



112 ACIL ÇAĞRI MERKEZİNE GELEN ÇAĞRI SAYILARINI BELİRLEYEBİLMEK İÇİN BİR YAPAY SİNİR AĞLARI TAHMİNLEME MODELİ GELİŞTİRİLMESİ

IMPROVING OF AN ARTIFICIAL NEURAL NETWORKS FORECASTING MODEL FOR DETERMINING OF THE NUMBER OF CALLS IN 112 EMERGENCY CALL CENTER

Erdal AYDEMİR^{1*}, Meltem KARAATLI², Gökhan YILMAZ³, Serdar AKSOY³

¹Endüstri Mühendisliği Bölümü, Mühendislik Fakültesi, Süleyman Demirel Üniversitesi, 32260, Isparta.

erdalaydemir@sdu.edu.tr

²İşletme Bölümü, İktisadi ve İdari Bilimler Fakültesi, Süleyman Demirel Üniversitesi, 32260, Isparta.

meltemkaraatli@sdu.edu.tr

³Ekonometri Bölümü, İktisadi ve İdari Bilimler Fakültesi, Süleyman Demirel Üniversitesi, 32260, Isparta.

yl1130227006@stud.sdu.edu.tr, yl1130227004@stud.sdu.edu.tr

Geliş Tarihi/Received: 07.05.2012, Kabul Tarihi/Accepted: 28.08.2012

doi: 10.5505/pajes.2014.98608

*Yazışılan yazar/Corresponding author

Özet

Tahminleme çalışmaları, teknik, sosyal ve ekonomik araştırmalar bakımından son derece önemlidir. İlgilenilen sistem hakkında gerçekleşmiş veriler kullanarak tahmin yapmak ya da yüksek doğrulukta tahminler yapabilmek genellikle çok zordur. Bilimsel yazında, tahminleme çalışmalarına enerji, personel planlama, üretim planlama, iklim değişimleri, satış-pazarlama ve ekonomik çalışmalarda sıklıkla rastlanmaktadır. Bu çalışmada, ülkemizde de son yıllarda yeniden yapılanma sürecine giren, sağlık, itfaiye ve güvenlik hizmetlerinin tek numarada birleştirilmesi konusundaki Acil Çağrı Merkezleri'nin bir pilot uygulaması olan Isparta ili 112 Acil Çağrı Merkezi için sağlık, güvenlik ve itfaiye ihtiyaçlarına yönelik gelebilecek çağrı sayısını tahminlemek amacıyla bir yapay sinir ağları (YSA) modeli geliştirilmiştir. Modelde gelecek dönemler için muhtemel çağrı sayısını tahminleme modeli için kurulan ağı eğitilmesinde momentum ve adaptif öğrenme oranı kullanan ileri beslemeli geri yayımlı en dik iniş algoritması kullanılmıştır. Uygulamada, geçmiş bir aylık verilerin %80'i öğrenme ve %20'si test amacıyla kullanılmıştır. Test süreci sonunda ortalama mutlak yüzdeler hata (OMYH) oranı %4,5 olarak elde edilmiş ve modelin test edilmesi uygun görülmüştür. Ayrıca, gelecek bir ay için OMYH oranı YSA modeli için %2,65, trend analizi modeli için %6,40 ve oto-regresif entegreli hareketli ortalama (ARIMA) modeli için %5,24 olacak şekilde çağrı türlerine göre çağrı sayıları her gün için elde edilmiştir. Sonuç olarak, YSA kullanılarak yapılan tahminleme ile trend analizi ve ARIMA (1 1 1) modeline göre daha düşük OMYH oranına sahiptir.

Anahtar kelimeler: 112 Acil çağrı, Yapay sinir ağları, Tahminleme, ARIMA.

Abstract

Forecasting studies are extremely important in the technical, social and economic research. Generally, we know it is very difficult to forecast with higher accurate about a system by using recent values. In the scientific literature, the forecasting studies of energy, personnel planning, production planning, climate changes, sales and marketing and economics etc. are frequently found. In this paper, for an emergency calls center in Isparta province of Turkey an artificial neural network (ANN) forecasting model was developed to determine the number of calls for as health, fire and security services on a pilot implementation of the emergency calls center on a single number 112. In the developed model, the gradient descent with adaptive learning and momentum (GDx) algorithm is selected as the training algorithm with feed-forward back-propagation by using 80% of input data and the 20% of input data is used for testing set data from last month. After the testing, the mean absolute percentage error (MAPE) rate is obtained as 4.5% and it is useful to test. In addition, the forecasting results of the next month are shown that the MAPE values are 2.65%, 6.40% and 5.24% with ANN, trend analysis and ARIMA (1 1 1) models respectively and, the number of calls are found separately on the types of calls in daily. Consequently, the developed model by using ANN to forecast the number of calls in an emergency call center is more accurate than the trend analysis and ARIMA models.

