

PAPER DETAILS

TITLE: YAPAY SINIR AGLARI YARDIMI ILE AGRI MERKEZI UYGULAMALARINDA NGR
MODELLEMESİ

AUTHORS: Sefa ORTAKAYA,Remzi TUNTAS

PAGES: 453-465

ORIGINAL PDF URL: <https://dergipark.org.tr/tr/download/article-file/744235>

Yayın Geliş Tarihi: 03.07.2018

Yayına Kabul Tarihi: 11.12.2018

Online Yayın Tarihi: 26.06.2019

<http://dx.doi.org/10.16953/deusosbil.440290>

Dokuz Eylül Üniversitesi

Sosyal Bilimler Enstitüsü Dergisi

Cilt: 21, Sayı: 2, Yıl: 2019, Sayfa: 453-465

ISSN: 1302-3284 E-ISSN: 1308-0911

Araştırma Makalesi

YAPAY SİNİR AĞLARI YARDIMI İLE ÇAĞRI MERKEZİ UYGULAMALARINDA ÖNGÖRÜ MODELLEMESİ¹

Sefa ORTAKAYA*

Remzi TUNTAŞ**

Öz

Yapay zekâ teknolojilerinden biri olan Yapay Sinir Ağları (YSA) tahmin, modelleme, sınıflandırma ve bunun gibi birçok sosyal ve mühendislik alanlarında yaygın olarak kullanılmaktadır. YSA'nın paralel yapısı, gerçek zamanlı uygulamalar için önemli bir özellik olup en önemli avantajları modelin esnek ve uyumlu doğasıdır. YSA'lar bir defa eğitimden geçirildikten sonra yeniden programlamaya gerek kalmadan herhangi bir uygulama için sorunsuz bir şekilde kullanılabilirler. YSA'lar, uygun öğrenme yöntemini kullanarak girdi ve çıktı kalıpları arasındaki doğrusal ve doğrusal olmayan ilişkileri belirlerler. Başka bir deyişle, karmaşık ve doğrusal olmayan sistemlerin giriş ve çıkışları arasındaki korelasyonu kullanarak sistemleri modelleme yeteneklerine sahiptirler. Bu çalışmada YSA yöntemi ile çağrı merkezi verilerine yönelik gelmesi beklenen çağrı sayıları ile yapılması beklenen görüşme süreleri tahmin edilmiştir. Çağrı merkezleri kurumların müşterilerinden/vatandaşlarından gelen talep, görüş, öneri, memnuniyetsizlik, şikâyet vb. konularda hizmet verdiği yüksek öneme sahip iletişim birimidir. Çağrı merkezi yöneticileri erken karar almada tahmin yapmak durumuyla karşı karşıyadırlar. Bu nedenle çağrı merkezi sistemlerinde yer alan raporlamalarda günlük, haftalık ve aylık periyotlarda gelen çağrı sayıları ile karşılanan çağrılarının görüşme sürelerinin tahmini önem arz etmektedir. Yapılan bu çalışmada, eğitim verileri olarak daha önceki aylara ait görüşme sayıları ve görüşme süreleri kullanılmıştır. Öngörü modellemesi için girişten çıkışa doğru ileri beslemeli YSA modeli elde edilmiş ve Levenberg-Marquardt algoritması ile ağ modeli eğitilmiştir. Giriş, gizli ve çıkış katmanından oluşan bu üç katmanlı YSA'nın gizli ve çıktı katmanları için lineer aktivasyon fonksiyonları kullanılmıştır. Bu çalışmada kullanılan ileri beslemeli ve geri yayımlı YSA modeli ile gelen çağrı sayıları ve bu çağrılarının görüşme süreleri tahmin edilmiş ve elde edilen bu YSA modelinin öngörü performansı ortaya konarak bu modelin güvenilir ve tutarlı olduğu gözlemlenmiştir.

Bu makale için önerilen kaynak gösterimi (APA 6. Sürüm):

Ortakaya, S. & Tuntaş, R. (2019). Yapay sinir ağları yardımı ile çağrı merkezi uygulamalarında öngörü modellemesi. *Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 21 (2), 453-465.

¹ Bu makale 09-11 Mart 2018 tarihlerinde Mardin'de gerçekleştirilen 1. Uluslararası İKSAD Sosyal Bilimler Kongresi'nde sözlü bildiri olarak sunulmuştur.

* Yüksek Lisans Öğrencisi, Van Yüzüncü Yıl Üniversitesi, Erciş İşletme Fakültesi, İşletme, ORCID: 0000-0001-8145-0705, sefaortakaya@hotmail.com

** Doç. Dr., Van Yüzüncü Yıl Üniversitesi, Erciş İşletme Fakültesi, İşletme, ORCID: 0000-0001-7973-2412, rtuntas@hotmail.com

Anahtar Kelimeler: Yapay Sinir Ağları, Çağrı Merkezleri, Öngörü Modellemesi.

