

YAPAY SİNİR AĞLARI YÖNTEMİ İLE ARALIKLI TALEP TAHMİNİ⁽¹⁾

DERYA SAATÇIOĞLU⁽²⁾, NECDET ÖZÇAKAR⁽³⁾

ÖZ

Talep tahmini ve doğruluğunun bir işletmenin başarısına ve müşteri memnuniyetine doğrudan etkisi bulunmaktadır. Düzgün talep yapısına sahip ürünlerin talep tahmini ve planlamasında birçok yöntem başarılı sonuçlar verirken çoğu zaman diliminde sıfır talep gören aralıklı talep yapısına sahip ürünlerin talep tahmininde başarılı olamamaktadır. Talep büyüklüğünün ve şeklinin değişkenliği bu ürünler için talep tahmini ve planlamanın yapılmasını zorlaştırmaktadır. Bu çalışmada, aralıklı talep yapısına sahip ürünlerin talep tahminini için Croston yöntemi ve bir yapay sinir ağı modeli olan Çok Katmanlı Algılayıcılar incelenmiştir. Bu yöntemler e-ticaret sektöründe faaliyet gösteren bir işletmenin satış yaptığı bir kategorideki aralıklı talep yapısına sahip ürünlerinin talep tahmini için kullanılmıştır. Daha sonra her bir yöntemin performansı uygun ölçütler kullanılarak ölçülmüştür.

Anahtar Kelimeler: Aralıklı talep, çok katmanlı algılayıcılar, yapay sinir ağları.

JEL Kodları: C45, C53

1 Bu makale İstanbul Üniversitesi Sosyal Bilimler Enstitüsü bünyesinde 2016 yılında tamamlanan "Aralıklı Talep Yapısına Sahip Ürünlerin Talep Tahmininde Makine Öğrenme Yöntemlerinin Uygulanması" başlıklı doktora tezinden derlenerek hazırlanmıştır.

2 Öğr. Gör. Dr., Beykoz Lojistik Meslek Yüksekokulu, deryasaatcioglu@beykoz.edu.tr

3 Prof. Dr., İstanbul Üniversitesi İşletme Fakültesi, necdet@istanbul.edu.tr

FORECASTING INTERMITTENT DEMAND WITH ARTIFICIAL NEURAL NETWORKS METHOD

ABSTRACT

Forecasting and accuracy of demand has a direct effect in the success of a business and customer satisfaction. Whereas many methods show successful results in forecasting and planning demand of products with smooth demand, they fail with products that have many time periods with zero demands. Variability of capacity and pattern of demand causes forecasting and planning of it to become difficult. In this study, for forecasting intermittent demand, Croston Method and Multilayer Perceptron which is also an artificial neural network have been analyzed. These methods have been used for forecasting intermittent demand in one of the categories of a business that operates in e-trade sector. Afterwards, performance of each method has been compared using appropriate accuracy measures.

Keywords: Intermittent demand, multilayer perceptron, artificial neural networks.

JEL Codes: C45, C53

1. Giriş

Rekabetin yoğun olarak yaşandığı günümüz Pazar koşullarında talep tahmini ve planlama işletmeler açısından büyük önem taşımaktadır. Talep tahmini ve planlamanın doğruluğu bir işletmenin başarısını doğrudan etkilemektedir. Doğru talep tahmini ile müşteri memnuniyeti arttırılmakta, stok fazlalığı azaltılmakta, üretim ve satın alma faaliyetleri daha etkili hale gelmekte, taşıma faaliyetleri daha iyi organize edilmekte ve bu sayede maliyetler de azaltılmaktadır.

Düzgün bir talep yapısına sahip olan ürünlerin talep tahmininde klasik talep tahmin yöntemleri başarılı sonuçlar vermektedir. Fakat rastgele gerçekleşen, çoğu zaman periyodunda sıfır talep gören aralıklı talep yapısına sahip ürünlerin talep tahmininde bu yöntemler başarısız olmaktadır. Talep büyüklüğünün ve şeklinin değişkenliği, bu ürünlerin talep tahmin ve planlamasının yapılmasını zorlaştırmaktadır.

Bu çalışmada e-ticaret sektöründe faaliyet gösteren bir işletmenin aralıklı talep yapısına sahip ürünlerinin talep tahmini ve planlaması için öncelikle literatürde sıklıkla kullanılan Croston yöntemi, daha sonra bir yapay sinir ağı modeli olan Çok Katmanlı Algılayıcılar yöntemi kullanılacaktır. Son olarak her iki yöntemin de performansları ölçülerek hangi yöntemin daha başarılı olduğu saptanacaktır.

2. Aralıklı Talep Tahmini

a. Aralık talebin tanımı

Aralıklı talep literatürde tahmin edilmesi zor olan talep senaryolarından biri olarak görülmektedir (Varghese ve Rossetti, 2008: 864). Yavaş hareket eden özelliklerinden dolayı aralıklı talebe sahip ürünler tükenme riskiyle karşı karşıyadırlar. Bu durum bir organizasyonun operasyonları üzerinde önemli bir etkiye neden olmaktadır (Kourentzes, 2013: 198).

Croston (1972) aralıklı talep zaman serilerinin klasik zaman serilerinden farklılık gösteren ve birden çok zaman diliminde talebin sıfır olduğu durumdur şeklinde tanımlamıştır. Johnston ve Boylan (1996) sıfırdan farklı olarak gerçekleşen talebin zaman aralıklarının ortalamasının, envanter gözden geçirme periyodundan 1.25 kat daha büyük olması durumunda talebin aralıklı olduğunu ortaya koymuştur.

Syntetos ve Boylan (2001) aralıklı talep için, rastgele gerçekleşen ve çoğu zaman diliminde talebin sıfır olduğu taleptir şeklinde tanımlamıştır. Talep gerçekleştiğinde ise talep miktarı arada sırada bir birimden fazladır. Aralıklı talep üretim ve tedarik süreçlerinde talep tahmini ve stok kontrolle ilgili olarak önemli problemler yaratmaktadır. Talep

büyükliđünün deđiřkenliđi kadar talep řeklinin deđiřkenliđi de aralıklı talebin tahmin edilmesini zorlařtırmaktadır.

Smart (2003) bir talep serisinin en az %30'unda talebin sıfır olmasını, US donanması stoktan sorumlu yöneticiler ise talep serisinin %60-70 oranına eřit ya da daha az olarak talebin sıfırdan farklı olmasını aralıklı talep olarak tanımlamaktadırlar. Johnston ve diđerleri (2003) aralıklı talebe sahip ürünlerin toplam stok deđerinin %60'ını oluřturduđunu ve genellikle havacılık, otomotiv, askerlik ve bilgi iřlem sektöründe rastlandıđını öne sürmüřlerdir.

Belirli bir ürün için kullanılan talep tahmin yönteminin dođruluđu, o ürüne ait geçmiř talep verilerinin özelliklerinin bilinmesine bađlıdır. Bu sebeple talep zaman serileri, en iyi talep tahmin yönteminin uygulanması için birkaç farklı sınıfa ayrılırlar (Kostenko ve Hyndman, 2006: 1256).

Syntetos ve diđerleri (2005) talep řekillerini; deđiřken talep, düzgün talep, düzgün olmayan talep ve aralıklı talep olmak üzere dört kategoride sınıflandırmıřlardır. Bu sınıflandırma iki parametre esas alınarak yapılmıřtır. Bu parametreler; p (talebin sıklıđı) ve CV^2 (talep büyükliđünün deđiřkenlik / varyasyon katsayısının karesi) parametreleridir (Kostenko ve Hyndman, 2006: 1256).

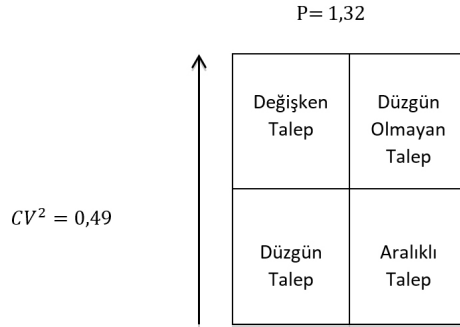
Yapılan bu sınıflandırmanın tanımları ařađıda yer almaktadır (Ghobbar ve Friend, 2002: 227) :

Deđiřken Talep: Büyük ölçüde tutarsız gerçekteřen, tutarsızlıđın birim zamanda gerçekteřen talepten daha çok talep büyükliđüne bađlı olan talep.

Düzgün Talep: Rastgele gerçekteřen ve belli zaman aralıklarında talebin sıfır olduđu taleptir. Talep küçük miktarlarda gerçekteřir.

Düzgün Olmayan Talep: Rastgele gerçekteřen ve çođu zaman diliminde talep miktarının sıfır olduđu taleptir. Talep gerçekteřtiđinde ise yüksek oranda deđiřkenlik söz konusudur.

Aralıklı Talep: Rastgele gerçekteřen ve çođu zaman diliminde talep miktarının sıfır olduđu taleptir. Talep gerçekteřtiđinde ise yüksek oranda deđiřkenlik söz konusu deđildir.



Şekil 1:
Talep Şekillerinin Sınıflandırılması (Syntetos vd., 2005: 500)

Syntetos ve diğerleri tarafından (2005) tarafından geliştirilen sınıflandırmada eşik değerler $p=1,32$ ve $CV^2=0,49$ olarak belirlenmiştir.

$P \leq x, CV^2 \leq y$ durumu, talebi çok aralıklı ve değişken olmayan stok birimleri için ölçülmüştür. (örnek olarak hızlı hareket eden parçalar)

$P > x, CV^2 \leq y$ durumu, yavaş hareket eden ya da sürekli/genellikle aralıklı talep yapısına sahip ve talep büyüklüklerinde yüksek değişikliklerin olmadığı stok birimleri için ölçülmüştür.

$P > x, CV^2 > y$ durumu, talebi düzenli olmayan stok birimleri için ölçülmüştür.

$P \leq x, CV^2 > y$ durumu, talebi değişken fakat çok aralıklı olmayan stok birimleri için ölçülmüştür.

