır. Mirmirani ve Li (2004) ABD'ndeki petrol fiyatlarını üç değişkene bağlı ve genetik algoritma içeren YSA ve VAR modelleri ile tahmin etmişlerdir ve modellerin sonuçlarını karşılaştırırken Karesel Ortalama Hata (Root Mean Squared Error) ve Ortalama Mutlak Hata (Mean Absolute Error) yöntemlerini kullanmışlardır.

III. Uygulama

Çalışmanın uygulama bölümünde bireysel tüketici ihtiyaç kredi talebi Vektör Otoregresyon ve Yapay sinir ağı modelleri ile tahmin edilmiştir ve farklı tahmin yöntemi çıktıları karşılaştırılmıştır.

Bireysel ihtiya kredisi tahmininde kullanılabilecek makro ekonomik deęiřkenler; Bist100 endeks deęeri, Bist100 Getiri oranı, Tüketicici Fiyat Endeksi (Tüfe), Toplam Mevduat miktarı, Mevduat faizi oranı, Dolar/TL kuru, Euro/TL kuru, Altın fiyatı, Devlet i borlanma senedi faiz oranı (Dıbs), Sanayi üretim endeksi, Petrol fiyatı, Tüketicici güven endeksi olarak belirlenmiřtir. Belirlenen makro ekonomik deęiřkenler ile kurulan ilk regresyon modeli Tablo 1’de verilmiřtir.

Tablo 1: Temel Deęiřkenler Regresyon Modeli

Dependent Variable: TUKETICIKREDIMIKTARI				
Method: Least Squares				
Date: 03/05/16 Time: 19:11				
Sample: 2005M01 2015M11				
Included observations: 130				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
TUFE	261.4067	301.8642	0.865975	0.3883
TUKETICIGUVENENDEKSI	-493.4626	132.8917	-3.713268	0.0003
TOPLAMMEVDUAT	2.97E-09	4.69E-10	6.340795	0.0000
SANAYIURETIMENDEKSI	37.21617	99.91391	0.372482	0.7102
PETROLFIYATI	-275.9011	63.93105	-4.315605	0.0000
MEVDUATFAIZI	12619.38	7220.943	1.747609	0.0831
EURO	-423284.7	133381.0	-3.173500	0.0019
DOLAR	-24456.05	11267.22	-2.170549	0.0320
DıBS	-2624.123	811.3640	-3.234212	0.0016
BIST100GETIRI	232.6423	127.3290	1.827096	0.0702
ALTIN	21.74463	5.673807	3.832457	0.0002
C	1612256.	504665.4	3.194703	0.0018
R-squared	0.969787	Mean dependent var	53530.19	
Adjusted R-squared	0.966971	S.D. dependent var	40260.92	
S.E. of regression	7317.023	Akaike info criterion	20.72156	
Sum squared resid	6.32E+09	Schwarz criterion	20.98626	
Log likelihood	-1334.901	Hannan-Quinn criter.	20.82911	
F-statistic	344.3276	Durbin-Watson stat	0.939134	
Prob(F-statistic)	0.000000			

Makroekonomik deęiřkenler ile bireysel ihtiya kredisi arasında anlamlı bir iliřkinin kurulması amacıyla regresyon modeli kurulmuřtur. Kurulan modelde; Tüfe, Sanayi Üretim Endeksi, Mevduat Faizi ve Bist100 Getiri deęiřkenlerinin modelde anlamsız olması nedeniyle modelden ıkarılması uygun görülmüřtür. Dięer deęiřkenler ile kurulan yeni regresyon modeli Tablo 2’de verilmiřtir.

Tablo 2: Anlamli İlişki Taşıyan Değişkenler İçin Regresyon Modeli

Dependent Variable: TUKETICIKREDIMIKTARI				
Method: Least Squares				
Sample: 2005M01 2015M11				
Included observations: 131				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
TUKETICIGUVENENDEKSI	-542.0661	113.0892	-4.793259	0.0000
TOPLAMMEVDUAT	3.30E-09	4.35E-10	7.590521	0.0000
PETROLFIYATI	-235.0693	61.36213	-3.830852	0.0002
DOLAR	-26347.05	11186.00	-2.355359	0.0201
DIBS	-1357.510	623.2180	-2.178226	0.0313
ALTIN	16.33055	5.348711	3.053176	0.0028
EURO	-419437.5	86479.88	-4.850116	0.0000
C	1648904.	340176.9	4.847194	0.0000
R-squared	0.967629	Mean dependent var		53300.51
Adjusted R-squared	0.965787	S.D. dependent var		40191.83
S.E. of regression	7434.227	Akaike info criterion		20.72470
Sum squared resid	6.80E+09	Schwarz criterion		20.90029
Log likelihood	-1349.468	Hannan-Quinn criter.		20.79605
F-statistic	525.2403	Durbin-Watson stat		0.824818
Prob(F-statistic)	0.000000			

