

# ÇEVİRİMİÇİ TÜKETİCİ BÜTÜNLEŞMESİ VE ARAMA MOTORU VERİLERİ KULLANILARAK YAPAY SİNİR AĞLARI İLE OTOMOBİL SATIŞ TAHMİNİ

*Araştırma Makalesi / Research Article*

Topal, İ. (2019). Çevrimiçi Tüketici Bütünleşmesi ve Arama Motoru Verileri Kullanılarak Yapay Sinir Ağları ile Otomobil Satış Tahmini. *Neşehir Hacı Bektaş Veli Üniversitesi SBE Dergisi*, 9(2), 534-551.

Geliş Tarihi: 14.08.2019

Kabul Tarihi: 05.12.2019

E-ISSN: 2149-3871

Dr. İbrahim TOPAL

Milli Savunma Üniversitesi, Deniz Astsubay Meslek Yüksekokulu, Bilgisayar Teknolojileri Bölüm Başkanlığı

[itopal@msu.edu.tr](mailto:itopal@msu.edu.tr), [ibrahimtopal30@gmail.com](mailto:ibrahimtopal30@gmail.com)

ORCID No: 0000-0002-7119-9470

## ÖZ

Satış miktarının tahmin edilmesi hammadde alımından reklam giderlerinin belirlenmesine kadar işletmelerde birçok bölüme etki etmektedir. Tüketici verileriyle yapılacak satış tahmininde çok sayıda veriye ihtiyaç duyulmaktadır. Fakat birçok tüketici verisinin kişisel olması nedeniyle kullanılması sorun oluşturmaktadır. Satın alma karar sürecinde etkili olan sosyal ağlar ve arama motorlarına ait veriler değerli olmanın yanında herkesin erişimine açıktır. İşletmeler tüketicilerin kişisel verilerini kullanmadan satış rakamlarını gerçeğe yakın tahmin etmeleri avantaj sağlayabilecektir. Çalışmada tüketicilerin satın alma karar sürecinde etkili ve halka açık olan Çevrimiçi Tüketici Bütünleşme ve arama motoru verileri kullanılarak bir otomobil markasının satış miktarının tahmin edilmesi amaçlanmıştır. Çevrimiçi Tüketici Bütünleşmesinin yoğun yaşandığı işletmeye ait Facebook marka sayfasından 2012-2017 yılları arasında oluşturulan 2267 adet gönderi ve bu gönderilere ait beğenme, yorum ve paylaşma verileri Facebook Graph API ile alınmıştır. Arama motoru verileri Google Trends, satış verileri Otomotiv Distribütörleri Derneği web sitesinden elde edilmiştir. Veriler Min-Max yöntemiyle normleştirilmiş ve yapay sinir ağları, Bayesian Regülasyon geri yayılım yöntemiyle analiz edilmiştir. Facebook marka sayfası ve arama motoru verileriyle %74 korelasyon ve %1 ortalama hata değeriyle başarılı satış miktarı tahmini yapılmıştır. Ayrıca 6 yılı kapsayan detaylı veriler düzenlenerek tanımlayıcı bilgiler olarak sunulmuştur. Çalışmada tüketicilerin kişisel bilgileri kullanılmadan başarılı satış tahminlemesi yapılmıştır. Çalışma gerçek verilere dayanması ve yapay sinir ağlarının işletme alanında kullanımıyla sektöre ve akademik yazına katkı sağlamaktadır.

**Anahtar Kelimeler:** Çevrimiçi Tüketici Bütünleşmesi, Arama Motoru, Satış Tahmini, Yapay Sinir Ağları, Bayesian Regülasyon.

## ESTIMATION OF AUTOMOBILE SALES WITH ARTIFICIAL NEURAL NETWORK USING DATA OF ONLINE CONSUMER ENGAGEMENT AND SEARCH ENGINE

### ABSTRACT

Estimation of sales volume affects many segments of the enterprises from raw material purchase to advertising expenses. A large number of consumer data is needed to be used in sales forecasting. But the use of many consumer data is private, causing problems. Data from social networks and search engines, which are influential in the purchasing decision process, are valuable and accessible to everyone. It would be advantageous for businesses to estimate their sales figures as accurate as possible without using consumers' personal data. The sales volume of an automobile brand is aimed to be estimated by using Online Consumer Engagement and search engine data. 2267 posts, created between 2012-2017, likes, comments, and sharing

data of these posts were taken from Facebook brand page of the business where Online Consumer Engagement is intense using Facebook Graph API. Search engine data was obtained from Google Trends, and sales data was obtained from Automotive Distributors Association website. Data were normalized by Min-Max method and analyzed by feedforward artificial neural networks and Bayesian Regulation backpropagation method. the correlation value of Successful is %74 and mean error value is %1, was made with Facebook brand page and search engine data. In addition, detailed data covering 6 years has been prepared and presented as descriptive information. In the study, successful sales estimation was made without using the private information of the consumers. This study contributes to the sector and academic literature by relying on real data and using artificial neural networks in the business administration.

**Keywords:** Online Consumer Engagement, Search Engine, Sales Estimation, Artificial Neural Networks, Bayesian Regulation.

## 1. GİRİŞ

İnternetin yaygınlaşması sonrasında ortaya çıkan sosyal medya tüketicilerin diğer tüketiciler ve işletmelerle arasında interaktif iletişimine imkân tanımıştır (Kelleher, 2009). Sosyal medyada tüketiciler kendi aralarında ürün ve hizmetler hakkında deneyim ve görüşlerini paylaşmanın yanında işletmeler ile aracı olmadan görüşebilmektedir (Si, 2016). 4 milyarın üzerinde kullanıcısı olan sosyal medya (We Are Social, 2018), aynı zamanda işletmelerin tüketicilere ulaşmasında yeni bir platform olarak görülmektedir. İşletmelerce oluşturulan gönderiler elektronik ağızdan ağıza iletişimin etkisiyle hızla çok sayıda kişi tarafından görülebilmektedir. Bu gönderileri tüketiciler çeşitli şekillerde cevaplamakta ve bu sayede işletmeler tüketicileri bütünleşebilmektedir.

Tüketici bütünleşmesi, işletme ile tüketiciler arasında uzun ve sağlıklı ilişkiler kurulması temeline dayanmaktadır. Bütünleşme yapılarak zamanla tüketiciyle derin ilişkiler geliştirilmesi ve satın alma kararlarının, etkileşimin ve katılımının yönlendirilmesi amaçlanmaktadır (Forrester Consulting, 2008).

Bütünleşme için tüketiciyle iletişim önemli bir gereklilik olmakla birlikte günümüz tüketicisinin çeşitli kaynaklardan çok sayıda mesaja mazur kalması nedeniyle geleneksel yöntemlerle gerçekleştirilmesi oldukça zordur. Buna karşın, kişilerin çevresindeki kişilerle irtibat halinde kalmak için kullandığı sosyal medya, işletmelerin tüketiciyle hem iletişime geçmesine hem de bütünleşmesine imkân tanımaktadır. İşletmelerin marka sayfaları ve oluşturduğu gönderilerin tüketiciler tarafından karşılık bulması sonucunda bütünleşme gerçekleşebilmektedir. Aynı zamanda işletmeler, tüketicilerle olan bütünleşmenin seviyesini kısa sürede takipçi, beğeni, yorum veya paylaşım sayılarına bakarak öğrenebilmektedir (Chu ve Kim, 2011). Sosyal medya çok yönlü iletişim kanalı olarak tüketici bütünleşmesine sağladığı katkı sağlamanın yanında tüketicilerin ürün/hizmetler hakkında konuşmalarına uygun alt yapıyı da sunmaktadır.

Tüketici ve diğer tüketiciler arasında yaşanan iletişim daha çok deneyim paylaşımına dayalı ilişkidir. Tüketiciler sosyal medyada ürün veya hizmet alımından önce bilgi almakta, satın aldıktan sonra ise deneyimlerini paylaşmakta ve çevresindeki kişilerin görüşlerini paylaşmaktadır. Bu sayede sosyal medya tüketici satın alma karar sürecinin her adımında kullanılabilir (Yadav, de Valck, Hennig-Thurau, Hoffman ve Spann, 2013). Tüketici işletme arasındaki bütünleşmenin satın alma, yeniden satın alma ve sadakatinde etkili olduğu (Hapsari, Clemes ve Dean, 2017) bilinmektedir. Bu bağlamda, sosyal medya üzerinden gerçekleştirilen çevrimiçi tüketici bütünleşmesinin satın alma davranışına etkisi olması muhtemeldir.

Tüketiciler, çeşitli AIDA, Etkilerin Hiyerarşisi Modeli, Yeniliğin Kabulü gibi modellerde belirtildiği üzere harekete geçmeden önce bilişsel bir süreçten geçmektedir. Dikkatini çeken ürünün hakkında bilgi ihtiyacını giderme arayışına girmektedir. Özellikle beğenmeli ve teknik özelliğe sahip ürünlerde bilgi arayış fazla olmaktadır. Günümüz tüketicisi bilgi arayışını internette ve sıklıkla arama motorları aracılığıyla yapmaktadır. Satın alma sürecinde yeterli bilgiye sahip olan tüketici daha sonraki adımlara geçebilmektedir. Bu bağlamda, arama motorları tüketicilerin satın alma eğilimlerini gösterebilmektedir.

