

T.C.
GEBZE TEKNİK ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ

OTOMOBİL SATIŞLARININ YAPAY SİNİR AĞLARI İLE
TAHMİNİ VE REGRESYON ANALİZİNE GÖRE
BAŞARISININ İNCELENMESİ

MERT TEKİN
YÜKSEK LİSANS TEZİ
İŞLETME ANABİLİM DALI

GEBZE
2023

T.C.
GEBZE TEKNİK ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ

OTOMOBİL SATIŞLARININ YAPAY SİNİR
AĞLARI İLE TAHMİNİ VE REGRESYON
ANALİZİNE GÖRE BAŞARISININ
İNCELENMESİ

MERT TEKİN
YÜKSEK LİSANS TEZİ
İŞLETME ANABİLİM DALI

Tez Danışmanı
Prof. Dr. Bülent SEZEN

GEBZE
2023

GTÜ Sosyal Bilimler Enstitüsü Yönetim Kurulu'nun 03/05/2023 tarih ve .2023 /17-01 sayılı kararıyla oluşturulan jüri tarafından 25/05/2023 tarihinde tez savunma sınavı yapılan Mert Tekin'in tez çalışması İşletme Anabilim Dalında YÜKSEK LİSANS tezi olarak kabul edilmiştir.

JÜRİ

ÜYE

(TEZ DANIŞMANI) : Prof. Dr. Bülent Sezen

ÜYE

: Prof. Dr. Hakan Kitapçı

ÜYE

: Doç. Dr. Tolga Mert

ONAY

Gebze Teknik Üniversitesi Enstitüsü Yönetim Kurulu'nun
...../...../..... tarih ve/..... sayılı kararı.

ÖZET

Müşteri ihtiyaçlarının zamanında karşılanması, müşteri memnuniyeti üzerinde büyük bir etkiye sahiptir ve bu sebeple planlama süreci, satış faaliyetlerinin başarısını doğrudan etkilemektedir. Satış tahminleri, planlama sürecinin satışlar üzerindeki başarısının en kritik unsurlarından biridir.

Şirketlerin satışları tahmin etme becerisi, sektörlerindeki performanslarının üst düzeyde olmasına katkıda bulunur. Bu nedenle, şirketler rekabette öne geçmek için çeşitli stratejiler benimser. Satışların geleceğini başarılı bir şekilde tahmin etmek, sadece satış performansını artırmalarına yardımcı olmakla kalmaz, aynı zamanda işi etkin bir şekilde yönetmelerine de imkan tanır. Erken uyarı göstergelerini ve riskleri belirlemek, satış sürecinde büyük önem taşır. Satış tahminleri, müşterilerin talep ettiği miktarları öngörmeye çalışır. Kampanyalar, fiyatlandırma, marka ve ürün iletişimi ve dağıtım kanalları, satış tahminlerine göre şekillendirilerek hedeflerin gerçekleştirilmesine destek olur.

Bu akademik çalışmada, Türkiye'deki otomobil satışlarını tahmin etmek amacıyla regresyon ve yapay sinir ağları (YSA) yöntemleri kullanılarak tahminler gerçekleştirilmiştir. Regresyon yöntemi, kapsamlı bir şekilde incelenmiş olup, geriye doğru eleme yöntemi ile en başarılı tahminler elde edilmiştir. Yapay sinir ağları yöntemi ise, çeşitli iterasyonlarla performansı optimize edilerek, en başarılı sonuçları verecek şekilde eğitilmiştir. İki farklı yöntemle elde edilen sonuçlar karşılaştırılmış ve en başarılı yöntem belirlenmiştir. Çalışmanın sonucunda, Türkiye'deki otomobil satışları tahmin edilmiş ve 2020 yılı gerçek satışlarıyla karşılaştırılarak değerlendirilmiştir. Bu analizler, otomobil sektörüne yönelik daha doğru ve etkili stratejiler geliştirilmesine katkıda bulunabilecek bilgilere ışık tutmaktadır.

Anahtar Kelimeler: Satış Tahmini, Yapay Sinir Ağları

SUMMARY

Meeting customer needs in a timely manner has a significant impact on customer satisfaction, and therefore, the planning process directly affects the success of sales activities. Sales forecasts are one of the most critical factors in the success of the planning process on sales.

The ability of companies to predict sales contributes to their high-level performance within their industries. As a result, companies adopt various strategies to stay ahead in competition. Successfully predicting the future of sales not only helps to improve sales performance but also allows for effective management of the business. Identifying early warning indicators and risks is of great importance in the sales process. Sales forecasts attempt to anticipate the quantities demanded by customers. Campaigns, pricing, brand and product communication, and distribution channels are shaped according to sales forecasts, supporting the achievement of targets.

In this academic study, regression and artificial neural networks (ANN) methods were used to make predictions for the purpose of estimating automobile sales in Turkey. The regression method has been thoroughly examined, and the most successful predictions have been obtained using the backward elimination method. The artificial neural networks method, on the other hand, has been trained to provide the most successful results by optimizing performance through various iterations. The results obtained from the two different methods were compared, and the most successful method was determined. As a result of the study, automobile sales in Turkey were predicted, and the estimations were evaluated by comparing them to the actual sales figures in 2020. These analyses shed light on information that can contribute to the development of more accurate and effective strategies for the automobile sector.

Keywords: Sales Prediction, Artificial Neural Network

TEŞEKKÜR

Yüksek lisans sürecim boyunca bu çalışmanın gerçekleştirilmesine deneyimi ve bilgisiyle katkıda bulunan değerli danışmanım Prof. Dr. Bülent Sezen'e, Ürün Geliştirme Mühendisi olarak görev yaptığım dönemdeki eski yöneticim Sayın Melih Zafer'e ve satış & pazarlama alanıyla tanışmamı sağlayarak tecrübeleriyle büyük katkılar sunan eski yöneticim Sayın Kenan Bilirgen'e içtenlikle teşekkür ediyorum. Ayrıca, eğitim hayatım süresince bana sağladıkları destekle sürekli yanımda olan anneme ve hep kalbimde yaşayan anneanneme minnettarım. Hayatım boyunca motivasyonumu yüksek tutmamda önemli rol oynayan ve her konuda birbirimize destek olduğumuz sevgili kardeşim Alper Tekin'e sonsuz teşekkürlerimi sunarım.

İÇİNDEKİLER

ÖZET	iv
SUMMARY	v
TEŞEKKÜR	vi
ŞEKİLLER DİZİNİ	viii
TABLolar DİZİNİ	ix
1.1. Tezin Tanımı ve Amacı	1
1.2. Literatür Araştırması	2
2. TALEP TAHMİNİ	5
2.1. Talep Tahmini Nedir?	5
2.2. Talep Tahminini Etkileyen Faktörler	7
3. TALEP TAHMİN YÖNTEMLERİ	10
3.1. Nitel Yöntemler	10
3.1.1. Delphi Tekniği	10
3.1.2. Yöneticilerin Görüşlerinin Esas Alınması	10
3.1.3. Kilit Personelin Kararı	10
3.1.4. Senaryo Analizi	11
3.2. Nicel Yöntemler	11
3.2.1. Zaman Serileri Analizi	11
3.2.2. Nedensel Yöntemler	16
3.3. Yapay Zeka Destekli Yöntemler	20
3.3.1. Bulanık Mantık	20
3.3.2. Yapay Sinir Ağları	22
4. TALEP TAHMİN UYGULAMASI	30
4.1. Veri Kaynağı	31
4.2. Hesaplamalar	32
4.2.1. Regresyon Analizi Yöntemi Kullanılarak	32
4.2.2. Yapay Sinir Ağları Yöntemi Kullanılarak	41
5. HESAPLARIN DEĞERLENDİRİLMESİ	44
6. TARTIŞMA	51
7. SONUÇ	53
KAYNAKLAR	54
ÖZGEÇMİŞ	57

ŞEKİLLER DİZİNİ

<u>Şekil No:</u>	<u>Sayfa</u>
Şekil 1	22
Şekil 2	23
Şekil 3	24
Şekil 4	26
Şekil 5	26
Şekil 6	27
Şekil 7	27
Şekil 8	42
Şekil 9	45
Şekil 10	47
Şekil 11	47
Şekil 12	47
Şekil 13	48
Şekil 14	50

TABLÖLAR DİZİNİ

<u>Tablo No:</u>	<u>Sayfa</u>
Tablo 1	32
Tablo 2	32
Tablo 3	33
Tablo 4	34
Tablo 5	35
Tablo 6	36
Tablo 7	37
Tablo 8	38
Tablo 9	40
Tablo 10	43
Tablo 11	44
Tablo 12	49

GİRİŞ

1.1. Tezin Tanımı ve Amacı

Türkiye otomobil satışları tahmininde lineer regresyon ve yapay sinir ağları yöntemlerinin etkinliğini değerlendiren bu akademik çalışma, en uygun metodolojinin tespit edilmesi amacını gütmektedir.

Zamanında müşteri ihtiyaçlarını karşılamak ve erken uyarı göstergelerini belirlemek, şirketlerin satış performansı ve işletme yönetimi üzerinde doğrudan etkisi olan unsurlardır. Bu kapsamda, Türkiye'deki otomobil satışlarının öngörülmesi hedefiyle, bu tezde regresyon analizi ve yapay sinir ağları yöntemlerine başvurularak tahminler yapılmıştır. İlgili bağımsız değişkenlerin seçimi ve analizi, şirketlerin satış tahminlerini daha doğru ve güvenilir kılmaya yönelik potansiyele sahiptir.

Çalışma neticesinde, Türkiye'deki otomobil satışları öngörülmüş ve 2020 yılı gerçek satışları ile mukayeseli olarak değerlendirilmiştir. Bu mukayese, kullanılan yöntemlerin etkinliklerini değerlendirmede önemli bir ölçüt teşkil etmektedir. Elde edilen sonuçlar, lineer regresyon ve yapay sinir ağları yöntemlerinin otomobil satışları tahmininde başarılı sonuçlar sağlamak amacıyla kullanılabilir olduğunu göstermektedir.

Tezin temel amacı, Türkiye otomobil satışları için sistemli bir tahmin modeli geliştirmektir. Bu süreçte, en başarılı tahmin yöntemlerinin belirlenmesi ve uygulanması, şirketlerin rekabet üstünlüğü sağlamasına ve satış performansını artırmasına katkıda bulunacaktır. Bunun yanı sıra, bu çalışma, satış tahminlerinde kullanılan bağımsız değişkenlerin, otomobil satışlarındaki değişimin önemli bir bölümünü açıkladığını ortaya koymuştur. Bu tespitler, gelecekteki araştırmalarda satış tahminlerini daha doğru ve güvenilir kılmak amacıyla kullanılabilir.

Nihayetinde, bu tez, Türkiye otomobil satışları tahmininde lineer regresyon ve yapay sinir ağları yöntemlerinin etkinliğini değerlendiren önemli bir çalışma niteliğindedir. Bu süreçte, en uygun metodolojinin tespit edilmesi ve uygulanması, şirketlerin satış performansı ve iş yönetimi üzerinde doğrudan etkisi olan unsurlardır. Bu bağlamda, gelecekteki araştırmalarda bu yöntemlerin etkinliklerinin artırılması ve daha

doğru tahminler elde etmek amacıyla kullanılması öngörülmektedir. Ayrıca, bu çalışma, otomobil sektöründeki şirketlerin, farklı ekonomik ve sosyal faktörlerin etkisini daha iyi anlayarak, pazar trendlerine uyum sağlama ve stratejik kararlar alabilme yeteneklerini geliştirmelerine de katkıda bulunmaktadır.

Gelecekteki çalışmalarda bu yöntemlerin başarılarının artırılması ve daha doğru tahminler elde etmek için kullanılması, şirketlerin satış performansını ve iş yönetimini daha etkin hale getirme potansiyeline sahiptir. Bu bağlamda, Türkiye otomobil satışları tahminlerinde lineer regresyon ve yapay sinir ağları yöntemlerinin uygulanması ve geliştirilmesi, sektördeki şirketlerin rekabet gücünü artırarak, daha sürdürülebilir ve başarılı bir iş modeli oluşturmalarına yardımcı olacaktır.

1.2. Literatür Araştırması

Herrera ve ark. (2010), güneydoğu İspanya'da bir şehrin kentsel alanında su tüketimi ve talebinin tahmin edilmesine yönelik bir çalışma gerçekleştirmişlerdir. Modelleri, su tüketimi zaman serisi verileri kullanılarak oluşturulmuştur. Yapay sinir ağları (ANN), Projeksiyon arayüzü regresyonu (PPR), Çoklu değişkenli uyarlanabilir regresyon çizgileri (MARS), Destek vektör regresyonu (SVR), Rastgele tahmin ve Su talebini tahmin etmek için ağırlıklı desen tabanlı model gibi tüm tahmin modelleri deneysel bir yöntem kullanılarak değerlendirilmiştir, bu nedenle bu çalışma çok önemlidir.

Yücesoy (2011), yapay sinir ağlarının tanımlanması ve talep tahmini yanı sıra bu çalışma için bir uygulama da oluşturmuştur. Bu uygulama, Türkiye'de temizlik kağıdı satış hacminin yıllık olarak tahmin edilmesinde kullanılmaktadır. Bu çalışma için kullanılan veriler 1981'den 2010'a kadar olan dönemi kapsamaktadır ve bağımsız değişkenler üretim hacmi, ithalat hacmi, kağıt ve baskı endüstrisi fiyat endeksi, gayri safi yurtiçi hasıla, nüfus, kentsel nüfus ve okuryazarlık oranıdır. Ayrıca, basit regresyon, çoklu regresyon ve yapay sinir ağlarının performansı gösterilmiştir. Sonuç olarak, karşılaştırılan sonuçlar yapay sinir ağlarının tahmin için verimli bir araç olduğunu göstermektedir.

Wu ve Liu (2012), bu çalışmada, radyal baz fonksiyon ağı ve geriye yayımlı sinir ağı kullanarak bir araç yakıt tüketimi tahmin sistemi üzerinde çalışmışlardır. Hesaplamalar için kullanılan yakıt tüketimini etkileyen beş çeşit mühendislik değişkeni

bulunmaktadır. Bu çalışmanın sonucu, önerilen sinir ağı sisteminin yakıt tüketimini tahmin etmede etkili ve tatmin edici olduğudur.

