

PAPER DETAILS

TITLE: Yapay Sinir Aglari ile Talep Tahmini Yapma: Beyaz Esya Üretim Planlama Örneđi

AUTHORS: Emre TÜRK,Farzad KIANI

PAGES: 30-37

ORIGINAL PDF URL: <https://dergipark.org.tr/tr/download/article-file/669380>



Yapay Sinir Ağları ile Talep Tahmini Yapma: Beyaz Eşya Üretim Planlaması için YSA Uygulaması

Emre TÜRK*, Farzad KIANI

Istanbul Sabahattin Zaim Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Bilgisayar Mühendisliği Bölümü, Halkalı, Cad. No:2, 34303 İstanbul, Türkiye

YAYIN BİLGİSİ

Yayın geçmişi:

Gönderilen tarih: 11 Ocak 2019

Kabul tarihi: 12 Mart 2019

Anahtar kelimeler:

üretim planlama

yapay sinir ağları

makine öğrenmesi

ÖZET

Üretim planlama için doğru bir talep tahmininin yapılması oldukça önemli bir parametredir. Müşterilerin gelecekteki talep eğilimleri, piyasa durumu ve mevsimsellik gibi birçok faktörden etkilenebilir. Üretim planlama, işletmelerin hedefleri doğrultusunda üretim politikaları, üretim programları ve üretimle ilgili süreçlerin planlanmasıdır. Doğru bir talep tahmini yapmak oldukça kritik bir öneme sahip olup kaynakların daha verimli kullanılmasına olanak sağlayabilecektir. Talep tahmin metotları, kantitatif ve kalitatif olarak iki ana başlık altında toplanır. Kantitatif tahmin metodu, insanların kendi tecrübelerinden oluşan bilgiye dayanak olarak tahmin yapma yöntemidir. Kalitatif metot ise, sayısal verilerin matematiksel modellemelerle desteklenerek ortaya çıkan sonuçlara dayanarak tahmin yapma yöntemidir. Yapay sinir ağları modeli kantitatif tahmin metotlarının arasında yer alır. Bu çerçevede, makine öğrenme yöntemleri özellikle destek vektör makinesi, en yakın n-komşu, regresyon ve yapay sinir ağları ve bayes ağları gibi metotlar ve algoritmaların kullanılması uygun olabilir. Bu makalede yapay sinir ağları metodu kullanılarak talep tahmini problemi minimum hatayı veren sinir ağlarıyla çözülmüştür. Yapay sinir ağları metodu, belirli değişkenlere bağlı olan bir talep tahminini önceki örneklerin verileriyle yapay sinir ağlarının öğretilmesiyle ileriye dönük doğru talep tahmini yapması hedeflenmektedir.

ABSTRACT

Demand forecasting represents an important part of production planning because it can estimate the future demand of products and services and the amount of resources that needs to be allocated in order to accomplish that demand. As the demands can vary as the times passes, the production plan must be able to face those variations. Demand estimation methods are classified under two main headings: quantitative and qualitative. The quantitative estimation method is a method of estimating the basis of knowledge of people's own experiences. The qualitative method is the method of estimating the numerical data based on the results obtained by supporting the mathematical modeling. Artificial neural network model is among quantitative estimation methods. Therefore, it may be appropriate to use methods and algorithms such as machine learning methods, especially support vector machine, nearest n-neighbor, regression and artificial neural networks and Bayesian networks. In this paper, we focus on the mining of the time series formed by all the past results using an artificial neural network-based simulation system that is able to identify an appropriate production forecast. The results of the production simulations are used as historical data in order to forecast the future demands and the amount of time needed to satisfy them. The time series forecast results show that data mining can be used in this domain in order to extract patterns that can be used to optimize the production process.

*Sorumlu yazar:.


E-mail: turk.emre@std.izu.edu.tr

1. Giriş

Üretim, insanların yaşamlarını sürdürecektir gereksinimlerinin karşılanması ve toplumun gelişmesi için doğada ortaya çıkan maddi ve beşerî faktörlerin emek ve sermaye sarf edilerek iktisadi değeri olan ürün ve hizmetlere dönüştürülmesidir. Üretilen malın istenilen miktar, kalite, zaman ve maliyet açısından en optimal değerlerinin bulunması işlemi ise üretim yönetimidir. Üretim yönetiminin rekabetin aşırı olduğu bir dünyada önemi çok büyüktür. Çünkü karar verme süreçlerinde hızlı ve doğru karar alabilmek için üretimin yönetiminin en önemli fonksiyonlarından biri olan üretim planlamasına ihtiyaç duyulmaktadır.