Tüketicilerin satın alma davranışının tahmin edilebilmesi işletmeler için birçok yönden önem taşıyan bir bilgidir. Satış tahminleri, ürün tedarikinden reklam kampanyalarına kadar kısa veya uzun

vadeli çeşitli kararlarda etkili olmaktadır. Bu nedenle satış miktarı, geçmişten günümüze çeşitli yöntemlerle tahmin edilmeye çalışılmıştır. Gelişen bilgisayar teknolojisinin sağladığı alt yapı ile 1980'lerden itibaren satış tahmininde yapay zekâ kullanılmaya başlanmıştır. İlerleyen dönemde de yapay zekâ ile satış tahminine yönelik çalışmalar devam etmiştir (Gupta ve Pathak, 2014; Qiu, Lin ve Li, 2015; Vellido, Lisboa ve Meehan, 2015). Satış tahmini çalışmalarında sıklıkla büyük tüketici verilerine ihtiyaç duyulmasına rağmen tüketicilere ait birtakım bilgiler kişisel olarak kabul edilmesi kullanılamamaktadır (Park ve Huh, 2019). İşletmelerin kişisel olmayan bilgilerle, yüksek doğruluk oranıyla satış tahmini yapması önemli bir avantaj sağlayacaktır.

Bu çalışmada, tüketici satın alma karar süreci, yeniden satın alma, sadakatte etkili olan çevrimiçi tüketici bütünleşmesi ve arama motoru verilerinin ile yapay zekâ yöntemi ile satış miktarı tahmin edilmesi amaçlanmıştır. Çalışma, Facebook marka sayfalarında çevrimiçi bütünleşmesinin yoğun olarak yaşandığı otomobil sektöründe yapılmıştır (McCulloch, 2015). Çalışmanın birinci bölümünde arama motoru verileri Google Trends'ten, satış verileri Otomobil Distribütörleri Derneğinden alınmıştır. Sonraki bölümde ileri beslemeli sinir ağları ve Bayesian Regülasyon yöntemleriyle analizler yapılmıştır. Sonuç bölümünde, bulgular çerçevesinde çalışmanın akademik alana ve sektöre olan katkıları yorumlanmıştır.

## 2. LİTERATÜR İNCELEMESİ

Tüketicilerin ihtiyacın farkına varmasıyla başlayan ve satın almayla biten süreci pazarlama iletişimi modelleriyle açıklanmıştır. Pazarlama iletişim modellerinin bilişsel, duyuşsal ve davranışsal olarak üç adımda gerçekleştiğinden bahsetmek mümkündür (Kotler, P., Keller, 2012). Tüketicilerin, mobil teknolojiler ve mobil internet ile zaman ve yer kısıtı olmaksızın erişebildikleri sosyal medya, arama motorları ile çok çeşitli ve fazla sayıda bilgi almaları/maruz kalmalarıyla bilişsel, duyuşsal ve davranışsal adımlar gerçekleşmektedir.

### 2.1. Sosyal Medya

Sosyal medya, işletmeler ile tüketiciler arasındaki ilişkide temel unsur olan iletişimin (Kelleher, 2009) her an, her yerden karşılıklı olarak gerçekleşmesini mümkün kılmakta ve tüketici görüşlerinin alınmasında geri dönüşü arttırmaktadır (Mudambi ve Schuff, 2010). Web 2.0 teknolojisi üzerine kurulu olan sosyal medya, içerisinde form, blog, mikroblog ve sosyal ağlar gibi araçları barındıran internet tabanlı uygulamalardan meydana gelmektedir. Bu araçlar tüketicilerin iyi vakit geçirmesi, sosyalleşmesi gibi ihtiyaçlarını karşılarken işletmelerin günümüz tüketicilerine ulaşmak ve aradaki iletişimi sürekli kılmakta kullanıldıkları önemli platformlardır (Berthon, Pitt, Plangger ve Shapiro, 2012). Sosyal medya araçları arasında hem pazarlama uzmanları hem de kullanıcılar tarafından en çok tercih edilen sosyal ağ Facebook'tur (Stelzner, 2014; We Are Social, 2018).

Sosyal ağlar, kullanıcılarının profil oluşturmalarına, bağlantıda oldukları diğer kullanıcıların profillerini listelemelerine, kendilerinin ve diğer kullanıcıların bağlantı listelerini görüntülenmelerine imkân sağlayan web tabanlı hizmetlerdir (Ellison ve Boyd, 2007). Facebook küresel olarak en yaygın kullanılan sosyal medya sitesidir. Aktif sosyal medya kullanıcısı olan 3,196 milyar kişiden 2,167 milyarı Facebook kullanmaktadır (We Are Social, 2018). Bu özellikleriyle Facebook sosyal medyanın en büyük ve önemli sitesidir.

Facebook, hedef kitlesiyle iletişime geçmek isteyen işletmelerin profil oluşturmaya imkân tanımaktadır. İşletmeler tarafından oluşturulan bu sayfalar marka sayfaları olarak adlandırılmaktadır (Richter, Riemer ve vom Brocke, 2011). Facebook işletmelerin geleneksel medyaya göre daha az maliyetle istenilen hedef kitesine ulaşmasını sağlamaktadır (Cunha, 2019). Aynı zamanda işletmelerin statik internet sitesi yerine interaktif yapıya sahip bir Facebook sayfası ile tüketicilere ulaşması ve bağ kurması daha zahmetsizce gerçekleşmekte ve pozitif geri dönüşü olmaktadır. Tüketicilerin %74'ünün işletmeyle sosyal medya üzerinden etkileşimde olmasından sonra daha pozitif marka izlenimine sahip olduğu ve "Beğen" butonuna tıklayan müşterilerde satın alma oranının %51 arttığı da bilinmektedir (Funk, 2010). Facebook, sunduğu fırsatlar ile işletme ve pazarlamacıların dikkatini çekmektedir.

Sosyal medyanın tüketicilerle ilişki geliştirme ve sürdürmede etkisi olmakta (Etter ve Fieseler, 2010) ve işletmelerin %89'u en etkili sosyal medya taktiklerini bilmek ve kullanıcılarla en iyi şekilde bütünleşmeyi istemektedirler (Stelzner, 2014). Facebook ise işletmelerin tüketici ile bütünleşebileceği uygun bir ortam olarak görülmektedir.

## **2.2. Çevrimiçi Tüketici Bütünleşmesi**

Bütünleşme, sosyoloji, psikoloji, eğitim psikolojisi, kurumsal davranış disiplinlerinde kent, sosyal, öğrenci, mesleki bütünleşme olarak farklı şekillerde ele alınmıştır. Bu kavramlarda bütünleşmenin birçok boyutu ortaya konmakla birlikte bütünleşmenin çeşidine göre bir bilişsel, duygusal veya davranışsal etkileşim olduğu görülmektedir. Örneğin öğrenci bütünleşmesinde derslere katılım, meslek bütünleşmesinde başlatıcı performans, işçi bütünleşmesinde kendini adama olarak görülebilmektedir (Hollebeek, 2011). Bununla birlikte bütünleşme pazarlamada, tüketici bütünleşmesi, işletmenin ürünlerine yönelik satın alma dışında, farklı tutumların ve davranışların geliştirilmesi (Doorn ve diğerleri, 2010) olarak bilinmektedir. İnternet teknolojileri üzerinden gerçekleştirilen bütünleşme ise çevrimiçi tüketici bütünleşmesini olarak adlandırılmaktadır. Sosyal medya, çok yönlü yapısıyla tüketici bütünleşmesine uygun bir platform olarak görülebilmektedir.

Sosyal medya mevcut ve olası müşterilerle ilişkinin kurulması, sağlıklı olarak devam ettirilmesi, işletmeyle satın alma dışı faaliyetlerin yapılabilmesi, etkileşim yaşanması, tüketicilerden geri bildirim alınmasını sağlamaktadır. İşletmeler, sosyal medya da marka sayfaları açarak, gönderilerek oluşturarak tüketicilerin beğeni, yorum ve paylaşım yapmalarını amaçlamaktadır (Cvijikj ve Michahelles, 2013). İşletmelerin tüketicilerle internet üzerinden etkileşime girmesi ve gönderilerine tüketicilerden karşılık bulması çevrimiçi tüketici bütünleşmesi olarak adlandırılmaktadır. Sosyal medyanın çok sayıda siteden oluşan yapısı tüketici bütünleşmesinin ölçülmesinde çeşitli yöntemlerin kullanılmasına neden olmaktadır.

Çevrimiçi tüketici bütünleşmesi, mikroblog sitesi olan Twitter'da tweet veya retweet (Rybalko ve Seltzer, 2010), blog sitelerinde oluşturulan gönderi (Yang, Kang ve Johnson, 2010), Facebook'ta ise beğeni, yorum ve paylaşım sayıları (Chu ve Kim, 2011; De Vries, Gensler ve Leeflang, 2012; Ji, Li, North ve Liu, 2017) üzerinden değerlendirilebilmektedir. Tüketicilerin ürün, hizmet, marka veya işletme hakkında çevresindeki kişilerinde göreceği şekilde yapacağı işlemler (beğeni, yorum, paylaşım) duygusal, bilişsel olarak işletmeye yaklaşma sağlayacak, gelecek davranışların olumlu olmasına temel oluşturabilecektir. Çevrimiçi tüketici bütünleşmesi Çevrimiçi tüketici bütünleşmesinin gerçekleşmesi sonucunda oluşabilecek etkilenebilecek davranışlardan biri de satın almadır.