Keywords: 112 Emergency calls, Artificial neural networks, Forecasting, ARIMA.

1 Giriş

Acil çağrı merkezleri, sağlık, güvenlik ve itfaiyeye en hızlı şekilde ulaşmak için kurulmuş servis/hizmet birimleridir. Ülkemizde de son dönemde acil hizmet birimlerinin tek numaradan (112 nolu hat) koordinasyonunun sağlanması hedeflenmektedir. Çağrı merkezleri sayesinde meydana gelen olumsuz bir olaya (kaza, yangın, afet vb.) en yakın ve uygun durumda bulunan sağlık, güvenlik veya itfaiye birimlerinin yönlendirilmesi amaçlanmaktadır. Güvenlik güçlerinin olaylara müdahalesi, sağlık ve itfaiye ekiplerinin ihtiyaç duyulan yerlere zamanında ulaşması hem insan hayatı noktasında hem de maddi zarar noktasında oldukça önemlidir. Bunu sürdürülebilir bir biçimde sağlayabilmek için, acil çağrı merkezlerine

gelebilecek çağrı sayılarını ve türlerini önceden doğru tahmin etmek hiç kuşkusuz öncül bir öneme sahiptir.

Tahmin, bir veya birden çok değişkenin şimdiki/mevcut değerleri kullanılarak gelecekteki değerlerinin kestirilmesidir [1]. Tahminleme kesin sonuçlar vermemektedir ancak bir öngörü oluşturabilmektedir. 112 acil sistemi açısından düşünürsek, ilgili birimlerde yapılan tahminlere göre personel ve ekipman ihtiyaçlarını zamanında sağlayarak olaya geç müdahale durumunu ortadan kaldırma imkanı verebilecektir. Çağrı merkezlerinin sektörel konumu incelediğinde dünyada 340 milyar dolar (\$) iken ülkemizde ise çağrı merkezleri için yatırım miktarı 2 milyar dolar (\$) civarına dayanmış durumdadır [2].

Bilimsel yazın incelendiğinde, tahminleme konusunda çok sayıda çalışmaya rastlanmaktadır. Özellikle regresyon analizi, hareketli ortalama, oto regresif entegreli hareketli ortalama, zaman serisi analizi vb. birçok yöntemin yanısıra özellikle son 20 yılda bulanık mantık, yapay sinir ağları (YSA) ve sezgisel yöntemler (genetik algoritmalar, tavlama benzetimi, parçacık sürüşü optimizasyonu vb.) sıklıkla kullanılmaktadır. YSA ile tahminleme konusunda yapılmış çok sayıda bilimsel yazın bulmak mümkündür. Bu çalışma kapsamında, özellikle son on yılda yapılan bilimsel çalışmalar içeren bir bilimsel yazın araştırması yapılarak bunlardan tahminleme teknikleri ile uygulamaları konusunda ilgili seçilen çalışmalar aşağıdaki şekilde özetlenmiştir.

Ho ve arkadaşları zaman serisi analizinde Box-Jenkins ARIMA (oto regresif entegreli hareketli ortalama) modeli üzerinde geliştirdikleri YSA modeli ile karşılaştırmalı bir çalışma yapmışlardır. Her iki modelin de kısa dönemli tahminlemelerde iyi sonuçlar verdiğini göstermişlerdir [3]. Benzer şekilde zaman serisi temelinde yapılan bir diğer çalışmada hibrit bir ARIMA model ile YSA modeli kullanarak doğrusal ve doğrusal olmayan tahminleme modelleri geliştirmiştir. Deneysel araştırmada tahminleme sonuçlarında ayrı ayrı sağlanan iyileştirmeler gösterilmiştir [4]. Ayrıca, Zhang ve Qi bir önceki çalışmayı trend ve sezon etkisi kullanarak genişletmişlerdir [5]. Hamzaçebi tarafından yapılan çalışmada ise, sezon etkisi olan zaman serisi analizi performansının YSA ile iyileştirilmesi sağlanmıştır [6].