Tüm bu durumlar için x eşik değeri $p = 1,32$ olarak belirlenen talepler arasındaki sürenin ortalamasını, y ise eşik değeri $CV^2 = 0,49$ olarak belirlenen talep büyüklüğünün değişkenlik / varyasyon katsayısının karesini ifade etmektedir (Ghobbar ve Friend, 2003: 2105).

b. Aralıklı talep tahmini için yapılan çalışmalar

Aralıklı talebe sahip ürünlerin talep tahmininde pratikte genellikle basit üstel düzeltme ve hareketli ortalama gibi tahmin yöntemleri kullanılmaktadır. Fakat bu basit klasik talep tahmin yöntemleri, çoğu zaman diliminde talebin sıfır olmasından dolayı aralıklı talep senaryolarında elverişsiz kalmaktadır (Varghese ve Rossetti, 2008: 865). Bununla birlikte, aralıklı talebe sahip ürünlerin talep tahmininde kullanılan herkesçe kabul edilen bir diğer yöntem de Croston (1972) tarafından geliştirilmiş ve literatürde Croston yöntemi olarak yer almaktadır.

Willemain ve diğeri (1994) Croston yöntemi ve basit üstel düzeltme yöntemini karşılaştırmak için hem yapay verileri hem de gerçek talep verileri kullanarak bir çalışma yapmıştır. Yaptıkları bu çalışmada Croston yönteminin basit üstel düzeltme yöntemine göre daha iyi sonuçlar verdiğini ispatlamışlardır Wallström ve Segerstedt, 2010: 627).

Syntetos ve Boylan (2001) Croston yöntemini geliştirebilmek amacıyla yöntem üzerinde bir çalışma yapmış ve talebin beklenen tahminindeki matematiksel türevinde bir hata bulmuşlardır. Yaptıkları çalışma sonucunda Croston yönteminin yeni bir varyasyonunu ortaya koymuşlardır (Syntetos ve Boylan, 2001: 457-458).

Ghobbar ve Friend (2003) aralıklı talebe sahip uçak yedek parçaları için 13 talep tahmin yöntemini karşılaştırmış ve ağırlıklı hareketli ortalama, Holt üstel düzeltme ve Croston yöntemlerinin diğeri yöntemlere göre daha iyi sonuç verdiğini ispatlamışlardır. Benzer bir çalışma da Regattieri ve diğeri (2005) tarafından yapılmıştır. 20 talep tahmin yöntemini karşılaştırmışlar ve aynı sonuca ulaşmışlardır.

Eaves ve Kingsman (2004) Kraliyet hava kuvvetleri vaka çalışmasında yedek parçalar üzerine bir çalışma yapmış ve basit üstel düzeltme, Croston (1972), Syntetos ve Boylan (2005) tarafından geliştirilen yöntemleri karşılaştırarak Syntetos ve Boylan (2005) tarafından geliştirilen yöntemin daha üstün olduğunu ispatlamıştır. Leven ve Segerstedt (2004) de Croston yöntemi üzerinde bir düzeltme yaparak yöntemin farklı bir varyasyonunu ortaya koymuşlardır.

Willemain ve diğeri (2004) yedek parçalar üzerine bir çalışma yaparak sabit tedarik süresi üzerine aralıklı talebin kümülatif dağılımının tahmini için patentli bir algoritma geliştirmişlerdir. Geliştirdikleri yöntemde Efron (1979) tarafından ortaya çıkan özyükleme (bootstrap) yöntemini aralıklı talep verilerinin tahmini için ve olasılık tümlev dönüşümünü aralıklı talep verilerine uygun tahmin doğruluğu ölçütünü bulmak için uyarlamışlardır. Willemain ve diğeri (2004) tarafından geliştirilen yöntem parametrik olmayan bir özyükleme (bootstrap) yaklaşımıdır. Yaptıkları çalışmada talep miktarlarının sıfır olduğu ya da sıfırdan farklı olduğu değerler arasında pozitif korelasyon olduğunu varsaymışlardır. Geliştirdikleri bu yöntem basit üstel düzeltme ve Croston yöntemlerine göre, özellikle geçmiş verilerin daha az olduğu durumlarda daha başarılı sonuçlar vermiştir (Willemain vd., 2004: 376).

Bao ve diğeri (2004) aralıklı talep yapısına sahip ürünlerin tahmini için destek vektör makinesini ve regresyon analizini kullanarak bir çalışma yapmışlardır.

Shenstone ve Hyndman (2005) Croston yönteminin temelinde stokastik model olan, tamamen formüle edilmemiş, özel ve geçici olarak oluşturulmuş bir yöntem olduğunu vurgulamışlardır. Aralıklı talebin yapısının özelliklerinden dolayı Croston yönteminin

tutarsız olduğunu fakat pratik işe yararlılığından dolayı deneysel olarak diğer klasik yöntemlere göre daha iyi sonuçlar verdiğini belirtmişlerdir.

Shale ve diğerleri (2006) siparişlerin poisson dağılımına göre gelmesi durumunda farklı bir modifikasyonun oluşacağını öne sürmüşlerdir (Kourentzes, 2013: 199).

Hua ve Zhang (2006) aralıklı talep yapısına sahip yedek parçalar için destek vektör makinesi ve lojistik regresyonunu kullanarak hibrid bir yaklaşım geliştirmişlerdir ve diğer yöntemlere göre daha başarılı olduğunu ispatlamışlardır.

Hua ve diğerleri (2007) de yedek parça talebinin tahmini üzerine talep miktarının sıfır olduğu ve talep miktarının sıfır olmadığı durumlar arasındaki ilişkiyi dikkate alarak özyükleme (bootstrap) yöntemi ve regresyon analizini birlikte kullanarak petrokimya sektörü için benzer bir çalışma yapmışlardır. Kendi yöntemlerini Croston yöntemi, basit üstel düzeltme ve Willemain (2004) tarafından özyükleme (bootstrap) yöntemleriyle karşılaştırmışlardır. Karşılaştırma sonunda, talep miktarının sıfır olduğu durumlardaki ortalama hatalarının istatistiksel sonuçlarına bakıldığında kendi geliştirdikleri yöntemin daha başarılı sonuçlar verdiğini görmüşlerdir.

Boylan ve Syntetos (2007) , Leven ve Segerstedt (2004) tarafından geliştirilen yöntemin Croston (1972) yöntemine göre özellikle yüksek derecede aralıklı talebin olduğu durumlarda daha kötü sonuç verdiğini ispatlamışlardır (Kourentzes, 2013: 198).

Gutierrez ve diğerleri (2008) yapay sinir ağlarını esas alarak basit üstel düzeltme, Croston (1972), Syntetos ve Boylan (2005) tarafından geliştirilen yöntemlerden daha iyi sonuç veren bir tahmin yöntemi geliştirmişlerdir. Yapay sinir ağlarını kullanarak benzer bir çalışma da Kourentzes (2013) tarafından yapılmıştır.

Altay ve diğerleri (2008) aralıklı talep yapısına sahip ürünlerin talep tahmini için Croston yönteminin son modifikasyonu ile Wright (1986) tarafından değiştirilmiş Holt üstel düzeltme yöntemlerini karşılaştırmıştır. İşletmenin önceliğinin stok seviyelerini düşürmek olması durumunda değişikliğe uğratılmış Croston yönteminin, müşteri memnuniyetini daha öncelikli tutması durumunda ise değişikliğe uğratılmış Holt yönteminin daha üstün olduğunu belirtmişlerdir.

Teunter ve Sani (2009); Croston yöntemi, Syntetos tarafından geliştirilen fakat yayınlanmayan yöntem, Leven ve Segerstedt (2004) ile Syntetos ve Boylan (2005) tarafından geliştirilen yöntemleri karşılaştırarak bir çalışma yapmıştır. Leven ve Segerstedt (2004) tarafından geliştirilen yöntemin diğer tahmin yöntemlerine göre aşırı tahminde bulunarak kötü sonuçlar verdiğini ispatlamıştır. En az sapmanın yaşandığı yöntem ise Syntetos tarafından geliştirilen yöntemdir. Fakat bu yöntemdeki eksiklik, varyans

başarısının Syntetos ve Boylan (2005) tarafından geliştirilen yöntem kadar başarılı olmamasıdır (Wallström ve Segerstedt, 2010: 627).

Wallström ve Segerstedt (2010); basit üstel düzeltme yöntemi, Croston yöntemi, Leven ve Segerstedt (2004) ile Syntetos ve Boylan (2005) tarafından geliştirilen yöntemleri karşılaştırarak yaptığı çalışmada Leven ve Segerstedt (2004) tarafından geliştirilen yöntemin en kötü sonuçları verdiğini ve en az uygun olan yöntem olduğunu ispatlamışlardır.

Nikolopoulos ve diğerleri (2010) ile Babai ve diğerleri (2012) ise bu alanda henüz yaygın olarak kullanılmayan küme temelli yöntemleri kullanarak çalışmalar yapmışlardır.

Kourentzes (2014) aralıklı talep tahmin modellerinin optimizasyonu ve seçimi üzerine bir çalışma yapmış ve model seçimi üzerine açık bir öneri sunamamıştır. Literatürde yer alan yeni yöntemler Croston yöntemi ve türevlerinden daha iyi sonuç vermekte olduğunu, güçlü ve geçerli bir model seçimi metodolojisinin gerekli olduğunu ortaya koymuştur.

3. Croston Yöntemi

Aralıklı talep yapısına sahip ürünlerin talep tahmini için kullanılan klasik bir yöntem olan Croston yöntemi (1972) iki farklı üstel düzeltme tahminini kullanmaktadır. Bunlardan biri talep büyüklüğü diğeri ise talebin sıfır olmadığı durumlar arasındaki zaman aralıklarıdır. Croston talebin normal dağıldığını, talepler arasında gerçekleşen sürenin ise Bernoulli dağılımına uygun olarak dağıldığını varsaymaktadır ve iki süreç de birbirinden bağımsızdır. Tahminler sadece talep meydana geldiğinde güncellenir. Bundan dolayı Croston yöntemi talebin her dönemde gerçekleşmesi durumunda klasik üstel düzeltme yöntemiyle aynıdır. Croston yönteminde varyans basit üstel düzeltme yöntemindeki varyanstan daha düşüktür (Babiloni vd., 2010: 120).