Sosyal ağların duygusal ve sosyal boyutlarıyla ele alınarak satın almaya etkisi (Kim, Gupta ve Koh, 2011) olduğu ve sosyal medya kanalıyla yapılan birebir iletişimin satın alma kararında etkili olduğunu (Wang, Yu ve Wei, 2012) gösterir çalışmalar mevcuttur. Sosyal ağlarla birlikte internette bilgi arayışının önemli destekleyicisi olan arama motorları da tüketiciler hakkında değerli bilgiler sunmaktadır.

## **2.3. İnternet Arama Motorları**

Tüketiciler özellikle alacakları ürün hakkında satın alma öncesi bilgi toplamaktadırlar. Bilgi toplama süreci alınacak olan ürünün özelliklerine göre değişiklik göstermektedir. Kolayda ürünlerde bu süre çok kısa olabilirken beğenmeli ürünlerde süre artmaktadır. Özellikle teknik özelliklere sahip beğenmeli ürünlerde tüketici birden fazla kaynağı kullanarak bilgi ihtiyacını gidermeye çalışmaktadır.

İnternet ve sosyal medya günümüz tüketicilerinin bilgiyi üretme ve arama alanıdır. Tüketiciler sosyal ağ, blog, form gibi sitelerde kolayca içerik üretebilmekte, deneyimlerini paylaşmakta bilgiye ihtiyaç duyan kişiler ise sıklıkla arama motorlarını kullanarak bu bilgiye ulaşabilmektedir. Arama motorları günlük hayatta çoğu insan tarafından en az birkaç kez kullanılmaktadır. %93'lük pazar payıyla en bilinen arama motoru olan Google'da ("Search Engine Market Share Worldwide", 2019) her saniye 63.000 arama yapılmaktadır (Sullivan, 2016). Google, arama sıklıklarını gösteren verileri Google Trends sitesinden paylaşılmaktadır.

Google Trends, coğrafi alana göre Google aramalarının zaman serisi olarak alınmasını imkân tanımaktadır. Öğrenilmek istenen arama kelimesi belirlenen zaman aralığındaki toplam arama ve zaman aralığına bölünür. Sonrasında konu tüm aramalara göre 0-100 arasında ölçeklendirilir (Choi ve Varian, 2012). Bu sayede tüketiciler arasında popüler olan konular rahatça gözlemlenebilir ve çeşitli konularda tahminde bulunulabilir.

İnternet arama verilerinin teknik karmaşıklığı fazla olan veya beğenmeli ürünlerde daha çok kullanılması olasıdır. Örneğin otomobil teknik yönü fazla, yüksek maliyetli bir ürün olmasının yanında sosyal statü göstergesidir. Kişiler sadece ürünün teknik özellikleri değil sosyal çevresi tarafından da kabul görmesini istemektedir. Bu nedenle otomobil sektörüne yönelik yapılacak satış tahminlemede sosyal ağ ile arama motoru verilerinin bir arada kullanılması fayda sağlayabilecektir.

#### **2.4. Satış Tahmini**

İşletmeler kısa veya uzun vadeli yapacakları birçok işleme temel olduğu için satış miktarlarına yönelik tahminlere ihtiyaç duymaktadırlar. Bu nedenle tüketiciler açısından satın alma niyeti ve işletmeler açısından ise satış rakamları birçok kez çeşitli yöntemlerle araştırılmıştır. Analiz yapılacak veriler anket yoluyla elde edilebildiği gibi gerçek tüketici verilerine de dayanabilmektedir. İnternetteki verilerin erişilebilirliğinin artması ve anketteki bazı dezavantajlardan uzak olması nedeniyle gerçek tüketici verileriyle yapılan analiz sayıları artmakta ve bunlar için çeşitli örnekler bulunmaktadır.

İnternet alışverişlerinin yaygınlaşması alışveriş sitelerinden elde edilen bilgiler ile tüketicilerin satın alma davranışları tahmin edilmeye çalışılmıştır. İnternet alışveriş sitelerinden elde edilen oturum sıklığı, harcanan zaman ve sayfa içeriği gibi veriler kullanılarak çalışmalar (Poel ve Buckinx, 2005; Sismeiro ve Bucklin, 2004) yapılmıştır. Online satın alma davranışı tahmini konusunda yapılan çalışmalarda sinir ağları (Vellido ve diğerleri, 2015), destek vektör makinesi, çok katmanlı algılayıcı sınıflandırması (Sakar, Polat, Katircioglu ve Kastro, 2018) karar ağacı (Gordini, Sanpaolo ve Veglio, 2015) analiz yöntemleri kullanılarak fiyatlandırma ve tüketici ilişkileri yönetimine katkı sağlanması amaçlanmıştır. Fakat bu tahminlemenin yapılabilmesi için kullanılan yöntemle bağlı olarak çok miktarda veriye ihtiyaç duyulabilmektedir.

Günümüz tüketicilerinin ürün ve hizmetler hakkında çoğunlukla ticari kaygı gütmeksizin yaptığı sosyal medya paylaşımları önemli bir veri kaynağıdır. İşletmelerin marka sayfaları üzerinden tüketicilerle bütünleşmesi çeşitli bilgilerin rapor olarak ellerinde bulunmasına imkan tanımaktadır. Sosyal medyadaki gerçek tüketicileri verileri analiz edilerek yapılan satın alma/satış tahminine yönelik çalışmalar yapılmıştır.

Ahn ve Spangler (2014) çalışmasında sosyal medyadaki duygu ve başlık bilgilerindeki sıklığı kullanarak aylık otomobil satışını tahmin etmiş; Ding ve arkadaşları (2015) yılındaki çalışmasında çeşitli ürünler ve yöntemler kullanılarak satın alma niyeti %64 ile %95 arasında başarı elde edilmiştir. Bir diğer çalışmada ise Lassen, Madsen ve Vatrappu (2014) tüketicilerin Twitter'daki sosyal grafiğini değerlendirmeye alarak bir telefon firmasının üç aylık satış rakamlarını tahmin etmiştir.

İnternette arama verileri diğer bir değerli bilgi olarak görülmektedir. Satın alma sürecindeki tüketicinin bilgi arayışı içerisinde olacağı ve arama motorunu kullanacağı varsayımına dayanarak satış rakamı tahmin edilmeye çalışılmaktadır. Yapılan araştırmalar, perakende (Schmidt ve Vosen, 2009), otomobil (Barreira, Godinho ve Melo, 2013) ve ev (Wu ve Brynjolfsson, 2015) satışları gibi çok çeşitli konularda olabilmektedir.

Sosyal medya verilerin, özellikle çevrimiçi tüketici bütünleşmesinin yüksek olduğu otomobil sektöründe kullanılmasının (McCulloch, 2015) daha iyi sonuçlar vermesi muhtemeldir. Otomobilin yapısı gereği teknik özelliklere sahip ve beğenmeli biri ürün olması ise satın alma öncesi arama motoru kullanımını arttırabilecektir. Bu bağlamda, satış rakamlarının tespitinde sosyal ağ ve arama motoru verilerinin kullanılması daha iyi performansla sahip tahminler yapılmasına imkan tanıyacaktır.

### 3. YÖNTEM

Türkiye’de 80 milyon kişiden 48 milyonu internet ve sosyal medya kullanmaktadır. Ayrıca Türkiye’nin sosyal medya kullanımındaki derinlik oranı %60 ile %37 olan dünya ve %44 olan doğu Avrupa ortalamasının çok üstündedir. Türkiye’de günlük olarak sosyal medyaya 3 saat 1 dakika zaman ayrılmaktadır. 48 milyon aktif Facebook kullanıcı sayısı ile dünyada yedinci sıradadır (We Are Social, 2018). Bu nedenlerle çevrimiçi tüketici bütünleşmesi araştırmasında Türkiye’de Facebook’un iyi bir araştırma sahası olacağı kanaatine varılmıştır.

Otomobil sektörü çevrimiçi bütünleşmenin yoğun olarak gerçekleştiği sektörlerdendir. Türkiye’deki otomobil markalarının satış ve Facebook takipçi sayılarına göre ilk üç marka Tablo 1.’de verilmiştir. Araştırma konusuna uygun olarak satış ve takipçi rakamları değerlendirilerek Volkswagen markası seçilmiştir.

**Tablo 1.** Satış ve Takipçi Sayılarına Göre Otomobil Markaları

Sıra No	Satış Rakamlarına Göre		Takipçi Sayılarına Göre	
	Marka	Satış Miktarı	Marka	Takipçi Sayısı
1.	Renault	113.454	Volkswagen	4 Milyon
2.	Volkswagen	89.688	Renault	2,1 Milyon
3.	FIAT	61.364	Mercedes-Benz	2 Milyon

Kaynak: Otomotiv Distribütörleri Derneği (2017), [www.odd.org.tr](http://www.odd.org.tr)

Social Bakers, Facebook Otomobil Markaları (2017).

<https://www.socialbakers.com/statistics/facebook/pages/total/turkey/brands/auto/cars/>

Çalışma yönteminin şeması aşağıda verilmiştir.