Eke tarafından orta dönem yük tahmini üzerine diferansiyel evrim algoritması ile desteklenmiş YSA modeli geliştirilmiştir [1]. Kaynar ve arkadaşları tarafından ham petrol fiyatlarının YSA ile tahminlemesi yapılmıştır [7]. Yeni ürün adaptasyonu konusunda, Parry ve arkadaşları ise piyasaya sürülmüş olan yeni bir dijital disk oynatıcı ürününün bir yıllık müşteri verilerinin ileri beslemeli geri yayımlı YSA ve genetik algoritma tabanlı iki modeli ile talep tahminlemesi yapmışlardır [8]. Papadopoulos ve Haralambous yaptıkları çalışma ile gerekli bir güven aralığını sağlayan aralık tahminlemesinden türetilmiş nokta tahminlemesi yerine klasik sinir ağları regresyonunun makine öğrenmesi temelinde genişletilmesi yoluyla pratik kullanıma daha uygun yeni bir tahminleme aracı geliştirmişlerdir [9]. Saphoğlu ve Çimen ise, YSA kullanarak geliştirdikleri tahminleme modeli ile ABD Portland bölgesine ait veri setini değerlendirerek günlük yağış miktarını tahminlemiştir [10]. Benzer çalışmalar, olasılıklı hidrolojik olayların tahminlemesinde [11] ve Hindistan yağmur ormanları üzerinde atmosferik olarak Nino fırtınalarının tahminlenmesi [12] şeklinde gösterilebilir. Özellikle yenilenebilir enerji kaynakları konusunda yapılan çalışmalara son yıllarda artan bir şekilde rastlanılmaktadır. YSA ve bulanık mantık modeli içeren doğalgaz talep tahminlemesi [13] ve ampirik kip ayrışım tabanlı benzer bir çalışmada ise, günlük rüzgar hızı parametresi üzerine çok aşamalı bir araştırma [14] yapılmıştır.

Doğa olaylarının yanı sıra turizm araştırmaları da yine son dönemde tahminleme konusunda kendisine bilimsel yazında yer edinmektedir. Metro istasyonlarını kullanan yolcu sayısının geri yayımlı YSA ve ampirik kip ayrışım yöntemiyle kısa dönemli tahminlemesi [15] ve Tayvan ülkesine gelen uluslararası turistlerin dağılımları ve değişimi üzerine ampirik kip ayrışım tabanlı deneysel bir çalışma [16] yapmışlardır.

Bir diğer tahminleme araştırma konusu olarak dünya borsaları tahminleme çalışmaları yapılmaktadır. Bu konuda, bilişim sektöründe yapılan saklı Markov modeli, YSA ve genetik algoritma yöntemleri ile tahminlemeye çalışılmıştır [17]. Bir diğer çalışmada ise, Asya borsa indeksleri üzerinde YSA ve

doğrusal olmayan bağımsız bileşen analizi yöntemlerini birleştirdikleri tahminleme çalışması sonucu yeni yöntemin güçlü bir alternatif yöntem olduğu sayısal örneklerle göstermişlerdir [18].

Bilimsel yazın araştırması sonuçları da dikkate alındığında gerçekleştirilen bu çalışmada, Isparta ili 112 Acil Çağrı Merkezi için YSA kullanarak gelecek bir aylık dönem için farklı çağrı türlerinde çağrı sayısı tahminlemesi yapılmıştır. Geliştirilen YSA modeli, aynı veri seti için kurulan trend analizi ve ARIMA modellerine göre karşılaştırılmıştır. Ayrıca, yapılan bilimsel yazın araştırması sürecinde YSA ile birçok tahminleme çalışması olmasına rağmen, acil çağrı merkezi için yapılan bir çalışmaya rastlanılmamıştır. Bu bakımdan mevcut çalışmanın bilimsel yazına da katkı sağlayacağı öngörülmektedir.