Croston tarafından aralıklı talep yapısına sahip ürünler için geliştirilen yöntemin algoritması aşağıdaki şekildedir (Croston, 1972: 302):

$$\begin{aligned} \bar{Z}_\eta &= \alpha y_t + (1 - \alpha) \bar{Z}_{\eta-1} \\ \bar{p}_\eta &= \bar{p}_{\eta-1}(1 - \alpha) + \alpha q \\ \bar{y}_t &= \bar{Z}_\eta / \bar{p}_\eta \\ q &= 1 \end{aligned} \quad \left| \neq 0 \right. \quad (1)$$

$$\left. \begin{array}{l} \bar{Z}_\eta = \bar{Z}_{\eta-1} \\ \bar{P}_\eta = \bar{P}_{\eta-1} \\ q = q+1 \end{array} \right\} y_t = 0 \quad (2)$$

t = zaman aralıklarının gözden geçirilmesi

h = talebin sıfır olmadığı dönemlerin sayıları

Y_t = dönemi için tahmin

\bar{Z}_η = ortalama (ve standart sapma (ile talep miktarının sıfır olmayan gözlemleri

p = gelişler arasındaki sürenin ortalaması

q = talepler arasındaki süre (p ortalamayla geometrik dağılıma uygun dağılır.)

4. Yapay Sinir Ağları

Yapay sinir ağları, birçok bilim dalında karmaşık dünya problemlerinin modellenmesi için ortaya çıkmış sayısal modelleme araçlarıdır. Yapay sinirler ya da ağ olarak adlandırılan yoğun ölçüde birbirine bağlanmış uyarlanabilir basit uygulama elemanlarından oluşmuş yapılar, paralel bilgi işleme sistemleri olarak da tanımlamak mümkündür (Basheer ve Hajmeer, 2000: 3).

Yapay sinir ağları, insan beyninin özelliği olan öğrenme vasıtasıyla yeni bilgiler üretebilme becerisini otomatik olarak bilgisayarlar ile gerçekleştiren sistemlerdir (Öztemel, 2012: 29). Bir bilgisayara insan gibi düşünme yeteneği verebilmek için araştırmacıların kullanabileceği tek model insan beynidir ve insan beyni oldukça karmaşık bir modeldir. İnsan beyni sinir hücrelerinden oluşmaktadır ve bilgisayarlar, yapay sinir ağlarını kullanarak bu hücrelerin davranışlarını taklit etmeye çalışmaktadırlar (Heaton, 2008: 39).

İnsan beyni ve bilgisayarlar birbirlerinden farklı yapıdadırlar. İnsan beyni sinir hücresi olarak adlandırılan aynı anda çalışan 10^{11} tane işlemciden oluşurken bilgisayarlarda genellikle tek bir işlemci mevcuttur. İnsan beynindeki bu işlemci hücrelerin bilgisayarların işlemcilerine göre daha yavaş ve basit olduğu fakat buna rağmen yüksek bağlantısalılıktan dolayı hesap yapma gücüne sahip oldukları düşünülmektedir. *“Bilgisayarda işlemci etkin, bellek edilgenken beyinde işlem ve belleğin birlikte ağ üzerine dağıtılmış olduğu düşünülür; işlem, ağdaki hücrelerce yapılırken bellek, aralarındaki kavşaklardır.”* (Alpaydın, 2012: 197).

Yapay sinir ağları, sayısal modellemenin mümkün olduğu çok çeşitli problemlerde uygulanabilmektedir. Kullanıldığı alanları; Örüntü tanıma, ses tanıma, kümeleme, denetim, görüntü sıkıştırma, insanlar ve karmaşık fiziksel sistemler arasında uyarlanabilir ara yüzler,

fonksiyon kestirimi, çağrışımsal bellek, tahmin ve kestirim, tümleşik optimizasyon ve doğrusal olmayan sistem modelleme olarak sıralayabiliriz (Hassoun, 1995: 1).

a. Yapay sinir ağları literatürü

İnsan beyni ve fonksiyonları üzerine yapılan çalışmalar uzun yıllar öncesine dayanmaktadır. İlk defa 1890 yılında beynin yapısı ve fonksiyonları hakkında bir yayın yayınlanmış olup 1911 yılında beynin sinir hücrelerinden meydana geldiği fikri benimsenmiştir. 1940'lı yıllardan önce bazı bilim adamlarının yapay sinir ağları üzerine çalışmaları olmasına karşın 1940'dan sonraki yıllarda yapılan çalışmaların, mühendislik değeri taşımasından dolayı, yapay sinir ağlarının ilk temelleri olduğu düşünülmektedir. 1940'lı yıllardan sonra yapay sinir ağlarıyla ilgili yapılan çalışmaları özetleyecek olursak (Öztemel, 2012: 37-41; Elmas, 2010: 26-28; Kriesel, 2005: 9-13; Yegnanarayana, 2005: 21-24):

1943 yılında Warren MacCulloch ve Walter Pitts ilk yapay sinir ağı modelini ana hatlarıyla oluşturmuşlardır. 1949 yılında Donald Hebb, yapay sinir ağları literatüründe temel bir öğrenme kuralı olan "*Hebbian öğrenme kuralı*" nı ortaya koymuştur. 1950 yılında nöropsikolog Karl Lasley, beyin bilgi depolamasının dağıtılmış sistemler olarak gerçekleştiğini savunmuştur. 1951 yılında Marvin Minsky doktora tezi için ilk nörobilgisayar olan *Snark*'ı geliştirmiş fakat hiçbir zaman pratikte uygulanamamıştır. 1956 yılında bilim adamları ve öğrencilerin katıldığı Dartmouth yaz araştırması projesinde ilk defa insan beyninin nasıl taklit edileceği tartışılmıştır.

1957-1958 yıllarında Frank Rosenblatt, Charles Wightman ve çalışma arkadaşları, "*Mark I perceptron*" adını verdikleri ilk başarılı nörobilgisayarı geliştirmişlerdir. Geliştirilen bu algılayıcı model, yapay sinir ağlarındaki çok katmanlı algılayıcıların temelini oluşturmaktadır. 1959 yılında Frank Rosenblatt, perceptron'un farklı versiyonlarını tanımlayarak "*Perceptron yakınsaklık teoremi*" ni formüle edip gerçekliğini ispatlamıştır.

1960 yılında Bernard Widrow ve Marcian E. Hoff, ADALINE (ADaptive LInear NEuron) ve MADALINE (for many ADALINES) olarak tanımladıkları ağ modelini geliştirmişlerdir. Bu model gerçek dünya problemlerine uygulanmış ilk yapay sinir ağı modelidir. 1965 yılında Nils Nilsson, "*Öğrenen makineler*" adlı kitabında yapay sinir ağları hakkında yapılan çalışmalara yer vererek bu alanda ilk kitabın yayınlanmasını sağlamıştır. 1969 yılında Marvin Minsky ve Seymour Papert, yayınladıkları bir yayında yapay sinir ağı algılayıcılarının birçok önemli probleme çözüm bulamadığını öne sürmüşlerdir. (Doğrusal ayrılabilirlik ve XOR problemi) Bu iddia bu alanda yapılan çalışmaların oldukça yavaşlamasına neden olmuştur.

1972 yılında Teuvo Kohonen ve James A. Anderson çağrışımsal bellek ile ilgili doğrusal ilişkilendirici modeli hakkında birbirine çok benzeyen farklı yayınlar yayınlamışlardır.

1974 yılında Harvard Paul Werbos doktora tezi için “*Geri yayılım modeli*” adı verilen bir öğrenme modeli geliştirmiştir. 1976-1980 yılları arasında Stephen Grossberg yapay sinir ağlarını matematiksel olarak incelediği çok sayıda yayın çıkartmıştır ve Gail Corpenner ile birlikte “*Adaptif Rezonans Teorisi (ART)*” ni geliştirmişlerdir.

1982 yılında Teuvo Kohonen, “*Kohonen haritaları*” olarak da bilinen “*Özörgütlemeli haritalar (Self organizing maps - SOM)*” çalışmasını yayınlamıştır. 1982 ve 1984 yıllarında John Hopfield, “*Hopfield ağları*” nı ortaya çıkartmış ve bu yıllar arasında yapmış olduğu çalışmalarda yapay sinir ağlarının birçok problem için uygulanabileceğini göstermiştir. Bu çalışmaların sonucunda Geoffrey E. Hinton ve arkadaşları “*Boltzman makinesi*” ni geliştirmişlerdir.


Hopfield 1985 yılında ise “*Gezgin satıcı*” probleminin çözümünde “*Hopfield ağları*” nı kullandığı bir makale yayınlamıştır. 1983 yılında Miyake ve Ito Fukushima, “*Neocognitron*” adı verilen el yazısını karakterlerini tanıyan bir yapay sinir ağı modeli geliştirmişlerdir. 1986 yılında David E. Rumelhart ve James MacClelland “*Paralel dağıtımli işleme*” konusundaki çalışmalarıyla ilgili yayınlar yayınlamışlardır. Bu çalışmalar vasıtasıyla çok katmanlı algılayıcılar ile XOR problemine çözüm bulunmuş ve 1969 yılında Marvin Minsky ve Seymour Papert’in tezi çürütülmüştür. Böylece yapay sinir ağlarına olan ilgi yeniden canlanmıştır.