Üretim planlama, işletmelerin hedefleri doğrultusunda üretim politikaları, üretim programları ve üretimle ilgili süreçlerin planlanmasıdır. Planlama, üretimi yapılacak malın tüketici talep durumunu göz önünde bulundurularak fiyat, kalite ve ürün miktarları gibi bilgiler toplanır ve değerlendirilir. Tüketici taleplerindeki değişiklikler izlenerek, taleplere uygun üretim planlaması yapılmalıdır. Planlamanın amacı önceden belirlenen hedeflere ulaşılması olduğundan mevcut satış verilerinden yararlanılarak, ürün için bir talep tahmininin yapılması ve üretim için ayrılacak kaynakların en uygun (optimal) şekilde değerlendirilmesi gerekir. Bundan dolayı üretim planlamasının önemli bir adımı olan ürüne ait talep tahminlerinin yapılmasıdır. Talep tahminlerinin doğruluğu işletmelerin hedeflerine ulaşmasında kritik rol oynar, bu tahminler bilimsel çalışmalara dayandırılmalıdır. (Karahan, 2011).

Talep tahmin metotları, kantitatif ve kalitatif olarak iki ana başlık altında toplanır. Kantitatif tahmin metodu, insanların kendi tecrübelerinden oluşan bilgiye dayanak olarak tahmin yapma yöntemidir. Kalitatif metot ise, sayısal verilerin matematiksel modellerle desteklenerek ortaya çıkan sonuçlara dayanarak tahmin yapma yöntemidir. Yapay Sinir Ağları (YSA) modeli kantitatif tahmin metotlarının arasında yer alır. Bu ağlar, insan beynini mimik ederek öğrenme işlemini gerçekleştirebilir, ayrıca, öğrendiklerini hatırlayarak sonraki faaliyetlerinde ve kararlarında eski tecrübeler ve öğrendiklerinden yararlanabilirler. Beynin hücreleri ve nöronlardan oluşan bu ağların yapısı bir nevi modern bilgisayarın orta çıkmasından daha da eski olduğu anlaşılmaktadır. Bu ağlara dayalı önerilen algoritmalar da bu temel kavram üzerinden ortaya çıkmıştır. Söylenmesi gereken başka bir konu, bu algoritmalar farklı alanlardaki yöntemler ile melez bir mekanizma halinde de çalışabilir ve çeşitli problemlerin çözümlerinde yararlı olabilir. Bu ağlar, tek nöronlardan da oluşabilir kaç katmanlı yapıdan da. Her bir nöron girdileri, eşik değerleri, hafızası ve çıktı parametrelerine sahiptir. Ayrıca, farklı modellerde mimariye sahip olabilirler, örneğin çok katmanlı geri beslemeli modelde (şekil 1.) her katmanda birden fazla nörona birden çok girdi girebilir. Bu nöronların sonuçları bir sonraki katmanda bulunan nöronların girdisi olarak değerlendirilir ve bu işlem son katmandaki nöronlardan oluşacak sonuçlara kadar devam eder. Ortaya çıkan son sonuç/sonuçlar beklenen cevaptan uzaksa geri beslemeli olarak ilk katmana kadar geri döner. Bu çalışmada da bu YSA modeli kullanılmıştır.



Şekil 1. Çok Katmanlı Yapay Sinir Ağ Modeli (Karaatlı vd., 2012).

Her girdinin ağırlıkları vardır ve bunlar problemin çözümüne yönelik güncellenmektedirler. Ağırlıkların büyük ya da küçük olması önemli veya önemsiz olduğu anlamına gelmez ancak bu değerlerin sıfır olması ilgili YSA için önemli bir event olabilir. YSA’larda ayrıca, toplama fonksiyonu vardır. Bu fonksiyon, bir nörona gelen net girdiyi hesaplamak için kullanılmaktadır. Probleme göre çeşitli ve farklı mekanizmalar ile bu fonksiyon tanımlanabilir. Diğer fonksiyon ise aktivasyon isimli bir fonksiyondur. Bu, genelde doğrusal olmayan bir fonksiyon seçer (Kabalcı, 2014). ve aldığı net girdiye göre çıktıyı hesaplar. Bu fonksiyon seçiminde türevlerinin kolay bir şekilde hesaplanması esas alınmalıdır. Bu makalede kullanılan çok katmanlı geri beslemeli modelde, bu fonksiyon için sigmoid fonksiyonu kullanılmıştır. Bir proses elemanının birden fazla çıktısı olmasına rağmen sadece bir çıktı olabilir (Karaatlı vd., 2012). YSA’ından beklentiler genelde kabul edilir düzeyde hata payları olmaları, hatalara toleranslı olmaları ve farklı uygulamaların yapılarına göre kolayca uyumlu bir şekilde çalışıp cevaplar üretmesidir (Karahan, 2011). Not olarak da, ağırlık güncelleme işlemlerinde ve hatta özellikler belirlemede sezgisel yöntemleri ve optimizasyon algoritmalarından da faydalanmak mümkündür.

Uzun süreli çalışmaların sonucunda bilgisayar ortamında insan beynin modellenmesi, insan beyninin sezgi ve deneyime dayalı tahmin yeteneğinin bilgisayar ortamına aktarılması, yapay zekâ modelini ortaya çıkarmış ve tahmin araçları arasında yerini almıştır. Beynin çalışma sistemini örnek olarak geliştirilen yapay sinir ağları, önceki verileri analiz ederek girdi ile çıktı arasında doğrusal olmayan ilişkileri tespit etmede kullanılır. (Ömürbek, vd., 2012).