2 Materyal ve Yöntem

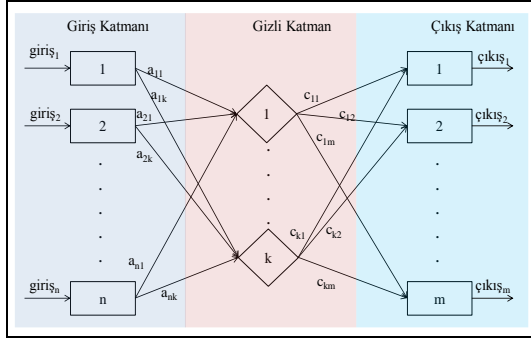
2.1. Yapay Sinir Ağları

Özellikle son yıllarda meydana gelen hızlı teknolojik gelişmeler sonucu, sistemler ve makineler üzerinde insan ve zeka davranışlarının modellendiği uygulamalı çalışmalara sıklıkla rastlanmaktadır. İnsan beyninin çalışma prensipleri sadece tıp alanının değil mühendislik başta olmak üzere diğer bilim dallarının da ilgisini çekmiştir. Bazı bilim adamları, beynimizin güçlü düşünme, hatırlama, problem çözme ve karar verme yeteneklerini matematiksel modellemeyle bilgisayara aktarmaya çalışmışlardır [19]. Bu gelişim sürecinde, yapay sinirlerle ilgili ilk çalışma 1943 yılında McCulloch ve arkadaşları tarafından elektrik devreleri üzerinde basit yapay sinirleri kullanarak yapılmıştır [20]. Sonraki yıllarda IBM tarafından farklı denemeler yapılmış ve ilk denemelerde başarısız olunmasına rağmen sonraki denemelerde basit bir YSA modeli benzetimi yapılmıştır [21]. Widrow ve Hoff tarafından gerçek dünya problemleri için modellenen ilk YSA ADALINE ve MADALINE yöntemleri geliştirilmiştir [22]. 1985 yılında ise Amerika Fizik Enstitüsünde yapay sinir hücrelerinin bilgisayarlar kullanılabileceği gösterilmiştir [21]. Basit bir şekilde insan beyninin çalışma prensibini taklit eden YSA örneklerden öğrenme, genelleme yapabilme, eksik bilgi ile çalışabilme, örüntü tamamlama, ilişki kurma, sınıflandırma ve optimizasyon işlemlerinden birini veya bir kaçını yapabilme gibi birçok önemli özelliğe sahiptir. YSA yapay zeka biliminin alt dallarından birisi olarak araştırmacıların en çok başvurdukları yöntemlerden birisidir. YSA'nın çalışmasına esas teşkil eden en küçük birimler yapay sinir hücresi ya da işlem elemanı olarak isimlendirilir [7], [23], [24].

Ayrıca, YSA araştırmalarında genellikle dijital, analog ve görsel olarak üç tip sinirsel ağ yapısı tanımlanmaktadır. Bir YSA şebekesi, ağız topolojik yapısı (mimarisi) ve bu yapının çalışmasını sağlayan matematiksel fonksiyonlardan oluşmaktadır [10]. Çok katmanlı bir YSA şebekesi Şekil 1'de verilmiştir.

Giriş katmanında ağız girdileri vektör olarak tanımlanır. Gizli katmanda ise, yer alan sinir hücreleri arasında aktivasyon fonksiyonu adı verilen matematiksel bir işlemci yer almaktadır. Dış işleyiş süreci ise, gizli hücreler arasındaki bağlantı değerlerinin öncelikle rastgele atanması ve sonrasında da amaçlanan çıktı için tahmin hatasının en küçüklenmesi yoluyla gerçekleşir [10], [23], [24].

YSA uygulamasında ağız işleyiş süreci ağız eğitimi ve test edilmesi şeklinde çalışır. Burada ağız eğitim sürecinde kullanılan öğrenme algoritmalarının amacı, girdi ve çıktı verileri arasındaki en uygun ilişkiyi sağlayacak olan bağlantı ağırlıklarının elde edilmesini sağlamaktır.



Şekil 1. Çok katmanlı bir YSA genel yapısı.

YSA sürecinde önemli olan bir öğrenme kuralını dikkate alarak eşik fonksiyonu yardımıyla "w" ağırlık vektörünü istenilen performansı sağlayacak şekilde ayarlamaya çalışır. Bu noktada aranan performans ölçütü enküçükleme veya enbüyükleme açısından değerlendirilir ve genellikle karesel ortalama hata enküçüklenmesi amacıyla araştırılır [23]:

$$\min F(w) = \int_A |f(x) - G(x, w)|^2 p(x) dv(x) \quad (1)$$

Burada;

$y = G(x, w)$: Giriş ve çıkış fonksiyonu,

y : Çıkış vektörü,

x : Giriş Vektörü,

w : Ağırlık vektörü,

$p(x)$: Olasılık yoğunluk fonksiyonu.