**Şekil 1.** Yöntemin Şeması

#### 3.1. Verinin Elde Edilmesi

Volkswagen Facebook marka sayfası ve Google Trends sitesindeki 01.01.2012 tarihinden 31.12.2017 tarihine kadar olan işlemler ele alınmıştır.

Sosyal ağdaki veriler, Facebook Graph API uygulaması kullanılarak alınmıştır. Bu kapsamda, Volkswagen Türkiye marka sayfasında oluşturulan 2267 gönderiye yapılan beğenme, yorum ve paylaşım sayıları değerlendirmeye alınmıştır.

Google Trends sitesi üzerinde “Volkswagen” sözcünün arama sıklığına bakılarak veriler aylık olarak indirilmiştir.

Firmaya ait satış verileri Türkiye Otomotivciler Derneği sayfası üzerinden 2012-2017 aylık bazda alınmıştır.

**Tablo 2.** Örnek Veriler

Ay	Gönderi Sayısı	Beğenme	Yorum	Paylaşım	Arama Verisi (Trend)	Satış Miktarı
1	47	543	99	122	49	2804
2	32	1207	201	242	57	3298
3	46	936	83	175	62	5470
...	...	...	...	...	...	...
10	29	5602	142	98	77	7956
11	36	6166	218	88	72	10228
12	32	7564	213	160	74	13003

### 3.2. Verinin Dönüştürülmesi

Sosyal medya oluşturulan gönderiye tüketicilerin her an her yerden etkileşimde olmasını sağlarken arama motoru verileri an az haftalık, satış rakamları ise en az aylık sürelerde elde edilebilmektedir. Bu nedenle marka sayfasından alınan beğenme, yorum ve paylaşım verilerinin aylık ortalamaları alınmış arama motoru verileri ise aylık olarak indirilmiştir.

Yapay sinir ağlarında (YSA) giriş verisinin normalleştirilmesi sonuçların daha verimli çıkmasını sağlayabilir (Jayalakshmi ve Santhakumaran, 2011). Geri yayma kullanırken, nöronların aktivasyon fonksiyonuna bağlı olarak bazı önışlemlerin yapılması gerekebilmektedir (Sola ve Sevilla, 1997). Bu nedenle, veriler normalleştirilerek ağın performansı ölçülmüştür. Normalleştirmede Min-Max yöntemi tercih edilmiştir. Min-Max'ta verinin genellikle 0-1 arasında ölçeklenir ve aykırı değerlerin bastırılmaktadır.

### 3.3. Yapay Sinir Ağları

Yapay zekâ 1940'larda ortaya çıkan ve 1980'lerde işletme alanında kullanımına başlanmıştır. Sıklıkla satış miktarı, sipariş tahminlerinde kullanıldığı görülmüştür. En bilinen yapay zeka yöntemlerinden bir tanesi ise yapay sinir ağlarıdır (YSA). YSA'nın yapısı beyindeki sinir hücrelerine benzetilerek geliştirilmiş bir metodudur.


Yapay sinir ağı bir X giriş verisi vektörü ile başlar ve Y çıkış verisi vektörü ile biter. Başka bir ifade ile X açıklayıcı değişkenler matrisi Y ise bağımlı değişken vektördür. Giriş vektörü ile çıkış vektörü arasındaki ağ yapısı YSA mühendisliği ile belirlenir (Yu, Wang ve Lai, 2007) Yapımın temel elemanları nöron, bağlantı ve öğrenme algoritmasıdır. Bu yapıda ağırlıklı bağlantılar ile birbirine bağlı elemanlar kendi belleğine sahiptir (Çuhadar ve Kayacan, 2005). Örnekler ile eğitilen sistem belli algoritmalar çalıştırılarak test edilir ve sistemin doğruluk oranı belirlenir. Yapay sinir ağları çok fazla girdinin işlenerek anlamlı ilişkiler ortaya konmasını sağlamaktadır. Bu sayede sınıflandırma, tahmin gibi birçok maksatla kullanılmaktadır.

YSA'nın geri beslemeli, kademeli ve ileri beslemeli olmak üzere üç çeşidi bulunmaktadır. İleri beslemeli yapay sinir ağı (İBYSA) hücrelerin yalnızca önceki katmanlardaki hücreler ile beslendiği ağ olarak tanımlanabilir (Cerit ve diğerleri, 2017). İleri beslemeli ağ giriş, gizli ve çıkış katmanından oluşur. Her katmanda çeşitli sayıda nöron bulunmaktadır. Giriş katmanındaki nöron sayısı kaynaktaki parametrelere göre belirlenir. Giriş katmanındaki veriler gizli katmanlara iletilir (Zhang, 2018, s. 3). Girişler ağırlıklar ile çarpıldıktan ve gizli katmandaki nöronlardaki değere eşik değer eklenerek ve transfer fonksiyonuyla sonraki katmana iletilir. İşlemler gizli katmandan çıkış katmanına geçilirken de yapılmaktadır (Günaydın ve Günaydın, 2008). İleri beslemeli YSA'a ait formül basit haliyle Denklem 1.'de verilmiştir.

$$\hat{Y}(t + 1) = F_2[V^T(t)F_1(W(t)X(t))] \quad (1)$$

$F_1$  gizli ile çıktı katmanı arasındaki aktivasyon fonksiyonunu,  $F_2$  giriş ile gizli katman arasındaki toplam fonksiyonunu,  $W_1$  gizli ile çıktı katmanı arasındaki ağırlık matrisini,  $V^T$  ise giriş ile gizli katman arasındaki ağırlık matrisini temsil etmektedir. İBYSA'nın gösterimi Şekil 2.'dedir.

$F_1$  gizli ile çıktı katmanı arasındaki aktivasyon fonksiyonunu,  $F_2$  giriş ile gizli katman arasındaki toplam fonksiyonunu,  $W_t$  gizli ile çıktı katmanı arasındaki ağırlık matrisini,  $V^T$  ise giriş ile gizli katman arasındaki ağırlık matrisini temsil etmektedir. İBYSA'nın gösterimi Şekil 2.'dedir. Bu çalışmanın yapısı Tablo 3.'te görülmektedir.



Şekil 2. İleri Beslemeli Yapay Sinir Ağları

Tablo 3. Yapay Sinir Ağı Giriş ve Çıkış Katmanları

Katman	Türü	Nöron
Giriş	Ay Bilgisi	I1
	Gönderi	I2
	Beğenme	I3
	Yorum	I4
	Paylaşma	I5
	Arama Verisi (Trend)	I6
Çıkış	Satışlar	O1

### 3.4. Geri Yayılım (Backpropagation)

Geri yayılım ağlar, çok boyutlu karmaşık haritalamayı öğrenebilme yeteneğine sahip olması nedeniyle yapay sinir ağı mimarisinde yaygın kullanıma sahiptir (Chopra, Yadav ve Chopra, 2019). Bu özellikleri nedeniyle birçok alanda başarılı şekilde uygulanmaktadır. Son zamanlarda yapay zeka ile yapılan satış tahmin çalışmalarında en çok kullanılan ikinci yöntemdir (Tkáč ve Verner, 2016).

Geri beslemeli ağ, nöron bağlantılarındaki ağırlıklarda oynama yaparak çıkış değerinin reel değere yakınsamasıdır. İşlem tekrarlandıkça çıkış değeri reel değerlere yaklaşmaktadır. Böylece



küçük değerlere sahip olması iyi olarak kabul edilen performans kriterlerinden karesel ortalama hata veya global hata değerleri azalmaktadır (Doğru, 2015). Çıkış katmanındaki hata değerleri beklenen değer olana kadar giriş katmanına geri yayılır. Bu süreçte nöronlara verilen ağırlıklar yeniden ayarlanır(Haykin, 1999).

Geri yayılım yöntemleri arasında Bayesian Regülasyon yönteminin sıklıkla kullanıldığı görülmektedir. Bayesian Regülasyon, lineer olmayan sistemleri iyi biçimlendirilmiş problemlere dönüştürmesi ve ağır ezberleme olasılığını azaltması (MacKay, 1992) tercih edilmesini sağlamaktadır. Bayesian Regülasyon yönteminin formülü Denklem 2’dedir.

$$O_F = \beta E_S + \alpha E_w \quad (2)$$

Denklem 2’de amaç fonksiyonu OF, hata kareleri toplamı ES, ağ ağırlıklarının kareleri toplamı EW, amaç fonksiyonu parametreleri  $\alpha$  ve  $\beta$  ile gösterilmiştir. Bayesian Regülasyon kuadratik hata, ağırlık kombinasyonunu minimize ederek ağır üretilmesinde doğru kombinasyonun belirlenmesini sağlamaktadır (Aşkın vd., 2011).

### 3.5. Performans Değerlendirme Kriterleri

Performansı değerlendirirken hata karelerinin ortalaması (MSE), mutlak yüzde hatalarının ortalaması (MAPE) ve korelasyon katsayısına (R) bakılmıştır. MSE’nin azalması sistem performansını arttırmaktadır. MAPE ise ağır tahmin ettiği değer ile gerçek değer arasındaki farkı yüzdesel olarak göstermektedir. Bu bağlamda, çalışmada MSE ve MAPE değerlerinin düşük olması beklenmektedir. Pearson korelasyon katsayısı ise değişkenler arasındaki ilişkinin derecesi ve yönünü -1 ile +1 değeri arasında göstermektedir. MSE’nin formülü Denklem 3’te, MAPE’nin formülü Denklem 4’te ve Pearson korelasyon katsayısının formülü Denklem 5’te verilmiştir.