Yapay sinir ağları, insan beyninin bilişsel öğrenme süreçlerini bilgisayar programlarıyla simüle edilmesi sonucunda tahminleme, sınıflandırma ve kümeleme gibi birçok doğrusal olmayan problemlere çözüm bulabilmektedir. Bundan dolayı, doğrusal olmayan veri modellemedeki üstün performansından ve optimizasyon, tahmin ve karar verme alanındaki geniş kapsamlı potansiyel uygulamalardan dolayı büyük ilgi görmüştür. Yapay sinir ağları ile ilgili ilk çalışmalar, 1940’ların başında Culloch ve Pitts’in, 1943 yıllarında yayınladıkları makalelerle başlamıştır. Bu ilk çalışmalar beyin hücreleri olan nöronların fonksiyonlarını ve birbirleri ile


haberleşmelerini ortaya çıkarmıştır. Sonraki yıllarda bir ağ içerisindeki uyarılara tepki veren bir model oluşturuldu. İlk sinirsel bilgisayar 1960 yılında ortaya çıkmıştır. 1970 ve 1980’lerde başarılı sonuçların elde edilmesiyle 1985’ten sonra yapay sinir ağları üzerine yoğun çalışmalar başlamıştır. (Efendigil, vd., 2009)

Talep tahmini, üretim planlaması, yapay sinir ağlarına yönelik literatürde birçok araştırma bulunmaktadır. Bu çalışmaların ilki olarak, (Marco Garetti & Marco Taisch, 1999) yapay sinir ağları uygulamalarını kullanarak üretim planlama ve kontrol problemlerine çözüm üretmiştir. Mehmet (Karahana, 2010) çalışmasında yapay sinir ağları modelini, Malatya ili baz alınarak kuru kayısı ürününe ait yurt dışı talep tahmini incelemiştir. Yapay sinir ağları modelinin sonuçları hata testlerinin yapılmasıyla, modelin tutarlılığını ve güvenilirliğini ortaya çıkarmıştır (Sevinçtekin, 2014) tez çalışmasında yapay sinir ağları metodu ile makine imalatı yapan bir firmanın satışları piyasa ve mevsime göre değişkenlik gösteren talep tahmini YSA uygulaması ile yapılmıştır. (Ömürbek vd., 2012) makalesinde yapay sinir ağları yöntemi ile otomobil satış miktarlarını kullanarak doğru talep tahminleri yapılmıştır. Otomotiv sektöründe daha doğru ve en uygun politikaların belirlenmesine katkı sağlamışlardır. (Koç ve Esnaf, 2015) makale çalışmasında 2004-2013 temel verilerini kullanarak 2023 mobilya talebini yapay sinir ağları ve regresyon analizi yöntemi ile talep tahmini gerçekleştirmiştir. İki modelin ortaya koyduğu sonuçların değerlendirilmesiyle yapay sinir ağları modelinin çok daha doğru sonuçlar verdiği açığa çıkmıştır. 2017’de Melih Yücesan, Muhammet Gül, Erkan Çelik çalışmalarında yapay

sinir ağı tahmin modeli ile MATLAB kullanılarak Türkiye Karadeniz bölgesinde bulunan bir mobilya üreticisinin toplam aylık satış verilerini işlemiştir. Bu yöntem yapay sinir ağlarının bir bileşeni olan Bayes Ağlarıdır (Bayesian regularization). Performans ölçümlerinin sonuçları Bayes kurallarına dayalı eğitime(training) YSA modeli kullanılarak gözlenen mobilya fabrikasının aylık satışların tahmini için uygulanabilir bir seçenek olduğunu göstermektedir. (Sevinçtekin, 2014).

2. Üretim Planlaması ve Kontrolü

Üretim yönetim fonksiyonlarının aşamalarından biri olan üretim planlaması, işletmelerin üretim hedeflerini dikkate alarak, üretim politikalarının, üretim programlarının ve üretimle ilgili süreçlerin gerekli planlama çalışmaları yapılır. Planlama sürecinde, üretim planlaması, iş gücü, malzeme ihtiyacı(MRP), üretim metotları, üretimin mali planlaması ve üretim sistemleri gibi birçok planlama talep tahminleri dikkate alınarak yapılır. İşletmelerin temel hedeflerinden biri de eldeki kaynakların verimli kullanılmasıdır. Kaynakların verimli kullanılması, üretim kontrolünün etkili olmasıyla ilişkilidir. Üretim planlaması ve kontrolü, üretimde verimlilik hedefine ulaşmak için üretim süreçlerinin koordinasyonunu sağlayan bir araçtır. Üretim planlama ve kontrol fonksiyonunda gerçekleştirilmesi gereken faaliyetler şekil 2’de gösterilmiştir. Bir işletmede koordine edilmesi ve yönetilmesi gereken üretim planlama ve kontrol süreçlerinin bütünüdür.