Çok katmanlı ileri beslemeli ağlar ile birçok kolaylıklar sağlanırken katman sayısının artması nedeniyle aralarındaki bağlantı ağırlıklarının nasıl değiştirileceği konusunda problem yaşanabilmektedir. Bu açıdan bakıldığında, geriye yayılma algoritması güçlü bir öğrenme içerdiğinden bu çalışmada tercih edilmiştir. Geriye yayılma algoritmasının çalışma esası, alt sistemlerde meydana gelen bir YSA'daki değişimlerin tamamen ve etkili bir şekilde hesaplanabilmesine dayanmaktadır [23], [24]. Bu da YSA'nın karmaşık, doğrusal olmayan modellerde ve işlem parametreleri arasındaki ilişkinin öğrenilmesinde tercih edilmesini sağlamaktadır.

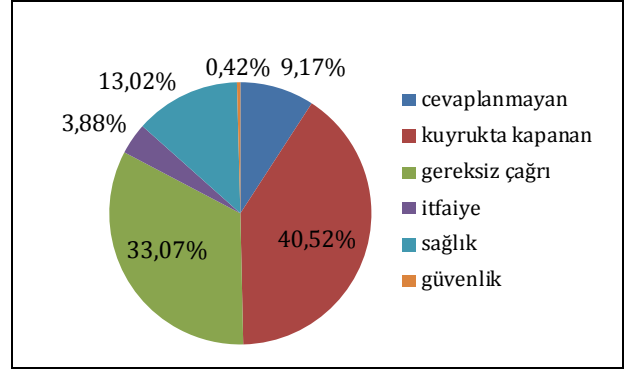
2.2 YSA Tabanlı Çağrı Tahminleme Modeli

Bilimsel yazın incelendiğinde, YSA ile tahminleme yapmak istatistiksel yöntemleri kullanarak tahminleme yapmaktan genellikle daha iyi sonuçlar vermektedir [3]-[6]. Bu nedenle bu çalışmada, YSA kullanarak tahminleme yapılmıştır.

Isparta iline ait 112 Acil Çağrı Merkezi'ne gelen bir aylık çağrı verileri kullanılarak bir sonraki aya yönelik gelebilecek çağrı tahminlemesi için bir YSA modeli kurulmuştur. Bu modelde kullanılan değişkenler; tüm çağrı sayısı (Y), cevaplanmayan çağrı sayısı (X₁), kuyrukta kapanan çağrı sayısı (X₂), gereksiz çağrı sayısı (X₃), itfaiye birimine aktarılan çağrı sayısı (X₄), sağlık birimine aktarılan çağrı sayısı (X₅) ve güvenlik birimine aktarılan çağrı sayısı (X₆) olarak belirlenmiştir. Oluşturulan modelde tüm çağrı sayısı bağımlı değişken diğer çağrı sayıları ise bağımsız değişken olarak ele alınmıştır. Yapılan sistem analizi ve izleme çalışmaları sonucu ortalama olarak günlük çağrı sayılarının yüzde dağılımı Şekil 2'de gösterilmiştir.

YSA ile tahminleme yapabilmek için elimizde bulunan ham verilere [0,1] arasında değerler alacak şekilde bir normalizasyon (ölçeklendirme) yöntemi uygulamak

gerekmektedir. Çalışmada kullanılan normalizasyon formülü aşağıda Denklem (2) olarak verilmiştir.



Şekil 2. Ortalama günlük çağrı sayılarının çağrı türlerine göre dağılımı.

$$v_N = 0,8 \times \left[\frac{v_R - v_{\min}}{v_{\max} - v_{\min}} \right] + 0,1 \quad (2)$$

Burada:


v_N : Normalizasyon değeri,

v_R : Gerçek veri değeri,

v_{\max} : En büyük değer,

v_{\min} : En küçük değer.

Denklem (2) ile gerçekleştirilen normalizasyon ile elde edilecek değerler pozitif değerler olacağından transfer fonksiyonu olarak Şekil 3'te gösterilen Log-Sigmoid transfer fonksiyonu kullanılmıştır.



Şekil 3. Log-Sigmoid transfer fonksiyonu.

Uygulanan normalizasyon işleminden sonra veriler eğitim verisi ve test verisi olmak üzere ikiye ayrılmıştır. Bu çalışmada, mevcut verilerin % 80'i eğitim verisi ve % 20'si test verisi olarak sınıflandırılmıştır. Verilerin bu şekilde ayrılmasının nedeni YSA'da oluşturulacak ağırlık deneme yanılma yöntemiyle belirlenmesidir [24]. Bu seçim yapılırken 30 günlük veri setinin her 6 gün içinden rassal seçilen 1 tanesi test diğer 5 tanesi eğitim setine ayrılmıştır.