MODELING OF FORECASTING IN CALL CENTER APPLICATIONS WITH ARTIFICIAL NEURAL ASSISTANCE²

Abstract

Artificial Neural Networks (ANN), one of the artificial intelligence technologies, are widely used in many social and engineering fields such as prediction, modeling, classification and so on. The parallel structure of ANNs is an important feature for real-time applications and the most important advantages are the flexible and harmonious nature of the model. Once ANN is trained, it can be used seamlessly for any application without having to re-program it. ANNs determine linear and nonlinear relationships between input and output patterns using the appropriate learning method. In other words, they have the ability to model systems using the correlation between inputs and outputs of complex and nonlinear systems. In this study, the number of calls expected to be made to the call center data by the ANN method and the expected call duration were estimated. Requests, opinions, suggestions, dissatisfaction, complaints etc. from the customers / citizens of the call centers institutions. It is a communication unit with high prefixes that it serves in the subjects. Call center managers are opposed to making early decisions. For this reason, it is important to estimate the call times of the calls that are met by the call counts of daily, weekly and monthly periods in the reports in the call center systems. In this study, the number of interviews and interviews of the previous month were used as training data. For the forecasting model, a forward-feed ANN model was obtained from the input to the output and the network model was trained by the Levenberg Marquardt algorithm. Linear activation functions are used for hidden and output layers of these three layered ANN which are composed of input, hidden and output layer. In this study, the number of incoming calls and the call duration of these calls using the forward and backward propagation ANN model are estimated and the predictive performance of this obtained ANN model is determined and it is observed that this model is reliable and consistent.

Keywords: Artificial Neural Networks, Call Centers, Forecasting Modeling.

GİRİŞ

Günümüzde yöneticilerin en önemli özelliği daha hızlı ve daha sistemli karar alma yeteneklerine bağlıdır. Yöneticiler, bulunmuş oldukları sistemin sağlıklı bir şekilde çalışması için genelde erken karar alma durumu ile karşı karşıyadırlar. Bu erken karar alma durumu sistemin işleyişi için hayati bir öneme sahiptir. Erken kararların alınabilmesi için öngöründe bulunulması sistemin olmazsa olmazlarından. Çünkü organizasyonun hedeflerine ulaşılabilmesi için ileriye görerek, tahminde bulunarak adımların atılması istenmektedir.

Bilgisayarların çalışma prensipleri üzerine yapılan çalışmalar sonucunda, insan beyninin modellenmesi gerçekleştirilmiştir. Böylece yapay zekâ teknolojileri

² This paper is presented as an oral presentation at the 1st International IKSAD Social Sciences Congress held in Mardin between 09-11 March 2018.

hayatımıza girmiştir. Bu alanda yapılan çalışmalarda sürekli ilerlemeler gözlemlenmiştir. Yapılan bu çalışmalar, yapay zekâ teknolojilerinden biri olan Yapay Sinir Ağları (YSA) adında yeni bir tekniği ortaya çıkarmıştır. İnsanlara özgü olan içgüdüsel düşünme özelliği ile onların tecrübelerine dayalı olan tahmin özelliğinin elektronik ortamda modellenmesi sonucunda geleneksel tahmin yöntemlerinin yerini yapay sinir ağları almıştır. YSA, insanlara özgü olan beynin çalışma düzeni ile beynin özelliklerinden ilham alınarak geliştirilmiştir. YSA, yeni bilgileri meydana çıkarabilme ve keşfedebilme gibi insana ait olan yeteneklerin, öğrenme yöntemlerinden yararlanarak bilgisayar ortamında kullanılmasını gerçekleştirmektedir. YSA'nın geleneksel yöntemlere göre üstün özelliklerinin olması sonucu doğrusal olmayan problemlerin çözümü için etkin bir model olarak yaygın bir şekilde kullanımı görülmektedir. YSA'nın öngörü modellemesinde tutarlı ve güvenilir sonuçlar vermesi, yöntemin kullanımına olan ilgiyi arttırmıştır (Karahan, 2011: 2).

Özellikle son yıllarda YSA tüm bilim dallarında geniş bir uygulama alanı bulmakta, bununla birlikte bu alanlarda çoğunlukla öngörü amaçlı ve etkin olarak kullanılmaktadır. YSA tekniği kullanılarak yapılan çalışmalar için literatür incelendiğinde çıkan sonuçlar, bu yöntemin öngörü özelliğine yönelik uygulamadaki geçerliliğini ve kabul edilebilir çıktıların ortaya çıktığını göstermektedir.