Şekil 2. Üretim Planlama ve Kontrol Fonksiyonu Faaliyetleri


Birinci aşamada, kaynak planlaması ve talep tahmini dikkate alınarak üretim planı ve ana üretim çizelgesi ortaya koyuluyor. İkinci aşamada, stok durumları ve malzeme ve kapasite bilgileri baz alınarak malzeme ihtiyaç planlaması (MRP) yapılıyor. Son aşamada ise, ana üretim çizelgesine göre MRP yapıldıktan sonra gerekli iş emirleri veya satın alma emirleri veriliyor. Üretim konusunda minimum stok maliyet hedeflerine ulaşmak, müşteri taleplerine zamanında karşılık vermek için üretim planlarının önceden hazırlanması gerekmektedir. Üretim planlamasında ön planlama yaparak, üretilecek ürünün miktarının belirlenmesi ilk aşamadır. Bunun

için üretimi yapılacak ürünün talep tahminin yapılması gerekir çünkü üretim planlama aşamasında hammadde, yarı mamul, makine ve insan gücü gibi parametrelerin belirlenmelidir. Kaynak planlama, işletmenin üretimi yapılacak olan ürüne ait kaynak kapasitesini uzun vadeli olarak planlama faaliyetidir. Üretim planı oluşturulduktan sonra, kaynak planlaması elde bulunan insan gücü, makine teçhizat, çalışma saatleri, sermaye, depo vb. gibi hazır kaynaklar değerlendirilir ve gelecekteki üretim için hazırlık yapılır. (Garetti, vd., 1999).

3. Talep Tahmini ve Yöntemleri

Talep, tüketicilerin bir mal veya hizmeti belli bir fiyat seviyesinde birim zamana düşen satın alma isteklerinin ölçüsüdür. Tahmin, bilinmeyen parametrenin değerinin, bilinen parametreler kullanılarak, gelecekteki durumunun kestirilmesidir. İşletmeler hedefleri doğrultusunda, piyasa talebini karşılamak için mal ve hizmet sağlarlar ve bunun için pazarlama araştırması yapar piyasa talebini ölçerek tahmin edilen bu talebi karşılamak için üretim planlamasını ve sistemlerini düzenlerler. Talep tahmini, işletmelerin üretmiş veya üretecek olduğu mal ve hizmete tüketicilerin ileride ne


kadar talep yapacaklarını bilinen parametreler yardımıyla tahmin edilmesidir. Tahmin metodları, kantitatif ve kalitatif olarak iki ana sınıfa ayrılabiliriz. Kalitatif yöntem türleri kişinin düşüncelerine bağlı bir yöntem olup, kantitatif yöntemler ise matematiksel modellere dayanan, yeterli sayıda verinin mevcut olduğu durumlarda kullanılır. Esnaf, vd (2014). Talep tahmin yöntemleri özet olarak Şekil 3’de sunulmuştur.



Şekil 3. Talep Tahmin Yöntemleri

3.1 Regresyon Analizi

Regresyon analizi, aralarında sebep sonuç ilişkisi bulunan bir bağımlı değişkenin bir veya daha fazla bağımsız değişken arasındaki ilişkiyi belirlemek ve tahminlerde bulunmak için bir fonksiyon şeklinde yazılmasıdır. Regresyon denklemi ile bağımlı ve bağımsız değişkenler arasındaki ilişkiyi kuran parametrelerin değeri tahmin edilir ve doğru bir regresyon katsayı ile güvenilir tahminler yapmak mümkündür. Regresyon analizinde, belli aralıktaki geçmiş sezon ve dönemlerin verileri kullanılarak formül geliştirilir. Geçmiş veriler ne kadar düzenli ve sürekli ise tahminlerin tutarlılığı o kadar yüksektir. Ancak, bağımsız değişken değerleri düzensiz ve farklılık gösteriyorsa, tahmin hatası da fazla olacaktır. İki değişkenin arasındaki ilişkinin doğrusal olduğunu varsayarsak, denklem ($Y = a + bx$) şeklinde ifade edilir ve bağımsız değişkenin değeri yerine konarak tahmin değeri elde edilir. Denklemde, a, b değerlerinin bulunması için kullanılan En Küçük Kareler (EKK) yöntemi grafiksel olarak Şekil 4’te gösterilmiştir.



Şekil 4. Regresyon Doğrusu


Şekil 4’te görüldüğü üzere, regresyon doğrusundaki bağımlı değişken değerleri ile gerçek değerler arasındaki farkın karelerinin toplamını minimum yapacak en uygun doğru bulunmaya çalışılmaktadır (Çağlar, 2007).