1988 yılında David Broomhead ve David Lowe filtreleme problemlerinde başarılı sonuçlar veren çok katmanlı algılayıcılara alternatif olarak geliştirilen “*Radyal tabanlı fonksiyonlar*” ı ortaya çıkartmışlardır. Yine aynı yıl Donald Specht “*Olasılıksal ağlar*” ve daha sonra “*Genel regresyon ağları*” modellerini geliştirmiştir. Bu tarihten itibaren yapay sinir ağlarıyla ilgili çok sayıda sempozyum ve konferans düzenlenmiş ve sayısız uygulamalar gerçekleştirilmiştir.

b. Yapay sinir hücresi


Bir yapay sinir ağı biyolojik sinir ağlarının yapısını ve fonksiyonlarını taklit etmeye çalışan matematiksel bir modeldir. İnsan sinir sistemi vücutta buldukları bölgelere bağlı olarak farklı tipte ve uzunlukta milyonlarca sinir hücresinden oluşmaktadır. Şekil 2’de biyolojik sinir hücresinin şematik gösterimi yer almaktadır. Temel bir biyolojik sinir hücresi dentrit, hücre gövdesi (soma), akson ve sinapslerden oluşmaktadır. Hücre gövdesinde bir çekirdek ve bir plazma bulunmaktadır. Hücre gövdesinden çıkan ve bir ağacın dallarına benzeyen dentritler, aksonlar aracılığıyla diğer sinir hücrelerinden gelen sinyalleri hücre gövdesine iletirler. Tipik bir sinir hücresindeki dentritlerin bu sinyalleri aldığı alan yaklaşık olarak 0,25 ’dir (Basheer ve Hajmeer, 2000: 4-5).

Akson, somanın ince uzun uzantısıdır. Bir aksonun uzunluğunun 1 metreden daha uzun olduğu da görülmektedir. Akson ile dentrit arasındaki boşluğa sinaps adı verilir. Komşu sinir hücreleri arasındaki sinyaller aksondan bu alana bırakılır. Dentritler tarafından alınan ve sinapse ulaşan sinyaller elektrikselsel uyarılardır (Zurada, 1992: 27). Neurotransmitter vasıtasıyla iki sinir hücresi arasındaki bilgi alış verişi gerçekleşmektedir (Öztemel, 2012: 47). Bir insan beyninde civarında sinir hücresi bulunmaktadır ve her bir sinir hücresi yaklaşık 10000 kadar başka sinir hücresiyle bağlantı kurmaktadır. Her bir sinir hücresinin sahip olduğu sinaps sayısı ise yaklaşık olarak civarındadır (Haykin, 1999: 6-8).



Şekil 2:
Biyolojik Sinir Hücresi (Basheer ve Hajmeer, 2000: 3)

Biyolojik sinir ağlarının yapısını ve fonksiyonlarını taklit etmeye çalışan yapay sinir hücrelerinin ise 5 temel ögesi bulunmaktadır: girdiler, ağırlıklar, toplama işlevi, aktivasyon işlevi ve çıktılar. Bir yapay sinirin çalışma prensibi Şekil 3’de yer almaktadır (Krenker vd., 2011: 3).



Şekil 3:
Yapay Sinir Hücresi (Krenker vd., 2011: 3)

Girdiler: Yapay sinir hücresine çevreden gelen bilgileri ifade etmektedir. Bir yapay sinir hücresine çevreden olduğu kadar diğer hücrelerden de bilgilerin gelmesi mümkündür (Öztemel, 2012: 49).

Ağırlıklar: Her girdi değeri farklı ağırlıklarla (W_1, W_2, \dots, W_i) çarpılmaktadır. Bu ağırlıklar, girdilerin sinir hücresindeki etkisini belirlemektedir. Ağırlık değeri büyük ise o girdinin yapay sinirle bağlantısının güçlü olduğu, değer küçük ise bağlantısının zayıf olduğu anlaşılır (Elmas, 2010: 31).

Toplama işlevi: Bu işlev, ağırlıklandırılmış girdi değerlerini eşik değeri ile toplayarak net girdiyi hesaplamaktadır. Net girdinin hesaplanmasının gösterildiği 3 numaralı denklemde W ağırlıkları, X ise girdileri, b ise eşik değerini ifade etmektedir. Literatüre bakıldığında bu formülün dışında daha karmaşık formüllerin de kullanıldığı görülmektedir (Krenker vd., 2011: 5).


$$Net_j = \sum_{i=1}^n W_{ij} X_{ij} + b \quad (3)$$

Aktivasyon işlevi: Bu işlev, toplama işlevinin sonucuna karşılık çıktıyı belirlemektedir. Toplama işlevindeki gibi aktivasyon işlevinde de farklı formüller kullanılmaktadır. En yaygın olarak kullanılan formül (step fonksiyonu) aşağıda yer almaktadır (Basheer ve Hajmeer, 2000: 6).

Şekil 4'de ise farklı aktivasyon işlevleri gösterilmektedir.

$$y = \begin{cases} 1 & \text{eğer } \sum_{i=1}^n W_{ij} X_{ij} \geq b \\ 0 & \text{eğer } \sum_{i=1}^n W_{ij} X_{ij} < b \end{cases} \quad (4)$$

Çıktılar: Aktivasyon işlevi sonucunda belirlenen değerleri ifade etmektedir. Üretilen çıktılar çevreye ya da diğer sinir hücrelerine gönderilmektedir. Ağ olarak gösteriminde birden çok çıktı değeri görünen bir yapay sinir hücresinin aslında tek bir çıktı değeri mevcuttur. Bu değer diğer yapay sinir hücrelerine girdi değeri olarak da iletilmektedir (Öztemel, 2012: 51).




Şekil 4:
Farklı Aktivasyon İşlevleri (Zupan, 1994: 332)

c. Yapay sinir ağlarının yapısı

Farklı sayıda yapay sinir hücrelerinin bir araya gelmesiyle yapay sinir ağı oluşmaktadır. Yapay sinir ağındaki sinir hücreleri tek katman ya da iki, üç ve daha fazla katman halinde bir araya gelebilir (Zupan, 1994: 334)

Şekil 5'de bir yapay sinir ağı örneği yer almaktadır. Yuvarlak şekiller sinir hücrelerini temsil etmektedir ve bir yapay sinir ağı girdi katmanı, gizli katman ve çıktı katmanı olmak üzere 3 katmandan oluşmaktadır.



Şekil 5:
Bir Yapay Sinir Ağı Örneği (Krenker vd., 2011: 3)

Girdi katmanında yer alan sinir hücreleri çevreden gelen bilgileri gizli katmana iletmektedirler. Tek bir gizli katman olabileceği gibi birden fazla gizli katman da olabilmektedir. Girdi katmanından gelen bilgiler gizli katmanlarda aktivasyon işlevi vasıtasıyla işlenerek çıktı katmanına iletilir. Çıktı katmanı ise kendisine gelen bilgilere uygun olarak çıktı değerlerini oluşturur (Wali, 2014: 107).

Yapay sinir ağlarının çalışma prensibine baktığımız zaman basit bir tanımlama yapmak oldukça zordur. Çoğunlukla birbirine paralel bağlı basit aritmetik birimleri kullanarak çoklu girdi ve çıktıları işleten bir kara kutuya benzetilmektedir. Unutulmaması gereken en önemli şey, yapay sinir ağları yöntemlerinin girdi ve çıktılar arasında doğrusal bir ilişki olmadığı durumlarda en iyi şekilde çalışacağıdır. Yapay sinir ağları doğrusal ilişkiyi tanımlamak ya da bulmak için de kullanılabilir fakat sonuçlar diğer basit standart istatistiksel yöntemlerin

sonuçlarından daha kötü çıkmaktadır (Zupan, 1994: 328).

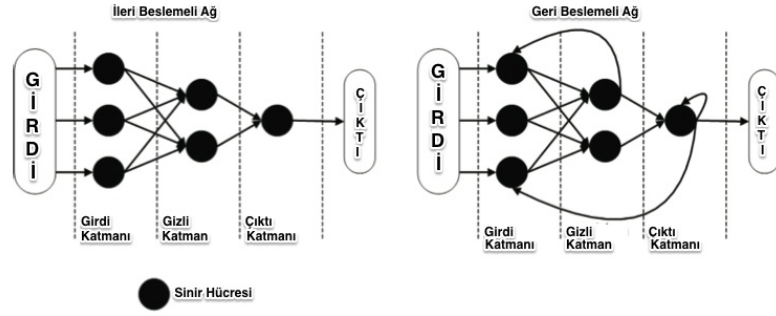
Bir yapay sinir ağının girdi değerlerini çıktı değerlerine nasıl dönüştürdüğü yani sonuçları nasıl oluşturduğunu açıklayamaması bu yöntemin bir dezavantajıdır. Bu durum bu ağa olan güveni zedelemekle birlikte yapay sinir ağlarıyla yapılan başarılı uygulamaların varlığı bu yönetime olan ilgili sürekli arttırmaktadır (Öztemel, 2012: 54).

d. Yapay sinir ağı mimarilerinin sınıflandırılması

İki ya da daha fazla yapay sinir hücresinin bir araya gelmesiyle bir yapay sinir ağı oluşmaktadır. Tek bir yapay sinir hücresi gerçek hayat problemlerinin çözümünde kullanışsızken yapay sinir ağları karmaşık gerçek hayat problemlerinin çözümünde oldukça yeteneklidir. Birbirlerinden ayrı yapay sinir hücrelerinin birbirlerine bağlanma şekline "*Topoloji*" adı verilmektedir. Bağlantının çeşitli yollardan yapılabilir olmasından dolayı çok sayıda farklı topolojiler söz konusu olmakla birlikte genellikle ileri beslemeli ve geri beslemeli olmak üzere iki ana topoloji ayrımı yapılmaktadır. Şekil 6'da bu iki topoloji örneği gösterilmektedir (Krenker vd., 2011: 6).

İleri Beslemeli Ağlar: Bir ileri beslemeli ağda, yapay sinir hücreleri katmanlara yerleştirilmiştir. Şekil 6'da da gösterildiği gibi bir katmanın her yapay sinir hücresi bir önceki katmanın yapay sinir hücreleriyle bağlantı halindedir. Sinyal yayılımı girdi katmanından çıktı katmanına doğru ağın gizli katmanlarından geçerek gerçekleşmektedir. Gizli yapay sinir hücreleri girdi özelliklerini temsil ederken, çıktı sinir hücreleri ağın tepkilerini ortaya çıkarmaktadır. Tek katmanlı algılayıcılar, çok katmanlı algılayıcılar ve radyal tabanlı fonksiyon ağları ileri beslemeli ağlardandır.