Kaç tane gizli katman kullanılacak, gizli katmanda kaç nöron kullanılacak veya hangi öğrenme algoritması kullanılacak bunların hepsi deneme yanılma yöntemiyle bulunmaktadır. Bu nedenle oluşturulan yapay sinir ağını test etme ihtiyacı ortaya çıkmaktadır. Daha sonra veriler MATLAB® yazılımı YSA modülü (ANN Toolbox) kullanılarak işlenmiştir. Oluşturulan ağda bir gizli katman kullanılmıştır, gizli katmanda kullanılacak olan nöron sayısı 1'den başlanarak en iyi sonuç veren nöron sayısı bulunana kadar devam etmiştir. Bu denemeler sonucunda kullanılacak olan nöron sayısı 6 olarak belirlenmiştir.

Öğrenme algoritmasının belirlenmesi süreci de aynı şekilde gerçekleşmiştir. Ağ eğitiminde kullanılacak olan öğrenme algoritmasının belirlenmesi ağı daha yüksek doğrulukta veya daha düşük OMYH değerine sahip sonuçlar vermesi açısından oldukça önemlidir [13]. Denenen öğrenme algoritmaları

içerisinde en iyi sonucu *adaptif öğrenmeli ve momentum özellikli en dik iniş* (GDX) öğrenme algoritması vermiştir. Daha sonra yazılımdan alınan değerler normalizasyon sürecinin tersi ile işlenerek gerçek değerler elde edilmiştir.

2.3 Trend Analizi ve ARIMA Modelleri

Trend analizi ve oto-regresif (AR), hareketli ortalama (MA) ve oto-regresif entegreli hareketli ortalama (ARIMA) modelleri sıklıkla başvurulan tahminleme modelleridir. Bu çalışmada ise, geliştirilen YSA tahminleme modelinin avantaj ve dezavantajlarını ortaya koyabilmek için aynı veri seti için trend analizi ve ARIMA modelleri kullanılmıştır. Her iki model de toplam çağrı sayısının değerlendirilmesi yolu ile gerçekleştirilmiştir. Trend analizi eşitliği Denklem (3) ile gösterilmiştir.

$$\hat{y}_t = 1122,9 + 3,82 \times t \quad (3)$$

Daha sonra oto-regresif (AR), hareketli ortalama (MA) ve oto-regresif entegreli hareketli ortalama (ARIMA) modelleri üzerinde denemeler yapılmıştır. ARIMA (1 1 1) modeli Denklem (4) ile gösterilmiştir.

$$\hat{Y}_t = \mu + Y(t-1) + \phi(Y(t-1) - Y(t-2)) - \theta e(t-1) \quad (4)$$

Sonuçta durağan olmayan süreçlerin modellenmesinde sıklıkla tercih edilen ARIMA modeli üzerinde ARIMA(1 1 1) karma modeli en düşük OMYH değerini sunduğundan çalışmada tercih edilmiştir. Modellerin değerlendirilmesi bulgular kısmında detaylı olarak ele alınmıştır.