3.2 Yapay Sinir Ağları

Yapay zekâ, matematiksel modellemesi oluşturulamayan ve çözülmesi zor olan problemlere yönelik bilgisayarlar tarafından çözüm üretmek için kullanılan sezgisel yöntemdir. Yapay sinir ağları, insan beyninin fonksiyonları olan öğrenme, kavrama ve tecrübe edinme yolu ile yeni bilgiler ortaya çıkarma gibi özelliklerini otomatik olarak gerçekleştirmek amacıyla geliştirilen bilgisayar sistemleridir. Yapay sinir ağları sinir hücrelerinden oluşmuş katmanlı ve paralel yapısının fonksiyonlarıyla birlikte bilgisayar ortamında modellenmesidir. Bu modeller kullanılarak olayların örneklerine bakıp ilgili olay hakkında genelleme yaparak ve bilgi toplayarak daha sonra karşılaşılabilecek örnekler hakkında öğrendiği bilgileri kullanarak karar verebilmektedir. Yapay sinir ağları, paralel olarak birbirlerine bağlanmış katmanlardan oluşur. Bu katmanlar insan beynindeki sinir sistemine göre benzetilmiş bir yapıdır. Yapay sinir ağları, girdi katmanı, bir veya birden fazla gizli katman ve çıktı katmanı dahil toplam üç katmandan oluşur. Ağın fonksiyonunu bu katmanlar arasındaki bağlantılar oluşturmaktadır. Katmanların birbirleriyle bağlandıkları ağırlık değerlerinin ayarlanarak belirli bir fonksiyonun gerçekleşmesi için ağın eğitilmesi sağlanır. Böylece ağda bir girdiye karşılık bir çıktı üretilir. Bir nöron girdisi başka bir nöronun çıktısıdır. Çıktılar

sinaps bağlantılarıyla iletilir. Sinaptik bağlantı ağırlıkları sayısal değerlerle ifade edilir. Şekil 5'te bir gizli katmana sahip yapay sinir ağı mimarisi bulunmaktadır. (Efendigil, vd.,

2017).



Şekil 5. Yapay Sinir Ağı Mimarisi

Gizli katmana girdi katmanından sinyal gönderildiğinde, sinaptik ağırlık denilen bağlantı kuvvetleriyle çarpılır. x_i , i . nöronun çıktısıdır. i nöronundan x_i olarak gelen girdiler j . nöronunda bulunan ağırlıklarla çarpma işleminden geçtikten sonra w_{jxi} nöronunda bulunan işlemci eleman tarafından toplama işlemi yapılır. Aktivasyon olarak adlandırılan bu toplam nöronun iç durumunu gösterir. Eğer çıkan sonuç pozitif ise; aktive olmuş nöronu, negatif ise kapalı nöronu temsil etmektedir. Bu adımdan sonra nöron tarafından çıktının belirlenmesi için sinyal transfer fonksiyonları uygulanır. Yapay sinir ağından nöronun çıktı değeri aktivasyon fonksiyonları tarafından istenen sınır değerleri arasında tutulur. Bu aralık değerleri genellikle $[0,1]$ veya $[-1,1]$ arasındadır. Öğrenme kapasitesinin yüksekliği ve basit algoritması nedeniyle geri yayılım algoritması, birçok alanda kullanılan ve genellikle tercih edilen öğrenme algoritmasıdır. Bu algoritma gradyan azalma tekniğini kullanarak gerçek çıktı y ve istenen çıktı d arasındaki karesel hatayı minimum yapar. Hata değeri aşağıdaki gibi hesaplanır.

$$E = \frac{1}{2} [\sum_p \sum_k (d_{pk} - y_{pk})^2]^{\frac{1}{2}} \quad (1)$$

E hata kareler ortalaması (MSE), d_{pk} istenen çıktı vektörünü ve y_{pk} gerçek çıktı vektörünü temsil eder. E değeri sıfıra ne kadar yakın olursa, ağ o kadar iyi eğitilmiş demektir. (Agatonovic ve Beresford, 2000).

3.2.1 İleri Beslemeli Geri Yayılmalı Yapay Sinir Ağları (Feed Forward Back Propagation ANN)

İleri beslemeli ağlarda, işlemci hücreleri (nöronlar) katmanlar şeklinde ayrılmışlardır. Bir katmandaki hücrenin çıktıları bir sonraki katmana girdi olarak verilir. Girdi katmanı, aldığı bilgileri herhangi bir değişiklik yapmadan gizli katmanına iletir. Bilgi, gizli ve çıktı katmanında işlenerek ağ çıkışı verilir. Girdi katmanından çıktı katmanına doğru tek yönlü bir bağlantı oluşturulmuştur. Böylece işlem elemanları arasında bir döngü oluşmaz. İleri beslemeli yapay sinir ağlarda, girdi katmanı aracılığıyla girilen bilgiler bulundukları katmanlarda ağırlıkları ile hesaplanarak çıktı katmanına gönderilir ve

herhangi bir döngü oluşmadığından işlem sonucunda gecikmeler gerçekleşmez. Çıkış değerleri, öğreticiden alınan çıkış değerleriyle uyumluluğu kontrol edilir ve bir hata değeri elde edilir. Bu hata sonucuna göre ağ ağırlıkları güncellenir. İleri beslemeli geri yayılmalı ağlar, yapay sinir ağlarının en çok kullanılan ve genellikle daha iyi sonuçlar veren bir modelidir. Bu modelde bilgi geriye doğru yayılarak öğrenme sürecinde bulunan hatalar çözülür. (hamid ve Iqbal, 2004).