Ataseven (2013), Özel bir şirketin ilgili olduğu üç ürünün satış rakamlarına yönelik YSA'nın öngörü özelliğini kullanarak, elde ettiği sonuçlarla literatürde yer alan diğer öngörü tekniklerinin karşılaştırmalı performans değerlendirmesini yapmıştır. Altunöz (2013), Banka başarısızlıklarının önceden tespiti için YSA yaklaşımını ele alarak literatürdeki çalışmaların uygulanabilirliğini test etmiştir. YSA'nın yüksek öngörülü sonuçlar verdiğine ulaşmıştır. Yurdusev vd. (2008), Akarçay kapalı havzasının aylık akımları, yağışı ve akım gözlemlerinden yola çıkarak YSA'nın tahmin özelliğini ele almışlardır. Elde etmiş oldukları sonuçları çok değişkenli regresyon analizi sonuçları ile kıyaslayarak YSA'nın öngörü üzerine isabetli sonuçlar verdiklerini gözlemlemişlerdir. Atasoy vd. (2017), Gelecek tahmini için tercih edilen yapay zekâ uygulamalarından biri olan YSA ile dövüş sporları alanındaki lisanslı sporcu sayılarının tahmini yapmışlardır. 2007-2016 yılları arasındaki verileri kullanarak 2017 ve 2018 yılı lisanslı sporcu sayıları için tahminde bulunmuşlardır. Ekinci vd. (2008), Finansal göstergelerden faydalanan ekonomik kriz dönemlerinde üretim sektöründe faaliyet gösteren firmaların performanslarına yönelik öngörü çalışması yapmışlardır. Elde ettikleri çıktılarına göre öngörü problem için YSA'nın kullanılabilir olduğuna ve kabul edilebilir sonuçlara ulaşılabilceğine yönelik değerlendirmelerde bulunmuşlardır. Yüksel (2014), Altın fiyatlarına yönelik YSA yönteminden faydalanan öngörü çalışmasında bulunmutur. YSA yöntemi ile oluşturulan modeli esas alarak gerçek değerler ile öngöründe bulunan değerlerini karşılaştırmıştır. Ayrıca yapmış olduğu duyarlılık analizinin çıktılarını değerlendirirken altın fiyatlarına etki eden faktörlere de ulaşmıştır. Sharda ve Wilson (1993), Yapay zekâ uygulamalarını ele alarak yapmış oldukları çalışmada YSA'nın istatistiksel açıdan geleneksel tekniklere göre analiz problemlerinin çözümünde daha

etkin olduğu sonucuna ulaşmışlardır. Aydemir vd. (2014), Acil durumlarda yoğunlukla tercih edilen 112 çağrı merkezine gelen çağrı raporlamalarından yola çıkarak çağrı sayılarının belirlenmesi için YSA çalışması yapmışlardır. YSA yardımıyla gelecek aylar için öngöründe bulunmuşlardır. Geliştirmiş oldukları YSA modelini trend analizi ve ARIMA modeline göre karşılaştırmışlardır.

YSA'nın yapısal olarak kolaylıkla anlaşılması ile birlikte sonucu için çaba gerektiren problemlere yönelik geniş uygulama alanı bulması yöntemin tercih edilme oranını arttırmıştır. YSA yönteminden yararlanılarak, öngörü modellemesi açısından erken uyarı sistemlerinin geliştirilmesine yönelik çalışmalar işletmeler açısından literatürde yer almaktadır.

Bu çalışmanın amacı çağrı merkezlerine yönelik raporlamalardan yola çıkarak öngörü modellemesinde bulunmak ve YSA'nın öngörü özelliğinin güçlü olduğunu ortaya koymaktır. Bu amaçla çağrı merkezine gelen çağrı sayıları ile görüşme süreleri için Anahtar Performans Göstergeleri (Key Performance Indicator - KPI) kullanılmıştır. Beklenen çağrı sayıları ile gerçekleşmesi beklenen görüşme süreleri sonraki dönemler için tahmin edilerek bulgu ve sonuçlar ortaya koyulmaya çalışılmıştır.

ÇAĞRI MERKEZLERİ

Çağrı merkezleri kurumlarla müşteriler arasında iletişim hizmeti vermek üzere kurulan bölümlerdir. Genellikle yardım masası ve müşteri hizmetleri olarak hizmet vermektedir. İlgili olduğu kurumun bir bölümü olabileceği gibi dış kaynak kullanımıyla da bu hizmet sağlanabilmektedir (Norman, 2005: 1). Çağrı merkezleri; en basit tanımıyla firmalar açısından ilgili oldukları müşteriler, tedarikçiler, bayiler ve diğer üçüncü kişilerden gelen aramaları karşılayan, gerektiği zaman çağrı konularına göre ortaya çıkan işlemleri başlatan, çağrı konusunu ilgili birimlere yönlendiren ve işin gereksinimlerine göre dış aramaları da gerçekleştirebilen iletişim birimleridir (Çalışma ve Sosyal Güvenlik Bakanlığı [ÇSGB], 2013: 1). Bu nedenle, çağrı merkezleri konumu gereği çağrı karşılamaktan çok iletişim merkezi görevini yerine getirmektedirler. Çağrı merkezleri sadece firmalar açısından değil kamu kurumları açısından da önemli bir iletişim görevini üstlenmektedir. Firmaların temasta olması gereken kişi ve kurumlara yönelik olabileceği gibi kamu kurumları açısından vatandaşlara yönelik hizmetleri de karşılayabilmektedir.