Kurulan yeni regresyon modelinde bireysel ihtiyaç kredisi miktarı ile anlamlı ilişki çıkan değişkenler; Tüketici Güven Endeksi, Toplam Mevduat Miktarı, Petrol Fiyatı, Dolar, Dibs, Altın ve Euro olarak belirlenmiştir. Değişkenler arasında kurulan anlamlı regresyon modeli VAR ve YSA tahmin modelleri için kullanılmıştır.


IV. VAR Modeli Uygulaması

Regresyon modeli ile elde edilen değişkenlerin VAR yöntemi ile tahmini yapılmadan önce durağanlığın sağlanması ve artıklar arasında otokorelasyon sorununun olmaması koşullarının sağlanması gerekmektedir. Öncelikli olarak değişkenler için Augmented Dickey-Fuller testi yardımıyla durağanlıkları sınanmıştır. Durağan olmayan değişkenler değişim yüzdesi alınarak durağan hale getirilmiştir.

Tablo 3: Durađanlıđın Test Edilmesi

Deđiřken Adı	Augmented Dickey-Fuller Test İstatistiđi (AIC) (%5 seviyesinde=-1,9433)	
	Ham Veri Test İstatistiđi (Olasılık Deđeri)	Birinci Fark Test İstatistiđi (Olasılık Deđeri)
Tüketici Kredi Miktarı	2,8809 (0,999)	-8,6717 (0,000)
Tüketici Güven Endeksi	-0,5474 (0,478)	-6,929 (0,000)
Toplam Mevduat Miktarı	8,9629 (1,000)	-2,8536 (0,0046)
Petrol Fiyatı	-0,7327 (0,397)	-8,7614 (0,000)
Euro	-0,1779 (0,62)	-2,2698 (0,023)
Dolar	2,4611 (0,997)	-10,0502 (0,000)
Dıbs	-5,2703 (0,000)	x
Altın	0,2469 (0,756)	-12,6924 (0,000)

Deđiřkenlerin test istatistikleri kontrol edildikten sonra durađanlıđın sađlandıđı birim kök testi ile test edilmiřtir. Devlet i borlanma senedi serisi durađan olduđu iin deđiřim yüzdesi alınmamıřtır. Regresyon modelinde yer alan deđiřkenler iin birim kök testi řekil 3'te görsel olarak sunulmuřtur.

řekil 3: Birim Kök Testi

Modelde yer alan deđiřkenler iin durađanlık kořulu sađlandıktan sonra gecikme uzunluđunun saptanması gerekmektedir. Kurulan VAR modeli gecikme uzunluđu testi istatistiđi Tablo 4'te sunulmuřtur.

Tablo 4: Gecikme Uzunluğunun Test Edilmesi

Lag	LogL	LR	FPE	AIC	SC	HQ
0	2190.568	NA	9.42e-26	-34.92109	-34.74008*	-34.84755*
1	2286.390	177.8452	5.67e-26	-35.43024	-33.80113	-34.76842
2	2373.999	151.3880	3.93e-26*	-35.80798*	-32.73077	-34.55787
3	2428.962	87.94169*	4.69e-26	-35.66339	-31.13809	-33.82500
4	2464.711	52.62291	7.81e-26	-35.21138	-29.23798	-32.78471
5	2524.541	80.41036	9.22e-26	-35.14465	-27.72315	-32.12969

* indicates lag order selected by the criterion
 LR: sequential modified LR test statistic (each test at 5% level)
 FPE: Final prediction error
 AIC: Akaike information criterion
 SC: Schwarz information criterion
 HQ: Hannan-Quinn information criterion