3.2.2 Çok Katmanlı Algılayıcılar (ÇKA)

Yapay sinir ağları yardımıyla birçok karmaşık ve doğrusal olmayan problemlere çözüm bulunabilmektedir. Problemin çözümüne göre farklı ağ modelleri kullanılmaktadır. Bu uygulamada Çok Katmanlı Algılayıcı (ÇKA) modeli kullanılmıştır. Çünkü bu ağ yapısıyla tahminleme problemlerine çözüm bulmak daha kolaydır. ÇKA modeli Rumelhart tarafından geliştirilmiştir. Bu model aynı zamanda geriye doğru hata yayma özelliği olduğundan geri yayılım ağı (backpropagation network) olarak da bilinir. Bu algoritma ara katmanlı yapay sinir ağlarında çok kullanılan bir öğrenme algoritmasıdır. (Çetin, vd., 2006).

4. Önerilen Metot Uygulaması

Bu uygulamada, 2007 yılından 2015 yılına kadar olan beyaz eşya satışına ait veriler kullanılarak Türkiye'deki toplam beyaz eşya satışları tahmin edilmiştir. Çalışmada, bağımlı ve bağımsız değişkenler olarak kullanılan veriler Türkiye İstatistik Kurumu'nun web sitesinden alınmıştır. Bu çalışmada, beyaz eşya satış miktarı (SM) bağımlı değişken olarak kullanılırken, tüketici güven endeksi (TGE), reel kesim güven endeksi (RKGE), gayri safi yurt içi hasıla (GSYH), sanayi üretim endeksi (SÜE), tüketim harcamaları (TH), hane halkı maddi durum beklentisi (HMDB), ekonomi güven endeksi (EGE) ve evlenme istatistikleri de bağımsız değişken olarak kullanılmıştır. Tablo 1'de 2007-2008 arası veriler örnek olarak gösterilmiştir.

Tablo 1. Uygulamada kullanılan 2007-2008 tarihleri arasındaki veriler.

Yıl	SM	TGE	RKGE	GSYH	SÜE	TH	EGE	HMDB	Evlenme
Ocak 07	437.322	78.6	117.0	189.593.408.03	58.66	651.338.20	112.6	95.2	36.548
Şubat 07	457.510	79.5	113.3	189.593.408.03	60.10	651.826.20	110.0	95.9	37.629
Mart 07	502.327	79.2	113.7	189.593.408.03	69.90	661.533.90	110.3	95.8	38.546
Nisan 07	401.233	80.4	115.9	212.565.694.63	65.82	665.134.10	111.5	96.6	46.221
Mayıs 07	392.002	81.7	106.8	212.565.694.63	71.46	666.185.20	106.1	97.4	55.577
Haziran 07	389.029	80.9	109.7	212.565.694.63	70.23	668.152.90	109.4	96.8	67.301
Temmuz 07	390.000	82.3	111.1	237.359.324.52	67.26	668.686.40	110.8	97.6	85.268
Ağustos 07	392.224	85.0	113.8	237.359.324.52	66.00	669.480.30	113.6	99.2	93.580
Eylül 07	488.966	83.9	110.8	237.359.324.52	69.92	672.603.40	112.2	98.3	46.971
Ekim 07	523.747	83.0	108.0	240.942.451.97	70.00	670.864.30	109.3	97.5	48.802
Kasım 07	518.088	79.3	109.0	240.942.451.97	75.48	673.905.70	108.4	94.8	45.228
Aralık 07	440.544	80.7	110.5	240.942.451.97	66.82	675.243.90	110.0	95.5	36.640
Ocak 08	359.984	78.9	108.4	217.948.233.82	64.98	676.469.70	107.1	94.0	40.139
Şubat 08	384.891	74.4	105.4	217.948.233.82	65.11	679.627.70	103.2	90.8	37.681
Mart 08	460.490	68.7	103.9	217.948.233.82	71.96	683.442.70	98.8	86.9	38.204
Nisan 08	392.947	63.0	99.9	249.483.189.18	70.97	688.768.50	92.6	83.0	47.877
Mayıs 08	417.026	62.1	99.1	249.483.189.18	73.16	697.638.60	90.7	82.3	57.158
Haziran 08	351.843	61.8	97.8	249.483.189.18	71.29	714.265.80	90.0	82.1	70.151
Temmuz 08	455.588	63.8	95.4	268.726.652.43	69.93	718.761.70	89.1	83.5	87.055
Ağustos 08	401.178	66.6	97.0	268.726.652.43	62.81	725.928.80	91.9	85.4	85.910
Eylül 08	437.031	67.5	89.7	268.726.652.43	66.50	727.839.50	87.3	86.2	33.697
Ekim 08	452.165	61.0	74.4	258.624.782.99	64.58	732.381.30	73.2	82.1	59.112
Kasım 08	451.176	55.7	59.8	258.624.782.99	64.57	732.829.70	60.4	78.8	44.278
Aralık 08	312.019	56.7	60.0	258.624.782.99	53.67	736.029.80	62.7	79.8	40.711


Uygulamada kullanılacak 2007-2017 arasındaki 10 yıllık veriler TÜİK'in web sitesinde güncel olarak alınmıştır. 2007-2015 arasındaki verileri eğitim verisi olarak kullanılmış ve 2016-2017 arasındaki mevcut bağımsız değişkenler kullanılarak 2016-2017 satış miktarları tahmin edilip karşılaştırılmıştır. Elimizde güncel olarak mevcut bulunmayan 2018-2023 arasındaki bağımsız değişkenler zaman serileri metotlarıyla tahmin edilip sonrasında, önümüzdeki 5 yıllık süreye ait tahminler yapılmıştır. Talep tahmini çalışmasında oluşturulan yapay sinir ağı Matlab programında uygulanmıştır. Performans ölçütü olarak MSE(Hata Kareler Ortalaması) esas alınmış ve en uygun olarak oluşturulan yapay sinir ağı modeli Şekil 6'da gösterilmiştir.

