

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:

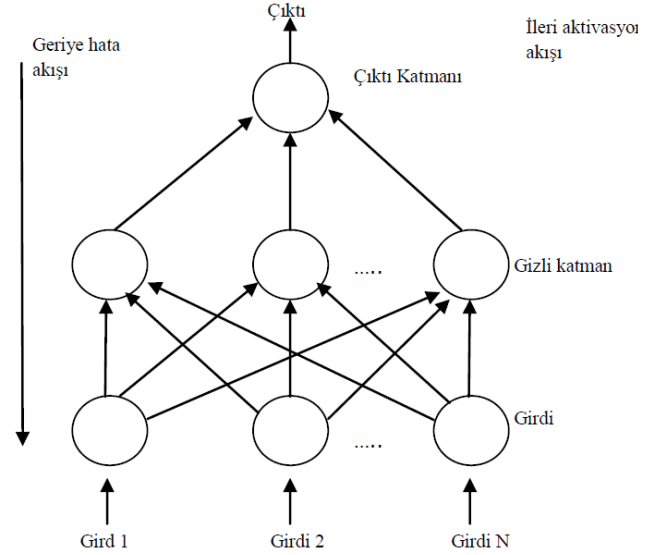
E-mail: turk.emre@std.izu.edu.tr

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. (Karahana, 2011).

Talep tahmin metodları, kantitatif ve kalitatif olarak iki ana başlık altında toplanır. Kantitatif tahmin metodu, insanların kendi tecrübelerinden oluşan bilgiye dayanak olarak tahmin yapma yöntemidir. Kalitatif metod ise, sayısal verilerin matematiksel modellemelerle desteklenerek ortaya çıkan sonuçlara dayanarak tahmin yapma yöntemidir. Yapay Sinir Ağları (YSA) modeli kantitatif tahmin metodlarının 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 (Karahana, 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 beyninin 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

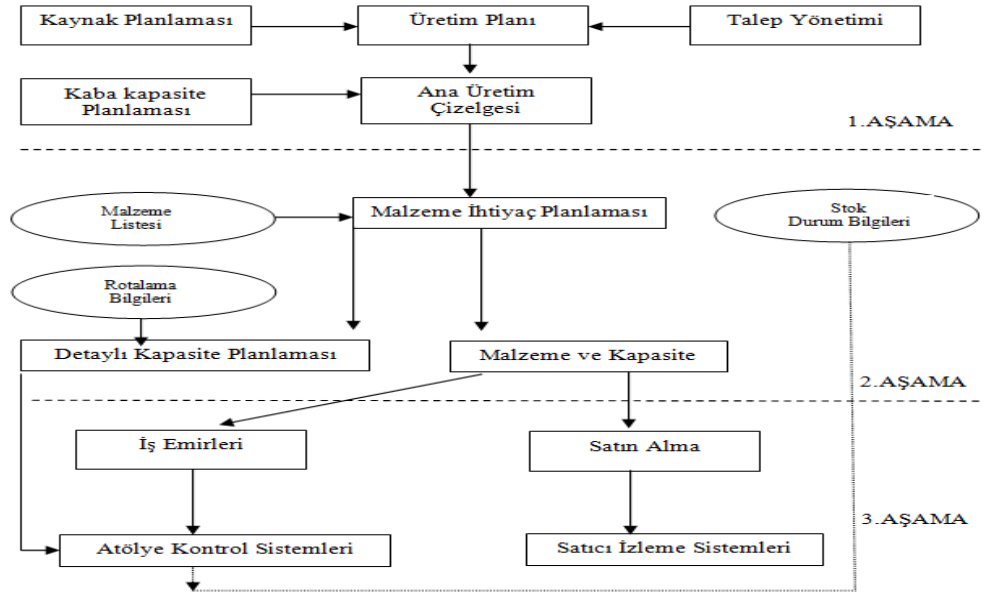
haberleşmelerini ortaya çıkarmıştır. Sonraki yıllarda bir ağ içerisindeki uyarılara tepki veren bir model oluşturuldu. İlk sinirsel bilgisayar 1960 yılında ortaya çıkmıştır. 1970 ve 1980'lerde başarılı sonuçların elde edilmesiyle 1985'ten sonra yapay sinir ağları üzerine yoğun çalışmalar başlamıştır.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