Geri Beslemeli Ağlar: Geri beslemeli bir ağ ileri beslemeli bir ağdan ayıran en önemli özellik en az bir geri besleme döngüsünün olmasıdır (Haykin, 1999: 23). Geri beslemeli ağlarda yapay sinir hücreleri çıktılarının ağa geri dönüşümü sağlanarak bu çıktılar girdi olarak kullanılmaktadır ve doğrusal olmayan çağrışımsal bellek gibi çalışmaktadır. İleri doğru bağlantılarla birlikte yapay sinir hücrelerinin kendi ya da kendinden önceki katmanda yer alan yapay sinir hücreleriyle de bağlantısı olmaktadır ve dinamik davranış sergilemektedirler (Alpaydın, 2012: 229; Öztemel, 2012: 165).




Şekil 6:

Bir Yapay Sinir Ağının İleri ve Geri Beslemeli Topolojisi (Krenker vd., 2011: 6)

e. Çok katmanlı algılayıcılar

1943 yılında MacCulloch ve Pitts ilk yapay sinir ağı modelini ana hatlarıyla oluşturulmuş ve 1949 yılında yapay sinir ağları literatüründe temel bir öğrenme kuralı olan “*Hebbian öğrenme kuralı*”nı ortaya koyulmuştur. 1958 yılında ise Rosenblatt, doğrusal ayrılabilir örüntü sınıflandırması için kullanılan *Perceptron* adı verilen basit tek katmanlı bir algılayıcı modeli geliştirmiştir ve geliştirdiği bu model çok katmanlı algılayıcıların temelini oluşturmuştur. Örüntü sınıflandırması için kullanılan, tek katmanlı ileri beslemeli bir ağ olan *Perceptron* sadece girdi ve çıktı katmanlarından oluşmaktadır.

Şekil 7’de tek katmanlı basit bir algılayıcı modeli olan Perceptron modeli yer almaktadır. Şekil 7’de X_1, \dots, X_d , girdileri, W_1, \dots, W_d bağlantı ağırlıklarını, $y(x)$ çıktıyı ifade etmektedir. W_0 eşik değeridir ve X_0 olarak gösterilen bu eşik değerinin girdisi her zaman 1 değerini almaktadır (Bishop, 1995: 79-81).




Şekil 7:

Perceptron Modeli (Bishop, 1995: 79)

Perceptron modelinin doğrusal olmayan problemlere çözüm bulamaması ve bu durumun yapay sinir ağlarına olan güveni azaltıp bu alandaki çalışmalarını ciddi anlamda duraklatmasından dolayı doğrusal ayrılabilir sınıflandırma problemlerinin üstesinden

gelebilmek için girdi katmanı ile çıktı katmanı arasında gizli katman adı verilen ek katmanlar yerleştirilerek çok katmanlı ileri beslemeli ağlar geliştirilmiştir. Şekil 8’ de üç katmanlı bir algılayıcının yapısı gösterilmektedir (Basheer ve Hajmeer, 2000: 7)

İleri beslemeli yapay sinir ağlarında dış çevreden alınan bilgi girdi katmanından gizli katmanlara oradan da çıktı katmanına doğru geri döngü olmaksızın tek bir yönde iletilmektedir. Katmanların sayısı ile yapay sinir hücresinde kullanılan aktivasyon işlevinin tipiyle ya da yapay sinir hücreleri arasındaki bağlantıların sayısı ile ilgili herhangi bir sınırlama söz konusu değildir (Krenker vd., 2011: 7).



Şekil 8:
Çok Katmanlı Algılayıcıların Yapısı (Basheer ve Hajmeer, 2000: 7)

Çok katmanlı bir algılayıcının ayırıcı özelliklerini özetleyecek olursak (Haykin, 1999: 156-157):

1. Ağdaki her bir yapay sinir hücresi doğrusal olmayan bir aktivasyon işlevine sahiptir. En yaygın olarak kullanılan işlev ise Sigmoid fonksiyonudur.
2. Ağda, girdi ve çıktı katmanlarının dışında bir ve birden fazla gizli katman bulunmaktadır. Bu gizli katmanlar ağa daha karmaşık görevlerin yerine getirilmesinde öğrenim kabiliyeti sağlamaktadır.
3. Ağda, ağın sinapsleri tarafından belirlenen yüksek seviyede bir bağlantı bulunmaktadır. Ağın bağlantısındaki bir değişiklik için sinaptik bağlantıların ya da onların ağırlıklarının değişimi gereklidir.

i) Geriye yayılım algoritması

Çok katmanlı algılayıcılar, “Geriye yayılım” ya da “Hatayı geriye yayma” adı verilen bir algoritmayla öğrenmeyi gerçekleştirmektedirler. Geriye yayılım algoritması, ağın çıktı değerleriyle, hedef çıktı değerleri arasındaki hata karelerini minimize etmek ister. Hata

karelerini minimize eden optimal bağlantı ağırlıklarını (W_{ij}) bulmak için de “Eğimli iniş” kuralını kullanır (Mitchell, 1997: 97).

Eğimli iniş yöntemine göre bağlantı ağırlıklarındaki değişim ΔW_{ij} g hata (E) eğiminin negatif yönünde ve (t + 1) iterasyonu için aşağıdaki şekilde hesaplanır (Kasabov, 1996: 273-275):

$$\Delta W_{ij}(t+1) = -h \frac{2E}{2W_{ij}(t)} \quad (5)$$

Burada h öğrenme katsayısını ifade etmektedir. Eğimli iniş yöntemiyle bir kaç iterasyondan sonra hata (E) minimum değere ulaşacaktır. Tüm eğitim örnekleri için hatalar toplamı aşağıdaki şekilde hesaplanmaktadır.

$$E = \sum_{(p)} \sum_{(j)} Er r_j^{(p)} \quad (6)$$

Bir örneğin (p) hatası $Er r_j^{(p)}$ ise aşağıdaki şekilde hesaplanmaktadır.

$$Err_j^{(p)} = \frac{(y_j^p - o_j^p)^2}{2} \quad (7)$$

i sinir hücresiyle j sinir hücresi arasındaki bağlantı ağırlığını değiştiren eğimli iniş kuralı 8 numaralı denklemde yer alan delta kuralı ya da 9 numaralı denklemde yer alan genelleştirilmiş delta kuralı ile ifade edilmektedir.

$$\Delta W_{ij}(t+1) = h.Er r_j \cdot o_i \quad (8)$$

$$\Delta W_{ij}(t+1) = h.Er r_j \cdot g'(u_j) \cdot o_i \quad (9)$$

Err_j , j sinir hücresi için hedef çıktı (y_j) ile gerçekleşen çıktı (o_j) arasındaki hatayı ($|y_j - o_j|$) simgeler. $g'(u_j)$ değeri ise g aktivasyon işlevinin ($2g/2u$) türevidir. u net girdi, o_i ise i sinir hücresi için çıktı değeridir. Aktivasyon işlevi g Lojistik fonksiyonu olduğunda $g'(u_j)$ değeri, $o_j(1 - o_j)$ olarak ifade edilir ve 9 numaralı formül aşağıdaki şekilde sadeleştirilir.

$$\Delta W_{ij}(t+1) = h.Er r_j \cdot o_j(1 - o_j) \cdot o_i \quad (10)$$

ii) İleri ve geri hesaplama

Geriye yayılım algoritmasındaki her iterasyon ileri ve geri hesaplama olmak üzere iki aşamadan oluşmaktadır.

İleri hesaplama: Bu aşamada girdi katmanındaki girdiler herhangi bir değişiklik olmadan ara yani gizli katmanlardan geçerek çıktı katmanına doğru yayılır. Girdi katmanındaki tüm sinir hücrelerinden gelen bilgiler bağlantı ağırlıkları da göz önünde bulundurularak gizli katmandaki j her sinir hücresine iletilir. Gizli katmandaki sinir hücresine gelen net girdi aşağıdaki şekilde hesaplanır. v_{ij} değeri, i girdi katmanı hücresini j gizli katman hücresine bağlayan bağlantının ağırlığıdır. v ilk katmanın ağırlıklarını, w ise ikinci katmanın ağırlıklarını temsil etmektedir (Marsland, 2009: 54-55; Öztemel, 2012: 78).

$$h_j = \sum_i v_{ij} \cdot x_i \quad (11)$$

j gizli katman hücresinin çıktısı ise bu net girdiye aktivasyon işlevinin uygulanmasıyla hesaplanmaktadır. Genellikle Sigmoid fonksiyonu kullanılmaktadır.

$$a_j = g(h_j) = \frac{1}{1 + \exp(-\beta h_j)} \quad (12)$$

12 numaralı denklemde yer alan β değeri, gizli katmanda bulunan j hücresine bağlı eşik elemanının ağırlığını ifade etmektedir. Gizli katmanın tüm sinir hücreleri ve çıktı katmanının sinir hücrelerinin çıktıları aynı şekilde hesaplanır ve çıktılar bulununca ileri hesaplama tamamlanmış olur.

Geri hesaplama: Bu aşamada ise hedef çıktılar ile gerçekleşen çıktılar arasındaki fark yani hata hesaplanarak bu hata, ağırlıkların değişiminin hesaplanması için geriye doğru yayılır (Marsland, 2009: 55; Öztemel, 2012: 79; Elmas, 2010: 129-131).