4.1 Modelin Tasarımı

Uygulamada kullanılacak yapay sinir ağı modeli, ileri beslemeli geri yayılım ağıdır. Bu yapay sinir ağının tercih edilmesinin nedeni, tahmin çalışmalarında çok kullanılan ve doğrusal olmayan modellerdeki tahmin başarısıdır. Tasarlanan bu modelde girdi katmanında 8 adet işlem elemanı(nöron) kullanılmıştır. Model, sekiz bağımsız değişkene ait sekiz işlem elemanı olan bir girdi katmanı, sekiz işlem elemanlı bir gizli katman ve bir çıktı katmanından oluşan ileri beslemeli geri yayılım yapay sinir ağıdır.

Uygulamada kullanılan gerçek veri setleri, sinir ağlarına girmeden önce normalizasyon işlemi yapılmıştır. Bu işlem sonucunda giriş verilerinin tümü [0,1] aralığına indirgenmiştir.

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (2)$$


**Şekil 6.** Uygulamada kullanılacak YSA ağ yapısı.

4.2 Bulgular

Çalışmada belirlenen yapay sinir ağının ürettiği sonuçlar ve gerçekleşen değerler Tablo 2'de verilmiştir. Ayrıca, Şekil 7'da 2015 ile 2017 arasındaki verilerin YSA ve Regresyon gösterimi ile sunulmuştur. Yapay sinir ağının ve çok değişkenli regresyon analizinin sonuçları gerçekleşen değerlere yakın sonuçlar çıkmıştır. Yapay sinir ağları ile yapılan tahmin sonucu MSE(Hata Kareler Ortalaması) değeri 0,004690279 çok değişkenli regresyon analizinin MSE değeri 0,037292913.

Tablo 2. 2015 ile 2017 arası YSA ve çoklu regresyon analizi tahmin sonuçları ve MSE değerleri.

Yıl	Gerçek Satış Miktarları	YSA Tahmini	MSE	Regresyon	MSE
Ocak 15	528.944	493.706	0.00081167	567.234	0.03212520
Şubat 15	426.357	535.269	0.00921231	562.889	0.00948270
Mart 15	540.925	589.206	0.00215008	615.538	0.01343699
Nisan 15	618.811	563.500	0.00261517	668.811	0.07552839
Mayıs 15	549.171	558.034	0.00006598	694.835	0.11564766
Haziran 15	592.435	643.533	0.00275223	685.519	0.02919824
Temmuz 15	711.890	503.803	0.02963403	615.245	0.06989522
Ağustos 15	632.220	620.405	0.00013957	490.450	0.04255871
Eylül 15	591.042	672.755	0.00747290	529.310	0.04601259
Ekim 15	698.454	728.735	0.00113133	611.992	0.01829168
Kasım 15	650.640	729.220	0.00762417	569.159	0.05188338
Aralık 15	768.739	679.140	0.00909516	586.910	0.01047703
Ocak 16	523.875	529.934	0.00002795	596.026	0.03154953
Şubat 16	551.674	567.362	0.00021293	591.340	0.01045604
Mart 16	578.345	649.436	0.00539540	646.520	0.00594319
Nisan 16	638.987	599.496	0.00147911	702.334	0.08050947
Mayıs 16	733.123	586.458	0.01968883	729.517	0.13299734
Haziran 16	671.170	677.858	0.00005055	719.595	0.03381657
Temmuz 16	470.657	529.369	0.00261891	645.701	0.08118981
Ağustos 16	570.117	728.258	0.03083201	514.629	0.11752596
Eylül 16	519.989	666.464	0.02371841	555.298	0.02187337
Ekim 16	747.959	837.892	0.01152013	641.917	0.06851135
Kasım 16	717.923	805.397	0.01049577	596.876	0.09086085
Aralık 16	745.925	709.400	0.00159507	615.377	0.00888297
Ocak 17	601.093	532.600	0.00360772	624.818	0.05503598
Şubat 17	588.435	598.525	0.00009631	619.792	0.01182741
Mart 17	651.973	698.975	0.00259463	677.502	0.00324095
Nisan 17	801.694	624.790	0.03161653	735.857	0.09693377
Mayıs 17	794.994	661.079	0.01961252	764.199	0.09527122
Haziran 17	653.663	610.796	0.00179433	753.670	0.13980182
Temmuz 17	815.573	671.417	0.02319788	676.157	0.01043630
Ağustos 17	758.024	774.167	0.00034345	538.808	0.13779587
Eylül 17	722.656	776.137	0.00377962	581.285	0.08049960
Ekim 17	778.783	790.897	0.00019769	671.842	0.01337585
Kasım 17	712.136	768.047	0.00408578	624.593	0.03129386
Aralık 17	747.750	645.351	0.01109636	643.843	0.00616106