Kılıç (2015) adlı araştırmacı, PAÜ yemekhanesinde günlük yemek talebini tahmin etme üzerine bir çalışma yapmıştır. Bu çalışma, veri hazırlama açısından diğerlerinden farklıdır. Akıllı kimlik veritabanı sistemi tüm verileri toplanmıştır. Veriler, SPSS kullanılarak işlenmiştir ve veriler arasındaki ilişki test edilmiştir. İlişkiye göre, veriler test ve eğitim yardımıyla iki bölüme ayrılmıştır. Sonuç olarak, araştırmacı yapay zeka yöntemleri ile daha iyi sonuçlar elde etmiştir.

Akyurt (2017) adlı bu çalışma, Türkiye'nin 2023 yılındaki otomobil üretim değerlerini tahmin etmeyi amaçlamıştır. Çalışmanın girdi değeri, Ocak 2011 ve Eylül 2015 arasındaki aylık satış rakamlarıdır. Bu zaman serisi talebini tahmin etmek için geri yayılım algoritması ile eğitilmiş bir besleme-ileri sinir ağı modeli kullanılmıştır. Modelin performansı, MAPE ve MSE kullanılarak ölçülmüştür.

Santoni et al., 2020 adlı çalışma ABD'de böbrek kanseri oluşumunu tahmin etmek için eğitilmiş bir sinir ağı oluşturmayı amaçlamıştır. Yöntemleri, hesaplama için üç katman seçmiştir ve gizli katmanın nöron sayısını beşle başlayarak arttırmıştır. Öğrenme performansına bir değer atamak için ortalama kare normalleştirilmiş hata performansı ve doğrusal regresyon için korelasyon katsayıları kullanılmıştır. Sonuçlar, hipertansiyonun önlenmesinin renal hücreli karsinom insidansını azaltmada en büyük etkiye sahip olduğunu göstermektedir. Buna karşılık, obezite ve sigaranın önlenmesi daha küçük bir etkiye sahip olacaktır.

Yazıcıoğlu, 2010 yılında otomotiv endüstrisinden verilerle çalışmıştır, ancak ana fark kullanılan veri aralığı ve odaklanılan veri setidir. Araştırmacı, Türkiye'deki otomobil üretim değerini tahmin etmeye odaklanmıştır. Bu ayrıca endüstriyel şirketlerin üretim öncesi aşamalarını yönetmelerine yardımcı olmak için çok yararlı olabilmektedir. Bu çalışmadaki bir diğer fark ise veri kapsamıdır. Bu alanlardaki çoğu çalışma, veri genişliğinin mümkün olduğunca büyük olması gerektiğini göstermektedir.

Wang ve diğerleri (2011), Tayvan'da otomobil satışlarının tahmin edilmesiyle ilgili bir çalışma yapmıştır. Çalışmada, mevcut otomobil satışları, tesadüf göstergesi, öncü gösterge, toptan fiyat endeksi ve gelir gibi birkaç bağımsız değişken kullanılmıştır.

Çalışmanın ilk adımı, ana çıktı değişkenlerini belirlemek için adımli regresyon analizidir. Daha sonra, değişkenler, girdi ve çıktılar adaptif ağ tabanlı bulanık çıkarım sistemi (ANFIS) içinde seçilir. Çalışmanın üçüncü adımı, bu modeli otoregresif entegre hareketli ortalama modeli (ARIMA) ve yapay sinir ağı (YSA) ile karşılaştırmaktır. Sonuç olarak, ANFIS yöntemiyle daha iyi sonuçlar elde edilmiştir.

Loureiro et al., 2018 adlı çalışma, moda endüstrisinde yeni ürünlerin gelecek sezonlarda satışlarını tahmin etmek için derin öğrenme yaklaşımının kullanılmasını araştırmaktadır. Beş farklı tahmin yöntemi kullanılmıştır: Karar Ağaçları, Rastgele Orman, Destek Vektör Regresyonu, Yapay Sinir Ağları ve Derin Sinir Ağları. Ayrıca, en iyi yöntemi belirlemek için her yöntem için bağımsız değişkenlerin çeşitlendirilmesi çalışması yapılmıştır. Çalışma diğerlerinden, bağımsız değişkenleri her yöntem için çeşitlendirmesiyle ayrılmaktadır. Çalışmanın sonucu: Doğruluk ölçüsü olarak R^2 kullanılırsa, Rastgele Orman en iyi teknik olarak kabul edilebilir. Hata ile ilgili metriklere dayalı olarak karar verildiğinde, Rastgele Orman ve Derin Sinir Ağı, her biri dört metriğin ikisi için en iyi sonuçları verdiğiinden, liderliği paylaşırlar.

Bu çalışma, konusu açısından diğerlerinden farklı olmasının yanı sıra regresyon analizinde kullanılan elemine etme yöntemi açısından da farklılık göstermektedir. Geriye doğru etkisiz bağımsız değişkenleri elemine etme sonuçları, tahmin için asla kullanılmamıştır. Ayrıca, ilgili diğer çalışmalar genellikle üretim miktarını tahmin etmeye odaklanırken, bu çalışmanın temel amacı miktar tabanlı satışlar ile ekonomik göstergeler arasındaki ilişkiyi açıklamaktır. Piyasanın genel resmini görmeyi amaçlamaktadır.

2. TALEP TAHMİNİ

2.1. Talep Tahmini Nedir?

Talep tahmini, belirli bir zaman diliminde müşteri talebine yönelik gelecekteki öngörülerin elde edilmesi süreci olarak tanımlanmaktadır. Genellikle, talep tahmini en doğru öngörülerin oluşturulması için geçmiş verilere ve diğer analitik bilgilere dayanır. Daha spesifik olarak, talep tahmini yöntemleri, temel ekonomik koşulları anlamak ve iş karlılığını optimize etmek amacıyla alınacak kritik tedarik kararlarına katkı sağlamak için, müşteri talebinin kavranması ve tahmin edilmesi adına geçmiş verilerin projeksiyon temelli analizini kullanır. Talep tahmini yöntemleri iki ana kategoriye ayrılır: nitel ve nicel yöntemler. Nitel yöntemler, uzman görüşleri ve sahadan elde edilen bilgilere dayanır ve genellikle analiz edilecek minimum verinin bulunduğu durumlarda kullanılır.

Örneğin, yeni bir işletme kurulduğunda veya piyasaya yeni bir ürün sürüldüğünde. Nicel yöntemler ise, tahminler oluşturmak için verileri ve analitik araçları kullanır. Talep tahmini, üretim planlaması, envanter yönetimi ve bazen gelecekteki kapasite ihtiyaçlarının değerlendirilmesinde veya yeni bir pazara girip girmeme kararının alınmasında kullanılabilir.

Talep tahmini, ticari faaliyetlerdeki riski azaltma konusunda farklı sektörlerdeki işletmeler için kritik bir rol oynar. Bununla birlikte, analiz süreçlerinin karmaşıklığı, özellikle nicel analiz nedeniyle şirketlerin karşılaştığı bir zorluktur. Müşteri ihtiyaçlarını anlamak, her sektörün ayrılmaz bir parçasıdır ve bu sayede iş planları daha etkin bir şekilde uygulanabilir ve pazar ihtiyaçlarına daha uygun yanıtlar verilebilir. İşletmeler talep tahmini konusunda uzmanlaştıkça, bu durum atıkların azaltılması, kaynakların daha uygun şekilde tahsis edilmesi ve satış ve gelirden potansiyel olarak önemli artışlar gibi çeşitli faydalara yol açar.

Daha detaylı olarak, işletmelerin talep tahminine ihtiyaç duydukları sebeplerden bazıları şunlardır:

- Hedeflere ulaşma: Başarılı organizasyonların çoğu, işletmenin optimum kapasitede çalışmasını sağlamak için önceden belirlenmiş büyüme yörüngelerine

ve uzun vadeli planlara sahiptir. İşletmeler, gelecekteki talep pazarlarını anlayarak, hedeflerin sektördeki büyüme eğilimleriyle uyumlu olmasını sağlamada proaktif olabilirler.

- İş kararları: Hedeflere ulaşma ile ilgili olarak, gelecekteki endüstri talebini tam olarak anlayarak, yönetim ve kilit yönetim kurulu üyeleri, daha yüksek karlılık ve iş büyümesi sağlayabilecek stratejik iş kararları alabilirler. Bu kararlar genellikle kapasite, pazar hedefleme, hammadde ve tedarikçi sözleşme yönetimi gibi kavramlarla ilişkilendirilir.

Büyüme: Şirketler, gelecekteki talep tahminlerini doğru bir şekilde anlayarak, maliyet etkin bir şekilde genişleme ihtiyaçlarını belirleyebilir ve zamanlamalarını planlayabilirler.

- İnsan sermayesi yönetimi: Talep tahminlerinin genellikle teknolojik gelişmeler ve üretim ile ilgili bilgileri içereceği düşünüldüğünde, işletmeler, çalışanların yeni teknoloji trendleri için uygun eğitime sahip olmasını sağlamak amacıyla eğitim planlamasından faydalanabilir. Bu, bir organizasyonun en verimli şekilde çalışmasına yardımcı olacaktır.
- Finansal planlama: Gelecekteki operasyonlar için etkin bir bütçe oluşturmak amacıyla talep tahminlerini anlamak büyük önem taşır. Güçlü talep tahminleri, gelecekteki potansiyel maliyetlerin ve gelirlerin ortaya çıkarılmasına yardımcı olacaktır.

Sonuç olarak, talep tahmini, işletmelerin büyüme, karlılık ve verimlilik açısından önemli faydalar sağlayan kritik bir süreçtir. İşletmelerin talep tahminlerine hakim olması ve bu bilgileri stratejik kararlarında kullanması, hem işletmenin kendisi hem de sektördeki genel performans için değerli sonuçlar doğuracaktır.

2.2. Talep Tahminini Etkileyen Faktörler

Talep tahmini, ürünlerin ne zaman, hangi miktarlarda ve hangi lokasyonlarda gereksinim duyulacağını öngörmeye yardımcı olan proaktif bir süreçtir. Bu süreci etkileyen birçok faktör bulunmaktadır.

Mal türleri, talep tahmini sürecini etkileyen önemli bir faktördür. Mallar, üretim malları, tüketim malları ve hizmetler olmak üzere sınıflandırılabilir; bunlar ise yerleşik ve yeni olarak ikiye ayrılır. Yerleşik mallar, piyasada mevcut olanlar; yeni mallar ise henüz piyasaya sunulmamış olanlardır.

Yerleşik mallar, talep, ikame ürünler ve rekabet seviyesi hakkında bilgilere erişebilirken, yeni mallar için talebi tahmin etmek daha zor olduğundan, tahminler farklı mal türleri için değişiklik gösterebilir.

Rekabet, talep tahmini sürecini etkileyen başka bir önemli faktördür. Rakiplerin sayısı, ürün talebini etkilemekte olup, yoğun rekabetin yaşandığı bir pazarda yeni girişimciler her zaman risk taşır. Bu durumda, talep tahmini daha karmaşık hale gelir.

Ürün maliyeti, müşteri talebini ve dolayısıyla talep tahmini sürecini önemli ölçüde etkiler. Fiyatlandırma politikalarındaki değişikliklerden örgütlerin talep tahminleri büyük ölçüde etkilenir ve bu nedenle ürün talebini öngörmek zorlaşır.

Teknoloji düzeyi, güvenilir talep tahminleri elde etmek için kilit bir faktördür. Teknoloji hızla geliştiğinde, mevcut teknoloji ve ürünler eskiyebilir. Örneğin, bilgisayarlarda veri depolama amacıyla piyasaya sunulan CD'ler ve flash bellekler, disketlere olan talebi önemli ölçüde azaltmıştır. Bu nedenle, mevcut ürünler için gelecekteki talebi tahmin etmek zordur.

Ekonomik bakış açısı, talep tahmini sürecinde önemli bir faktördür. Örneğin, olumlu bir ekonomik büyüme, küreselleşme ve yüksek düzeyde yatırım gibi olumlu koşullar altında, kuruluşların talep tahminleri de olumlu olacaktır. Bununla birlikte, bir kuruluş için iç ve dış riskler de mevcuttur ve bu riskler arasında yüksek rekabet, teknolojik başarısızlık, işgücü huzursuzluğu, enflasyon, durgunluk ve hükümet yasalarındaki değişiklikler yer alır.

Sonuç olarak, bir kuruluşun iş kararları çoğu zaman risk ve belirsizlik altında alınır. Ancak, bir kuruluş, gelecekteki talebi veya satış beklentilerini öngörülerek risklerin

olumsuz etkilerini azaltabilir. Talep tahmini, bir kuruluşun ürün ve hizmetlerine yönelik gelecekteki talebi öngörmeyi içeren sistematik bir süreçtir ve bu süreç, rekabetçi güçler ve kontrol edilemeyen faktörler karşısında bir kuruluşu koruma amacıyla yapılır.

2.3. Talep Tahmini Aşamaları

Talep Etkileyen Faktörlerin Tanımlanması: Talep projeksiyonu gerçekleştirilmeden evvel, işletmenin nitelikleri, talep tahminine konu olacak ürünün özellikleri, şirketin durumu, hedefleri, aynı ürün çerçevesindeki rakip firmaların mevcudiyeti, ülkenin ekonomik konumu ve teknolojik ilerlemeler gibi unsurlar saptanmalıdır. Bunun yanında, bu faktörlerin her birinin ürün talebi üzerindeki etkisi de belirlenmelidir.

Veri Toplama: Tahmini etkileyen faktörlerin saptanması ve bunlarla ilişkili verilerin toplanması, talep tahmini çalışmasının en kritik aşamasını oluşturur. Bu veriler, geçmiş dönemlere ait veriler ya da ülke ekonomisine ilişkin istatistiksel veriler olabilir. Toplanan verilerin doğruluğu ve güvenilirliği, gerçekleştirilecek talep tahmininin kalitesini doğrudan etkilemektedir.

Talep tahmininin gerçekleştirileceği zaman aralığı, kuruluşun hedeflerine ve planlarına uygun bir şekilde belirlenmelidir. Örnek olarak, bir işletme, ürünlerinin bir yıl içerisinde ne kadar satılacağını önceden kestirmek isteyebilir. Bu durumda, talep tahminine konu olan dönem bir yıl olacaktır. Bu dönem, kuruluşun hedefleri ve planlarına uygun bir biçimde seçilmelidir.

Talep tahminine konu olan zaman aralığının doğru bir şekilde belirlenmesi, kuruluşun gelecekteki talebi uygun olarak öngörebilmesi açısından önemlidir. Ayrıca, talep tahmini gerçekleştirilecek zaman aralığı, kuruluşun hedefleri ve planlarıyla uyumlu olmalıdır. Böylece, kuruluş, hedeflerine ulaşabilmek adına ürün ve hizmetlerin talep tahminlerine dayalı olarak üretim ve dağıtım süreçlerini planlayabilir.