Denklemlerde “N” veri setinin ağır tarafından tahmin edilen değerini, “R” gerçek değeri, “n” veri boyutunu göstermektedir. Denklem 5’te yer alan “ $\mu_R$ ” gerçek değerlerin ortalaması, “ $\sigma_R$ ” gerçek değerlerin standart dağılımı, “ $\mu_N$ ” ağır tarafından tahmin edilen değerlerin ortalaması ve “ $\sigma_N$ ” tahmin edilen değerlerin standart sapmasıdır.

$$MSE = \frac{1}{n} \sum_{i=1}^n (R_i - N_i)^2 \quad (3)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|R_i - N_i|}{R_i} \times 100 \quad (4)$$

$$\rho(R, N) = \frac{1}{n-1} \sum_{i=1}^n \left( \frac{R_i - \mu_R}{\sigma_R} \right) \left( \frac{N_i - \mu_N}{\sigma_N} \right) \quad (5)$$

Çalışmadaki veriler %80 eğitim ve %20 test olarak sistematik örnekleme metoduyla ayrılmıştır. Böylece, ağır 72 aylık verinin 58’i ile eğitilmiş, 14 tanesi ile test edilmiştir. Ağır giriş katmanına Gönderi, Beğenme, Yorum, Paylaşma, Trend, Ay Bilgisi verilerinden oluşan 5 giriş bulunmaktadır. Çıkış katmanı ise Satış verisi olarak 1 tanedir. Gizli katmanda en iyi sonucu veren nöron sayısının tespit edilebilmesi amacıyla 1-100 arasında tüm nöron sayıları denenmiştir.

## 4. BULGULAR

Volkswagen Türkiye'nin marka sayfasındaki altı yıllık süre zarfında oluşturulan 2267 gönderi oluşturulmuştur. Aylık oluşturulan gönderi miktarı, gönderilere yapılan beğenme, yorum ve paylaşım sayılarının aylık ortalamaları Şekil 3.'te verilmiştir.

Tablo 1'de görüleceği üzere marka sayfasında 2012 yılında ayda 88 gönderiye ulaşılmasına rağmen sonrasında en fazla ayda 38 gönderi oluşturulmuştur. Yıllık olarak değerlendirildiğinde 2012 yılında 575 gönderi paylaşılmış sonrasında ise bu sayı 2016 yılında en fazla 368'e ulaşmıştır. 2012 ile 2016 yılı arasında 208 gönderi farkı bulunmaktadır. Bunun aksine 2012 yılında toplam beğeni sayısı 19.494 beğeni alırken 2016 yılında 108,549'a ulaşmıştır. Buradaki ters orantının tüketici-işletme bağı dışında sebepleri de bulunmaktadır. Türkiye'deki Facebook kullanıcı sayısının 2012 yılında 31 milyon (Caner, 2012) iken 2016 yılında 42 milyona yükselmiştir. Ayrıca mobil teknolojiler ve mobil internetin yaygınlaşması daha uzun süreli sosyal ağ kullanımına neden olmuştur. Teknolojik gelişmelerin çevrimiçi tüketici bütünleşmesini artırması muhtemeldir.

**Tablo 4.** Gönderi, Beğenme, Yorum, Paylaşma ve Satışlar (2012-2017)

Yıl	Gönderi	Beğenme	Yorum	Paylaşma	Satış
2012	575	19,494	2,055	2,984	66,792
2013	334	33,852	2,262	3,149	88,304
2014	328	47,041	1,283	1,638	84,646
2015	318	70,673	1,258	1,491	107,401
2016	368	108,549	4,137	2,975	101,763
2017	347	108,140	4,138	2,899	102,030

Yorum ve paylaşım sayıları ise gönderi sayılarındaki tutarsız değişim olması ise daha çok gönderinin içeriğine göre değiştiği şeklinde yorumlanabilir.

Altı yıllık süre içerisinde en çok beğeni, yorum ve paylaşım yapılan gönderiler Tablo 2-4'te verilmiştir. Bu gönderilerin en az iki tanesinde markanın popülerliği geçmişe dayanan Beetle modeli kullanılmıştır.

**Tablo 5.** Volkswagen Marka Sayfasında En Çok Beğenme Yapılan Gönderiler (2012-2017)

Gönderi İçeriği	Tarih	Beğeni Sayısı
"Uzun zaman önce çok, çok uzak bir park yerinde... #RogueOne"	14.12.2016	170.168
"Bulunduğu her şehre uyum sağlayan bir ikon: #Beetle"	10.08.2017	98.650
"Yeni #Golf ile doğanın tüm renklerinin uyumu... Göz kamaştırıcı..."	25.08.2017	86.887

**Tablo 6.** En Çok Yorum Yapılan Gönderiler (2012-2017)

Gönderi İçeriği	Tarih	Yorum Sayısı
"Sizce bu göz alıcı led ön farlar hangi Volkswagen modeline ait?"	08.07.2013	8577
"Haftaya eğlenceli başlamak için biraz oyun oynayalım mı? Volkswagen'i park alanına denk getirenlerin ekran görüntülerini yorumlara bekliyoruz. :)"	21.11.2016	42161
"Wolfsburg'daki fabrikamızdan bir görüntü. Bakalım hangi araç olduğunu tahmin edebilecek misiniz?"	16.12.2016	12926

**Tablo 7.** En Çok Paylaşım Yapılan Gönderiler (2012-2017)

Gönderi İçeriği	Tarih	Paylaşım Sayısı
“Volkswagen’i sevmek için ona sahip olmanıza gerek yok.”	24.12.2013	8585
“Uzun zaman önce çok, çok uzak bir park yerinde... #RogueOne”	14.12.2016	7408
“Gözümden hiçbir şey kaçmasın diyenler için Volkswagen'den çevresel Görüş Sistemi “Area View”.”	24.11.2016	7119

Volkswagen satış sayılarının 2015 yılına kadar arttığı ve 2016, 2017 yıllarında bir miktar düştüğü Tablo 4’te görülmektedir. Bununla birlikte, 2012-2017 yıllarında Şekil 4.’ten anlaşılacağı üzere yılsonunda artış olduğu görülmektedir.

Eğitim ve test verilerinin MSE, MAPE ve korelasyon değerleri Tablo 6.’da verilmiştir. Nadiren eğitim verisinin test verisinden daha düşük performansı olduğu görülmektedir. Bu ağda 100 denemenin 6 tanesinde test verisi eğitim verisinden daha iyi performansa sahiptir. Buna test verilerinde en iyi sonucu veren gizli katmanın 70 nörondan oluştuğu ağ şekli de dahildir. Bu ağda regresyon değeri, test için 0,7438 çıkarken eğitimde 0,6853 bulunmuştur. Aynı zamanda MAPE değeri test için %-1, eğitim için ise %15’tir. Eğitim ve Test regresyon grafikleri Şekil 5.’te verilmiştir.


**Tablo 8.** Test ve Eğitim Performans Değerleri (En iyi 10 değer)

	Nöron Sayısı	MSE	MAPE	R
Test	<b>70</b>	<b>0,1543</b>	<b>-1,0897</b>	<b>0,7438</b>
	78	0,1398	-36,5233	0,7302
	88	0,1400	-45,3942	0,7189
	36	0,1349	-50,2604	0,7179
	33	0,1386	-45,9843	0,7142
	51	0,1338	-51,1308	0,7057
	24	0,1474	-45,5998	0,6886
	53	0,1511	-44,1946	0,6844
	19	0,1519	-44,9636	0,6809
	75	0,1442	-72,9032	0,6793
Eğitim	<b>70</b>	<b>0,0827</b>	<b>-15,6840</b>	<b>0,6853</b>
	78	0,0845	-9,5499	0,6759
	88	0,0799	-21,7714	0,6894
	36	0,0810	-24,4859	0,6833
	33	0,0800	-26,9557	0,6860
	51	0,0823	-26,1422	0,6747
	24	0,0787	-22,3857	0,6938
	53	0,0793	-15,0560	0,6953
	19	0,0769	-20,9433	0,7033
	75	0,0776	-35,2629	0,6990

**Tablo 9.** Analizde Kullanılan Özellikler

Ad	Açıklama	Min.	Maks.	Ortalama	SD
Gönderi	Volkswagen Facebook Marka sayfasında oluşturulan aylık gönderi sayısı	8	88	31,49	11,30
Beğenme	Aylık ortalama Beğenme	543	18618	5254,71	3541,18
Yorum	Aylık ortalama Yorum	33	1640	185,57	210,39
Paylaşma	Aylık ortalama Paylaşma	57	652	198,50	119,03
Trend	Google Trends'te elde edilen Türkiye'deki "Volkswagen" arama sayısı	49	96	71,01	9,34
Satışlar	Aylık satış	2792	14539	7480,47	2364,10
Ay Bilgisi	Kaçıncı ay olduğu bilgisi (kategorik veri)				

. Bu aşda korelasyon değeri, test için 0,7438 çıkarken eğitimde 0,6853 bulunmuştur. Korelasyon değerinin 0.6 ile 0.8 arasında olması güçlü korelasyon olduğunu göstermektedir. Bu bağlamda eğitim ve test verileriyle yapılan analiz neticesinde gerçek değer ile tahmin edilen değer arasında güçlü korelasyon olduğu gözlenmiştir. Aynı zamanda MAPE değeri test için %-1, eğitim için ise %15'tir. Eğitim ve Test regresyon grafikleri Şekil 5.'te verilmiştir.