Çağrı merkezleri kamu kurumları açısından vatandaşlardan gelecek olan her türlü talep, ihbar, şikâyet, görüş, öneri ve bilgi edinmelerin etkin ve hızlı bir şekilde karşılanmasını, gelen çağrıların hızlıca karşılık bulmasını, yapılan başvuruların kurum tarafından takip edilmesini, bürokrasi ve kırtasiyeciliğin azaltılmasını sağlamak amacıyla faaliyet göstermektedirler. Bu nedenle çağrı merkezleri gelen çağrıların geri bildirim dönüşüğü, başvuruların izlendiği, vatandaşların isteklerinin saptandığı birimlerdir. Çağrı merkezlerinde yapılan görüşmeler için raporlamaların elde edilmesi kurumlar için önemli bir geri bildirim aracıdır.

Çağrı merkezi yöneticileri zamanı etkin yönetmek durumuyla karşı karşıyadırlar. Gerçekleşmesi beklenen çağrı sayıları ile gelecek olan çağrılarının süreleri için öngöründe bulunarak organizasyonun hedeflerine ulaşmasını sağlamalıdır. Özellikle çalışan personelin vardiya planlaması, eğitim planlaması, sosyal etkinlik zamanlaması ve ileriye dönük çeşitli adımlar için öngöründe bulunmak yüksek bir öneme sahiptir. Bu durum işletmelerin genelinde olduğu gibi çağrı merkezleri için daha da belirgindir.


YAPAY SİNİR AĞLARI

Yapay zekâ teknolojilerinden olan YSA insana özgü olan öğrenme işlevinin bilgisayarlarda kullanılmasıdır. Bu sistemde öğrenme süreci örneklerden yararlanarak gerçekleştirilmektedir. YSA birbirleri ile bağlantısı olan yapay sinir hücrelerinden meydana gelmiştir. Süreçte yer alan bağlantıların her birinin ağırlık değerleri mevcuttur. YSA'na ait olan bilgi, bağlantıların ağırlık değerlerinde gizlidir ve bilgi ilgili olduğu tüm ağa yayılmış durumdadır (Öztemel, 2006: 41). Bir başka deyişle YSA-insana ait olan öğrenme yeteneğinin modellenmesidir. Beynin üstün nitelikli bir yapıya sahip olması kesintisiz bir şekilde bilim adamlarının araştırmalarına ışık tutmuştur. Bu üstün özellikli yapıdan yola çıkılarak beyin üzerine modeller geliştirilmiştir. Beyin üzerine bir takım matematiksel modellerin üretilmesi gerçekleşse bile beyne özgü tüm fonksiyonları kapsayan modellerin oluşturulması gerçekleşmemiştir ve beyin biyolojik yapısı gereği modellenen özellikler sınırlıdır (Sağıroğlu, vd., 2003). YSA biyolojik beyin sistemi üzerine yapılmış olan matematiksel modelledir. Biyolojik sistemden ilham alınarak meydana getirilen bu yöntem bilgisayar endüstrisinden sonra gelen önemli ilerlemedir (Anderson & Mcneill, 1992: 2). YSA'nın tarihsel gelişimi incelendiğinde, ilk önemli çalışmanın W.S. McCulloch ile Walter H. Pitts tarafından 1943 yılında yapıldığı görülmektedir. Bu dönemde biyolojik sinir ağının matematiksel modellenmesi gerçekleştirilmiştir (Macukow, 2016: 3). Bu başlangıçtan sonra model üzerinde çeşitli yöntemler gerçekleştirilerek YSA çalışmalarda geniş bir kullanım alanına sahip olmuştur.

Biyolojik Sinir Ağları (Nöronlar) ve Yapay Sinir Ağları

İnsan beynini modelleyen YSA'nın çalışma prensibi ve yapısı biyolojik sinir ağları ile benzerlik göstermektedir. YSA'nın gelişimine biyolojik sinir hücresi ilham vermiştir. Biyolojik sinir hücresinin (nöronların) üç ana bileşeni bulunmaktadır. Bunlar dendritler, hücre gövdesi ve aksonlardır. Bir ağacın dallarına benzeyen dendritler almış oldukları sinyalleri hücre gövdesine taşımaktadırlar. Hücre gövdesi bu sinyalleri toplayıp eşleştirdikten sonra akson yardımı ile sinaps adı verilen temas noktalarına iletmektedir (Hagan, vd. 2014: 8). Biyolojik sinir ağlarında görev üstlenen işlem elemanları Şekil 1'de gösterilmiştir.