VAR modeli gecikme uzunluğu testi sonucu; Akaike bilgi kriterine göre 3 ve Schwarz ve Hannan Quinn bilgi kriterlerine göre 1 gecikme olarak uygun olduğu analiz sonuçları gösterilmiştir. VAR modeli için hem bilgi kriterlerine göre hem de veri kaybının yaşanmaması için uygun gecikme sayısının analizinde 1 gecikmenin tercih edilebilirliği görülmüştür. VAR modeli koşullarından artıklar arasında otokorelasyon olmaması koşulu Lagrange-Multiplier testi ile seçilen gecikme sayısına uygun olarak 1 dönemlik gecikme için test edilmiştir ve Tablo 5'te gösterilmiştir.

Tablo 5: Artıklar İçin Korelasyon Testi

Lags	LM-Stat	Prob
1	146.5734	0.0000

VAR Residual Serial Correlation LM Tests
 Null Hypothesis: no serial correlation at lag order h
 Sample: 2005M01 2015M11
 Included observations: 129
 Probs from chi-square with 64 df.

Artıklar arasında 1 gecikme iin korelasyon sorununun olmadıęı tespit edilmiřtir. Ayrıca artıkların sabit varyansa sahip olup olmadıęı test edilmiřtir ve analiz sonucu Tablo 6'da sunulmuřtur.

Tablo 6: Artıklar İin Sabit Varyans Testi

VAR Residual Heteroskedasticity Tests: No Cross Terms (only levels and squares)		
Sample: 2005M01 2015M11		
Included observations: 129		
Joint test:		
Chi-sq	df	Prob.
673.9568	540	0.0001

Artıkların sabit varyansa sahip olduęu doęrulanmıřtır. VAR modeli kořullarının saęlanması sonucu tüketicici ihtiya kredisi miktarı iin kurulan VAR modeli ve Tahmin ıktısı Tablo 7'de verilmiřtir.


Tablo 7: VAR Modeli ve Tahmin ıktısı

Vector Autoregression Estimates	
Sample (adjusted): 2005M03 2015M11	
Included observations: 129 after adjustments	
Standard errors in () & t-statistics in []	
	TUKETICIKREDIMKTDEGSM
TUKETICIKREDIMKTDEGSM(-1)	0.048527 (0.09288) [0.52245]
TUKETCGVNNDKDEGSM(-1)	0.009883 (0.15337) [0.06444]
TOPLAMMEVDUATDEGSM(-1)	0.349444 (0.28105) [1.24334]
PETROLFIYATDEGISM(-1)	-0.035707 (0.06184) [-0.57742]
DOLARDEGISIM(-1)	-0.024398 (0.16207) [-0.15054]
EURODEGISM(-1)	-17.44389 (103.041) [-0.16929]
DIBS(-1)	0.004367 (0.00483) [0.90359]
ALTINDEGSM(-1)	0.055147 (0.09914) [0.55626]
C	0.028958 (0.07746) [0.37383]
R-squared	0.032450
Adj. R-squared	-0.032053
Sum sq. resids	0.352394
S.E. equation	0.054191
F-statistic	0.503080
Log likelihood	197.6887

Akaike AIC	-2.925406
Schwarz SC	-2.725885
Mean dependent	0.026839
S.D. dependent	0.053342
Determinant resid covariance (dof adj.)	3.00E-26
Determinant resid covariance	1.68E-26
Log likelihood	2363.571
Akaike information criterion	-35.52823
Schwarz criterion	-33.93206
Tahmin Çıktısı	
Model: TuketiciKredimiktari	
Sample: 2005M03 2015M11	
Solve Options:	
Static-Deterministic Simulation	
Solver: Broyden	
Max iterations = 5000, Convergence = 1e-08	
Parsing Analytic Jacobian:	
0 derivatives kept, 0 derivatives discarded	
Scenario: Baseline	
Solve begin 13:20:11	
Solve complete 13:20:11	

VAR modeli ile yapılan tahmin sonuçları ve sapma miktarları Şekil 4'te verilmiştir. Grafik incelendiği zaman 2015 yılı Şubat ayı hariç başarılı bir tahmin modeli olarak değerlendirilebileceği görülmektedir.