**Şekil 5.** Test-Eğitim Verilerinin Tahmin-Gerçek Değer Arasındaki Korelasyon Grafiği

## 5. TARTIŞMA

Otomobil üretimden tüketime kadar ülke, işletme veya tüketici açısından ayrı önemi bulunmaktadır. Otomobil üretimi ve satışı birçok sektöre etki ediyor olması nedeniyle ülke ekonomilerinde önemli yere sahiptir. İşletmeler açısından ise otomobilin satılabilecek miktardan fazla veya az üretimi istenilen kârın elde edilmemesine, zarar edilmesine, eksik kapasite kullanımına neden olabilmektedir. Tüketiciler ise beğenmeli bir ürün olması ve kolayda ürünlere göre maliyetinin fazla olması nedeniyle değer vermektedir. Bu bağlamda, otomobil satışlarının tahmininde tesir ettiği ülke, işletme ve tüketici verileri kullanılabilir.

Otomobil satışlarında ülke genelinde ekonomik veriler olan gayri safi milli hasıla, tüketici fiyat endeksi, reel sektör güven endeksi, aylık çalışma saati, üretilmiş model sayısı, Amerikan doları

takas değeri, kayıtlı araç sayısı gibi veriler ile yapılan yapay sinir ağları kullanılarak başarılı satış tahminlemesi yapılabilmektedir (Arslankaya ve Öz, 2018).

İşletmelerin yaptıkları satışlara ait veriler ile tahminleme de yapabilmektedirler. Örneğin geçmiş satış verileri kullanılarak satışlar tahmin edilebilmektedir (Apiwattanachai ve Pichitlamken, 2010). Diğer bir veri kaynağı olarak ise tüketicilere ait kayıtlar kişilerden gerekli izinler alınarak kullanılabilir. Tüketici verilerinin kullanılmasında izin alınmasına ihtiyaç duyulmadan kullanılabilir kaynaklarda mevcuttur.

Tüketicilerin işletmeyle ve sosyal medya üzerinden bütünleşmesi ve internet üzerinden yaptıkları aramalara ilişkin kayıtlar herkese açık olarak sunulmaktadır. Sektör bazlı olarak bu verilerin kullanma ihtimali artmakta veya azalmaktadır. Otomobil sektörü tüketicilerin sosyal medyadaki ve internet arama motorlarındaki davranışları açısından avantajlıdır. Tüketiciler sosyal medyada otomobil işletmeleriyle yoğun bütünleşmekte ve internet arama motorlarında sıklıkla arama yapmaktadırlar. İşletmeler tüketicilere ilişkin bu verileri kullanarak başarılı tahminleme yapabilmektedir.

Otomobil işletmelerinin sosyal medya ve internet arama motoru verilerini kullanarak herhangi bir izne ihtiyaç duymadan kendisi, rakipleri veya sektör genelinde tahminlemede bulunulması mümkün görülmektedir. İşletmelerin tüketici verileriyle sektör genelden özele kadar yapılacak tahminlemeler ile taktik ve operasyonel seviye yapılan hamlelerin başarısına katkı sağlayabilecektir. Diğer veri kaynaklarından alınan veriler ile daha performans elde edilmesi mümkün olmakla birlikte en az veriyle başarılı sonuçlar elde edilmesi işlemleri kolaylaştıracak gereken zamanı azaltacaktır.

## 6. SONUÇ

Çalışmada, tüketicilerin hayatlarında önemli yeri olan sosyal medya ile bilgiye erişmekte sıklıkla başvurdukları arama motoru verileri yapay sinir ağları yönetimi ile analiz edilerek bir otomobil firmasına yönelik satış tahmini yapılmıştır.

İşletme akademik alanında sıklıkla mühendis alanında kullanılan yapay sinir ağlarıyla analiz yapılarak çok disiplinli bir çalışma ortaya çıkarılmıştır. Sosyal bilimlerde yazınında yapay sinir ağları ile yapılan tahminlemelerde %60 korelasyon değerinin kabul edildiği görülmektedir (Atsalakis, Atsalaki ve Zopounidis, 2018; King, Abrahams ve Ragsdale, 2014). Bu çalışma bulunan korelasyon %74 ile kabul edilebilir değerin üzerindedir. Ayrıca %1'lik ortalama hata değeri ile sistem modellenmiştir. Bu bağlamda, oluşturulan model ile başarı ile satış tahmini yapıldığı görülmektedir.

Ayrıca, firmanın Facebook marka sayfasında yapılan veri analizi ile 6 yıl boyunca 2267 gönderinin beğeni, yorum ve paylaşma sayılarının toplanması ve derlenmesinin uzun bir süreçteki işlemlerin özeti olarak işletmelere faydası olacağı değerlendirilmektedir. Örneğin çok sayıda gönderi oluşturmanın her durumda çok sayıda beğeni, yorum ve paylaşım almayacağı Tablo 2.'de görülmektedir. Diğer bir örnek olarak ise gönderilerde içeriğin iyi belirlenmesinin tüketici bütünleşmesine katkı sağladığıdır. Küresel olarak sevilen eski bir model (Volkswagen, Beetle) ile popüler bir sinemanın (Stars Wars, Rogue One) bir araya getirilerek yeni model (yeni Beetle) tanıtımının yapıldığı gönderi en çok beğeni alan gönderidir. İçerik oluştururken diğer popüler yaklaşımlardan (sinema, müzik vb.) fayda sağlaması muhtemeldir.

Çalışmanın diğer bir avantajı ise analizin tüketicilerin kişisel bilgilerine ihtiyaç duyulmadan yapılmasıdır. İşletmeler kullanılan halka açık veriler ile kendi işletmelerinin yanında rakip işletmeler ve geniş kapsamlı çalışma ile sektöre yönelik satış tahmininde bulunabilirler. . Bu sayede işletmelerin etik veya kanun dışı girişimlerde bulunmadan da bazı tahminlemeleri kolayca yapabilmelerinin mümkün olduğu görülmüştür.

Satış miktarını doğru tahmin etme, hammadde alımından, kapasite kullanımı ve ödeme dengesine kadar birçok konuda etkili olmaktadır. Satış miktarının tespitinde akademik yayında arama motoru ve bazı sosyal medya sitelerine ilişkin verilerle satış tahminlemesi yapılmış olmakla birlikte en yaygın kullanıma sahip Facebook ve Google arama verilerinin yapay sinir ağlarıyla analiz edildiği kısıtlı çalışmaya katkı sağlanmıştır. Otomobil sektörü üretiminde çelikten tekstile kadar

birçok hammaddeyi barındırmaktadır. Başarılı satış tahmini yapılması ise birçok sektörü etkilemektedir. İşletmelerdeki uzmanların diğer verilerin yanında kolaylıkla elde edebileceği Facebook marka sayfası ve arama motoru verilerini satış tahmininin de kullanabilecekleri çalışmada görülmektedir. Mevcut verilere ek olarak sosyal medya sitelerinin sunduğu bazı raporlarla birleştirilerek daha iyi performansa sahip satış tahminleri yapmaları muhtemel görülmektedir.

Gelecek çalışmalarda, diğer sektörlerde ve diğer sosyal medya araçları kullanılarak veri çeşitlendirilerek satış miktarı tahminlemesi yapılması mümkündür. Ayrıca Google arama verilerinde birden çok arama verisi kullanılarak sektörün geneline hitap eden çalışmalar yapılabilir.