3 Araştırma Bulguları

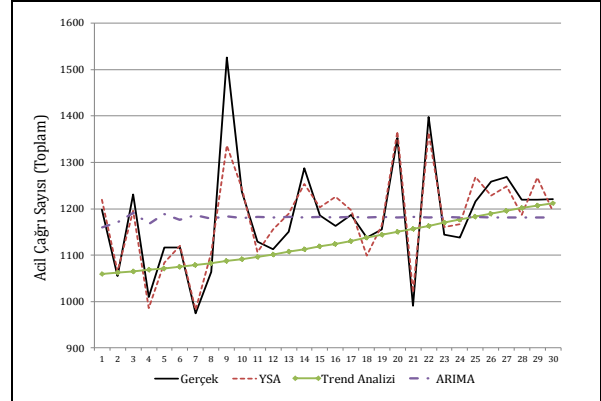
Oluşturulan ağda gizli katmanda 6 nöron ve GDX öğrenme algoritması yer almaktadır. Ağ oluşturduktan sonra mevcut verilerin %80'i eğitim ve %20'si de test veri setini oluşturacak şekilde sınıflandırılmıştır. Ağın test seti için yaptığı tahminleme ile gerçek veri seti karşılaştırılarak OMYH değerine bakıldığında ağın yaptığı tahminleme ile gerçek değer arasındaki OMYH değeri %4,5 olarak elde edilmiştir. OMYH değeri % 10'nun altında ise ağın kullanılabilmesi bilimsel yazında yapılan araştırmalara göre uygun kabul edilmektedir [6]. Önümüzdeki bir aylık çağrı sayısının tahminlenmesinde önerilen YSA ağı, mevcut durum için oluşturulan trend analizi ve ARIMA (1 1 1) sonuçları Şekil 4'te gösterilmiştir. Tahminleme sonucu olarak, test sürecinde gerçekleşen OMYH değerleri YSA ile oluşturulan tahminleme modeli için %2,65, trend analizi modeli için %6,40 ve ARIMA (1 1 1) modeli için %5,24 olarak elde edilmiştir. Sonuçta, YSA tahminleme modeli trend analizi ve ARIMA (1 1 1) tahminleme modellerine göre daha düşük OMYH değerine sahiptir.

YSA tahminleme modeli sonucuna göre, 112 Acil Çağrı Merkezi sistemine her gün için gelecek toplam çağrı sayıları elde edilmiştir. Ancak günlük ortalama çağrı sayısı olarak ~1180 adet acil çağrı gelmesi beklenmektedir. Bu sayıyı çağrı türleri bakımından sınıflandıracak olursak (Şekil 2) yaklaşık olarak günde 108 adet cevaplanmayan çağrı, 478 adet kuyrukta kapanan çağrı, 390 adet gereksiz çağrı, 45 adet itfaiye birimine aktarılan çağrı, 153 adet sağlık birimine aktarılan çağrı ve güvenlik birimine aktarılan 5 adet çağrının geleceği tahmin edilmektedir.

4 Sonuç

Bu çalışmada, YSA yöntemi kullanılarak 112 Acil Çağrı Merkezi'ne gelebilecek çağrı sayısı tahminlemesi yapılmıştır. Tahminlemede pilot bölge uygulaması olan Isparta İli 112 Acil Çağrı Merkezi'ne ait tüm çağrı sayısı, gereksiz çağrı sayısı, kuyrukta kapanan çağrı sayısı ve itfaiye, sağlık, güvenlik

birimlerine aktarılan çağrı sayıları kullanılmıştır. Sonuç olarak, önerilen YSA tahminleme modeli trend analizi ve ARIMA (1 1 1) modeline göre daha düşük OMYH değerine sahip olduğundan daha etkin bir tahminleme modeli olduğu söylenebilir.



Şekil 4. Tahminleme sonuçları.

Çalışmanın sonraki aşaması olarak, 112 acil çağrı merkezi açısından gereksiz çağrı, kuyrukta kapanan çağrı ve cevaplanmayan çağrı sayısının önemli bir miktarda (~%80) olması nedeniyle, personel ve vardiya planlaması çalışmaları öncelikle yapılabilir. Sonuçta yapılacak çalışmalarda hedef göstergesi olarak anlamlı acil çağrılar sonucu aktif hale gelen sağlık, güvenlik ve itfaiye birimleri içinde benzer çalışmaların yapılması düşünülebilir. Ayrıca araştırma tekniği olarak bakıldığında tahminleme çalışmalarının dinamik olması nedeniyle, sürekli tekrarlayan periyotların dönemsel ve mevsimsel etkilerinin de araştırılabilecek olması mevcut (öncül) çalışmanın bir derinliğe sahip olduğunu göstermektedir.

5 Teşekkür

Isparta İli 112 Acil Çağrı Merkezi çalışanlarına ve makalenin geliştirilmesine katkı sağlayan hakemlere göstermiş oldukları ilgi ve destekten dolayı teşekkür ederiz.