Şekil 4: VAR Modeli Tahmin Edilen ve Gerçekleşen Değerler

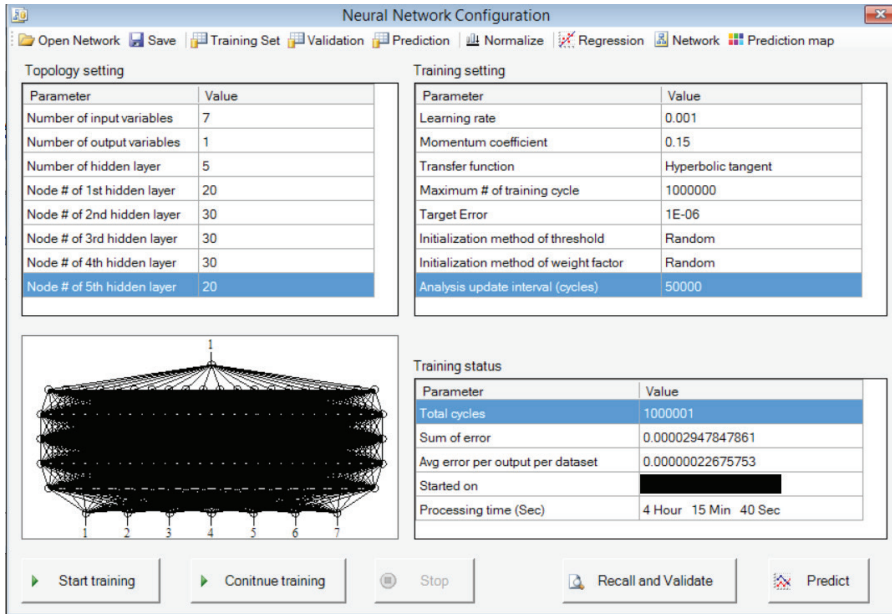


V. Yapay Sinir Ađı Modeli Uygulaması


YSA modelinde tahmin iin kullanılan deđiřkenler VAR modeli ile denk olması amacıyla ortak seilmiřtir. Bu amala YSA modelinde kullanılan 7 temel makro ekonomik deđiřken; Tüketici Güven Endeksi, Toplam Mevduat Miktarı, Petrol Fiyatı, Dibs, Altın Fiyatı, Dolar ve Euro Kuru olarak belirlenmiřtir.

Modelin performansı gerek deđerler ile tahmini deđerler arasındaki hataya gre belirlenmiřtir. İlk ađırlık deđerleri 0,2'den tretilmiřtir ve ilk eřik deđerleri 0 olarak deđerlendirilmiřtir. Veriler Visual Gene Developer 1.7 programı ile analiz edilmiřtir. Program tarafından verilerin normalizasyonu yapılmıřtır. Literatrde analiz deđiřkenlerine ait deđerlerin bulunmasına ynelik yntem bulunamamıřtır. Mevcut kaynaklarda deneme yanılma yntemi ile hata minimizasyonu sađlanmaya alıřılmıřtır. Yapılan denemeler sonucunda program ıktısı olarak programın analiz ara yz Őekil 5'te verilmiřtir.


Őekil 5: YSA Modeli Tahmin Sonucu



YSA modeli deđiřkenleri hata dzeyi minimum olacak Őekilde deneme yanılma yntemiyle bulunmuřtur. Danıřmanlı đrenme modeline uygun olarak nerilen 0,01 đrenme oranı 0,001; momentum katsayısı 0,15; đrenme dngs 1.000.000; hedef hata dzeyi 0,000001 olarak deđiřtirilerek minimum hata dzeyine ulařılmıřtır. Programın alıřma sresi 4 saat 15 dakika ve 40 saniyedir. Toplam hata dzeyi yaklařık 3×10^{-5} ve ortalama hata dzeyi $2,3 \times 10^{-7}$ olarak optimal dzeye eriřilmeye alıřılmıřtır.

Şekil 6: YSA Modeli Ağ Yapısı

YSA tahmin analizi için erişilen minimum hata düzeyi YSA ağ yapısı Şekil 6'da gösterilmiştir. Yapılan denemeler sonucunda en uygun gizli ağ tabakası 5 olarak belirlenmiştir. Programın çalışma süresi dikkate alınarak en uygun düğüm sayıları 20-30-30-30-20 olarak belirlenmiştir.