**Şekil 7.** 2015 ile 2017 arasındaki verilerin YSA ve Regresyon gösterimi.

5. Sonuç

Bu çalışmada yapay sinir ağı ve regresyon analizi tekniği kullanılarak Türkiye'deki beyaz eşya satışları tahmin edilmiştir. Beyaz eşya satışlarını etkileyen değişkenler olarak tüketici güven endeksi, reel kesim güven endeksi, gayri safi yurt içi hasıla, sanayi üretim endeksi, tüketim harcamaları, hane halkı maddi durum beklentisi, ekonomi güven endeksi ve evlenme istatistikleri bağımsız değişken olarak belirlenmiştir. Sonuçlar hata kareler ortalaması esas alındığında doğru tahminler olduğu gözlemlenmiştir. Sonuçlar karşılaştırıldığında yapay sinir ağlarının regresyon analizlerine göre daha iyi sonuç ürettiği kanıtlanmıştır. Yapılan tahminler gerçek değerler ile karşılaştırıldığında genelde tahminler ve gerçekleşen değerlerin birbirlerine yakın olduğu görülmektedir. Bu çalışmanın amacı, beyaz eşya sektöründe üretim yapan firmaların kaynak ve üretim planlamaları çalışmalarında yardımcı olmaktır.

Kaynaklar

- Agatonovic, S., & Beresford R. (2000). Basic Concepts of Artificial Neural Network (ANN) Modeling and Its Application in Pharmaceutical Research. *Journal of Pharmaceutical and Biomedical Analysis* 22(5): 717-27.
- Çağlar, T. (2007). *Talep Tahmininde Kullanılan Yöntemler ve Fens Teli Üretimi Yapan Bir İşletmede Uygulanması*. Yüksek Lisans Tezi, Kırıkkale Üniversitesi, Fen Bilimleri Enstitüsü, Kırıkkale.
- Çetin, M., Uğur, A., Bayzan, Ş. (2006). *İleri Beslemeli Yapay Sinir Ağlarında Backpropagation (Geriye Yayılm) Algoritmasının Sezgisel Yaklaşımı*. Bilgisayar Mühendisliği Bölümü, Pamukkale Üniversitesi.
- Efendilgil, T., Eminler, Ö., E. (2017). *Havacılık Sektöründe Talep Tahmininin Önemi: Yolcu Talebi Üzerine Bir Tahmin Modeli*. *Journal of Yasar University*, 12: 14-30
- Efendilgil, T., Önüt, S., Kahraman, C. (2009). A decision support system for demand forecasting with artificial neural networks and neuro-fuzzy models: A comparative analysis. *Expert Systems with Applications*, 36: 6697–6707.
- Garetti, M., Taisch, M. (1999). Neural networks in production planning and control. *Production Planning & Control The Management of Operations and control*, 10(4): 324-339, doi: 10.1080/095372899233082
- Hamid, S., A. & Iqbal, Z. (2004). Using neural networks for forecasting volatility of s&p 500 index futures prices. *Journal of Business Research*, 57: 1116-1125.
- Kabalci, E. (2014). Yapay Sinir Ağları. Ders Notları <https://ekblc.files.wordpress.com/2013/09/ysa.pdf>
- Karaatlı, M., Helvacıoğlu, Ö. Ömürbek, N. (2012). Gönül TOKGÖZ, "Yapay Sinir Ağları Yöntemi İle Otomobil Satış Tahmini", *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 8(17), 87-100.
- Karahan, M. (2011). *İstatistiksel Tahmin Yöntemleri: Yapay Sinir Ağları Metodu İle Ürün Talep Tahmini Uygulaması*. Selçuk Üniversitesi/İşletme Anabilim Dalı / Üretim Yönetimi ve Pazarlama Bilim Dalı Konya, Türkiye.
- Koç, H., Esnaf, Ş., (2016). Türkiye Mobilya Satış Değerlerinin Örnek Bir Yapay Zeka Uygulaması ile Tahmini. *Selçuk-Teknik Dergisi*, 3. *Ulusal Mobilya Kongresi (UMK-2015)*, 1172-1182.
- Ömürek, N., Karaatlı, M., Tokgöz, G. (2012). Yapay Sinir Ağları Yöntemi ile Otomobil Satış Tahmini. *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 8(17): 1-14. doi: 10.11122/ijmeh.2012.8.17.290.
- Sevinçtekin, E. (2014). *İmalat Sektöründe Yapay Sinir Ağları Uygulaması*. Yıldız Teknik Üniversitesi/Fen Bilimleri Enstitüsü/Endüstri Mühendisliği Ana Bilim Dalı/Sistem Mühendisliği, İstanbul, Türkiye.
- Yücesan, M., Gül, M., Çelik, E. (2017). Application of Artificial Neural Networks Using Bayesian Training Rule in Sales