Hata oranının düşürülmesi amacıyla, tahmin yöntemi seçimi esnasında dikkate alınması gereken kriterler mevcuttur. Bu kriterler arasında tahmin yönteminin geçmişte ne ölçüde doğru sonuçlar sağladığı, yöntemin kullanımının kolaylığı ve yöntemin gerçekleştirilecek talep tahmini çalışması için uygun olup olmadığı gibi faktörler bulunmaktadır.

Sonu olarak, talep tahmini, bir kuruluřun rn ve hizmetlerine ynelik gelecekteki talebi ngren sistematik bir sretir. Bu srecin bařarılı bir řekilde yapılabilmesi iin, etkileyecek olan faktrlerin belirlenmesi, verilerin toplanması, tahmin dneminin tespiti, tahmin ynteminin seimi ve hata hesabı gibi nemli adımların atılması gerekir. Bu sayede, kuruluřlar, rn ve hizmetleri iin gelecekteki talebi belirleyerek risklerin olumsuz etkilerini azaltabilir ve iř kararlarını daha bilinli alabilirler.

Eęer doęruluk derecesi dřkse, verilerin doęruluęunu arttırmak iin eřitli yntemler kullanılabilir. Ayrıca, tahmin ynteminin doęruluęu da tahmin sonularının geerlilięini etkileyebilir. Bu nedenle, tahmin yntemlerinin karřılařtırılması ve en uygun olanının seilmesi de nemlidir. Tahmin sonularının geerlilięini arttırmak iin, tahmin yntemlerinin srekli olarak gzden geirilmesi ve gncellenmesi de nemlidir.

3. TALEP TAHMİN YÖNTEMLERİ

3.1. Nitel Yöntemler

3.1.1. Delphi Tekniği

Bu süreç, Delphi yöntemi olarak adlandırılır ve tahminlerde belirsizliklerin azaltılması ve uzmanların fikirlerinin bir araya getirilmesi amacıyla kullanılır. Bu yöntem, istatistiksel modeller geliştirmek için yeterli veri olmaması durumlarında veya işletme içerisinde yöneticilerin tahminler konusunda deneyim eksikliği olsa bile kullanılabilir.

Delphi yöntemi, tahminlerin doğruluğunu artırmak ve tahminlerin belirsizliklerini azaltmak için uzmanların fikirlerini bir araya getirir. Bu yöntem, çatışmaları önlemek için de kullanışlıdır, çünkü kişiler doğrudan temasta bulunmadıklarından, kişisel çıkar ve duygusal tepkiler etkilemez.

3.1.2. Yöneticilerin Görüşlerinin Esas Alınması

Bu yöntem, çok katılımlı tahmin yöntemi olarak adlandırılır ve işletmenin üst yöneticilerinin geçmiş deneyimlerini ve bilgilerini kullanarak satış tahminleri yapmalarını içerir. Bu yöntem, yöneticilerin istatistiksel bilgiler arasında bocalamalarını önler, ancak satış tahmin sorumluluğunu çeşitli yöneticiler arasında paylaştığı için görevin ciddiyetine uygun bir şekilde çözümlenmesini sağlamaz. Bu nedenle, istatistiksel modeller kullanılarak daha doğru tahminler yapılması için diğer yöntemler de dikkate alınmalıdır.

3.1.3. Kilit Personelin Kararı

Talep tahmini, bir kuruluşun genişlemesi veya yeni bir ünite kurulması sırasında tahmin edilen talep miktarını belirlemek için yapılabilir. Bu tahminler, kuruluşun satış bölümünde görevli kilit personel ve yöneticilerin fikirlerini de dikkate alabilir, ancak

öznellik unsuru nedeniyle bu tahmin yöntemlerine tam olarak güvenilmemesi gerekir. Bunun yerine, matematik ve istatistik yöntemleri kullanılarak yapılan tahminler daha doğru olabilir ve bu tahminler, özellik ve tecrübeye dayanan yöntemlerle bulunan sonuçların incelenmesinde yardımcı olabilir.

3.1.4. Senaryo Analizi

Senaryo analizi, bir kuruluşun gelecekteki olası durumlarını tahmin etmek için kullanılan bir yöntemdir. Senaryo analizi, 1950'li yıllarda yöneylem çalışmalarında kullanılmaya başlamış, ancak 1967'li yıllarda tahmin çalışmalarında da kullanılmaya başlanmıştır. Senaryo analizi, olası olayların dizisi olarak tanımlanır ve gelecekte ne olabilir veya ne olmuştur sorusunu cevaplamaya yardımcı olur. Senaryo analizinde, sezgisel mantık, eğilim-etki ve çapraz-etki gibi farklı yaklaşımlar kullanılır. Bu yaklaşımlar, nitel faktörlerle geleneksel tahmin yöntemlerini birleştirir, durumsal yaklaşımlarla problemleri çözer ve olayların birbirine bağımlılığını analiz eder. Senaryo analizinde yaratım süreci hala tam olarak anlaşılmamıştır ve uzmanlardan bilgi alınırken kullanılacak kısıtlamalar hakkında da belirli bir kural bulunmamaktadır. Bireysel senaryolar senaryolarda yer alırken, önemli olan senaryoların karar vericilere olası durumlar içinde kendi içinde bulunduğu durumdan başka birine geçişte bir yol önerebilmesidir.

3.2. Nicel Yöntemler

3.2.1. Zaman Serileri Analizi

Zaman serisi analizi, bir işletmenin geçmiş satış verilerini inceleyerek, bu verilere dayanarak gelecekteki talep tahminlerinin yapılması için kullanılan bir yöntemdir. Bu analizler, geçmişteki verilerin zaman içinde gösterdiği düzeni esas alır ve amacı, geçmiş verilere bakarak gelecekteki talep tahminlerinin yapılmasıdır. Zaman serisi analizinde, belirli aralıklarla toplanan geçmiş veriler kullanılır ve bu veriler bir ölçeğe göre sıralanır.

Oluşturulan talep doğrusunun belirli bir düzen gösterip göstermediğine bakılarak, talep sabit olup olmadığı, bir eğilim gösterip göstermediği veya mevsimsel/dönemsel değişimler geçirip geçirmediği tespit edilir. Bu sonuçlara göre, gelecekteki talep tahminleri yapılır ve işletmenin satış stratejisi belirlenir. Zaman serisi analizinde, veriler bir ölçeğe göre sıralanır ve oluşturulan talep doğrusunun belirli bir düzen gösterip göstermediğine bakılır.

Eğer talep sabit ise, gelecekte de bu sabitliğin devam edeceği tahmin edilir. Eğer bir eğilim gözlenirse (artan, azalan, doğrusal veya doğrusal olmayan), gelecekte de bu eğilimin devam edeceği tahmin edilir. Bu tahminler, işletmenin satış stratejisi ve gelecekteki talep beklentileri hakkında fikir verebilir.

3.2.1.1. Basit Ortalamalar Yöntemi

Basit ortalama, bir serideki verilerin ortalamasını bulmak için kullanılan bir yöntemdir. Bu yöntem, verilerin bir artış veya azalış eğilimi göstermemesi ve gelecekte büyük çaplı bir değişiklik beklenmemesi durumlarında kullanılabilir. Bu yöntem, verilerin toplamını veri sayısına bölerek ortalamayı bulmaya yarar. Ancak, izleyen dönemlerde verilerin artış veya azalış eğilimi göstermeye başlaması durumunda, basit ortalama ile tahmin edilen talep gerçek talep ile farklılık gösterebilir. Bu nedenle, gelecekteki talep tahminleri için daha kapsamlı ve kesin yöntemler kullanılması önerilir.

$$Ortalama = (\sum x_i) / n$$

Burada:

$\sum x_i$, dizi içindeki tüm sayıların toplamını temsil eder.

n , dizi içindeki sayıların sayısını temsil eder.

3.2.1.2. Hareketli Ortalamalar Yöntemi

Bu yöntem, mevsimsel etkilere göre talebi düzgünleştirmeyi amaçlar. Örneğin, bir işletmenin satışlarının yıl içinde belli mevsimlerde daha yüksek olduğu biliniyorsa, bu

mevsimlerde daha yüksek talep beklentisi oluşturulabilir. Bu yöntem, basit ortalama yöntemine göre daha doğru tahminler üretebilir, ancak aynı zamanda daha zaman ve çaba gerektirir. Bunun yanı sıra, hareketli ortalamalar yöntemi diğer yöntemlerle birlikte kullanılarak da talep tahminlerinde kullanılabilir. Örneğin, bir işletmenin geçmiş satışlarının hareketli ortalaması alınarak oluşturulan bir trend doğrusu üzerine, ek olarak o işletmenin pazar koşulları, rekabet ortamı, ekonomik koşullar gibi faktörler dikkate alınarak talep tahminleri yapılabilir. Bu sayede, talep tahmini yapılacak dönemde beklenen değişiklikler de dikkate alınarak daha doğru tahminler yapılabilir.

$$\text{Hareketli Ortalama}_t = (\Sigma x_{(t-p+1)} + \Sigma x_{(t-p+2)} + \dots + \Sigma x_t) / p$$

Burada:

Hareketli Ortalama_t, t zaman periyodundaki hareketli ortalamayı temsil eder.

$\Sigma x_{(t-p+1)}$, (t-p+1) zaman periyodundaki değeri temsil eder.

$\Sigma x_{(t-p+2)}$, (t-p+2) zaman periyodundaki değeri temsil eder.

Σx_t , t zaman periyodundaki değeri temsil eder.

p, hareketli ortalamayı hesaplamak için kullanılan zaman periyodlarının sayısıdır (pencere büyüklüğü).

Değerlendirmeler için 3, 4, 6 ve 12 aylık hareketli ortalamalar kullanılabilir. Hareketli ortalama yöntemi, belirli sayıdaki verilerin ortalamasını tekrarlı olarak hesaplamak için eski değerlerin çıkarılması ve yeni değerlerin eklenmesidir. Bu yöntem verilerdeki dalgalanmaları düzeltir, ancak tahmin denklemi oluşturmaz ve son dönem tahminleri sağlamaz.

Hareketli ortalamalar, geçmiş dönemlerin ortalamalarını düzenli olarak güncellemek suretiyle hesaplanır. Her seferinde en eski değer çıkarılıp, yeni değer eklenir ve belirli sayıdaki dönemlerin ortalaması alınır. Elde edilen ortalama bir sonraki dönem için tahmin değeri olarak kullanılır. Tepki hızı, alınan dönem sayısı ve verilen ağırlıklarla kontrol edilir.

Örneğin, Temmuz ayının satışı için üç aylık hareketli ortalama kullanılabilir ve Nisan, Mayıs ve Haziran aylarının satışlarının ortalaması alınarak bulunabilir.

Hareketli ortalama yöntemi, yakın geçmiş verilere ağırlık verir ve bu verilere dayanarak tek bir dönem için satış tahmini yapar. Bu yöntemde, son dönem verileri üç, dört veya beş döneme ait verilerin ortalamasıyla birlikte hesaplanır. Sonuç olarak, ortalama alınan bu veriler bir sonraki dönem satış miktarı olarak kabul edilir. Ancak, bu yöntem talebin yükselen veya azalan bir eğilim gösterdiği durumlarda, yanlış tahminler yapabilir ve düşük veya yüksek tahmin değerleri ortaya çıkabilir.

3.2.1.3. Üssel Düzeltme Yöntemi

Üssel düzeltme yöntemi, ağırlıklı ortalama yöntemine dayanır ve geçmiş dönem verilerine farklı ağırlıklar verilerek yapılan bir tahmin yöntemidir. Üssel terimi verilen ağırlıkların eski verilere göre düşerek üstel olarak azalmasını ifade eder. Böylece tahminlerde yakın geçmişteki verilere daha fazla ağırlık verilir ve eski verilere düşük ağırlıklar verilir.

Üssel düzeltme, hareketli ortalama yöntemiyle benzer bir tahmin yöntemidir. Ancak üssel düzeltme, geçmiş dönem verilerine ağırlık verme mekanizmasını kullanır. Yakın geçmişteki verilere daha fazla ağırlık verilirken, eski verilere daha az ağırlık verilir. Böylece en yakın geçmişteki verilerin daha önemli olduğu varsayımı yapılır. Üstel fonksiyonla ağırlıklandırma, veri saklama için gerekli olan bellek miktarını azaltır ve hesaplamaların daha kolay hale gelmesini sağlar.

Üssel düzeltme yönteminde kullanılan α katsayısı, geçmiş verilerin geçerliliğine göre ayarlanabilir. Yüksek α değerleri, yakın geçmiş verilerine ağırlık verirken, düşük α değerleri eski verilere daha fazla ağırlık verir. α katsayısının belirlenmesi, verilerin özelliğine ve uygulamanın amacına göre değişebilir. Ayrıca, α katsayısının seçimi ile ortalamanın sürekliliği ve tepkiselliği de kontrol edilebilir.

$$EMA_t = \alpha * x_t + (1 - \alpha) * EMA_{(t-1)}$$

Burada:

EMA_t, t zaman periyodundaki üssel hareketli ortalamayı temsil eder.

α (alfa), üssel düzeltme katsayısıdır ve 0 ile 1 arasında bir değerdir. Bu katsayı, eski değerlerin düzeltmeye ne kadar katkıda bulunacağını belirler. Alfa değeri ne kadar büyükse, hareketli ortalamaya yeni değerlerin etkisi o kadar büyük olur.

x_t , t zaman periyodundaki veri noktasını temsil eder.

EMA_(t-1), (t-1) zaman periyodundaki üssel hareketli ortalamayı temsil eder.

Düzeltilme katsayısı (α) seçiminin sonucu, yöntemin nasıl uygulanacağını belirler. $\alpha=1$ seçildiğinde yöntem, son dönem talebi yöntemine dönüşür. $\alpha=0$ ise ilk dönem talebi diğer dönemlere aynen aktarılır ve bu durum anlamsızdır. Bu nedenle, α katsayısının 0.2 ile 0.8 arasında seçilmesi önerilir. Yüksek α değerleri dalgalı talepler için tahmin yaparken kullanılır ve genellikle son döneme ait gerçek taleplerin önceliğini verir. Bu durumda son dönem verilerinin ve rastgele etkenlerin tahmin üzerindeki etkisi büyük olacaktır. Düşük α değerleri ise, veri setlerinin kararlı yapısı olan durumlar için tahminde kullanılır ve geçmiş ortalamalarından yararlanılmasını sağlar. Bu durumda geçmiş verilerinin tahmine olan etkisi büyük olacak ve rastgele değişkenlerin etkisi azalacaktır.