Öncelikle toplam hata hedef çıktı değerleri (y_k) ile gerçekleşen çıktı (o_k) değerleri arasındaki farkın kareleri toplamı alınarak aşağıdaki şekilde hesaplanır. Daha sonra çıktı biriminin δ_o hatası kullanılarak ikinci katmandaki ağırlıklarda ilk güncelleme yapılır. Daha sonra δ_h hatası kullanılarak ilk katmandaki ağırlıklarda güncelleme yapılır.

$$\text{Toplam Hata} = \frac{1}{2} \sum_{k=1}^n (y_k - o_k)^2 \quad (13)$$

Çıktıdaki hatanın hesaplanması 14 numaralı denklemde ve gizli katmanlardaki hatanın hesaplanması 15 numaralı denklemde yer almaktadır.

$$\delta_{ok} = o_k (1 - o_k) (y_k - o_k) \quad (14)$$

$$\delta_{hj} = a_j (1 - a_j) \sum_k w_{jk} \delta_{ok} \quad (15)$$

Çıktı katmanındaki, ağırlıklar 16 numaralı denklemdeki gibi güncellenirken gizli katmandaki ağırlıklar 17 numaralı denklemdeki gibi güncellenmektedir.

$$w_{jk} \leftarrow w_{jk} + \eta \delta_{ok} a_j^{gizli} \quad (16)$$

$$v_{ij} \leftarrow v_{ij} + \eta \delta_{hj} x_i \quad (17)$$

Böylece ağdaki bağlantı ağırlıkları güncellenmiş olacaktır. Her bir iterasyon aynı şekilde yapılarak öğrenme bitene kadar yinelenecektir.

4. Uygulama

Bu bölümde, e-ticaret sektöründe faaliyet gösteren bir işletmenin aralıklı talep yapısına sahip ürünlerinin talep tahmini ve planlaması için bir yapay sinir ağı modeli olan Çok Katmanlı Algılayıcılar yöntemi uygulanmış ve yöntemin performansı ölçülmüştür.

a. Veri setinin hazırlanması

Çalışmada Türkiye'nin önde gelen bir e-ticaret işletmesinin gerçek verileri kullanılmıştır. Bahsi geçen e-ticaret işletmesi 9 ana kategoride satış yapmaktadır. Her bir ana kategorinin altında alt kategoriler yer almaktadır. Aralıklı talebe sahip ürünlerin toplam stok değerinin büyük bir kısmının genellikle havacılık, otomotiv, askerlik ve bilgi işlem sektöründe rastlandığı bilgisinden yola çıkarak bu işletmenin *Elektronik* ana kategorisinin altında yer alan *Bilgisayarlar* alt kategorisinin verileri kullanılmıştır. Bu kategoride tablet, masaüstü, dizüstü bilgisayar, monitör ve mini masaüstü olmak üzere toplam 640 adet ürün mevcuttur ve her bir ürünün 01.05.2014 - 31.05.2015 tarihleri arasındaki toplam 396 gün için günlük talep miktarları temin edilmiştir.

b. Aralıklı talebin sınıflandırılması

Bilgisayarlar alt kategorisinde 640 adet ürün bulunmaktadır. Bu ürünlerden aralıklı talep yapısına sahip olan ürünlerin belirlenebilmesi için Syntetos ve diğerleri (2005) tarafından geliştirilen sınıflandırma tekniği kullanılmıştır. Bu sınıflandırma talebi; değişken talep, düzgün talep, düzgün olmayan talep ve aralıklı talep olmak üzere dört kategoriye ayırmaktadır ve bu sınıflandırmayı yaparken iki parametreyi esas almaktadır. Bu parametrelerden birisi talebin sıklığı yani iki ardışık talep arasında geçen zaman periyodlarının ortalaması (p), diğeri ise talep büyüklüğünün değişkenlik/varyasyon katsayısının karesi (CV^2) parametreleridir. Bu teknikte bu parametreler için belirlenen eşik değerler $p = 1,32$ ve $CV^2 = 0,49$ değerleridir ve $p > 1,32$, $CV^2 \leq 0,49$ durumunu sağlayan ürünler aralıklı talep yapısına sahip olan ürünlerdir.


640 adet ürün için p ve CV^2 değerleri hesaplandığında $p > 1,32$, $CV^2 \leq 0,49$ koşuluna uyan toplam 98 adet ürün tespit edilmiştir. Başka bir ifadeyle 640 adet üründen 98 adet ürün aralıklı talep yapısına sahiptir. Bu hesaplama yapılırken Excel formatında gelen veriler R programı ile okunup data.frame nesnesi içinde saklanmıştır ve talebin gerçekleşmediği günlere 0 değer atanmıştır. Daha sonrasında her bir ürün için p ve CV^2 değerleri hesaplatılmıştır.

640 adet ürün için p ve CV^2 değerleri hesaplanıp $p > 1,32$, $CV^2 \leq 0,49$ koşuluna uyan toplam 98 adet ürün tespit edildikten sonra elde edilen aralıklı talebe sahip ürünlerin talep verilerinin %80'i eğitim için kalan %20'si de test için ayrılmıştır. 01.05.2014 - 31.05.2015 tarihleri arasındaki 396 günlük talebin ilk 316 günlük bölümü eğitim kümesi, son 80 günlük bölümü ise test kümesi olarak kullanılmıştır.

Uygulamada tüm yöntemler için periyodik ilerleme (rolling) mekanizması kullanılmıştır. Periyodik ilerleme mekanizması tahmin doğruluğunun artırılması için kullanılan etkili bir yöntemdir. Düzensiz bir yapıya sahip verinin olması durumunda talep tahmin doğruluğunu arttırmak için her yeni dönemi tahmin ederken en son döneme ait veriyi de kullanarak tahmin gerçekleştirilmektedir (Akay ve Atak, 2007: 1672).

c. Croston yöntemiyle aralıklı talep tahmininin yapılması

Croston yöntemi için R programındaki forecast paketinin Croston fonksiyonu kullanılmıştır. Bu fonksiyon ile alfa değeri de fonksiyon içerisinde kestirilmektedir. Croston yöntemine göre hesaplanmış bir ürün için 80 günlük test verisinin gerçekleşen talepler ile tahmini talep değerleri Tablo 1'de, eğitim verisi ve test verisine ait talep zaman grafiği ise Şekil 9'da yer almaktadır. Grafikte kırmızı çizgiler gerçekleşen talebi, mavi çizgi ise tahmin değerlerini ifade etmektedir.



Şekil 9:
Croston Yöntemine Göre Bir Ürünün Talep Zaman Grafiği
(Gerçekleşen ve Tahmini Talep)

Tablo 1:
Croston Yöntemine Göre Gerçekleşen ve Tahmin Edilen Talep Değerleri

Gün	Gerçekleşen	Croston	Gün	Gerçekleşen	Croston	Gün	Gerçekleşen	Croston	Gün	Gerçekleşen	Croston
1	1	0,5279	21	0	0,3898	41	0	0,3761	61	2	0,3482
2	0	0,3616	22	1	0,3898	42	0	0,3761	62	0	0,3514
3	0	0,3616	23	0	0,3915	43	1	0,3761	63	0	0,3514
4	2	0,3616	24	0	0,3915	44	1	0,3492	64	0	0,3514
5	0	0,3825	25	0	0,3915	45	0	0,3578	65	0	0,3514
6	0	0,3825	26	0	0,3915	46	0	0,3578	66	0	0,3514
7	0	0,3825	27	1	0,3915	47	0	0,3578	67	0	0,3514
8	0	0,3825	28	0	0,3735	48	0	0,3578	68	0	0,3514
9	0	0,3825	29	0	0,3735	49	0	0,3578	69	0	0,3514
10	1	0,3825	30	0	0,3735	50	0	0,3578	70	0	0,3514
11	0	0,3578	31	1	0,3735	51	2	0,3578	71	0	0,3514
12	0	0,3578	32	1	0,3634	52	0	0,3568	72	0	0,3514
13	0	0,3578	33	0	0,3724	53	0	0,3568	73	2	0,3514
14	1	0,3578	34	1	0,3724	54	0	0,3568	74	1	0,3195
15	1	0,3485	35	0	0,3743	55	1	0,3568	75	1	0,3323
16	0	0,3593	36	1	0,3743	56	0	0,3482	76	0	0,3421
17	0	0,3593	37	0	0,3761	57	0	0,3482	77	0	0,3421
18	0	0,3593	38	0	0,3761	58	0	0,3482	78	1	0,3421
19	0	0,3593	39	0	0,3761	59	0	0,3482	79	0	0,3400
20	3	0,3593	40	0	0,3761	60	0	0,3482	80	0	0,3400


d. Yapay sinir ağları ile aralıklı talep tahmininin yapılması

Yapay sinir ağları literatüründe doğrusal olmayan modelleme ile ilgili birçok yöntem bulunmaktadır. Geriye yayılım algoritmasıyla öğrenmeyi gerçekleştiren çok katmanlı algılayıcılar (ÇKA) bu yöntemlerden en yaygın olarak kullanılan yöntemdir.

ÇKA yöntemi için MATLAB 2014a ve R v3.2.2 araçları ile “Neural Network Toolbox” paketi kullanılmıştır. Uygulama sırasında 3 katman kullanılmıştır. Bu katmanlar girdi katmanı, gizli katman ve çıktı katmanıdır. Girdi katmanında bir önceki dönemin sonunda gerçekleşen talep değeri ile talep değeri sıfır olmayan son iki talep arasındaki dönem sayısı yer almaktadır. Çıktı katmanı ise mevcut dönem için tahmin edilen talep değerini ifade etmektedir. Gizli katmanda ise 3 nöron kullanılmıştır. Öğrenme katsayısı 0,1 ve momentum katsayısı 0,9 olarak belirlenmiştir. “Fitnet” ve “train” fonksiyonları kullanılarak öğrenme gerçekleştirilmiş ve daha sonra “sim” fonksiyonu ile eğitilmiş veriler kullanılarak tahmin yapılmıştır. “Data Division” olarak “Random”, “Training” olarak “Levenberg-marquardt” ve “Performance” olarak “Mean Squared Error” kullanılmıştır. Diğer parametreler için varsayılan değerler kullanılmıştır.