## KAYNAKÇA

- Ahn, H. il ve Spangler, W. S. (2014). Sales Prediction With Social Media Analysis. *Annual SRII Global Conference, SRII*, 213–222. doi:10.1109/SRII.2014.37
- Apiwattanachai, T. ve Pichitlamken, J. (2010). Forecasting Model For Automobile Sales In Thailand. *National Institute of Development Administration*, 52(25), 298–303.
- Arslankaya, S. ve Öz, V. (2018). Time Series Analysis Of Sales Quantity In An Automotive Company And Estimation By Artificial Neural Networks. *Sakarya University Journal Of Science*, 22(5), 1–1. doi:10.16984/saufenbilder.456518
- Aşkın, D., İskender, İ. ve Mamızadeh, A. (2011). Farklı Yapay Sinir Ağları Yöntemlerini Kullanarak Kuru Tip Transformatör Sargısının Termal Analizi, 26(4), 905–913.
- Atsalakis, G. S., Atsalaki, I. G. ve Zopounidis, C. (2018). Forecasting The Success Of A New Tourism Service By A Neuro-Fuzzy Technique. *European Journal Of Operational Research*, 268(2), 716–727. doi:10.1016/j.ejor.2018.01.044
- Barreira, N., Godinho, P. ve Melo, P. (2013). Nowcasting Unemployment Rate And New Car Sales In South-Western Europe With Google Trends. *NETNOMICS: Economic Research And Electronic Networking*, 14(3), 129–165. doi:10.1007/s11066-013-9082-8
- Berthon, P. R., Pitt, L. F., Plangger, K. ve Shapiro, D. (2012). Marketing Meets Web 2.0, Social Media, And Creative Consumers: Implications For International Marketing Strategy. *Business Horizons*, 55(3), 261–271. doi:10.1016/j.bushor.2012.01.007
- Caner, E. (2012). Türkiye’de Facebook Kullanıcı Sayısı Hangi Durumlarda Artar?
- Cerit, I., Yıldırım, A., Ucar, M. K., Demirkol, A., Cosansu, S. ve Demirkol, O. (2017). Estimation Of Antioxidant Activity Of Foods Using Artificial Neural Networks. *Journal of Food and Nutrition Research*, 56(2), 138–148.
- Choi, H. ve Varian, H. (2012). Predicting The Present With Google Trends. *Economic Record*, 88(SUPPL.1), 2–9. doi:10.1111/j.1475-4932.2012.00809.x
- Chopra, S., Yadav, D. ve Chopra, A. N. (2019). International Journal Of Swarm Intelligence And Evolutionary Computation Artificial Neural Networks Based Indian Stock Market Price Prediction : Before and After Demonetization, 8(1), 1–7. doi:10.4172/2090-4908.1000174
- Chu, S. C. ve Kim, Y. (2011). Determinants Of Consumer Engagement In Electronic Word-Of-Mouth (eWOM) In Social Networking Sites. *International Journal of Advertising*, 30(1). doi:10.2501/IJA-30-1-047-075
- Çuhadar, M. ve Kayacan, C. (2005). Yapay Sinir Ağları Kullanılarak Konaklama İşletmelerinde Doluluk Oranı Tahmini : Türkiye’deki Konaklama İşletmeleri Üzerine Bir Deneme, 24–30.
- Cunha, M. da. (2019). 5 Reasons You Should Be Advertising On Facebook. *wordstream.com*. 8 Nisan 2019 tarihinde <https://www.wordstream.com/blog/ws/2015/10/14/advertising-on-facebook> adresinden erişildi.
- Cvijikj, I. P. ve Michahelles, F. (2013). Online Engagement Factors On Facebook Brand Pages. *Social Network Analysis And Mining*, 3(4), 843–861. doi:10.1007/s13278-013-0098-8
- De Vries, L., Gensler, S. ve Leeflang, P. S. H. (2012). Popularity Of Brand Posts On Brand Fan Pages: An Investigation Of The Effects Of Social Media Marketing. *Journal Of Interactive Marketing*, 26(2), 83–91. doi:10.1016/j.intmar.2012.01.003
- Ding, X., Liu, T., Duan, J. ve Nie, J.-Y. (2015). Mining User Consumption Intention From Social Media Using Domain Adaptive Convolutional Neural Network. *Proceedings Of The 29th AAAI Conference On Artificial Intelligence (AAAI’15)*, 2389–2395.
- Doğru, F. (2015). Güncel Optimizasyon Yöntemleri Kullanılarak Rezidüel Gravite Anomalilerinden Parametre Kestirimi. *Yerbilimleri/Hacettepe Üniversitesi Yerbilimleri Uygulama Ve Araştırma Merkezi Dergisi*, 36(1), 31–43. doi:10.17824/yrb.71895
- Doorn, J. van, Lemon, K. N., Mittal, V., Nass, S., Pick, D., Pirner, P. ve Verhoef, P. C. (2010). Customer

- Engagement Behavior: Theoretical Foundations And Research Directions. *Journal Of Service Research*, 13(3), 253–266. doi:10.1177/1094670510375599
- Ellison, N. B. ve Boyd, D. (2007). Social Network Sites: Definition, History, And Scholarship. *Journal of Computer-Mediated Communication*, 210–230. doi:10.1111/j.1083-6101.2007.00393.x
- Etter, M. ve Fieseler, C. (2010). On Relational Capital In Social Media. *Studies In Communication Sciences*, 10(2), 167–189.
- Forrester Consulting. (2008). How Engaged Are Your Customers?, (September), 1–22. [http://www.indigopacific.com/pdf/Forrester\\_TLP\\_How\\_Engaged\\_Are\\_Your\\_Customers.pdf](http://www.indigopacific.com/pdf/Forrester_TLP_How_Engaged_Are_Your_Customers.pdf) adresinden erişildi.
- Funk, T. (2010). *Advanced Social Media Marketing: How To Lead, Launch, And Manage A Successful Social Media Program*. Press.
- Gordini, N., Sanpaolo, I. ve Veglio, V. (2015). *Customer Relationship Management And Data Mining : A Classification Decision Tree To Predict Customer Purchasing Behavior In Global Market*. doi:10.4018/978-1-4666-4450-2.ch001
- Günaydın, K. ve Günaydın, A. (2008). Peak Ground Acceleration Prediction By Artificial Neural Networks For Northwestern Turkey. *Mathematical Problems In Engineering*, 2008. doi:10.1155/2008/919420
- Gupta, R. ve Pathak, C. (2014). A Machine Learning Framework For Predicting Purchase By Online Customers Based On Dynamic Pricing. *Procedia - Procedia Computer Science*, 36, 599–605. doi:10.1016/j.procs.2014.09.060
- Hapsari, R., Clemes, M. D. ve Dean, D. (2017). The Impact Of Service Quality, Customer Engagement And Selected Marketing Constructs On Airline Passenger Loyalty. *International Journal of Quality and Service Sciences*, 9(1), 21–40. doi:10.1108/IJQSS-07-2016-0048
- Haykin, S. (1999). *Neural Networks: A Comprehensive Foundation, 2nd ed.* Englewood Cliffs, NJ.: Prentice-Hall.
- Hollebeek, L. (2011). Exploring Customer Brand Engagement: Definition And Themes. *Journal Of Strategic Marketing*, 19(7), 555–573. doi:10.1080/0965254X.2011.599493
- Jayalakshmi, T. ve Santhakumaran, A. (2011). Statistical Normalization And Back Propagation For Classification. *International Journal Of Computer Theory And Engineering*, 3(1), 89–93. doi:10.7763/IJCTE.2011.V3.288
- Ji, Y. G., Li, C., North, M. ve Liu, J. (2017). Staking Reputation On Stakeholders: How Does Stakeholders' Facebook Engagement Help Or Ruin A Company's Reputation? *Public Relations Review*, 43(1), 201–210. doi:10.1016/j.pubrev.2016.12.004
- Kelleher, T. (2009). Conversational Voice, Communicated Commitment, And Public Relations Outcomes In Interactive Online Communication. *Journal Of Communication*, 59(1), 172–188. doi:10.1111/j.1460-2466.2008.01410.x
- Kim, H. W., Gupta, S. ve Koh, J. (2011). Investigating The Intention To Purchase Digital Items In Social Networking Communities: A Customer Value Perspective. *Information And Management*, 48(6), 228–234. doi:10.1016/j.im.2011.05.004
- King, M. A., Abrahams, A. S. ve Ragsdale, C. T. (2014). Ensemble Methods For Advanced Skier Days Prediction. *Expert Systems With Applications*, 41(4), 1176–1188. doi:10.1016/J.ESWA.2013.08.002
- Kotler, P., Keller, K. L. (2012). *Marketing Management 14E*. New York: Pearson Education Inc.
- Lassen, N. B., Madsen, R. ve Vatrapu, R. (2014). Predicting iPhone Sales From iPhone Tweets. *Proceedings . IEEE 18th International Enterprise Distributed Object Computing Conference, 2014–Decem*(December), 81–90. doi:10.1109/EDOC.2014.20
- MacKay, D. J. C. (1992). A Practical Bayesian Framework For Backpropagation Networks. *EFSA Journal*, 4, 448–472. doi:10.2903/j.efsa.2018.5430
- McCulloch, A. (2015). Measuring The Right Social KPIs. *SocialBakers*. 2 Mart 2018 tarihinde <https://www.socialbakers.com/blog/2384-measuring-the-right-social-kpis> adresinden erişildi.
- Mudambi, S. M. ve Schuff, D. (2010). What Makes A Helpful Online Review? A Study Of Customer Reviews On Amazon.com. *MIS Quarterly*, 34(1), 185–200. doi:Article
- ODD. (2017). 2017 Yılı (Ocak-Aralık) Perakende Satışlar (Yerli&İthal). *Otomotiv Distribütörleri Derneği*. 5 Ağustos 2019 tarihinde [http://www.odd.org.tr/web\\_2837\\_1/sortial.aspx?linkpos=3&target=categorial1&type=36&primary\\_id=&detail=single&sp\\_table=&sp\\_primary=&sp\\_fields=&sp\\_language=&sp\\_table\\_extra=&extracriteria=&language\\_id=1&search\\_fields=&search\\_values=](http://www.odd.org.tr/web_2837_1/sortial.aspx?linkpos=3&target=categorial1&type=36&primary_id=&detail=single&sp_table=&sp_primary=&sp_fields=&sp_language=&sp_table_extra=&extracriteria=&language_id=1&search_fields=&search_values=) adresinden erişildi.
- Park, S. ve Huh, S. (2019). A Social Network-Based Inference Model For Validating Customer Profile Data, 36(4), 1217–1237.
- Poel, D. Van Den ve Buckinx, W. (2005). Predicting Online-Purchasing Behaviour, 166, 557–575. doi:10.1016/j.ejor.2004.04.022