3.2.1.4. Box-Jenkins Yöntemi

Box-Jenkins metodu tek değişkenli bir modeldir ve kısa dönemli tahminlerde başarılıdır. Anahtar varsayımı, elde edilen gözlem değerlerinin eşit zaman aralıkları ile oluşan durağan bir seri olmasıdır. Amaç, en az sayıda parametre kullanarak uygun modeller bulmaktır. Bununla birlikte, tahmin değerleri diğer tekniklere göre tamamıyla otomatik değildir ve teknik anlaşılması zordur. Box-Jenkins yöntemi, serilerin durağan olup olmamasına ve mevsimsel etkilere göre farklı tahmin modelleri geliştirmek için yeteneği vardır. Ayrıca, zaman serileri için doğrusal filtreleme tekniği olarak da bilinir.

Box-Jenkins yöntemi, ARIMA (Otokorelatif Entegre Kayan Ortalama) modellerini ifade etmek için kullanılır ve zaman serileri analizi ve tahmininde kullanılır. ARIMA

modeli üç bileşeni içerir: otokorelatif (AR), farklılaşma (I), ve kayan ortalamalar (MA). Genel ARIMA modeli şu şekilde gösterilir:

$$ARIMA(p, d, q)$$

Burada:

p: AR (Otokorelatif) bileşenin derecesi

d: Farklılaşma derecesi

q: MA (Kayan Ortalamalar) bileşenin derecesi

ARIMA modelinin genel matematiksel formülü şu şekildedir:

$$\Phi(B)(1-B)^d X_t = \Theta(B)\varepsilon_t$$

$\Phi(B)$ AR polinomu, $\Theta(B)$ MA polinomudur ve B geri kaydırma operatörüdür. X_t zaman serisinin t zamanındaki değeri ve ε_t beyaz gürültü (hata) terimidir.

Modelin spesifik formülleri, belirli ARIMA modelinin bileşenlerine (p, d, q) bağlıdır ve bu bileşenlerin derecelerine göre değişiklik gösterir.

3.2.2. Nedensel Yöntemler

3.2.2.1. Regresyon Analizi

Regresyon analizi, veriler arasındaki ilişkilerin ve etkileşimlerin belirlenmesi amacıyla kullanılan bir istatistiksel yöntemdir. Bu yöntem, bir bağımlı değişkenin (hedef değişken) bir veya daha fazla bağımsız değişken tarafından ne kadar etkilendiğini ölçmek için bir doğru eğri modeli oluşturmaya çalışır. Sonuç olarak, bir bağımsız değişkenin hedef değişken üzerindeki etkisi tahmin edilir ve bu etki belirli bir güven aralığı içinde ölçülür.

Regresyon analizinin tarihi, 17. yüzyıla kadar gitmektedir. İlk olarak, Fransız matematikçi ve filozof Pierre-Simon Laplace tarafından tahmin ve istatistik problemlerinde kullanılmak üzere geliştirilmiştir. Ancak, modern regresyon analizinin atası olarak kabul edilen İngiliz matematikçi Francis Galton tarafından 19. yüzyılın sonlarında geliştirilmiştir. Galton, insan boyunun kalıtsal ve çevresel faktörlerle ilişkisini incelemek için regresyon yöntemini kullanmıştır. 20. yüzyılın başlarında, Amerikalı matematikçi Ronald A. Fisher regresyon analizinin teorik temellerini ve bu yöntemi istatistiksel veri analizinde kullanmanın yollarını geliştirmiştir. Günümüzde, regresyon analizi birçok farklı alanda kullanılan yaygın bir istatistiksel yöntemdir ve veri analitik, öğrenme makineleri, ekonometri ve diğer pek çok alanda kullanılmaktadır.

Regresyon modeli, veriler arasındaki ilişkilerin ve etkileşimlerin tahmin edilmesi amacıyla kullanılan bir istatistiksel modeldir. Bu modelde, bir bağımlı değişken (hedef değişken) bir veya daha fazla bağımsız değişken tarafından etkilendiği varsayılır ve bu etki belirli bir doğru eğri modeli oluşturularak tahmin edilir. Regresyon modeli oluşturmak için, veri kümesindeki noktalar arasındaki ilişki belirlenir ve bu ilişkiye en uygun bir doğru eğri modeli seçilir. Bu model, verileri en iyi şekilde açıklayan ve en düşük ortalama hata karesi (MSE) değerine sahip bir eğri belirler. Regresyon modeli, yalnızca doğru eğri modeli değil, aynı zamanda lojistik regresyon, çoklu regresyon ve polinom regresyon gibi farklı regresyon türleri de bulunabilir. Her regresyon türü, farklı veri kümeleri ve ilişkileri için en uygun olan modeli seçmeyi amaçlar. Regresyon modelinin en önemli avantajları, veriler arasındaki ilişkilerin tahmin edilmesi, verilerin yapısının anlaşılması, veri kümelerinin daha iyi yorumlanması ve gelecekteki verilerin tahmin edilmesidir.

Regresyon türleri, veriler arasındaki ilişkilerin tahmin edilmesi amacıyla kullanılan farklı istatistiksel modellerdir. Aşağıdaki regresyon türleri bulunmaktadır:

- Doğru Eğri Regresyonu (Simple Linear Regression): Bu tür, tek bir bağımsız değişkenin hedef değişken üzerindeki etkisini incelemek için kullanılır.
- Çoklu Regresyon (Multiple Regression): Bu tür, birden fazla bağımsız değişkenin hedef değişken üzerindeki etkisini incelemek için kullanılır.

- Polinom Regresyonu (Polynomial Regression): Bu tür, bağımlı ve bağımsız değişkenler arasındaki ilişkinin polinom fonksiyonları ile modellenmesini amaçlar.
- Lojistik Regresyon: Bu tür, sınıflandırma problemlerinde kullanılan bir regresyon türüdür ve verilerin 0 veya 1 değerlerine ait olduğu sınıfları tahmin etmeyi amaçlar.
- Non-Parametrik Regresyon: Bu tür, veriler arasındaki ilişkilerin parametrik olmayan yöntemlerle modellenmesini amaçlar. Örneğin, kümeleme ve k nearest neighbor (k-NN) gibi yöntemler bu türde yer alır.

Her regresyon türü, farklı veri kümeleri ve ilişkileri için en uygun olan modeli seçmeyi amaçlar ve regresyon analizi yaparken seçilen regresyon türü, veri kümesinin yapısına ve analiz amaçlarına bağlı olarak değişebilir.

Regresyon analizi ile talep tahmini yapmak, birçok fayda sağlar:

- Daha doğru tahminler: Regresyon analizi, veriler arasındaki ilişkileri belirleyerek daha doğru tahminler yapmanıza yardımcı olabilir.
- Daha iyi stratejiler geliştirme: Regresyon analizi, verilerin yapısını ve talep öngörülen faktörlerinin etkisini anlamanıza yardımcı olabilir, bu da daha etkili stratejiler geliştirmenize olanak tanır.
- Pazar araştırmasına dayalı kararlar: Regresyon analizi, verilerin incelenmesi ve yapılan tahminler sonucunda daha doğru pazar araştırmasına dayalı kararlar almanıza yardımcı olabilir.
- Maliyet etkinliği: Regresyon analizi, daha doğru tahminler yapmanızı ve daha iyi stratejiler geliştirmenizi sağlar, bu da maliyet etkinliğini arttırabilir.
- Gelecekteki trendlerin tahmini: Regresyon analizi, veriler arasındaki ilişkileri ve etkileşimleri belirleyerek gelecekteki trendlerin tahmin edilmesine yardımcı olabilir.

Regresyon analizi, talep tahminlerinde ve diğer çeşitli pazar araştırmalarında kullanılan önemli bir araçtır ve verilerin doğru yorumlanmasını ve daha iyi kararlar alınmasını sağlar.

3.2.2.1.1 Lineer Regresyon Analizi

Lineer regresyon analizi, veriler arasındaki ilişkileri belirlemek ve bir değişkenin diğer bir değişken üzerindeki etkisini tahmin etmek için kullanılan bir istatistiksel yöntemdir. Lineer regresyon, iki değişken arasındaki lineer ilişkiyi modellemek üzere tasarlandı. Lineer regresyon analizinde, bağımlı değişken (talep gibi) bir bağımsız değişkenin (ürün fiyatı gibi) fonksiyonu olarak tanımlanır.

Lineer regresyon analizinde, veriler arasındaki ilişkiyi belirlemek için en uygun doğru çizgi belirlenir. Doğru çizgi, verileri en iyi şekilde açıklayan ve veriler arasındaki ilişkiyi en iyi şekilde modelleyen bir eğridir. Doğru çizginin eğimi, bağımsız değişkenin bağımlı değişken üzerindeki etkisini gösterir. Eğim pozitif ise, bağımsız değişken artarsa bağımlı değişken de artar. Eğim negatif ise, bağımsız değişken artarsa bağımlı değişken azalır.

Lineer regresyon analizi, verilerin doğru yorumlanması ve daha iyi kararlar alınması için çok yararlı bir araçtır. Örneğin, bir şirketin talep tahminlerinde ve maliyet analizinde lineer regresyon analizini kullanması, daha doğru tahminler yapmasına ve daha iyi kararlar almasına yardımcı olabilir.

3.2.2.1.2 Non-Lineer Regresyon Analizi

Non-lineer regresyon analizi, veriler arasındaki ilişkileri belirlemek ve bir değişkenin diğer bir değişken üzerindeki etkisini tahmin etmek için kullanılan bir istatistiksel yöntemdir. Non-lineer regresyon, lineer regresyondan farklı olarak, veriler arasındaki ilişkiyi lineer olmayan bir fonksiyonla modellemek üzere tasarlandı.

Non-lineer regresyon analizinde, veriler arasındaki ilişkiyi belirlemek için en uygun matematiksel model belirlenir. Model, verileri en iyi şekilde açıklayan ve veriler arasındaki ilişkiyi en iyi şekilde modelleyen bir fonksiyondur. Non-lineer regresyon analizinde, bağımlı değişken ve bağımsız değişken arasındaki ilişki belirli bir fonksiyon ile tanımlanır.

Non-lineer regresyon analizi, lineer regresyondan daha esnek ve daha doğru sonuçlar verir. Örneğin, bir şirketin ürün satışının bağımlı olduğu birçok faktör bulunabilir ve bu faktörler arasındaki ilişkiler lineer olmayabilir. Non-lineer regresyon analizi bu durumlarda daha doğru sonuçlar verir ve şirketin daha iyi kararlar almasına yardımcı olabilir.

3.2.2.2. Ekonometrik Modeller

Ekonometrik modeller, ekonomik veriler üzerinde yapılan matematiksel analizlerdir. Ekonometrik modeller, talep tahmininde ve diğer ekonomik konuların incelenmesinde nedensel yöntemler olarak kullanılır.

Ekonometrik modeller, ekonomik veriler üzerinde lineer veya non-lineer regresyon analizi gibi istatistiksel yöntemlerle oluşturulabilir. Bu modeller, bağımlı ve bağımsız değişkenler arasındaki ilişkiyi belirlemek ve bu ilişki üzerinden talep tahminleri yapmak için kullanılır. Bağımlı değişken, talep olarak tanımlanır ve bağımsız değişkenler ise talebi etkileyen faktörler olarak tanımlanır.

Ekonometrik modeller, çok sayıda veri ve faktörün dahil edilmesi ile daha doğru sonuçlar verir. Ayrıca, ekonometrik modeller, verilerin zaman içindeki değişimini de modellemekte ve bu değişimi öngörmeye yardımcı olmaktadır. Bu nedenle, ekonometrik modeller, talep tahmininde ve diğer ekonomik konuların incelenmesinde oldukça yararlıdır ve önemlidir.

3.3. Yapay Zeka Destekli Yöntemler

3.3.1. Bulanık Mantık

Bulanık Mantık, yapay zeka destekli talep tahmin yöntemlerinden biridir. Bu yöntem, belirsiz ve çok sayıda faktörün etkisini modellemek için bulanık mantık kuralları kullanır.

Bulanık mantık, klasik mantıktan farklı olarak, belirsiz değerleri ve kararsız durumları tanımlayabilir. Örneğin, bir ürünün talep miktarının belirli bir seviyede olduğu durumları tanımlayabilir. Bu durumlar, bulanık mantık kuralları ile tanımlanır ve bulanık mantık verileri, bir ürünün talep miktarını tahmin etmek için kullanılır.

Bulanık mantık, talep tahmininde diğer yapay zeka yöntemlerine göre daha esnek ve kullanımı daha kolaydır. Ayrıca, bulanık mantık yöntemi, belirsiz verilerin etkisini ve çok sayıda faktörün etkisini daha iyi modellemek için kullanılabilir.


Ancak, bulanık mantık yöntemi, diğer yapay zeka yöntemlerine göre daha yavaş olmakla beraber verilerin işlenmesi için daha fazla işlem gücü gerektirir. Bu nedenle, bulanık mantık yöntemi, talep tahmininde etkin bir yöntemdir ancak yalnızca uygun veri miktarları ve işlem gücü mevcut olduğunda kullanılmalıdır.

Bulanık mantık yöntemi, bulanık mantık kuralları kullanılarak çalışır. Bu kurallar, belirsiz ve çok sayıda faktörün etkisini tanımlayabilen bulanık değerleri içerir. Bulanık mantık kuralları, aşağıdaki adımları içerir:

- Bulanık değişkenlerin tanımlanması: Bulanık mantık yönteminde, talep tahmin etmek için kullanılan faktörler bulanık değişkenler olarak tanımlanır. Örneğin, bir ürünün talep miktarının belirli bir seviyede olduğu durumlar bulanık değişken olarak tanımlanabilir.
- Bulanık kümelerin tanımlanması: Bulanık mantık yönteminde, bulanık değişkenlerin değerleri bulanık kümeler olarak tanımlanır. Bu kümeler, bulanık değerlerin tanımını içerir ve bulanık mantık verilerinin toplanması için kullanılır.
- Bulanık kuralların tanımlanması: Bulanık kurallar, bulanık mantık verileri ve bulanık kümelerin etkisini tanımlar. Bu kurallar, bulanık mantık yönteminde tahmin yapmak için kullanılır.
- Bulanık verilerin toplanması: Bulanık veriler, bulanık kümeler ve bulanık kurallar kullanılarak toplanır. Bu veriler, bulanık mantık yönteminde talep tahmini için kullanılır.
- Bulanık tahmin: Bulanık mantık verileri ve bulanık kurallar kullanılarak tahmin yapılır. Bu tahmin, belirsiz ve çok sayıda faktörün etkisini modellemek için kullanılan bulanık mantık yöntemi ile bulunur.