Şekil 1. Biyolojik Sinir Hücresinin Yapısı



Sinapslar sinir hücrelerinin kendi arasındaki temas noktaları olarak görülebilir. Fiziksel bağlantılardan olmayıp bir sinir hücresinden diğer sinir hücresine elektrik sinyallerinin geçişine yarayan boşluklardır. Sinapslardan gelen sinyaller dentritler aracılığı ile işlenmesi için hücre gövdesine iletilmektedir ve işleme tabi tutulduktan sonra, yeni bir elektrik sinyali üretilmektedir. İşlenen sinyaller ise akson aracılığıyla bağlı olduğu diğer nöronunun dendritlerine gönderilir (Öztemel, 2006, 47).


Biyolojik sinir ağlarının sinir hücreleri olduğu gibi yapay sinir ağlarının da yapay sinir hücreleri bulunmaktadır.

Biyolojik sistemde her bir sinir ağı (nöronlar) ilk aşamada iletişimde olduğu kaynaklardan girdileri alır, onları birleştirir, genel olarak doğrusal yapıda olmayan süreçleri gerçekleştirerek nihai sonuç için çıktı üretir. YSA'nda ise bu süreçler matematiksel olarak gerçekleştirilmektedir. YSA'lar temel olarak benzer bir yapıya sahiptir. Dış dünyadan girdi değerleri girdi ünitesi tarafından kabul edilir. Gizli tabakada işlendikten sonra çıktı tabakası aracılığıyla dışarı iletilir. (Anderson & Mcneill, 1992:8)

YSA'nın mimari yapısını girdi, gizli ve çıktı üniteleri (katmanları) oluşturmaktadır. Yapıdaki düğümler birbirleri ile bağlantılı bir şekilde katmanlar halinde bulunmaktadır. Girdi – çıktı ilişkisi için gizli bir üniteye ihtiyaç vardır (Freeman & Skapura, 1991: 5). Şekil 2'de görüldüğü gibi, en basit bir yapıda ağa verilen çeşitli girdiler matematiksel olarak x_n sembolü ile gösterilmiştir. Bu girdilerin her birinin bir bağlantı ağırlığı da bulunmaktadır. Bu ağırlıklar ise w_n ile sembolü ile gösterilmiştir. Bir sonraki aşamada değerler birleştirilmektedir ve daha sonra bir

transfer fonksiyonu aracılığıyla çıktı elemanına iletilmektedir (Anderson & Mcneill, 1992: 5).

Şekil 2. YSA'nın Matematiksel Yapısı



Levenberg–Marquardt Algoritması

YSA'nın eğitilebilmesi için tercih edilen ve öğrenme özelliği olan algoritmalarından biri de Levenberg–Marquardt (LM) algoritmasıdır. LM algoritması, küçük ve orta ölçekli problemlerin çözümü için uygundur. Diğer algoritmalarla göre daha hızlı ve daha istikrarlı yakınsama eğilimine sahiptir. Yaygın olarak kullanılan geri yayılım algoritmasının yavaş yakınsaması nedeniyle LM algoritması tercih edilmektedir. LM algoritması Dik İniş ve Gauss-Newton algoritmalarının birleşmesi ile meydana gelmiştir. Bununla birlikte, LM algoritması Gauss-Newton algoritmasına göre yakınsama bakımında biraz daha yavaş eğilimde iken dik iniş yönteminden çok daha hızlı bir yakınsamaya sahiptir (Wilamowski & Yu 2010: 930-931). Geri yayılım algoritmasının yavaş yakınsama göstermesi nedeniyle hataları en aza indirmek için performans endeksi $F(w)$ olarak tanımlanır (Suratgar, vd. 2007: 1745):

$$F(w) = e^T e \quad (1)$$

Burada ağ ağırlıklardan oluşur ağırlıklar $w = (w_1, w_2, w_3, \dots, w_n)$ olarak ifade edilir. e ise hata vektörüdür. LM algoritması ile ağ eğitilirken ağırlıklar Δw şeklinde aşağıdaki gibi elde edilebilir (Suratgar, vd. 2005: 1745):

$$\Delta w = [J^T J + \mu I]^{-1} J^T e \quad (2)$$

Burada; w : Ağırlık vektörünü, J : Jacobian matrisini, μ : Kombinasyon katsayısını, I : Birim matrisi, e : Hata vektörünü ifade etmektedir.

YSA eğitilirken ağda bulunan $J (PxM) \times N$ uzantısında Jacobian matrisini, $e (PxM) \times 1$ uzantısında hata vektörünü ifade etmektedir. P eğitimde kullanılan

örneklerin sayısını, M çıktıların sayısını ve N ağırlıkların sayısını göstermektedir. μ kombinasyon katsayısı ise ayarlanabilen parametrelerdendir. μ değeri büyükse LM algoritması dik iniş yöntemi, μ değeri küçükse LM algoritması Newton yöntemi gibi davranış göstermektedir (Çavuşlu, vd. 2012).