Şekil 7: YSA Modeli Tahmin Edilen ve Gerçekleşen Değerler

YSA modeli ile yapılan tahmin sonuları ve sapma miktarları Őekil 7’de verilmiřtir. Grafikten de anlařılacađı gibi tahmin deđerleri gerek deđerler ile yaklařık aynı sonuları vermiřtir. Tahmin hatası eđrisi incelendiđinde sıfıra yakın deđerler aldıđı grlmektedir.

Sonuç

Gnmzde finansman ihtiyaı tketiciler aısından her geen gn artarak daha byk nem arz etmektedir. Ekonomik belirsizlikler nedeniyle tketiciler kredi ihtiyaı talep tahmini de makro ekonomik deđiřkenlere bađlı olarak istikrarsızlık gsterebilmektedir. Her geen yıl artan bireysel tketiciler ihtiyaı kredisi talebi alıřmanın konusunu oluřturmaktadır. Literatrde yer alan VAR ve YSA tahmin modelleri ile bireysel tketiciler ihtiyaı talebi tahmini yapılmıřtır.

Uygulama blmnde ilk olarak VAR modeli ile tketiciler kredi ihtiyaı tahmin modeli kurulmuřtur. YSA modelinde VAR modelinde kullanılan temel makro deđiřkenler kullanılarak modellerin kıyaslanabilir olması sađlanmıřtır. Kurulan model sonuları grsel olarak sunulmuřtur. Őekillerden de anlařılacađı gibi YSA modeli VAR modelinden ok daha etkin sonular vermiřtir. Tahmin modellerinin gerek deđerlerden sapmasını deđerlendiren MSE (Mean Square Error), RMSE (Root Mean Square Error), MAE (Mean Absolute Error) ve MAPE (Mean Absolute Percentage Error) yntemlerinin her iki tahmin modeline gre sonuları Tablo 8’de verilmiřtir (Hydman ve Koehler, 2006: 682).

Tablo 8: VAR ve YSA Modellerinin Karřılařtırılması

Karřılařtırma Yntemi	VAR Modeli	YSA Modeli
MSE	21.412.562,093	406,7786
RMSE	4.627,371	20,1688
MAE	1.154.487	15,9363
MAPE	1,824	0,0314

Karřılařtırma deđerlerine bakıldıđında YSA modeli sonularının VAR modelinden ok daha etkin tahmin yapabildiđi grlmektedir. Hata deđerlerinin karesinin toplamı olan MSE ynteminde deđerlerin nicelik byklklerinden dolayı sađlıklı bir karřılařtırma yapılmasını sađlamamaktadır. Benzer Őekilde MSE oranlarının karekk olan RMSE ynteminin kullanılması da etkin bir karřılařtırma yapılmasını engellemektedir. Hata miktarlarının ortalaması olan MAE yntemi, her iki yntemin bařarısı hakkında ipucu vermektedir ancak yetersiz kalmaktadır. MAE oranlarına gre YSA modeli ile VAR modelinde elde tahmin deđerlerinden yaklařık olarak 72 kat daha iyi bireysel tahminde bulunduđu grlmektedir. Hata deđerlerini yzde olarak deđerlendiren MAPE oranlarına gre YSA modeli VAR modelinden 58 kat daha dođru tahminde bulunduđu sonucu elde edilmiřtir. Bu nedenle YSA modeli ile benzer tahmin alıřmalarında etkin sonular elde edilebileceđi sonucuna varılmıřtır.