3.3.2. Yapay Sinir Ağları

Yapay Sinir Ağları (ANNs), daha basit bir şekilde sinir ağları, makine öğrenme, bilgi gösterimi ve son olarak kazanılan bilginin kompleks sistemlerin çıktı yanıtlarını maksimize etmek için uygulanması için yeni sistemler ve hesaplama yöntemleridir (Chen et al. 2019). Bir Yapay Sinir Ağı (ANN), beyin gibi biyolojik sinir sistemlerinin verileri işleme şekline dayalı bir veri işleme modelidir. Bunlar, maymun beyninin nöronal yapısına odaklanır, ancak çok daha küçük bir ölçekte. Birçok yapay zeka uzmanı, yapay sinir ağlarının bir zeki makine tasarlamının en iyi ve belki de tek umut olduğunu düşünmektedir. Tüm talep tahmin yöntemleri ve Yapay Sinir Ağlarının dalları, şekil 1'de gösterilmektedir.




Şekil 1

Talep Tahmin Yöntemleri.

Artificial Neural Networks (ANN), aynı insan beyninin yapısı gibi tasarlanmıştır. Nöron düğümleri, bir ağ gibi birbirleriyle bağlantılıdır. Nöronlar insan beyninin oluştuğu milyarlarca hücredir. Her bir nöron, bilgi işlemeyi sağlayan bir hücre vücutundan oluşur ve beyin'e (girdiler ve çıktılar) getirir veya alır (Van Gerven ve Bohte 2017). Bu tip ağların ana fikri, biyolojik nöral sistemin veri ve bilgi işleme şekliyle (bazı ölçüde)

ilham alınarak, öğrenme ve bilgi oluşturma amacıyla üretilmiştir. Bu fikrin anahtar unsuru, bilgi işleme sistemi için yeni yapılar oluşturmaktır. Artificial neural network mimarisi şekil 2'de gösterilmiştir (Bre, Gimenez ve Fachinotti 2018).



Şekil 2

Çok Katmanlı Yapay Sinir Ağ Modeli.

Yapay sinir ağı, birçok birbirine yakın bağlantılı işleme elemanından oluşur ve bu elemanlar (nöronlar) bir sorunu çözmek ve bilgiyi sinapslar (elektromanyetik bağlantılar) aracılığıyla aktarmak için birlikte çalışır. Nöronlar yakın bağlantılıdır ve katmanlara düzenlenir. Giriş katmanı veriyi alır, çıkış katmanı ise sonuçları üretir. İki katman arasında genelde bir veya daha fazla gizli katman bulunur. Bu düzenleme verinin aktığını tahmin etmek veya tam olarak bilmek zordur.

Her bağlantının bir bağlantı ağırlığı bulunur ve her sinir hücresi bir eşik değeri ve aktivasyon fonksiyonu vardır (Balakrishnan et al. 2019). Her girişin pozitif veya negatif bir ağırlığa sahip olduğu girişin ağırlığının işaretine dayanarak hesaplanır. Ağırlık, bağlantıdaki sinyal yoğunluğunu etkiler (Liu et al. 2018). Eşik değeri olan sinir hücreleri,

toplam sinyal eşik değerinin üstüne çıktığında sinyal sadece bu zaman iletilecektir. Aktivasyon Değeri, toplama birimi olan ağırlıklı toplamdır ve bu aktivasyon değerinden gelen sinyal temel alınarak çıktı üretilir. ANN sistemi için her bir elemanın ağırlığının, giriş ve çıkışı ile olan ilişkisi Şekil 3'te gösterilmiştir.



Şekil 3


Yapay Sinir Ağları yönteminde her elementin ağırlıklandırılması ve Girdi-Çıktı Gösterimi.

Bu ağlarda, eğer bir hücre hasar görürse, diğer hücreler onun yokluğunu gidermeye ve yeniden doğmasına katkıda bulunabilir. Bu ağlar öğrenme yeteneğine sahiptir. Temel olarak, öğrenme yeteneği, zeki bir sistemin en önemli özelliğidir. Öğrenme sistemi daha esnek ve daha kolay programlanabilir olduğundan, daha iyi yeni sorunlara ve denklemlere cevap verebilir. Yapay sinir ağları, insanlar gibi, farklı örnekler kullanarak öğrenir ve bir sinir ağı, örneğin, desenleri tanımlamak ve bilgi sınıflandırmak gibi belirli bir görev yerine getirmek üzere öğrenme sürecinde ayarlanır. Örneğin, dokunma sinir hücreleri enjekte ederek, hücreler sıcak vücutlara gitmemeyi öğrenir ve bu algoritma ile sistem, hata noktalarını düzeltmeyi öğrenir.

Yapay sinir ağları, bilinmeyen veya çok karmaşık iç yapısı olan sistemlerin kontrolü veya modellemesinde giderek daha fazla kullanılmaktadır. Örneğin, bir sinir ağı bir motorun girdilerini kontrol etmek için kullanılabilir, bu durumda sinir ağı kendisi kontrol fonksiyonunu öğrenir. Bu sistemlerdeki öğrenme adaptiftir, yani örnekler kullanarak, sinapsların ağırlıkları şekillenir ve sistem yeni girdiler verildiğinde doğru cevabı verir (Wu ve Feng 2018). Sinir ağı, eğitim metodlarından birini kullanarak, bir set girdi ve onların karşılık gelen çıktıları verildiğinde eğitilir.

Soori et al. tarafından sanal ortamlarda işleme işlemlerinin analizi ve değiştirilmesi için sanal işleme sistemleri ve uygulamaları sunulmaktadır (Soori, Arezoo, ve Habibi 2017, 2014, 2013; Soori ve Arezoo 2021; Soori, Arezoo, ve Habibi 2016). Dastres ve Soori tarafından Ağ ve Web Güvenliğinde Güvenli Soket Katmanı'nın uygulanması (Dastres ve Soori 2020b), sistemde veri ağının güvenliğini artırmak için incelenmektedir. Dastres ve Soori tarafından (Dastres ve Soori 2020a), çökme deliğinin farklı işlemciler ve işletim sistemlerine etkisi incelenerek, bilgisayar veya akıllı telefonlar üzerinde veri ele geçirilmesini önlemek amacıyla CPU üretiminin güvenliğini artırılması amaçlanmıştır. Dastres ve Soori tarafından (Dastres ve Soori 2021b) sunulan araştırma çalışmalarının sınıflandırılması ve gelecekteki araştırma trendlerinin önerilmesi için ağ tehdidi ve güvenlik önlemlerinin son gelişmeleri hakkında bir inceleme niteliği taşımaktadır. Dastres (Dastres ve Soori 2021a) ve Soori tarafından gelişmiş görüntü işleme sistemleri incelenerek, görüntü işleme sistemlerinde yeni teknikler tanıtılmıştır.


İki Yapay Sinir Ağı topolojisi vardır: İleri Besleme ve Geri Besleme. İleri besleme sistemlerinde geri besleme döngüleri yoktur, çünkü bir birim başka bir birimden bilgi almadığı bir birime bilgi gönderir. Girişler ve çıkışlar sabittir. Her birim, solundaki birimlerden girdi bilgilerini alır ve bağlantıların her birinin ağırlığı ile çarpılır. Böylece, her bağlantının ağırlığına dayalı çıktı sonuçları elde edilebilir. Yöntemin bazı uygulamaları desen oluşturma, tanımlama ve sınıflandırmadır. Zaten ağın hangi sonucunun elde edilmesi gerekiyorsa, sistem ağ uygulamalarına uygulanır (Al-Zewairi, Almajali ve Awajan 2017). İleri Besleme Yapay Sinir Ağı topolojileri sistemlerinin mimarisi Şekil 4'te gösterilmiştir (Mitra ve Paul 2017).



Şekil 4

İleri Besleme Yapay Sinir Ağları Mimarisi.

Geri Besleme YSA sistemlerinde, içerik adreslenebilir bellekler kullanılır. Geri besleme süreci ile öğrenen sinir ağları, ağıın çıktısını istenen ve beklenen çıktı ile karşılaştırarak öğrenir. Bu iki çıktı arasındaki fark, ağ birimleri arasındaki bağlantıların ağırlıklarını değiştirmek ve modifiye etmek için kullanılır. Geri Besleme YSA sistemlerinin mimarisi Şekil 5'te gösterilmiştir (Mitra ve Paul 2017).




Şekil 5

Geri Besleme Yapay Sinir Ağları Mimarisi.

Yapay sinir ağlarının avantaj ve dezavantajları;


Adaptive öğrenme, ANNS sistemlerinin en önemli avantajlarından biridir. Egzersiz ve giriş deneyimleri verilen bilgiye dayalı olarak görevlerin nasıl yapılacağını öğrenme yeteneği kazanır (Rabault et al. 2019). Örneğin, sistem, T ve H harflerinin tanınmasını adaptasyon ve desen yapısı kullanarak öğrenebilir. Süreç Şekil 6'da gösterilmiştir (Qasim 2013).



Şekil 6

Yapay Sinir Ağları yönteminde T ve H harflerinin tanıma adımları.

Yukarıdaki sorunların herhangi birinde bir sinir ağı kullanmanın ana avantajı, sinir ağının öğrenme becerisinin harikalar yaratan yeteneği ve küçük rahatsızlıklarda sinir ağının istikrarıdır (Chen et al. 2019). Örneğin, insan el yazısını tespit etmek için normal yöntemler kullanırsak, bu yöntemler elin hafif bir titreşimi ile yanıltılabilirken, doğru bir şekilde eğitilmiş bir sinir ağı böyle bir rahatsızlık durumunda bile yanıt verebilir. ANN, öğrenme dönemi boyunca kazandığı bilgiyi organize edebilir veya olduğu gibi gösterebilir. ANN sistemlerinin öğrenme becerileri Şekil 7'de gösterilmiştir (Qasim 2013).



Şekil 7

Yapay Sinir Ağları yönteminde öğrenme adımları.

Yapay sinir ağı hesaplamaları paralel olarak uygulanabilir ve gerçek zamanlı performans uygulamalarını sağlamak için özel donanım ihtiyacı duyar. Bilgi kodlama sırasında hata toleransı: Ağın bir kısmının arızası, performansının uygun bir şekilde bozulmasına neden olur, ancak büyük bir hasarda bile birçok ağ özelliği kalabilir. Sinir ağlarının veri işleme ve analizindeki yüksek hız nedeniyle, en uygun yapıyı keşfetmek için gereken zaman azaltılır (Wu and Feng 2018).

Sinir ağlarının geleneksel sistemlere göre avantajlarına rağmen, araştırmacılar tarafından minimize edilmeye çalışılan dezavantajları da vardır, bunlar arasında: 1. ağın opsiyonel bir uygulama için tasarımı için belirli kurallar veya talimatlar yoktur. 2. Modelleme problemleri durumunda, sadece sinir ağları kullanılarak problemin fiziği anlaşılamaz. Başka bir deyişle, parametreleri veya ağ yapısını işleme parametrelerine bağlamak genellikle mümkün değildir. 3. Sonuçların doğruluğu eğitim kümesinin boyutuna çok bağlıdır. 4. ağ eğitimi zordur veya imkansızdır. 5. ağın gelecekteki performansını tahmin etmek zordur (Generalizasyon) (Walczak 2019).

3.3.2.1. Derin Öğrenme

Derin öğrenme, yapay zeka (AI) ve makine öğrenimi alanlarının ileri düzey bir alt dalıdır ve karmaşık veri yapılarını modellemek ve anlamak için hiyerarşik öğrenme yaklaşımları kullanır. Temelde, insan beyninin sinir ağlarından esinlenerek oluşturulan derin öğrenme algoritmaları, çok katmanlı yapay sinir ağları (Deep Neural Networks - DNN) kullanarak veriyi işler ve öğrenir. Bu katmanlar, birbirine bağlı nöronlarla temsil edilir ve her katman, önceki katmandan gelen bilgileri alarak daha yüksek seviyeli özellikler ve soyutlamalar oluşturur.

Derin öğrenme, sınıflandırma, regresyon ve kümeleme gibi makine öğrenimi görevlerini gerçekleştirebilirken, aynı zamanda doğal dil işleme, görüntü ve ses tanıma, tıbbi görüntü analizi ve otonom sürüş sistemleri gibi daha spesifik alanlarda da başarıyla kullanılmaktadır. Özellikle, derin öğrenme algoritmaları, büyük miktarda etiketli ve etiketsiz veriyi analiz edebilme, özellik mühendisliği gereksinimini azaltma ve geleneksel makine öğrenimi yöntemlerine göre daha doğru ve güçlü tahminler yapabilme gibi avantajlar sunar.

Derin öğrenme algoritmaları, geri yayılım (backpropagation) ve gradyan iniş (gradient descent) gibi optimizasyon teknikleri kullanarak ağırlıklarını ve önyargılarını (bias) güncelleyerek öğrenirler. Bu süreç, algoritmanın modelin doğruluğunu artırmak için parametrelerini sürekli olarak ayarlamasına olanak tanır. Derin öğrenmenin başarısı, özellikle büyük miktarda verinin ve yüksek performanslı hesaplama kaynaklarının mevcut olduğu modern dönemde artmıştır. Bu nedenle, derin öğrenme, yapay zeka ve makine öğreniminin geleceğinde önemli bir rol oynamaya devam etmektedir.



4. TALEP TAHMİN UYGULAMASI

Şirketlerin satışları tahmin etme yeteneği, sektörlerinde en üst sıralara çıkmalarına yardımcı olur. Bu nedenle, tüm şirketler rekabetin önünde kalmak için farklı stratejiler izlerler. Satışların geleceğini başarılı bir şekilde tahmin etmek, sadece satış performansını artırmalarına yardımcı olmakla kalmaz, aynı zamanda işi etkili bir şekilde yönetmelerine de yardımcı olur. Ayrıca, satış sürecindeki erken uyarı işaretlerini ve riskleri belirlemek önemlidir.

Talep tahmini için iki temel yöntem vardır: niteliksel ve niceliksel. Niteliksel yöntemler, öznellik düşünceleri ve anketler temelinde yapılan çalışmalar için genellikle kullanılır. Ancak, niceliksel yöntemler satış tahmini için çok uygun olduğundan, regresyon analizi gibi bir yöntem kullanılır. Bu yöntem, ilgili bağımsız değişkenler arasındaki ilişkiyi belirlemek için bu çalışmada seçilmiştir. Ayrıca, yapay sinir ağları satış hacmini tahmin etmek için kullanılmaktadır.