VERİ SETİ VE YÖNTEM

Bu çalışmada, geçmiş aylarda gelen çağrı sayıları ve bu çağrıların görüşme sürelerine ait zaman serileri kullanılarak YSA yöntemi ile söz konusu zaman serilerinin gelecek aylara ait öngörüdeki başarısının ölçülmesi amaçlanmıştır. YSA yöntemi ile elde edilen en uygun model kullanılarak tahmin edilmek istenen aylarda gelmesi muhtemel çağrı sayıları ve bu çağrıların görüşme süreleri ile daha önce tespit edilmiş olan zaman serileri arasındaki farklılıkları incelenmiştir. Bu farklılıklar literatürde sıklıkla kullanılan ve denklemleri aşağıda verilen; Belirleme Katsayısı (R^2), Ortalama Hata Kareleri (MSE), Ortalama Hata Karelerinin Karekökü (RMSE), Ortalama Mutlak Hata (MAE), Ortalama Mutlak Yüzde Hata (MAPE) değerleri karşılaştırılarak en iyi sonuca ulaşılmaya çalışılmıştır.

$$R^2 = 1 - \frac{\sum_{i=1}^N (G_i - T_i)^2}{\sum_{i=1}^N (G_i - \bar{T})^2} \quad (3)$$

$$MSE = \frac{1}{N} \sum_{i=1}^N (G_i - T_i)^2 \quad (4)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (G_i - T_i)^2} \quad (5)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |G_i - T_i| \quad (6)$$

$$MAPE = \frac{100}{N} \sum_{i=1}^N \frac{|G_i - T_i|}{G_i} \quad (7)$$

Burada; G_i : Gözlenen değer, T_i : Tahmin edilen değer, $\bar{T}$: Gözlenen değerlerin ortalaması, N : Gözlem sayısıdır.

Bu çalışmada kullanılan veriler, çağrı merkezinden alınmıştır. Ocak 2017 ile Aralık 2017 arasında her bir müşteri temsilcisine gelen çağrı sayıları ve bu çağrıların görüşme sürelerine göre hesaplanan 2017 yılına ait aylık veriler kullanılmıştır. YSA modelinin geliştirilmesi ve yapılan çalışmanın analizi Matlab R2013a programında gerçekleştirilmiştir. Her bir müşteri temsilcisine gelen çağrı sayıları göz önünde bulundurularak Ocak ve Şubat 2017 de 100'er tane müşteri temsilcisine olmak üzere toplamda 200 tane müşteri temsilcisinin her birine gelen çağrı verilerinin; %70'lik kısmı yani 140 müşteri temsilcisine gelen veriler eğitim için, %15'lik kısmı yani 30 müşteri temsilcisine gelen veriler geçerlilik için ve geri kalan %15'lik kısmı yani

30müşteri temsilcisine gelen veriler de test için rassal olarak seçilmiştir. Kullanılan YSA modeli, geçmiş aylarda müşteri temsilcilerine gelen çağrı sayıları ve bu çağrılarının görüşme süreleri olmak üzere 2 adet giriş ve bu girişlere ait sonraki dönem değerleri olmak üzere 2 adet de çıkıştan oluşmaktadır. YSA'nın parametre güncellemesi için öğrenme algoritması olarak LM algoritması ve öğrenme modeli olarak da danışmanlı öğrenme modeli kullanılmıştır.

BULGULAR

Kurulan YSA modeli, 2017'nin Ocak ve Şubat aylarına ait veriler ile eğitilerek, 2017'nin Mart ayı için 100 tane müşteri temsilcisinden her bir müşteri temsilcisine gelen çağrı sayısı ve bu çağrılarının görüşme süreleri tahmin edilmiştir. YSA modellerinin oluşturulması aşamasında gizli katmanda 5'ten 15'e kadar değişen sayıda nöron kullanılarak yapılan eğitim, geçerlilik ve test işlemleri sonucunda en uygun YSA modeli deneme yanılma yöntemiyle tespit edilmiştir. Oluşturulan bu YSA modellerinin eğitim (öğrenme), geçerlilik (uygunluk) ve test sonuçlarından elde edilen korelasyon (R) değerleri Tablo 1'de verilmiştir:

Tablo 1: Eğitim, Geçerlilik ve Test Seti İçin Gizli Katmandaki Nöron Sayılarına Göre R Korelasyon Karşılıkları