Kaynaklar

- AMARI, Shun-ichi. (1994). Neural Networks: A Review From Statistical Perspective: Comment, *Statistical Science*, 9(1), 31-32.
- AYTAÇ, Deniz. (2010). Enerji ve Ekonomik Büyüme İlişkisinin Çok Değişkenli VAR Yaklaşımı ile Tahmini, *Maliye Dergisi*, 158, 482-495.
- Bankacılık Düzenleme ve Denetleme Kurumu (2016). Türk Bankacılık Sektörü İnteraktif Aylık Bülten, <http://ebulten.bddk.org.tr/ABMVC/>, (Erişim Tarihi: 01.01.2016).
- BAYKAL, Nazife. & BEYAN, Timur. (2004). Bulanık Mantık Uzman Sistemler ve Denetleyiciler, Bıçaklar Kitabevi, Ankara.
- BOZKURT, Hilal Y. (2007). Zaman Serileri Analizi, Ekin Kitabevi, Bursa.
- CHEN, Wu. & MINGHUA, Zhang. (2012). Personal Credit Forecast Based on the Optimal Naive Bayesian Classifier. *Journal of Jiangsu University of Science and Technology (Natural Science Edition)*, 26(4), 376-380.
- DAUJI, Saha., DEO, Makarand C., & BHARGAVA, Kapilesh. (2015). Prediction of Ocean Currents With Artificial Neural Networks. *ISH Journal of Hydraulic Engineering*, 21(1), 14-27.
- DALAN, Özlem. (2015). Adli Vakaların Coğrafi Bilgi Sistemleri ve Yapay Sinir Ağları ile Tahminlenmesi: İzmir İli Hırsızlık Suçları Örneği. *Adli Tıp Dergisi*, 30(1), 29-40.
- DOMINGO, Laura Montalban., FERNÁNDEZ-VILLA, Juan Antonio Villaronte., SENDRA, Claudio Masanet., & HERRÁIZ, Julia. I. Real. (2015). An Artificial Neural Network Model As A Preliminary Track Design Tool, *Proceedings of the Institution of Mechanical Engineers, Part F: Journal of Rail and Rapid Transit*, 1-13.
- ELMAS, Çetin. (2003). Yapay Sinir Ağları (Kuram, Mimari, Eğitim, Uygulama), Seçkin Yayıncılık, Ankara.
- GANI, Abdullah., MOHAMMADI, Kasra., SHAMSHIRBAND, Shahaboddin., KHORASANIZADEH, Hossein., DANESH, Amir Seyed., PIRI, Jamshid., ISMAIL, Zuraini. & ZAMANI, Mazdak. (2015). Day of The Year-Based Prediction of Horizontal Global Solar Radiation By A Neural Network Auto-Regressive Model, *Theoretical and Applied Climatology*, 1-11.
- GUPTA, Sanjeev., & KASHYAP, Sachin. (2015). Forecasting Inflation in G-7 Countries: An Application of Artificial Neural Network, *Foresight*, 17(1), 63-73.
- GÜREL, Sinem Pınar. (2012). İktisadi Büyümeyi Etkileyen Dış Dinamiklerin Doğrusal Olmayan Analizi, Ege Üniversitesi, Sosyal Bilimler Enstitüsü, İktisat Anabilim Dalı, Yayınlanmamış Doktora Tezi, İzmir.
- GÜNAY, M. Erdem. (2016). Forecasting Annual Gross Electricity Demand by Artificial Neural Networks Using Predicted Values of Socio-Economic Indicators and Climatic Conditions: Case of Turkey, *Energy Policy*, 90, 92-101.
- HEBB, Donald Olding. (1949). *The Organization of Behavior: A Neuropsychological Approach*. John Wiley & Sons, New York.
- HELHEL, Yeşim. (2009). Makroekonomik Değişkenler ve Döviz Kuru İlişkisi: Yapay Sinir Ağı ve Var Yaklaşımları ile Öngörü Modellemesi, T.C. Süleyman Demirel Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Anabilim Dalı, Yayınlanmamış Doktora Tezi, Isparta.
- HOPFIELD, John J. (1982). Neural Networks And Physical Systems With Emergent Collective Computational Abilities, *Proceedings of The National Academy Of Sciences*, 79(8), 2554-2558.
- HYDMAN, Rob J. & KOEHLER, Anne B. (2006). Another Look at Measures of Forecast Accuracy, *International Journal of Forecasting*, 22, 679-688.