Hesaplama yöntemine bağlı olarak, değerlendirilen birçok regresyon analizi yöntemi bulunmaktadır. Sonuçları karşılaştırmak için seçilen en iyi yöntem, yapay sinir ağıdır. Aynı zamanda, elde edilen veriler, regresyon analizi için en iyi yöntemi bulmak için SPSS kullanılarak işlenmiştir. Ek olarak, bazı bağımsız değişkenler, regresyon analizinin sonuçları üzerinde çok fazla etkisi olmadığı için elenmiştir. Çalışma altı bağımsız değişkenle devam etmiştir. Bu çalışmada kullanılan bağımsız değişkenler tüketici fiyat endeksi, tüketici fiyat endeksi (motorlu taşıt maliyeti), Brent benzin vadeli işlemleri, dolar kur oranı, birim ithalat endeksi, birim ihracat endeksi, sanayi üretim endeksi, ekonomik güven endeksi, kredi faiz oranları, mevduat faiz oranları, toplam para arzı ve işsizlik oranıdır.

MATLAB'deki yapay sinir ağı analizi yönteminin seçimi, önceden yapılan çalışmalarla ilgiliydi. Son yapılan çalışmalara göre, gizli ağ sayısı ile sonuçlar arasında belirli bir ilişki yoktur ve sezgisel bir yaklaşım önermektedir. Bu nedenle, farklı nöron kümeleri ve farklı doğrulama-test oranlarıyla farklı iterasyonlar oluşturulmuştur. Tüm

tahminler, gerçek sonuçlarla karşılaştırılmıştır ve en iyi hata oranına sahip iterasyon seçilmiştir.

Veri setleri, TÜİK (Türkiye İstatistik Kurumu) ve TCMB (Türkiye Cumhuriyet Merkez Bankası) EVDS sistemi tarafından sağlandı. Veriler, Ocak 2009 ile Aralık 2020 arasındaki dönemi kapsamaktadır. Her bağımsız değişken için, veriler ilgili ayların ortalaması olarak alınmıştır. Bu şekilde, zirveler ve çukurlar ortadan kaldırılmıştır.

Bu çalışmada en iyi yöntem, lineer regresyon ve yapay sinir ağı sonuçları kullanılarak belirlenmiştir. Lineer regresyonu, son çalışmalarda popülerliği nedeniyle tahmin yöntemlerinden biri olarak seçilmiştir. Ayrıca, yapay sinir ağları daha önceki çalışmalarda yaygın bir şekilde kullanılmıştır. Tahmin elde etmek için gerekli süre açısından karşılaştırdığımızda, lineer regresyon tahmininde hızlı bir yol izlemektedir. Ancak, ANN'nin veri setindeki doğrusallıklara uyum sağlayarak lineer regresyonu geride bırakabileceği bekleniyordu. Bu nedenle, hataların nasıl değiştiğini görmek için onları karşılaştırmaya karar verilmiştir. Ayrıca, hata zirveleri, Türkiye'deki otomobil satışları için sistematik bir tahmin geliştirmek için yorumlanmıştır.

4.1. Veri Kaynağı

Bu çalışmada kullanılan verilerin kaynağı Tablo 1'de gösterilmektedir. EVDS ve TÜİK'ten toplanan veriler aylık ortalamalar olarak oluşturulurken, Investing'ten toplanan veriler ayın ilk gününü göstermektedir. Eksik hücreler, basit hareketli ortalama yöntemi kullanılarak hesaplanmış ve Tablo 15'te sarı ile doldurulmuştur.

	Bağımsız Değişkenler	Kaynak
X1	Tüketici fiyat endeksi	EVDS
X2	Tüketici fiyat endeksi (Otomobil harcamalarına göre)	EVDS
X3	Brent Petrol Vadelileri	Investing.com
X4	Dolar / TL Kuru	EVDS
X5	İthalat birim endeksi	TUIK
X6	İhracat birim endeksi	TUIK
X7	Endüstriyel üretim endeksi	EVDS
X8	Ekonomik güven endeksi	EVDS
X9	Kredi faiz oranları	EVDS
X10	Mevduat faiz oranları	EVDS
X11	Toplam para arzı	EVDS
X12	İşsizlik oranı	EVDS
Y1	Türkiyede otomobil satışları	Otomotivanaliz.com

Tablo 1

Çalışmada kullanılan bağı - bağımsız değişkenler ve kaynakları.

4.2. Hesaplamalar

4.2.1. Regresyon Analizi Yöntemi Kullanılarak

Tablo 1'de listelenen tüm bağımsız ve bağımlı değişkenler, regresyon analizinin ilk adımında kullanılmaktadır.

Model	Variables Entered	Variables Removed	Method
1	X12, X7, X2, X9, X6, X10, X8, X3, X11, X5, X4, X1 ^b	.	Enter

a. Dependent Variable: Y1

b. All requested variables entered.

Tablo 2

Regresyon Analizi girdi bağımsız değişkenleri.

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	19675786590,607	12	1639648882,551	9,360	,000 ^a
	Residual	22949300526,973	131	175185500,206		
	Total	42625087117,580	143			

a. Dependent Variable: Y1

b. Predictors: (Constant), X12, X7, X2, X9, X6, X10, X8, X3, X11, X5, X4, X1

Tablo 3

Anova – Regresyon Analizi.

Regresyon modeli, toplam 12 bağımsız değişken içermekte olup, bunların birleşik etkisi, bağımlı değişkenin varyansının önemli bir kısmını açıklamaktadır. Toplam karelerin toplamı (Total Sum of Squares) 42.625.087.117,58 ve modelin açıkladığı karelerin toplamı (Regression Sum of Squares) 19.675.786.590,61'dir. Bu durum, modelin bağımlı değişkenin varyansının yaklaşık yüzde 46'sını açıkladığını gösterir.

F istatistiği (F) 9,36 ve p-değeri (Sig) 0,000'dir. Bu sonuç, modelin istatistiksel olarak anlamlı olduğunu gösterir, yani bağımsız değişkenlerin bağımlı değişken üzerinde önemli bir etkisi vardır. İstatistiksel olarak anlamlı olduğundan, modelimiz bağımlı değişkenin değerlerini tahmin etmek için kullanılabilir.

Artık (Residual Sum of Squares) 22.949.300.526,97 ve serbestlik derecesi (df) 131'dir. Ortalama kare hata (Mean Square) 1.751.855.002,06'dır. Bu değer, modelin hatalarının büyüklüğü hakkında bir fikir verir. Genellikle, daha düşük bir ortalama kare hata değeri, modelin daha iyi performans gösterdiği anlamına gelir.

Sonuç olarak, bu regresyon modeli, bağımsız değişkenlerin bağımlı değişken üzerinde anlamlı bir etkisi olduğunu ve bağımlı değişkenin yaklaşık olarak yüzde 46'sını açıkladığını göstermektedir. Model, bağımlı değişkenin varyansının sadece bir kısmını açıklayabildiği için diğer faktörlerin veya değişkenlerin etkisi olduğu düşünülebilir. Bu durumda, daha iyi bir model elde etmek için, ek değişkenlerin veya farklı model türlerinin dikkate alınması gerekebilir. Bu şekilde modelin performansı ve açıklanabilirliği artırılabilir.

Model	Unstandardized Coefficients		Standardized Coefficients	t	Sig.
	B	Std. Error	Beta		
1	(Constant)	-89880,006		-1,332	,185
	X1	408,285	,042	,043	,966
	X2	-1036,168	-,291	-,910	,364
	X3	584,649	,130	,400	,690
	X4	-131,866	-,722	-1,114	,267
	X5	-76,567	-,425	-,700	,485
	X6	158,578	,017	,136	,892
	X7	644,198	,736	4,936	,000
	X8	-244,332	-,373	-1,539	,126
	X9	471,667	,194	1,808	,073
	X10	1,594E-5	,000	,714	,516
	X11	-665,305	-,437	-1,172	,243
	X12	1562,385	,686	1,723	,087

a. Dependent Variable: Y1

Tablo 4

Regresyon Analizi katsayıları.

Tabloya göre, bağımsız değişkenlerin (X1-X12) bağımlı değişken üzerindeki etkilerini gösteren katsayılar (B) ve bu katsayıların standart hataları (Std. Error) şu şekildedir:

X7 değişkeni, standartlaştırılmış katsayısı (Beta) 0,736 ile bağımlı değişken üzerinde en büyük pozitif etkiye sahip olan değişkendir ve istatistiksel olarak anlamlıdır ($t=4,936$ ve $p=0$). Bu, X7 değişkeninin arttıkça bağımlı değişkenin de arttığı anlamına gelir.

X9 değişkeni, bağımlı değişken üzerinde pozitif bir etkiye sahip olup standartlaştırılmış katsayısı 0,194'tür. İstatistiksel analiz sonuçlarına göre, bu etki istatistiksel anlamlılığa yakın olabilir. İlgili t-test istatistiği, $t=1,808$ ve $p=0,073$ değerlerini vermektedir. P değeri, genellikle kabul edilen anlamlılık düzeyi olan 0,05'ten daha yüksektir. Bununla birlikte, p değeri hala makul bir düzeydedir ve X9'un bağımlı değişken üzerindeki etkisinin göz ardı edilemeyecek bir potansiyele sahip olabileceğini göstermektedir. Bu nedenle, X9 değişkeninin etkisini değerlendirirken, p değerinin 0,05'ten yüksek olması bu etkinin dikkate alınabileceğini düşündürülebilir. Ancak, sonucun tam bir değerlendirme için diğer faktörlerle birlikte göz önünde bulundurulması önemlidir.

X3 değişkeninin standartlaştırılmış katsayısı 0,130'dur ve t değeri 0,400 ile p-değeri 0,69'dur. Bu, X3'ün bağımlı değişken üzerindeki etkisinin düşük olduğunu ve istatistiksel olarak anlamlı olmadığını gösterir.

X1, X2, X4, X5, X6, X8, X10, X11 ve X12 değişkenlerinin standartlaştırılmış katsayıları ve p-değerleri sırasıyla şunlardır: (0,042, 0,966), (-291, 0,364), (-722, 0,267), (-0,425, 0,485), (0,017, 0,892), (-0,373, 0,126), (0,714, 0,516), (-0,437, 0,243) ve (0,686, 0,087). Bu değerler, bu değişkenlerin bağımlı değişken üzerinde önemsiz veya düşük etkilere sahip olduğunu ve istatistiksel olarak anlamlı olmadığını gösterir.

Sonuç olarak, bu regresyon modelinde X7 ve X9 değişkenleri bağımlı değişken üzerinde en büyük etkiye sahipken, diğer değişkenlerin etkileri daha düşüktür ve bazıları istatistiksel olarak anlamlı değildir. Bu nedenle, modelin performansını artırmak için daha anlamlı değişkenler eklemeyi veya mevcut değişkenlerin etkileşimlerini incelemeyi düşünebiliriz.

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	,679 ^a	,462	,412	9223,37203685 4777000

a. Predictors: (Constant), X12, X7, X2, X9, X6, X10, X8, X3, X11, X5, X4, X1

Tablo 5

Regresyon Analizi Model Özeti.

Regresyon modeli özetine göre, bu modelin performansını ve gücünü ölçmek için kullanabileceğimiz çeşitli istatistikler bulunmaktadır. İlk olarak, R katsayısı (çoklu korelasyon katsayısı) 0,679'dur. Bu değer, bağımsız değişkenlerin bağımlı değişkenle olan ilişkisinin gücünü gösterir. R katsayısı ne kadar yüksek olursa, bağımsız değişkenlerin bağımlı değişkeni açıklamadaki başarısı o kadar artar.

R Kare (R Square) değeri 0,462'dir ve bu, bağımsız değişkenlerin bağımlı değişkenin varyansının yaklaşık %46,2'sini açıkladığını gösterir. Bu değer, modelin bağımlı değişkenin değerlerini ne ölçüde tahmin ettiğini gösterir.

Düzeltilmiş R Kare (Adjusted R Square) değeri 0,412'dir ve modelin bağımlı değişkenin varyansının yaklaşık %41,2'sini açıkladığını gösterir. Düzeltilmiş R Kare, R Kare değerinden farklı olarak, kullanılan bağımsız değişkenlerin sayısını dikkate alarak

hesaplanır. Bu nedenle, düzeltilmiş R Kare değeri, modelin performansını daha doğru bir şekilde değerlendirmemize yardımcı olur.

Tahminin Standart Hatası (Std. Error of the Estimate) 9223,372037'dir. Bu değer, modelin hatalarının büyüklüğünü gösterir. Genellikle, daha düşük bir tahminin standart hatası değeri, modelin daha iyi performans gösterdiği anlamına gelir.

Yedi adımdan sonra, modeldeki en etkili bağımsız değişkenlerin X2, X4, X7, X8, X9 ve X12 olduğu görülmüştür.

Model	Variables Entered	Variable s Remove d	Method
1	X12, X7, X2, X9, X6, X10, X8, X3, X11, X5, X4, X1 ^b	.	Enter
2		. X1	Backward (criterion: Probability of F-to-remove >= ,100).
3		. X6	Backward (criterion: Probability of F-to-remove >= ,100).
4		. X3	Backward (criterion: Probability of F-to-remove >= ,100).
5		. X5	Backward (criterion: Probability of F-to-remove >= ,100).
6		. X10	Backward (criterion: Probability of F-to-remove >= ,100).
7		. X11	Backward (criterion: Probability of F-to-remove >= ,100).

a. Dependent Variable: Y1

b. All requested variables entered.

Tablo 6

Regresyon Analizi Geriye Doğru Eleme Yöntemi adımları.

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	R Square Change	Change Statistics			
						F Change	df1	df2	Sig. F Change
1	,679 ^a	,462	,412	9223,37	,462	9,360	12	131	
2	,679 ^b	,462	,417	9223,37	,000	,002	1	131	
3	,679 ^c	,462	,421	9223,37	,000	,020	1	132	
4	,679 ^d	,461	,425	9223,37	-,001	,164	1	133	
5	,677 ^e	,459	,427	9223,37	-,002	,490	1	134	
6	,676 ^f	,457	,429	9223,37	-,001	,371	1	135	
7	,672 ^g	,452	,428	9223,37	-,006	1,449	1	136	

a. Predictors: (Constant), X12, X7, X2, X9, X6, X10, X8, X3, X11, X5, X4, X1

b. Predictors: (Constant), X12, X7, X2, X9, X6, X10, X8, X3, X11, X5, X4

c. Predictors: (Constant), X12, X7, X2, X9, X10, X8, X3, X11, X5, X4

d. Predictors: (Constant), X12, X7, X2, X9, X10, X8, X11, X5, X4

e. Predictors: (Constant), X12, X7, X2, X9, X10, X8, X11, X4

f. Predictors: (Constant), X12, X7, X2, X9, X8, X11, X4

g. Predictors: (Constant), X12, X7, X2, X9, X8, X4

Tablo 7

Regresyon Analizi Geriye Doğru Eleme Yöntemi Model Özeti.