Nöronların Sayısı	Eğitim Seti	Geçerlilik Seti	Test Seti
5	0.73743	0.70652	0.70374
6	0.73670	0.70471	0.70185
7	0.88168	0.82356	0.82062
8	0.89793	0.84507	0.84147
9	0.86226	0.81638	0.81479
10	0.90437	0.87935	0.87658
11	0.92911	0.89784	0.89524
12	0.95757	0.91597	0.91306
13	0.98555	0.92636	0.92571
14	0.99878	0.95738	0.95598
15	0.99964	0.98382	0.98167

Tablo 1'de görüldüğü gibi, öğrenme ve kabul edilebilirlik için kullanılan verilerin korelasyon katsayısı incelendiğinde ara (gizli) katmandaki nöron sayısı çoğladıkça eğitim daha iyi gerçekleşmekte ve sınamaya (test) aşaması için ayrı tutulan veri setinden daha iyi sonuçlar elde edilmektedir. Ayrıca eğitim ve test sonuçlarının birbirine yakın olması verilerin yeterli olduğunu göstermektedir. 15 Nöronunda en yakın değerdedir. YSA modelinden üretilmiş olan tahmin sonuçlarının gerçekleşen değerler ile karşılaştırılması sonucunda, gizli katmandaki farklı nöron sayıları için ayrı ayrı hesaplanan R^2 , MSE, RMSE, MAE ve MAPE gibi öngörü performans kriter


değerleri Tablo 2’de verilmiştir:

Tablo 2. Gizli Katmandaki Farklı Nöron Sayıları İçin Hesaplanan Öngörü Performans Kriter Değerleri

Nöron Sayısı	R ²	MSE	RMSE	MAE	MAPE(%)
5	0.54381	76793	277.12	181.31	0.023728
6	0.54273	76975	277.44	177.35	0.023795
7	0.77736	37478	193.59	130.36	0.011622
8	0.80628	32610	180.58	116.17	0.010066
9	0.74338	43198	207.84	128.97	0.013362
10	0.81789	30656	175.09	102.63	0.009488
11	0.86325	23020	151.72	67.62	0.007105
12	0.91694	13981	118.24	62.02	0.004313
13	0.97132	4828.6	69.488	41.73	0.001511
14	0.99755	411.74	20.291	10.9	0.000145
15	0.99919	135.62	11.646	6.36	0.000231

Tablo 2’den de görüleceği üzere YSA’nın gizli katmanında kullanılacak en uygun nöron sayısı 15 olarak bulunmuştur. Dolayısıyla en iyi sonuçlar 15 nöronla kurulan modelden elde edilmiştir. Şekil 3’te gerçek değerler ile en iyi YSA modelden elde edilen değerler arasındaki korelasyon (R) değerleri grafiksel olarak gösterilmektedir.


Şekil 3. Eğitim Veri Seti İçin En İyi YSA Modelin R Korelasyon Grafiği




Oluşturulan en iyi YSA modeli ile elde edilen çağrı sayılarının tahmini ile gerçek değerlerin kıyaslanması, Şekil 4’te ve bu çağrıların görüşme sürelerinin

tahmini ile gerçek değerlerin kıyaslanması da Şekil 5’de ki grafiklerde gösterilmiştir. Bu grafiklerde de görüldüğü gibi 2017’nin Mart ayında gelen çağrı sayıları ve konuşma süreleri için YSA modeli tarafından üretilen tahmin değerlerinin gerçek değerlere çok yakın olduğu görülebilmektedir:

Şekil 4. Gelen Çağrı Sayılarının Gerçek Değerleri ve YSA Tahmin Değerleri



Şekil 5. Gelen Çağrılarının Görüşme Sürelerinin Gerçek Değerleri ve YSA Tahmin Değerleri



SONUÇ VE DEĞERLENDİRME

Bu çalışmada, çağrı merkezlerinde gelen çağrılar ile karşılanan çağrılar gözlemlendiği ve işlendiği raporlamalardan yola çıkılarak öngörü modellemesinde bulunulmuş ve YSA’nın tahmin özelliğinin güçlü olduğu ortaya konulmuştur. YSA metodolojisi ile hesaplanan öngörü değerleri gerçekleşen değerler ile karşılaştırılmıştır. Karşılaştırma sonucunda hesaplanan öngörü performans kriter

değerlerinde, YSA yöntemi ile elde edilen değerlerin gerçek değerlere çok yakın olduğu ($R^2=0,99964$) ve dolayısıyla öngörü hesaplamasında YSA'nın çok iyi sonuçlar verdiği (eğitim:0.99964 ve test:0.98167; MSE: 135.62) gözlemlenmiştir. ÇKA tipi ağlarda belirleyici hata MSE dir.

Sonuç olarak karmaşık bir modele gereksinim duyulmadan YSA ile yalnızca iki girdi değişkeni kullanarak, çağrı merkezlerinde her bir müşteri temsilcisine gelen çağrı sayıları ve bu çağrıların görüşme sürelerinin yüksek tutarlılıkta öngörülebilir olduğu sonucuna ulaşılmıştır.