ÇKA yöntemine göre hesaplanmış bir ürün için 80 günlük test verisinin gerçekleşen talepler ile tahmini talep değerleri Tablo 2’de eğitim verisi ve test verisine ait talep zaman

grafiği ise Şekil 10'da yer almaktadır. Grafikte kırmızı çizgiler gerçekleşen talebi, mavi çizgi ise tahmin değerlerini ifade etmektedir.



Şekil 10:
ÇKA Yöntemine Göre Bir Ürünün Talep Zaman Grafiği (Gerçekleşen ve Tahmini Talep)

Tablo 2:

ÇKA Yöntemine Göre Gerçekleşen ve Tahmin Edilen Talep Değerleri

Gün	Gerçekleşen	ÇKA	Gün	Gerçekleşen	ÇKA	Gün	Gerçekleşen	ÇKA	Gün	Gerçekleşen	ÇKA
1	1	1,6698	21	0	0,1415	41	0	0,0000	61	2	1,6698
2	0	0,3094	22	1	1,6698	42	0	0,0000	62	0	0,1516
3	0	0,0212	23	0	0,3094	43	1	1,6698	63	0	0,0212
4	2	1,6698	24	0	0,0212	44	1	1,6305	64	0	0,0000
5	0	0,1516	25	0	0,0000	45	0	0,3094	65	0	0,0000
6	0	0,0212	26	0	0,0000	46	0	0,0212	66	0	0,0000
7	0	0,0000	27	1	1,6698	47	0	0,0000	67	0	0,0000
8	0	0,0000	28	0	0,3094	48	0	0,0000	68	0	0,0000
9	0	0,0000	29	0	0,0212	49	0	0,0000	69	0	0,0000
10	1	1,6698	30	0	0,0000	50	0	0,0000	70	0	0,0000
11	0	0,3094	31	1	1,6698	51	2	1,6698	71	0	0,0000
12	0	0,0212	32	1	1,6305	52	0	0,1516	72	0	0,0000
13	0	0,0000	33	0	0,3094	53	0	0,0212	73	2	1,6698
14	1	1,6698	34	1	1,6698	54	0	0,0000	74	1	1,9349
15	1	1,6305	35	0	0,3094	55	1	1,6698	75	1	1,6305
16	0	0,3094	36	1	1,6698	56	0	0,3094	76	0	0,3094
17	0	0,0212	37	0	0,3094	57	0	0,0212	77	0	0,0212
18	0	0,0000	38	0	0,0212	58	0	0,0000	78	1	1,6698
19	0	0,0000	39	0	0,0000	59	0	0,0000	79	0	0,3094
20	3	1,6698	40	0	0,0000	60	0	0,0000	80	0	0,0212

e. Uygulanan yöntemlerin tahmin performans sonuçları

Tahminlerin doğruluğu ve kontrol edilmesi talep tahmini süreci için oldukça önemlidir. Bu sebeple tahmini yapacak kişiler tahmin hatalarının olabildiğince minimum seviyede olmasını isterler. Gerçek dünya değişkenlerinin karmaşık tabiatı gereği gelecek değerleri düzgün bir şekilde tahmin etmek neredeyse imkânsızdır. Tüm değişkenler dikkate alınsa bile rastgele gerçekleşen değişiklikler söz konusu olabilir.

Tahmin hatası, belirli bir zaman dilimi için tahmin edilen değer ile gerçekleşen değer arasındaki farktır. Tahmin doğruluğunun saptanabilmesi için bir takım ölçütler kullanılmaktadır (Nahmias, 2013: 61). Yapay sinir ağlarıyla yapılan talep tahminin doğruluğunun ölçümü için aralıklı talep tahmini literatüründe sıklıkla kullanılan MSE, MAD, RMSE, sMAPE ve MASE ölçütleri hesaplanmıştır.

i) Ortalama hataların karesi (MSE)

Tahmin hatalarının belirlenmesinde en yaygın olarak kullanılan ölçüt Ortalama Hataların Karesi (MSE)' dir. Ortalama Hataların Karesi (MSE) aşağıdaki şekilde hesaplanmaktadır (Nahmias, 2013: 61).

t dönemi için tahmin hatası e_t , t dönemi için tahmin değeri F_t ve t dönemi için gerçekleşen değer D_t olması durumunda tahmin hatası 18 numaralı denklemde yer almaktadır.

$$e_t = D_t - F_t \quad (18)$$

n dönemde gerçekleşen tahmin hataları e_1, e_2, \dots, e_n olması durumunda ortalama hataların karesi (MSE) :

$$MSE = (1/n) \sum_{i=1}^n e_i^2 \quad (19)$$

ii) Ortalama mutlak sapma (MAD)

Tahmin hatalarının belirlenmesinde yaygın olarak kullanılan bir diğer ölçüt ise Ortalama Mutlak Sapma (MAD)' dir. MAD hesaplaması en kolay fakat hataları doğrusal olarak değerlendiren bir ölçüttür (Stevenson, 2009: 76).

Ortalama Mutlak Sapma (MAD) aşağıdaki şekilde hesaplanmaktadır (Nahmias, 2013: 61).

$$MAD = (1/n) \sum_{i=1}^n |e_i| \quad (20)$$

iii) Ortalama hata kareleri karekökü (RMSE)

Ortalama Hata Kareleri Karekökü (RMSE) basit bir şekilde ifade edilecek olursa Ortalama Hataların Karesinin (MSE) karekökünün alınmasıdır. Tahmin hatalarının büyüklüğünü tanımladığı için diğer doğruluk ölçütlerine göre birçok uygulayıcı tarafından tercih edilmektedir. Ortalama Hata Kareleri Karekökü (RMSE) ise aşağıdaki şekilde hesaplanır (Hyndman ve Koehler, 2006: 682).

$$RMSE = \sqrt{(1/n) \sum_{i=1}^n e_i^2} \quad (21)$$

iv) Simetrik ortalama mutlak yüzde hata (sMAPE)

Ortalama Mutlak Yüzde Hata (MAPE) gibi zaman serileri ilgili doğruluk ölçütleri çoğu zaman diliminde talep değeri sıfır olan aralıklı talep tahmininde kullanılamamaktadır. Bu durumda Simetrik Ortalama Mutlak Yüzde Hata (sMAPE) hesaplanır (Syntetos ve Boylan, 2005: 307).

Böyle bir durumda sMAPE ölçütünün kullanılmasının iki nedeni vardır. Birincisi talep değeri sıfıra yakın ve tahmin değeri taleple karşılaştırıldığında daha büyük ise yüzdesel

hatanın büyümeyecek olmasıdır. İkinci neden ise hatanın simetrisidir. Talep değerinin tahmin değerinden daha büyük olması ya da aksi durumu önemli değildir, hata yine aynı kalacaktır (Wallström ve Segerstedt, 2010: 628).

Simetrik Ortalama Mutlak Yüzde Hata (sMAPE) aşağıdaki şekilde hesaplanmaktadır.

$$sMAPE = (1/n) \sum_{i=1}^n \frac{|D_i - F_i|}{(|D_i + F_i|)/2} \times 100 \quad (22)$$

v) Ortalama mutlak ölçekli hata (MASE)

Hyndman ve Koehler (2006) aralıklı talebe sahip ürünlerin talep tahmininde tahmin doğruluğunun ölçülebilmesi için Ortalama Mutlak Ölçekli Hata (MASE) olarak bilinen yeni bir ölçüt önermişlerdir. Farklı ölçeklere sahip, sıfıra yakın ya da negatif verilerin bulunduğu durumlarda Ortalama Mutlak Ölçekli Hatanın (MASE) tahmin doğruluğunun ölçülmesinde en iyi ölçüt olduğunu öne sürmüşlerdir.

Ortalama Mutlak Ölçekli Hata (MASE) aşağıdaki şekilde hesaplanmaktadır (Hyndman ve Koehler, 2006: 685).

$$MASE = \text{ortalama}(|q_t|) \quad (23)$$


$$q_t = e_t / \frac{1}{n-1} \sum_{i=2}^n |D_i - D_{i-1}| \quad (24)$$

Bu hata ölçütü zaman serileriyle ilgili diğer ölçütlerde hesaplamadan doğan sıfır ve sonsuz hata olasılığını minimize etmektedir (Kourentzes, 2013: 202).

Bütün bu ölçütler göz önünde bulundurularak ÇKA ve Croston yöntemleri karşılaştırıldığında tahmin hatasının en düşük olduğu yöntemin ÇKA yöntemi olduğu görülmektedir. Tablo 3'de iki yöntemin MSE, MAD, RMSE, sMAPE ve MASE ölçütlerinden aldıkları değerler ve Şekil 11'de ise yöntemlerin bu hata ölçütlerine göre karşılaştırılma grafiği yer almaktadır.

Tablo 3 :
Yöntemlerin Hata Ölçütlerine Göre Karşılaştırılması

Yöntem	MSE	RMSE	MASE	MAD	sMAPE
ÇKA	0,97115	0,828	0,49046	0,51477	1,23699
Croston	1,5342	1,1553	0,9256	0,9388	1,2689



Şekil 11:
Yöntemlerin Hata Ölçütlerine Göre Karşılaştırılma Grafiği

5. Sonuç ve Öneriler

Talep tahmini ve planlama bir işletmenin başarısını doğrudan etkilediği için büyük önem taşımaktadır. Düzenli talep yapısına sahip ürünlerin talep tahmininde klasik yöntemler başarılı sonuçlar verirken çoğu zaman döneminde rastgele gerçekleşen ve talebi sıfır olan aralıklı talep yapısına sahip ürünlerin talep tahmininde bu yöntemler yetersiz kalmaktadır ve iyi sonuçlar vermemektedir. Aralıklı talep yapısına sahip ürünlerin talep büyüklüğü ve şeklinin değişikliği tahmin ve planlama yapılmasını zorlaştırmaktadır. Bu zorluğun üstesinden gelebilmek için Croston (1972) özellikle aralıklı talebe sahip ürünler için bir tahmin yöntemi geliştirmiş daha sonra bu yöntem Syntetos ve Boylan ile Leven ve Segerstedt tarafından değişikliğe uğratılarak farklı modifikasyonları ortaya çıkmıştır. Yapılan çalışmalarda bu yöntemlerin basit üstel düzeltme yöntemiyle karşılaştırıldığı görülmektedir. Fakat bu yöntemlerin de çok iyi sonuçlar vermediği görülmüş ve son zamanlarda daha gelişmiş makine öğrenme yöntemleriyle çalışmalar yapılmıştır.