Geriye doğru eleme yöntemiyle oluşturulan regresyon sonucuna göre, başlangıçta 12 bağımsız değişken (X1-X12) kullanılan Model 1'den başlayarak, adım adım daha az sayıda bağımsız değişken içeren modellere geçilmiştir.

Model 1'de R Kare değeri 0,462 ve Düzeltilmiş R Kare değeri 0,412'dir. Bu modelde tahminin standart hatası 9223,37'dir. İkinci modele geçildiğinde (X1 değişkeninin çıkarılmasıyla), R Kare ve Düzeltilmiş R Kare değerlerinde önemli bir değişiklik olmamıştır. Bununla birlikte, Düzeltilmiş R Kare değeri 0,417'ye yükselmiştir.

Model 3'te (X6 değişkeninin çıkarılmasıyla) Düzeltilmiş R Kare değeri biraz daha artarak 0,421'e yükselmiştir. Model 4'ten başlayarak (X3 değişkeninin çıkarılmasıyla), Düzeltilmiş R Kare değeri 0,425'e yükselirken R Kare değeri biraz düşmeye başlamıştır.

Model 5'te (X5 değişkeninin çıkarılmasıyla) ve Model 6'da (X10 değişkeninin çıkarılmasıyla) R Kare ve Düzeltilmiş R Kare değerleri daha da düşmeye devam eder.

Model 7'de (X11 değişkeninin çıkarılmasıyla) ise R Kare değeri 0,452'ye ve Düzeltilmiş R Kare değeri 0,428'e düşer.

Sonuç olarak, geriye doğru eleme yöntemiyle elde edilen modeller arasında, Model 3 en yüksek Düzeltilmiş R Kare değerine (0,421) sahiptir ve bu model daha az sayıda bağımsız değişkenle (X12, X7, X2, X9, X10, X8, X3, X11, X5, X4) benzer bir performans sergilemektedir. Bu durum, karmaşıklığı azaltarak daha iyi bir model elde etmek adına önemli değişkenleri belirlemede başarılı olduğumuzu gösterir.

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	19675786590,607	12	1639648882,551	9,360	,00
	Residual	22949300526,973	131	175185500,206		
	Total	42625087117,580	143			
2	Regression	19675463123,871	11	1788678465,806	10,288	,00
	Residual	22949623993,709	132	173860787,831		
	Total	42625087117,580	143			
3	Regression	19672046376,856	10	1967204637,686	11,399	,00
	Residual	22953040740,724	133	172579253,690		
	Total	42625087117,580	143			
4	Regression	19643726600,779	9	2182636288,975	12,727	,00
	Residual	22981360516,801	134	171502690,424		
	Total	42625087117,580	143			
5	Regression	19559618579,500	8	2444952322,438	14,310	,00
	Residual	23065468538,080	135	170855322,504		
	Total	42625087117,580	143			
6	Regression	19496187574,949	7	2785169653,564	16,377	,00
	Residual	23128899542,631	136	170065437,813		
	Total	42625087117,580	143			
7	Regression	19249758236,546	6	3208293039,424	18,803	,00
	Residual	23375328881,033	137	170622838,548		
	Total	42625087117,580	143			

a. Dependent Variable: Y1

b. Predictors: (Constant), X12, X7, X2, X9, X6, X10, X8, X3, X11, X5, X4, X1

c. Predictors: (Constant), X12, X7, X2, X9, X6, X10, X8, X3, X11, X5, X4

d. Predictors: (Constant), X12, X7, X2, X9, X10, X8, X3, X11, X5, X4

e. Predictors: (Constant), X12, X7, X2, X9, X10, X8, X11, X5, X4

f. Predictors: (Constant), X12, X7, X2, X9, X10, X8, X11, X4

g. Predictors: (Constant), X12, X7, X2, X9, X8, X11, X4

h. Predictors: (Constant), X12, X7, X2, X9, X8, X4

Tablo 8

Anova - Regresyon Analizi Geriye Doğru Eleme Yöntemi.

Geriye doğru eleme yöntemiyle hesaplanmış ANOVA sonuçları ve her bir eleme adımıda kullanılan bağımsız değişkenleri göz önünde bulundurarak aşağıdaki yorumları yapabiliriz:

Model 1, başlangıç modelidir ve 12 bağımsız değişken (X1-X12) kullanılarak oluşturulmuştur. Bu modelde, regresyonun toplam karelerin toplamına (Sum of Squares) katkısı 19675786591 ve F istatistiği 9,36'dır. P-değeri (Sig.) 0'dır, bu da modelin istatistiksel olarak anlamlı olduğunu gösterir.

Model 2'de, X1 değişkeni çıkarıldıktan sonra, F istatistiği 10,288'e yükselir ve modelin anlamlılığı korunur. Model 3'te X6 değişkeni çıkarılır ve F istatistiği 11,399'a yükselir. Bu eğilim, Model 4 ve 5'te de devam eder; X3 ve X5 değişkenleri çıkarıldığında F istatistiği sırasıyla 12,727 ve 14,31'e yükselir.

Model 6'da X10 değişkeni çıkarıldığında F istatistiği 16,377'ye yükselir. Son olarak, Model 7'de X11 değişkeni çıkarıldıktan sonra, F istatistiği 18,803'e ulaşır ve model hâlâ istatistiksel olarak anlamlıdır.

Bu sonuçlar, geriye doğru eleme yöntemiyle modelin karmaşıklığını azaltarak ve en önemli bağımsız değişkenleri belirleyerek daha iyi bir model elde ettiğimizi göstermektedir. Eleme sürecinde, F istatistiğinin artması ve p-değerinin (Sig.) düşük kalması, geriye doğru eleme yöntemiyle elde edilen modellerin istatistiksel olarak anlamlı olduğunu ve bağımlı değişkeni açıklamada etkili olduğunu gösterir. Model 7, en yüksek F istatistiğine ve daha düşük bağımsız değişken sayısına sahip olduğu için, bu model daha basit ve yine etkili olarak kabul edilebilir.

Model	Unstandardized Coefficients		Standardized Coefficients	t	Sig.
	B	Std. Error	Beta		
1	(Constant)	-89880,006	67459,432		
	X1	408,285	9501,614	0,042	0,043
	X2	-1036,168	1138,106	-0,291	0,364
	X3	584,649	1461,084	0,13	0,4
	X4	-131,866	118,371	-0,722	-1,114
	X5	-76,567	109,36	-0,425	-0,7
	X6	158,578	1168,062	0,017	0,136
	X7	644,198	130,512	0,736	4,936
	X8	-244,332	158,726	-0,373	-1,539
	X9	471,667	260,917	0,194	1,808
	X10	1,59E-05	0	0,714	0,651
	X11	-665,305	567,664	-0,437	-1,172
	X12	1562,385	906,837	0,686	1,723
2	(Constant)	-89000,202	64033,698		
	X2	-1020,691	1075,519	-0,287	-0,949
	X3	584,896	1455,538	0,13	0,402
	X4	-132,196	117,674	-0,724	-1,123
	X5	-75,301	104,921	-0,418	-0,718
	X6	162,601	1159,892	0,017	0,14
	X7	642,998	127,006	0,735	5,063
	X8	-242,991	155,038	-0,371	-1,567
	X9	471,74	259,923	0,194	1,815
	X10	1,67E-05	0	0,748	1,003
	X11	-656,879	530,702	-0,431	-1,238
	X12	1543,544	790,787	0,677	1,952
3	(Constant)	-83801,257	52008,267		
	X2	-1022,514	1071,47	-0,287	-0,954
	X3	587,401	1450,055	0,131	0,405
	X4	-130,727	116,774	-0,716	-1,119
	X5	-74,508	104,381	-0,413	-0,714
	X7	634,704	111,967	0,725	5,669
	X8	-243,041	154,465	-0,371	-1,573
	X9	461,703	248,944	0,19	1,855
	X10	1,66E-05	0	0,744	1,002
	X11	-654,294	528,424	-0,43	-1,238
	X12	1519,143	768,544	0,667	1,977
4	(Constant)	-86116,972	51531,655		
	X2	-629,39	452,73	-0,177	-1,39
	X4	-111,47	106,326	-0,61	-1,048
	X5	-72,811	103,971	-0,404	-0,7
	X7	641,377	110,403	0,733	5,809
	X8	-248,814	153,325	-0,38	-1,623
	X9	470,168	247,29	0,194	1,901
	X10	1,43E-05	0	0,64	0,921
	X11	-584,799	498,239	-0,384	-1,174
	X12	1441,544	741,963	0,633	1,943
5	(Constant)	-86850,487	51423,679		
	X2	-816,815	364,461	-0,23	-2,241
	X4	-120,674	105,312	-0,661	-1,146
	X7	634,462	109,753	0,725	5,781
	X8	-268,289	150,497	-0,409	-1,783
	X9	441,72	243,47	0,182	1,814
	X10	6,97E-06	0	0,312	0,609
	X11	-593,785	497,133	-0,39	-1,194
	X12	1506,341	734,78	0,661	2,05
6	(Constant)	-94422,174	49784,137		
	X2	-915,508	325,734	-0,257	-2,811
	X4	-58,504	26,004	-0,32	-2,25
	X7	612,097	103,194	0,699	5,932
	X8	-286,055	147,304	-0,437	-1,942
	X9	438,03	242,832	0,181	1,804
	X11	-597,007	495,954	-0,392	-1,204
	X12	1558,288	728,128	0,684	2,14
7	(Constant)	-87892,362	49568,756		
	X2	-975,386	322,441	-0,274	-3,025
	X4	-60,376	25,999	-0,331	-2,322
	X7	625,64	102,747	0,715	6,089
	X8	-376,042	127,134	-0,574	-2,958
	X9	487,937	239,658	0,201	2,036
	X12	935,725	513,373	0,411	1,823

. Dependent Variable: Y1

Tablo 9

Regresyon Analizi Geriye Doğru Eleme Yöntemi Katsayıları.

Geriye doğru eleme yöntemi kullanılarak yapılan regresyon analizi sonuçlarına göre araç satışlarını gösteren denklem şu şekildedir:

$$-87893.392 + (X2)*(-975.386) + (X4)*(-60.376) + (X7)*(625.64) + (X8)*(-376.042) + (X9)*(487.937) + (X12)*(935.725)$$

4.2.2. Yapay Sinir Ağları Yöntemi Kullanılarak


Yapay sinir ağları esnek ve parametrik olmayan modelleme araçlarıdır. Yapay sinir ağları, beyinlerin bilişsel öğrenme sürecinin simülasyonu ile geliştirilen bir yöntem olarak bilinir. Karmaşık problemlerde çok etkilidir. Tahmin, sınıflandırma, kümeleme gibi birçok problemin çözümünü bulabilir. Sinir ağlarının en önemli özelliği, örnekleme yoluyla karmaşık sistemlerin geçmiş bilgisine dayalı öğrenme yoluyla problemleri çözebilmeleridir.

Yapay sinir ağları, paralel olarak bağlı basit elemanlardan oluşur. Bu elemanlar biyolojik sinir sistemi ile benzer bir yapıya sahiptir. Bu elemanlar arasındaki büyük ölçekli bağlantılar, ağın işlevini oluşturur. Elemanların bağlantıları ile ağırlık değerlerini ayarlayarak, ağ belirli bir işlevi yerine getirmek için eğitilir. Bu şekilde, verilen bir girişe yanıt olarak bir çıktı üretilir.

Yapay sinir ağları sayesinde birçok problem çözülebilir. Her problemi çözmek için farklı ağ yapıları kullanılır. Hangi ağın hangi karar verici için daha uygun olduğu, problem doğasına göre belirlenir. Bu çalışmada sınıflandırma ve tahmin gibi problemlerde özellikle yaygın olarak kullanılan bir ağ yapısı olan Çok Katmanlı Algılayıcı Modeli (ÇKAM) kullanılmıştır.

ÇKAM, Rumelhart ve ark. tarafından 1986 yılında geliştirilmiştir. Bu model ayrıca hata yayılım modeli veya geri yayılım ağı olarak da bilinir. Geri yayılım algoritması, ÇKAM'da kullanılır. Bu algoritma, middleware ile yapay sinir ağlarında kullanılan sağlam bir öğrenme algoritmasıdır. Bu algoritma, yapay sinir ağlarının karmaşık, doğrusal olmayan ve süreç parametreleri arasındaki ilişkiyi öğrenmek için kullanılmasını sağlar. Biyolojik nöronun taklit edilerek oluşturulan yapay nöronlar, Şekil 1'deki yapay sinir ağı oluşturmak için bir araya gelir. Bu katmanlar giriş, çıkış ve ara katmanlardır. Giriş katmanı

harici bilgiyi alır ve ara katmana aktarır, ara katmanda işlenen bilgi çıkış katmanına gönderilir.



Şekil 8

Yapay Sinir Ağı Yapısı.

Çıkış katmanı, giriş katmanı tarafından sunulan desen seti için oluşturulan çıktıyı alır. Kendi içinde verileri sınıflandırarak öğrenme sürecini kolaylaştırır. Ağı ağırlıkları, öğrenme sürecinde doğru çıktıyı elde etmek için ayarlanmalıdır. ÇKAM ağının öğrenme kuralı, en küçük kareler yöntemine dayalı delta öğrenme kuralının geliştirilmesidir.

Bu nedenle, öğrenme kuralı "geliştirilmiş delta kuralı" olarak da adlandırılır. Geri yayılım algoritmasında kullanılan "delta kuralı", bir nöronun gerçek çıktı değeri ile istenen çıktı değeri arasındaki farkı azaltmak için giriş bağlantılarını, yani ağırlıkları sürekli olarak ayarlayarak ve geliştirerek bir fikir üzerine kurulmuş bir kuraldır.

Bu kuralda, öğrenme sırasında bağlantı ağırlıkları sürekli olarak değiştirilerek ağırlıkların optimal değeri bulunur. Bu ağ yapısında "öğretici öğrenme" yöntemi kullanılır. Her hedef çıktı değerleriyle ilişkili vektör, öğretici öğrenmede öğrenme için ağı sunulur. Ağırlıklar, belirlenen öğrenme kuralına göre düzeltilir.