TEŞEKKÜR

Çalışmada kullanılan veri seti için MEBİM çağrı merkezi raporlamalarının kullanılmasında desteklerini esirgemeyen Milli Eğitim Bakanlığı Basın ve Halkla İlişkiler Müşavirliğine teşekkür ederiz.

KAYNAKÇA

Altunöz, U. (2013). Bankaların finansal başarısızlıklarının diskriminant analizi ve yapay sinir ağları çerçevesinde tahmini. *Sakarya İktisat Dergisi*, 2 (4), 1-22.

Anderson, D. & Mcneill G. (1992). *Artificial neural networks technology*, A DACS State of the Art Report. Newyork: Kaman Sciences Corporation.

Ataseven, B. (2013). Yapay sinir ağları ile öngörü modellemesi. *Öneri Dergisi*, 10 (39), 101-115.

Atasoy, M., Dalkılıç, M. & Uğraş, S.(2017). Yapay sinir ağları ile dövüş sporları alanında lisanslı sporcu sayılarının tahmini. *Kilis 7 Aralık Üniversitesi Beden Eğitimi ve Spor Bilimleri Dergisi*, 1 (1), 33-37.

Aydemir, A., Karaatlı, M., Yılmaz, G. & Aksoy, S. (2014). 112 Acil çağrı merkezine gelen çağrı sayılarını belirleyebilmek için bir yapay sinir ağları tahminleme modeli geliştirilmesi. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 20 (5), 145-149.

Çavuşlu, M, Becerikli, Y. & Karakuzu, C. (2012). Levenberg-Marquardt algoritması ile ysa eğitiminin donanımsal gerçekleşmesi. *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*, 5 (1), 1-7.

ÇSGB (2013). *Çağrı merkezlerinde çalışma koşullarının iyileştirilmesi ve sosyal tarafların bilinçlendirilmesine yönelik programlı teftiş sonuç raporu*, Ankara: Çalışma ve Sosyal Güvenlik Bakanlığı İş Teftiş Kurulu Başkanlığı Yayınları, Yayın No: 58.

Ekinci, Y., Temur, G. T., Çelebi, D & Bayraktar, D. (2010). Ekonomik kriz döneminde firma başarısı tahmini: Yapay sinir ağları tabanlı bir yaklaşım. *Endüstri Mühendisliği*, 21 (1), 17-29.

Freeman, J. A. & Skapura, D. M. (1991). *Neural networks: algorithms, applications, and programming techniques*, Boston: Reading, Addison & Wesley.

Hagan, M.T., Demuth, H.B., Beale, M.H. & Jesus, O. D. (2014). *Neural network design*, (2nd Edition). USA: Martin Hagan.

Karahan, M. (2011). *İstatistiksel tahmin yöntemleri: yapay sinir ağları metodu ile ürün talep tahmini uygulaması*. (Yayımlanmamış Doktora Tezi). Selçuk Üniversitesi, Sosyal Bilimler Enstitüsü, Konya.

Macukow, B. (2016). Neural networks – state of art, brief history, basic models and architecture, *Faculty of Applied Mathematics and Information Science*, 3-14.

Norman, K. (2005). *Call centre work – characteristics, physical, and psychosocial exposure, and health related outcomes*. Phd Thesis. Linköpings Universitet, National Institute for Working Life, Swedish.

Öztemel, E. (2006). *Yapay sinir ağları*. (Birinci Baskı). Türkiye: Papatya Yayınevi.

Sağiroğlu, Ş., Beşdok E. & Erler M. (2003). *Mühendislikte yapay zekâ uygulamaları - 1 yapay sinir ağları*. Kayseri: Ufuk Yayınevi.

Sharda, R. & Wilson, R.L. (1993). Performance comparison issues in neural network experiments for classification problems, *Proceedings of the 26th Hawaii International Conference on Systems Sciences*, 2 (14), 6-28.

Suratgar, A.A., Tavakoli, M.B. & Hoseinabadi A. (2007). Modified Levenberg-Marquardt method for neural networks training, *World Academy of Science, Engineering and Technology*, 1 (6), 1745-1747.

Wilamowski, B.M. & Yu, H. (2010). Improved computation for levenberg-marquardt training, *IEEE Transactions on Neural Networks*, 21 (6), 930-937.

Yüksel, R. (2014). *Altın fiyatlarının yapay sinir ağları ile tahmini ve bir uygulama*. (Yayımlanmamış Yüksek Lisans Tezi). Dumlupınar Üniversitesi, Sosyal Bilimler Enstitüsü, Kütahya.

Yurdusev, M., Acı, M., Turan, M. E. & İçağa, Y. (2014). Akarçay nehri aylık akımlarının yapay sinir ağları ile tahmini. *Celal Bayar Üniversitesi Fen Bilimleri Dergisi*, 4 (1), 73-88.