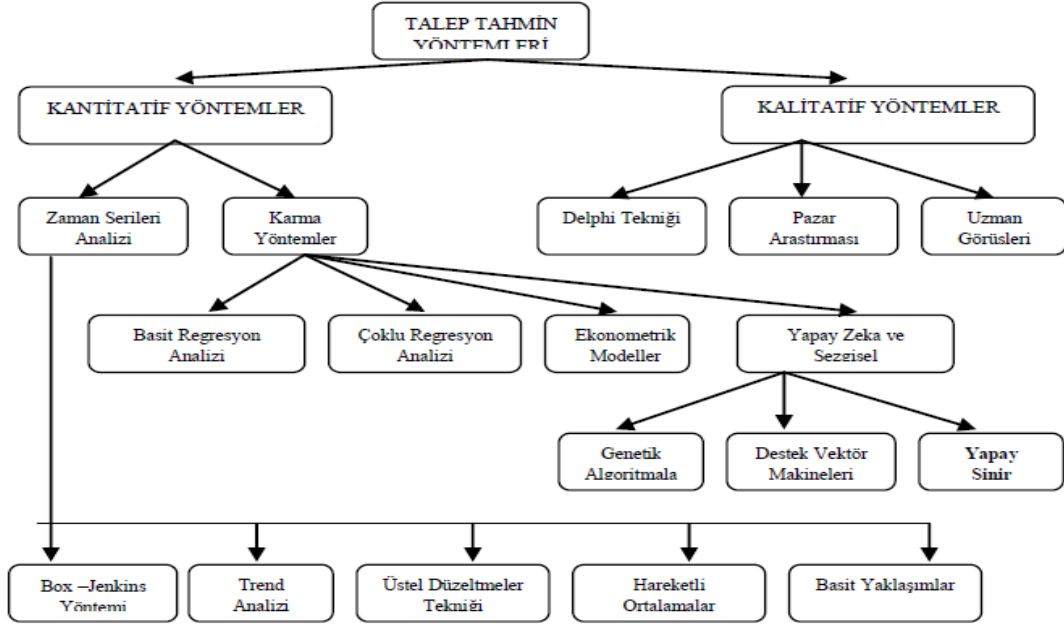
Birinci aşamada, kaynak planlaması ve talep tahmini dikkate alınarak üretim planı ve ana üretim çizelgesi ortaya koyuluyor. İkinci aşamada, stok durumları ve malzeme ve kapasite bilgileri baz alınarak malzeme ihtiyaç planlaması (MRP) yapılıyor. Son aşamada ise, ana üretim çizelgesine göre MRP yapıldıktan 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

inçin üretimi yapılacak ürünün talep tahmininin 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 sağları 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 metotları, 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 ağırlık 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 ağırlıkla 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 Yayılımlı 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 buldukları 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 yayılımlı 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 |

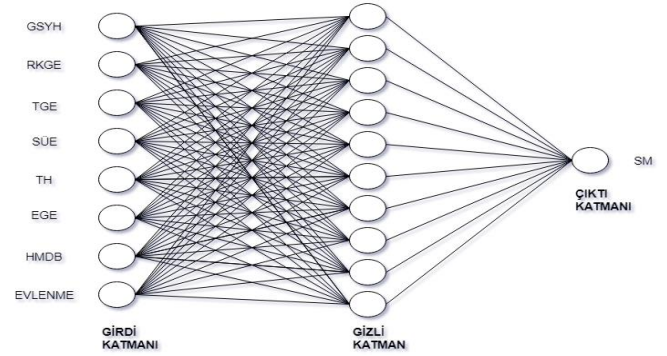
Uygulamada kullanılacak 2007-2017 arasındaki 10 yıllık veriler TÜİK'in web sitesinde güncel olarak alınmıştır. 2007-2015 arasındaki verileri eğitim verisi olarak kullanılmış ve 2016-2017 arasındaki mevcut bağımsız değişkenler kullanılarak 2016-2017 satış miktarları tahmin edilip karşılaştırılmıştır. 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'de 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 indirilmiştir.

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


**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 (Geriyeye Yayılım) Algoritmasının Sezgisel Yaklaşımı*. Bilgisayar Mühendisliği Bölümü, Pamukkale Üniversitesi.
- Efendigil, T., Eminler, Ö., E. (2017). *Havacılık Sektöründe Talep Tahmininin Önemi: Yolcu Talebi Üzerine Bir Tahmin Modeli*. *Journal of Yasar University*, 12: 14-30
- Efendigil, 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