Bu çalışmada e-ticaret sektöründe faaliyet gösteren bir işletmenin aralıklı talep yapısına sahip ürünlerinin talep tahmininde; Croston yöntemi bir yapay sinir ağı modeli olan Çok Katmanlı Algılayıcılar kullanılarak talep tahmini yapılmıştır. Daha sonra bu yöntemlerin

hataları karşılaştırılarak performansları incelenmiştir. Daha sonra elde edilen sonuçlar MSE, RMSE, MASE, MAD ve sMAPE hata ölçütleri göz önünde bulundurularak karşılaştırılmıştır. Bu karşılaştırma sonucunda en düşük hatayı Çok Katmanlı Algılayıcılar yönteminin verdiği görülmektedir. Bu çalışmasında talep tahmini yapılırken talebi etkileyen diğer faktörler (fiyat, rekabet, kampanya vb.) dikkate alınmamıştır. Daha sonraki çalışmalarda bu faktörleri de göz önünde bulundurularak ve parametre optimizasyonu yapılarak tahmin hatası iyileştirilebilir.

KAYNAKÇA

Altay, Nezh, Frank Rudisill ve Lewis A. Litteral (2008) "Adapting Wright's Modification of Holt's Method to Forecasting Intermittent Demand", *International Journal of Production Economics*, 111(2), s.389-408.

Alpaydın, Ethem (2012) *Yapay Öğrenme*, 2. Baskı, **İstanbul**: Boğaziçi Üniversitesi.

Akay, Diyar ve Mehmet Atak (2007) "Grey Prediction with Rolling Mechanism for Electricity Demand Forecasting of Turkey", *Energy*, 32(9), s.1670-1675.

Babai, Mohamed Z., Mohammad M. Ali ve Konstantinos Nikolopoulos (2012) "Impact of Temporal Aggregation on Stock Control Performance of Intermittent Demand Estimators: Empirical Analysis", *Omega*, 40(6), s.713-721.

Bao, Yukun, Wen Wang ve Jinlang Zhang (2004) "Forecasting Intermittent Demand by SVMs Regression", *IEEE International Conference on Systems Man and Cybernetics*, s.461-465.

Basheer, Imad ve Maha Hajmeer (2000) "Artificial Neural Networks: Fundamentals, Computing, Design and Application", *Journal of Microbiological Methods*, 43(1), s.3-31.

Babiloni, Eugenia, Manuel Cardos, Jose M. Albarracin ve Marta E. Palmer (2010) "Demand Categorisation, Forecasting and Inventory Control for Intermittent Demand", *South African Journal of Industrial Engineering*, 21(2), s.115-130.

Bishop, Christopher M. (1995) *Neural Networks for Pattern Recognition*, Oxford: Clarendon.

Boylan, John E. ve Aris A. Syntetos (2007) "The Accuracy of a Modified Croston Procedure", *International Journal of Production Economics*, 107(2), s.511-517.

Croston, J. D. (1972) "Forecasting and Stock Control for Intermittent Demand", *Journal of the Operational Research Society*, 23(3), s.289-303.

Eaves, Andrew H. ve Brian G. Kingsman (2004) "Forecasting for the Ordering and Stock-holding of Spare Parts", *Journal of the Operational Research Society*, 55(4), s.431-437.

Efron, Bradley (1979) "Bootsrap Method: Another Look at the Jackknife", *Annals of Statistics*, 7(1), s.1-26.

Elmas, Çetin (2010) *Yapay Zekâ Uygulamaları*, Ankara: Seçkin.

Ghobbar, Adel A. ve Chris H. Friend (2003) "Evaluation of Forecasting Methods for Intermittent Parts Demand in the Field of Aviation: A Predictive Model", *Computers & Operations Research*, 30(14), s.2097-2114.

Ghobbar, Adel A. ve Chris H. Friend (2002) "Sources of Intermittent Demand for Aircraft Spare Parts within Airline Operations", *Journal of Air Transport Management*, 8(4), s.221-231.

Gutierrez, Rafael S., Adriano O. Solis ve Somnath Mukhopadhyay (2008) "Lumpy Demand Forecasting Using Neural Networks", *International Journal of Production Economics*, 111(2), s.409-420.

Hassoun, Mohamad (1995) *Fundamentals of Artificial Neural Networks*, New York: MIT.

Haykin, Simon (1999) *Neural Networks: A Comprehensive Foundation*, 2. Baskı, Singapur: Prentice Hall.

Heaton, Jeff (2008) *Introduction to Neural Networks for C*, Chesterfield: Heaton Research.

Hua, Zhangsheng, Bin Zhang, Jie Yang ve D.S.Tan (2007) "A New Approach of Forecasting Intermittent Demand for Spare Parts Inventories in the Process Industries", *Journal of the Operational Research Society*, 58(1), s.52-61.

Hua, Zhangsheng ve Bin Zhang, (2006) "A Hybrid Support Vector Machines and Logistics Regression Approach for Forecasting Intermittent Demand of Spare Parts", *Applied Mathematics and Computation*, 181(2), s.1035-1048.

Hyndman, Rob J. ve Anne B. Koehler (2006) "Another Look at Measures of Forecast Accuracy", *International Journal of Forecasting*, 22(4), s.679-688.

Johnston, F. Roy, John E. Boylan ve Estelle A. Shale (2003) "An Examination of the Size of Orders from Customers, Their Characterisation and the Implications for Inventory Control of Slow Moving Items", *The Journal Of The Operational Research Society*, 54(8), s.833-837.

Kasabov, Nikola K. (1996) *Foundations of Neural Networks, Fuzzy Systems and Knowledge Engineering*, London: MIT.

Kourentzes, Nikolaos (2013) "Intermittent Demand Forecasts with Neural Networks", *International Journal of Production Economics*, 143(1), s.198-206.

Kostenko, Audrey V. ve Rob J. Hyndman (2006) "Viewpoint - A Note on the Demand Categorization of Demand Pattern", *Journal of the Operational Research Society*, 57(10), s.1256-1258.

Krenker, Andrej, Janez Bester ve Andrej Kos (2011) "Introduction To Artificial Neural Networks", *Artificial Neural Networks-Methodological Advances and Biomedical Applications* içinde (der. K. Suzuki), InTech, s.3-19.

Kriesel, David (2015) *A Brief Introduction to Neural Networks*, <http://goo.gl/CpZ0QV>, Erişim Tarihi: 27 Aralık 2015.

Levén, Erik ve Anders Segerstedt (2004) "Inventory Control with a Modified Croston Procedure and Erlang Distribution", *International Journal of Production Economics*, 90(3), s.361-367.

Marsland, Simon (2009) *Machine Learning: An Algorithmic Perspective*, USA: A Chapman & Hall Book CRC.

Mitchell, Tom M. (1997) *Machine Learning*, New York: MacGraw Hill.

Nahmias, Steven (2013) *Production & Operations Analysis*, 6. Baskı, New York: McGraw Hill Education.

Nikolopoulos, Konstantinos, Aris A. Syntetos, John E. Boylan, Fotios Petropoulos ve Vassilis Assimakopoulos (2010) "An Aggregate-Disaggregate Intermittent Demand Approach (ADIDA) to Forecasting: An Empirical Proposition and Analysis", *Journal of the Operational Research Society*, 62(3), s.544-554.

Öztemel, Ercan (2012) *Yapay Sinir Ağları*, 3. Baskı, İstanbul:Papatya.

Regattieri, Alberto, Mauro Gamberi, Rita Gamberini ve Riccardo Manzini (2005) "Managing Lumpy Demand for Aircraft Spare Parts", *Journal of Air Transport Management*, 11(6), s.426-431.

Syntetos, Aris A. ve John E. Boylan (2001) "On the Bias of Intermittent Demand Estimates", *International Journal of Production Economics*, 71(1-3), s.457-466.

Syntetos, Aris A. ve John E. Boylan (2005) "The Accuracy of Intermittent Demand Estimates", *International Journal of Forecasting*, 21(2), s.303-314.

Shenstone, Lydia ve Rob J. Hyndman (2005) "Stochastic Models Underlying Croston's Method for Intermittent Demand Forecasting", *Journal of Forecasting*, 24(6), s.389-402.

Teunter, Ruud ve Babangida Sani (2009) "On the Bias of Croston's Forecasting Method", *Journal of Operational Research*, 194(1), s.177-183.

Varghese, Vijith ve Manuel Rossetti (2008) "A Classification Approach for Selecting Forecasting Techniques for Intermittent Demand", *IIE Annual Conference Proceedings* içinde, ABD: Institute of Industrial Engineers-Publisher, s.863.

Wali, Akhil (2014) *Clojure for Machine Learning*, Birmingham: Packt.

Wallström, Peter ve Anders Segerstedt (2010) "Evaluation of Forecasting Error Measurements and Techniques for Intermittent Demand", *International Journal of Production Economics*, 128(2), s.625-636.

Willemain, Thomas R., Charles N. Smart ve Henry F. Schwarz (2004) "A New Approach to Forecasting Intermittent Demand for Service Parts Inventories", *International Journal of Forecasting*, 20(3), s.375-387.

Willemain, Thomas R., Charles N. Smart, Joseph H. Shockor ve Philip A. DeSautels (1994) "Forecasting Intermittent Demand in Manufacturing: A Comparative Evaluation of Croston's Method", *International Journal of Forecasting*, 10(4), s.529-538.

Yegnanarayana, Bayya (2005) *Artificial Neural Network*, Eastern Economy Edition, Yeni Delhi: Prentice-Hall of India.

Zupan, Jure (1994) "Introduction to Artificial Neural Network Methods: What They Are and How to Use Them.", *Acta Chimica Slovenica*, 41(3), s.327-352.