- KAASTRA, Iebling. & BOYD, Milton. (1996). Designing a Neural Network for Forecasting Financial and Economic Time Series, *Geurocomputing*, 10, 215-236.
- KADILAR, Cem. (2000). Uygulamalı Çok Deęiřkenli Zaman Serileri Analizi, Bizim Büro Basımevi, Ankara.
- KAYIKI, řafak. (2014). Web Sayfalarının Yapay Sinir Aęları ile Sınıflandırılması. T.C. Marmara Üniversitesi, Sosyal Bilimler Enstitüsü, Gazetecilik Anabilim Dalı, Yayınlanmamıř Doktora Tezi, İstanbul.
- KOHONEN, Teuvo. (1982). Self-Organized Formation of Topologically Correct Feature Maps, *Biological Cybernetics*, 43(1), 59-69.
- KOMYAKOV, Alexandr A., ERBES, Viktor. V., & IVANCHENKO, Vladimir. I. (2015). Application of Artificial Neural Networks For Electric Load Forecasting on Railway Transport, In *Environment and Electrical Engineering (EEEEC)*, IEEE 15th International Conference on, Rome, 43-46.
- MCCLOUGH, Warren S. & PITTS, Walter. (1943). A Logical Calculus of The Ideas Immanent in Nervous Activity, *Bulletin of Mathematical Biophysics*, 5, 115-133.
- MIRMIRANI, Sam. & LI, Hsi. C. (2004). A Comparison of Var And Neural Networks With Genetic Algorithm In Forecasting Price Of Oil (in Jane M. Binner, Graham Kendall, Shu-Heng Chen (ed.) *Applications of Artificial Intelligence in Finance and Economics (Advances in Econometrics, Volume 19)*) Emerald Group Publishing Limited, 203 - 223.
- NABIYEV, Vasif V. (2003). *Yapay Zeka*, Seçkin Yayıncılık, Ankara.
- NAZEMI, Alireza., ABBASI, Behzad., & OMIDI, Farahnaz. (2015). Solving Portfolio Selection Models With Uncertain Returns Using An Artificial Neural Network Scheme, *Applied Intelligence*, 42(4), 609-621.
- ROSENBLATT, Frank. (1958). The Perceptron: A Probabilistic Model For Information Storage and Organization In The Brain, *Psychological Review*, 65 (6), 386-408.
- SIMS, Christopher A. (1980). “Macroeconomics and Reality” *Econometrica*, 48(1), s. 1-5.
- SING, Michael C., EDWARDS, David J., LIU, Henry J., & LOVE, Peter E. D. (2015). Forecasting Private-Sector Construction Works: VAR Model Using Economic Indicators, *Journal of Construction Engineering and Management*, 141(11), 1-9.
- SANTOS, Soares Dos T., MENDES, David., & TORRES, Rodrigues R. (2015) Artificial Neural Networks and Multiple Linear Regression Model Using Principal Components to Estimate Rainfall over South America. *Nonlin. Processes Geophys.*, 23(1), 13-20.
- řEN, Zekai. (2004). *Yapay Sinir İlkeleri*. Su Vakfı Yayınları, İstanbul.
- řENTÜRK, Mehmet. (2014). Türkiye’de Cari İşlemler Açığı Etkileyen Faktörlerin VAR Modelleri ile Analizi, T. C. İnönü Üniversitesi, Sosyal Bilimler Enstitüsü, İktisat Anabilim Dalı, Yayınlanmamıř Doktora Tezi, Malatya.
- TARI, Recep. & BOZKURT, Hilal. (2005). Türkiye’de İstikrarsız Büyümenin VAR Analizi (1991.1-2004.3), VII. Ulusal Ekonometri ve İstatistik Sempozyumu, 26-27 Mayıs, İstanbul.
- Türkiye Bankalar Birlięi (2016). Nakit Kredilere İliřkin Bilgi Notu, https://www.tbb.org.tr/Content/Upload/Dokuman/7340/TBB_Bilgi_Notu_RM_Bulten.pdf, (Eriřim Tarihi: 22.02.2016).
- WARNER, Brad. & MISRA, Manavendra., (1996). Understanding Neural Networks As Statistical Tool, *The American Statistician*, 50(4), 284-293.
- WIDROW, Bernard. & HOFF, Marcian E. (1960). Adaptive Switching Circuits. WESCON Convention Record Part IV, New York (Reprinted in JA Anderson and E. Rosenfeld. *Neurocomputing: Foundations of Research*).

- ZHANG, Caiqing., & ZHENG, Jincheng. (2015). VAR Model For Relations of China's Carbon Productivity and Social Electricity Consumption, *International Journal of Applied Mathematics and Statistics™*, 53(2), 36-45.
- ZHAO, Lutao., CHENG, Lei., WAN, Yongtao., ZHANG, Hao., & ZHANG, Zhigang. (2015). A VAR-SVM Model for Crude Oil Price Forecasting. *International Journal of Global Energy Issues*, 38(1-3), 126-144.