- Qiu, J., Lin, Z. ve Li, Y. (2015). Predicting Customer Purchase Behavior In The E-Commerce Context. *Electronic Commerce Research*, 15(4), 427–452. doi:10.1007/s10660-015-9191-6
- Richter, D., Riemer, K. ve vom Brocke, J. (2011). Internet Social Networking. *Wirtschaftsinformatik*, 53(2), 89–103.
- Rybalko, S. ve Seltzer, T. (2010). Dialogic Communication In 140 Characters Or Less: How Fortune 500 Companies Engage Stakeholders Using Twitter. *Public Relations Review*, 36(4), 336–341. doi:10.1016/j.pubrev.2010.08.004
- Sakar, C. O., Polat, S. O., Katircioglu, M. ve Kastro, Y. (2018). Real-Time Prediction Of Online Shoppers ' Purchasing Intention Using Multilayer Perceptron And LSTM Recurrent Neural Networks. *Neural Computing And Applications*, 0. doi:10.1007/s00521-018-3523-0
- Schmidt, T. ve Vosen, S. (2009). Forecasting Private Consumption. *Economic Papers*, 155, 23.
- Search Engine Market Share Worldwide. (2019). *statcounter.com*. 28 Temmuz 2019 tarihinde <http://gs.statcounter.com/search-engine-market-share> adresinden erişildi.
- Si, S. (2016). Social Media And Its Role In Marketing. *Business and Economics Journal*, 07(01), 1–5. doi:10.4172/2151-6219.1000203
- Sismeiro, C. ve Bucklin, R. E. (2004). Modeling Purchase Behavior At An E-Commerce Web Site: A Task Completion Approach Catarina Sismeiro And Randolph E. Bucklin 1. *Journal of Marketing Research*, 41(3), 306–323.
- Sola, J. ve Sevilla, J. (1997). Importance Of Input Data Normalization For The Application Of Neural Networks To Complex Industrial Problems, 44(3), 1464–1468.
- Stelzner, M. A. (2014). 2014 Social Media Marketing Industry Report. *How Marketers Are Using Social Media To Grow Their Businesses*, (May), 1–52. [papers3://publication/uuid/C53C1FA9-9CA1-430B-8E0E-89CAE65678A2](https://papers3://publication/uuid/C53C1FA9-9CA1-430B-8E0E-89CAE65678A2) adresinden erişildi.
- Sullivan, D. (2016). Google Now Handles At Least 2 Trillion Searches Per Year. *Search Engine Land*. 28 Temmuz 2019 tarihinde <https://searchengineland.com/google-now-handles-2-999-trillion-searches-per-year-250247> adresinden erişildi.
- Tkáč, M. ve Verner, R. (2016). Artificial Neural Networks In Business: Two Decades Of Research. *Applied Soft Computing Journal*, 38, 788–804. doi:10.1016/j.asoc.2015.09.040
- Vellido, A., Lisboa, P. J. G. ve Meehan, K. (2015). Quantitative Characterization And Prediction Of On-Line Purchasing Behavior : A Latent Variable Approach Approach, 4415. doi:10.1080/10864415.2000.11518380
- Wang, X., Yu, C. ve Wei, Y. (2012). Social Media Peer Communication And Impacts On Purchase Intentions: A Consumer Socialization Framework. *Journal Of Interactive Marketing*, 26(4), 198–208. doi:10.1016/j.intmar.2011.11.004
- We Are Social. (2018). Digital In 2018: World's Internet Users Pass The 4 Billion Mark. *January*, (January), 153. <https://wearesocial.com/uk/blog/2018/01/global-digital-report-2018> adresinden erişildi.
- Wu, L. ve Brynjolfsson, E. (2015). *Volume Title : Economic Analysis Of The Digital Economy Publication Date : April 2015 Chapter Title : The Future Of Prediction : How Google Searches Foreshadow Housing Prices And Sales*. doi:10.3386/w19549
- Yadav, M. S., de Valck, K., Hennig-Thurau, T., Hoffman, D. L. ve Spann, M. (2013). Social Commerce: A Contingency Framework For Assessing Marketing Potential. *Journal of Interactive Marketing*, 27(4), 311–323. doi:10.1016/j.intmar.2013.09.001
- Yang, S. U., Kang, M. ve Johnson, P. (2010). Effects Of Narratives, Openness To Dialogic Communication, And Credibility On Engagement In Crisis Communication Through Organizational Blogs. *Communication Research*, 37(4), 473–497. doi:10.1177/0093650210362682
- Yu, L., Wang, S. ve Lai, K. K. (2007). *Foreign-Exchange-Rate Forecasting With Artificial Neural Networks*. *Springer Science & Business Media*.
- Zhang, Z. (2018). *Multivariate Time Series Analysis In Climate And Environmental Research*. Beijing China: Springer. doi:10.1007/978-3-319-67340-0



## EXTENDED SUMMARY

### Purpose

Businesses want to estimate the sales figures as accurate as possible and thus seize the advantages. However, it is a problem that businesses cannot use private information or demand permission from consumers in estimating. On the other hand, consumers can express their thoughts about products, services, brands or businesses by simply liking, commenting and sharing on social media. The transactions that can be considered as the consumers' response to the posts made by the brand pages of the firm constitute the online consumer engagement (OCE). OCE with consumers in the automobile industry is high. On the other hand, internet search engines are often used for consumers to search for information before purchasing products or services. Since automobile is a product that has a preferable/optional and social status, as well as having technical features, it is frequently searched on the internet before the purchase. Both social networking and search engine data are publicly available. This data can be used easily without any restrictions on businesses. In this context, it is aimed to estimate the sales volume of an automobile brand by using OCE and search engine data that are effective and publicly available in the purchasing decision process of consumers.

### Methodology

Facebook is an ideal communication platform for businesses and consumers and allows for consumer engagement. At the same time, because it is the most used social network with 48 million users in Turkey, Facebook was chosen for the study.

The automobile is one of the sectors where online consumer integration is intense. Volkswagen is the second best-selling company with 89,688 units in Turkey as of 2017. In the same period, Volkswagen Facebook brand page, with 4 million followers, was the most followed company. Therefore, Volkswagen was chosen in the study.

In the study, the data between the years 2012-2017 on Volkswagen's Facebook brand page were taken with Facebook Graph API. A total of 2267 posts and their likes, comments, and sharing data have been downloaded.

Google has 90% of the search engine market. It provides search data in Google Trends. Search engine data for "Volkswagen" between 2012-2017 were obtained from Google Trends.

Automobile sales data is taken from the Automotive Distributors Association website.

Data were normalized with Min-Max method for better performance in artificial intelligence methods.

An artificial neural network (ANN), which is one of the methods of artificial intelligence, has a structure similar to the neurons in the human brain. ANN consists of input, hidden and output layer. In feedforward networks, the number of neurons in the input layer is determined by the type of input data and the estimated data in the output layer. Experiments are performed to see how many neurons are best used in the hidden layer. The study also tested the numbers of 1-100 neurons in the hidden layer. In addition, the backpropagation method was used to improve the performance of the network. Backpropagation is the attempt to reduce the difference between the actual value and the predicted value by going backward in the network and changing neuron weights. Although there are a wide variety of back-propagation methods, the study has also been preferred to the widely used Bayesian Regulation method.

### Findings

In the study, it is known the number of neurons in the input and output layers of the network. The hidden layer's neurons were tested from 1 to 100 for the best performance of the network. As a result, the hidden layer of 70 neurons had the best values. As a result of the estimation, 74% correlation was found between the actual value and the estimated value. As a result of the model, MAPE value which is the average of the difference between the real value and the estimated values was found to be -1%. The average of the error squares was determined as 0.1543.

In the descriptive analysis posts, likes, comments, sharing, search engine, and sales data for 2012-2017 were given. In this data, it was observed that the number of comments and shares were

inconsistent, but the number of likes increased. The maximum number of posts created by the business is in 2012. Sales figures declined slightly in 2016. The nine posts which were the most liked, commented and shared over a 6 year period were listed.

### **Conclusion and Discussion**

In this study, data obtained from the search engine, which was frequently used to access information, and the social media, which enables consumer engagement are analyzed with artificial neural network management and sales forecast is made for an automobile company.

In the business administration, a multidisciplinary study was developed by using the artificial neural networks which are frequently used in engineering. As a result of the analysis, the sales estimate correlation value is %74. The accepted value in artificial intelligence applications used in social sciences is more than %60. In addition, the system is modeled with an average error value of 1%. In this context, it is seen that sales forecast is made successfully with the model created.

In addition, data mining on the Facebook brand page of the company evaluates that collecting and compiling the number of likes, comments and shares of 2,267 posts for 6 years will be a benefit for the firms as a summary of the long-term transactions.

For example, increasing the number of posts and likes, comments and sharing is not expected to increase. In addition, combining models that are popular, even if they are old, with other popular approaches may increase engagement.

Another contribution of the study is that it doesn't need the personal information of consumers. Valuable information for businesses was obtained using publicly available information. In this way, it is seen that it is possible for firms to make some estimates easily without making ethical or illegal initiatives.

Accurate estimation of sales volume is crucial in many aspects such as raw material purchase to capacity utilization and payment balance. In this context, public data and data mining and artificial intelligence methods have contributed to both the academic and the sector.