6 Kaynaklar

- [1] Eke, İ., "Diferansiyel Evrim Algoritması Destekli Yapay Sinir Ağı ile Orta Dönem Yük Tahmini", *International Journal of Research and Development*, 3 (1), 28-32, 2011.
- [2] Ağaç, F., "Çağrı Merkezleri", *TBD Bilişim Dergisi*, 145, 104-145, 2012.
- [3] Ho, S.L., Xie, M. and Goh, T.N., "A comparative study of neural network and Box-Jenkins ARIMA modeling in time series prediction", *Computers&Industrial Engineering*, 42, 371-375, 2002.
- [4] Zhang, G. P., "Time series forecasting using a hybrid ARIMA and neural network model", *Neurocomputing*, 50, 159-17, 2003.
- [5] Zhang, G.P. and Qi, M., "Neural network forecasting for seasonal and trend time series", *European Journal of Operational Research*, 160, 501-514. 2005.
- [6] Hamzaçebi, C., "Improving Artificial Neural Networks Performance in Seasonal Time Series Forecasting", *Information Sciences*, 178 (23), 4550-4559, 2008.
- [7] Kaynar, O., Taştan, S. ve Demirkoparan, F., "Ham Petrol Fiyatlarının Yapay Sinir Ağları İle Tahmini", *Ege Akademik Bakış*, 10 (2), 559-573, 2010.
- [8] Parry, M.E., Cao, Q. and Song, M., "Forecasting New Product Adoption with Probabilistic Neural Networks", *Product Development & Management Association*, 28, 78-88, 2011.

- [9] Papadopoulos, H. and Haralambous, H., "Reliable prediction intervals with regression neural networks", *Neural Networks*, 24, 842-851, 2011.
- [10] Saphioğlu, K. ve Çimen, M., "Yapay Sinir Ağlarını Kullanarak Günlük Yağış Miktarının Tahmini", *Mühendislik Bilimleri ve Tasarım Dergisi*, 1(1), 14-21, 2010.
- [11] Araghinegad, S., Azmi, M. and Kholghi, M., "Application of artificial neural network ensembles in probabilistic hydrological forecasting", *Journal of Hydrology*, 407, 94-104, 2011.
- [12] Shukla, R., Tripathi, K., Pandey, A. and Das, I.M.L., "Prediction of Indian summer monsoon rainfall using Nino indices: A neural network approach", *Atmospheric Research*, 102, 99-109, 2011.
- [13] Kızılaslan, R., Büyükkınacı, B., Bayraktar, D. ve Çelebi D., "Doğalgaz Talep Tahmini İçin Yapay Sinir Ağları ve Bulanık Mantık Model Önerileri", *Yöneylem Araştırması ve Endüstri Mühendisliği 29. Ulusal Kongresi*, 22-24 Haziran 2009, Ankara.
- [14] Guo, Z., Zhao, W., Lu, H. and Wang, J., "Multi-step forecasting for wind speed using a modified EMD-based artificial neural network model", *Renewable Energy*, 37, 241-249, 2012.
- [15] Wei, Y. and Chen, M.-C., "Forecasting the short-term metro passenger flow with empirical mode decomposition and neural networks", *Transportation Research Part C*, 21, 148-162, 2012.
- [16] Chen, C., Lai, M. and Yeh, C., "Forecasting tourism demand based on empirical mode decomposition and neural network", *Knowledge-Based Systems*, 26, 281-287, 2012.
- [17] Hassan, R., Nath, B. and Kirley, M., "A fusion model of HMM, ANN and GA for stock market forecasting", *Expert Systems with Applications*, 33(1), 171-180, 2007.
- [18] Dai, W., Wu, J.-Y. and Lu, C.-J., "Combining nonlinear independent component analysis and neural network for the prediction of Asian stock market indexes", *Expert Systems with Applications*, 39, 4444-4452, 2012.
- [19] Çetin, M., Uğur A. ve Bazyan, Ş., "İleri Beslemeli Yapay Sinir Ağlarında Backpropagation Algoritmasının Sezgisel Yaklaşımı", *IV. Bilgitek ve Akademik Bilişim 2006 Sempozyumu*, 9-11. Denizli, Şubat 2006.
- [20] McCulloch, S. W. and Pitts, H. W., "A Logical Calculus of the Ideas Immanent in Neural Net", *Bulletin of Mathematical Biophysics*, 5, 115-133 1943.
- [21] Wang, W., "Stochasticity, Nonlinearity and Forecasting of Streamflow Processes", *Ph.D. Thesis at Technische Universiteit Delft*. 2006.
- [22] Widrow, B. and Hoff, M., "Adaptive Switching Circuit", *1960 IRE WESCON Convention Record*, Part 4, 1960.
- [23] Öztemel, E., *Yapay Sinir Ağları*, Papatya Yayıncılık, İstanbul, 2003.
- [24] Sen, Z., *Yapay Sinir Ağları İlkeleri*, Su Vakfı Yayınları, İstanbul, 2004.