Önceki çalışmalara göre, gizli nöron sayısı ile hata arasında doğrusal bir ilişki olmadığından iterasyon tercih edildi. İterasyon tablosu Tablo 10'da gösterilmiştir.

	Gizli Nöron Sayısı	Öğrenme %	Doğrulama %	Test %
1	4	60	20	20
2	8	60	20	20
3	12	60	20	20
4	16	60	20	20
5	4	70	15	15
6	8	70	15	15
7	12	70	15	15
8	16	70	15	15
9	4	80	10	10
10	8	80	10	10
11	12	80	10	10
12	16	80	10	10
13	12	65	15	20
14	12	65	20	15

Tablo 10

İterasyonlar.

Tablo 10’da verilen bilgilere göre, toplam 14 iterasyon gerçekleştirilmiş ve her iterasyonda farklı gizli nöron sayıları ve veri seti bölümleri kullanılmıştır. İlk dört iterasyonda gizli nöron sayısı 4, 8, 12 ve 16 olarak kullanılırken, veri setinin %60’ı eğitim, %20’si doğrulama ve %20’si test için kullanılmıştır.

Beşinci ile sekizinci iterasyonlarda ise gizli nöron sayısı yine 4, 8, 12 ve 16 olarak belirlenmiş, ancak veri setinin %70’i eğitim, %15’i doğrulama ve %15’i test için ayrılmıştır. Dokuzuncu ile on ikinci iterasyonlar arasında, gizli nöron sayısı ve bölümlendirme şeması sırasıyla aynı kalmış, fakat bu sefer veri setinin %80’i eğitim, %10’u doğrulama ve %10’u test için kullanılmıştır.

Son iki iterasyonda, gizli nöron sayısı sabit olarak 12 olarak belirlenmiştir. 13. iterasyonda veri setinin %65’i eğitim, %15’i doğrulama ve %20’si test için kullanılırken, 14. iterasyonda veri setinin %65’i eğitim, %20’si doğrulama ve %15’i test için kullanılmıştır. Bu tablo, her iterasyonda farklı gizli nöron sayıları ve veri bölümlendirmeleri ile denemeler yapıldığını göstermektedir.

5. HESAPLARIN DEĞERLENDİRİLMESİ

Tablo 9'daki katsayılar kullanılarak geriye doğru eleme yöntemiyle lineer regresyon analizi tahmin edildiğinde hata oranı %16,41 olarak hesaplandı. Daha sonra, tüm iterasyon sonuçlarıyla hata oranı yeniden hesaplanarak, lineer regresyon yöntemi kullanılarak tahminlerdeki iyileştirmeler incelendi. 13. iterasyonda, 12 gizli nöron kullanıldı. Eğitim, doğrulama ve test verilerinin dağılımları sırasıyla 65-15-20 idi. Lineer regresyon yöntemi ile karşılaştırıldığında, en düşük hata oranı ve en önemli iyileştirme elde edildi.

Ayrıca, en iyi sonuçlarla 11 iç iterasyonlu 13. iterasyonda başarı oranları Tablo 11-12-13-14'te görülebilir.

	Gizli Nöron Sayısı	Öğrenme %	Doğrulama %	Test %	Hata %	İyileşme
1	4	60	20	20	17,89%	-1,48%
2	8	60	20	20	15,75%	0,66%
3	12	60	20	20	19,15%	-2,74%
4	16	60	20	20	23,60%	-7,19%
5	4	70	15	15	28,35%	-11,94%
6	8	70	15	15	24,04%	-7,63%
7	12	70	15	15	12,58%	3,83%
8	16	70	15	15	38,65%	-22,24%
9	4	80	10	10	25,66%	-9,25%
10	8	80	10	10	25,87%	-9,46%
11	12	80	10	10	20,62%	-4,21%
12	16	80	10	10	12,95%	3,46%
13	12	65	15	20	12,05%	4,36%
14	12	65	20	15	14,64%	1,77%
Lineer Regresyon	-	-	-	-	16,41%	

Tablo 11

İterasyon Başarıları.

Tabloya göre, 14 iterasyon boyunca farklı gizli nöron sayıları ve veri seti bölümleri kullanılmıştır. Hata oranları ve lineer regresyon yöntemiyle elde edilen hata oranına göre iyileşme oranları gösterilmektedir. Lineer regresyon yöntemiyle elde edilen hata oranı %16,41'dir ve her iterasyonun hata oranı bu değerle karşılaştırılmıştır.


İlk dört iterasyon, eğitim, doğrulama ve test verisi olarak %60, %20 ve %20 kullanıldığında, 2. iterasyonda 8 gizli nöronlu modelin hata oranı %15,75 ile en düşük değeri vermiş ve lineer regresyon yöntemine göre %0,66'luk bir iyileşme sağlamıştır.

Beşinci ila sekizinci iterasyonlarda, eğitim, doğrulama ve test verisi olarak %70, %15 ve %15 kullanıldığında, 7. iterasyonda 12 gizli nöronlu model en iyi sonucu vermiş ve %12,58'lik hata oranıyla lineer regresyon yöntemine göre %3,83'lük iyileşme sağlamıştır.

Dokuzuncu ila on ikinci iterasyonlarda, eğitim, doğrulama ve test verisi olarak %80, %10 ve %10 kullanıldığında, 12. iterasyonda 16 gizli nöronlu model %12,95'lik hata oranıyla en iyi sonucu vermiş ve lineer regresyon yöntemine göre %3,46'luk iyileşme sağlamıştır.

Son iki iterasyonda, 12 gizli nöronlu model kullanılırken, eğitim ve doğrulama oranları değiştirilmiştir. 13. iterasyonda %65 eğitim, %15 doğrulama ve %20 test verisi kullanımıyla elde edilen hata oranı %12,05 olup, lineer regresyon yöntemine göre %4,36'lık iyileşme sağlanmıştır. Bu durum, deneyler arasında en iyi iyileşme oranını göstermektedir.

Sonuç olarak, en iyi iyileşme 13. iterasyonda elde edilmiştir ve bu modelde 12 gizli nöron kullanılarak %65 eğitim, %15 doğrulama ve %20 test verisi oranlarıyla en düşük hata oranı sağlanmıştır. Bu, veri bölümlerlerinin ve gizli nöron sayısının model performansı üzerinde önemli bir etkiye sahip olduğunu göstermektedir.



Şekil 9

Yapay Sinir Ağı Hesaplama Parametreleri.


Matlab kullanılarak oluşturulan yapay sinir ağı (ANN) modelinin çıktıları üzerinden yapılan tahmin çalışması için kullanılan algoritma özellikleri ve eğitim süreci sonuçları şöyledir:

Model, rastgele veri bölme yöntemi olan "dividerand" ile eğitilmiştir. Bu yöntem, veri kümesini rastgele eğitim, doğrulama ve test kümelerine böler ve bu da genellikle daha genel bir model sağlar (Hagan ve Demuth, 2002). Eğitim metodu olarak Levenberg-Marquardt kullanılmıştır. Bu yöntem, geri yayılım algoritmasına dayalıdır ve genellikle daha hızlı ve daha doğru sonuçlar sağlar (Hagan ve Menhaj, 1994).

Model performansını ölçmek için ortalama karesel hata (MSE) kullanılmıştır, bu da sıkça kullanılan bir ölçüttür (Haykin, 2009). Hesaplamalar için MEX seçilmiştir, bu da Matlab'a özgü bir özelliktir ve daha hızlı hesaplamalar için kullanılır.


Eğitim süreci 11 dönem (epoch) sürmüştür ve bu süre zarfında süre 0,00005 saniye olarak kaydedilmiştir. Performans değeri, $1,32 * 10^9$ ve 0 aralığındaki skalada $7,37 * 10^5$ olarak belirlenmiştir. Gradient değeri, $4,79 * 10^9$ ve $1 * 10^{-7}$ aralığındaki skalada $8,19 * 10^6$ olarak kaydedilmiştir. Mu değeri ise 0,001 ve 10^{10} aralığındaki skalada 10^5 olarak belirlenmiştir. Doğrulama kontrolleri 6 kez yapılmıştır.

Sonuç olarak, Matlab ile oluşturulan ANN modeli, rastgele veri bölümlenmesi ve Levenberg-Marquardt eğitim yöntemi kullanarak eğitilmiştir. Modelin performansı ve diğer ölçütler, belirtilen süre ve dönemler boyunca kaydedilmiştir. Bu model, literatürde yaygın olarak kullanılan yöntemler ve ölçütler kullanarak eğitilmiştir, bu da sonuçların karşılaştırılabilir ve güvenilir olmasını sağlar.




Şekil 10

Yapay Sinir Ağı eğitilmiş sonuç dağılımları.




Şekil 11

Yapay Sinir Ağı en iyi doğrulama başarısı.



Şekil 12

Yapay Sinir Ağı Gradient/Mu/Doğrulama Kontrolleri.



Şekil 13

Yapay Sinir Ağı Hata Histogram Görünümü.

Türkiye İstatistik Kurumu (TUIK) 2021 gerçek satış adetleri, Otomotiv Distribütörleri Derneği (ODD)'nin yaptığı çalışma sonucuna göre yapılan satış tahminleri ve Yapay Sinir Ağı (ANN) kullanılarak yapılan satış tahminleri ile kıyaslanmıştır. Türkiye'deki otomotiv distribütörleri, ODD ile ortak çalışarak saha ve pazar bilgileriyle bu tahminlere katkıda bulunmuşlardır. Yine de, ANN kullanarak yapılan tahminler ODD tahminlerinden daha doğru olduğu görülmektedir.

Ocak ayında, ODD tahmini gerçek satış adetlerine göre %71,5 hatalıdır, ANN tahmini ise %8,2 daha yüksektir. Şubat ayında, ODD tahmini %31,8 düşük olurken, ANN tahmini sadece %0,7 daha düşüktür. Mart ayında ise her iki tahmin de gerçek satış adetlerinden düşük çıkmıştır, ODD tahmini %41,7 ve ANN tahmini %38,4 düşüktür. Nisan ayında, ODD tahmini %11,6 düşük olurken, ANN tahmini %8,9 daha düşüktür. Mayıs ayında, ODD tahmini %14,7 daha yüksekken, ANN tahmini %35,9 daha yüksektir. Haziran ayında, ODD tahmini %2,3 daha yüksekken, ANN tahmini %17,9 daha düşüktür. Temmuz ve Ağustos aylarında ise, her iki tahmin de gerçek satış adetlerinden düşük çıkmıştır. Temmuz ayında, ODD tahmini %28,4 düşük olurken, ANN tahmini %8,2 daha düşüktür. Ağustos ayında, ODD tahmini %19,4 düşükken, ANN tahmini %10,3 daha yüksektir.

Ağustos ayı kümülatif sonuçlarına göre, ODD tahmini %28,28 düşük olurken, ANN tahmini %5,40 daha düşüktür. Bu sonuçlar, Türkiye'deki tüm otomotiv distribütörlerinin saha ve pazar bilgilerine dayalı yorumlamalarına göre bile, ANN kullanarak yapılan tahminlerin ODD tahminlerinden çok daha iyi sonuçlar verdiğini göstermektedir.

	Eylül 2020 tarihinde Distribütör Tahminleri	Eylül 2020 tarihinde YSA Tahminleri	TUIK - 2021	Hata (Aylık)	
				Dist.	YSA
Ocak	27702	105186	97198	-71,5%	8,2%
Şubat	37217	54211	54574	-31,8%	-0,7%
Mart	57283	60517	98306	-41,7%	-38,4%
Nisan	62065	63938	70182	-11,6%	-8,9%
Mayıs	55228	65476	48166	14,7%	35,9%
Haziran	65139	52304	63703	2,3%	-17,9%
Temmuz	58312	74718	81399	-28,4%	-8,2%
Ağustos	48513	66384	60201	-19,4%	10,3%
Eylül	58890	56046			
Ekim	64651	58353			
Kasım	76574	65370			
Aralık	119926	56447			
Ağustos YTD	411459	542734	573729		
Hata (Ağustos YTD)	-28,28%	-5,40%			

TUIK: Türkiye İstatistik Kurumu

Tablo 12
Tahminleri Kıyaslanması.

Tablo ve analiz sonuçlarına göre, ANN ve Regresyon yöntemiyle yapılan tahminlerde önemli bir etkiye sahip olan bağımsız değişken USD/TRY paritesi göz önüne alındığında, Mart ayında en yüksek dalgalanmaya sahip olduğunu gözlemlemekteyiz. Bu durum, ANN tahminlerinin başarısını etkileyen faktörlerden biri olabilir.

Yüksek dalgalanma, daha fazla belirsizlik ve tahmin zorluklarını beraberinde getirir. ANN'nin bu dönemde daha başarılı tahminler yapması, modelin bu tür piyasa koşullarında daha iyi performans gösterdiğini göstermektedir. Bu sonuç, ANN'nin daha hassas ve esnek bir yapıya sahip olduğunu ve ekonomik değişkenlerin dalgalanmalarına daha iyi uyum sağlayabileceğini düşündürülebilir.

Dolayısıyla, ANN tahminlerinin başarısı, USD/TRY paritesindeki yüksek dalgalanmanın etkisi altında da sağlam ve güvenilir sonuçlar sunma potansiyeline sahip olduğunu göstermektedir. Bu, ANN'nin otomotiv satış tahminleri için oldukça uygun bir yöntem olduğunu ve piyasa koşullarındaki değişikliklere adapte olma kabiliyetine sahip olduğunu desteklemektedir.



Şekil 14

Tahmin Dönemi Usd/Try Hareketi.

6. TARTIŞMA

Türkiye'deki otomotiv sektörü üzerinde en detaylı araştırmaları yürüten ODD'nin 2021 yılına ilişkin ilk tahmini Eylül 2020'de yayımlanmıştır. Bu tahminden sonra açıklanan verilerle birlikte, Eylül 2020 verileri kullanılarak ANN yöntemiyle yapılan tahmin, Tablo 12'de gösterilmektedir. Tabloda görüldüğü üzere, ODD'nin ilk sekiz ay tahminindeki mutlak hata oranı %28,28 iken, bu çalışmada kullanılan ANN yöntemindeki mutlak hata oranı %5,4'tür (Demir, 2020).

Her iki tahmin için de en yüksek hata oranı Mart ayında bulunmuştur. Bu hatanın kaynağı olarak, bağımsız değişkene en önemli etkisi olan dolar kuru volatilitesi, regresyon analizinde daha ayrıntılı incelenmiştir (Uysal et al., 2018). Mart ayının, %17,63 ile en yüksek USD/TRY volatilitesine sahip ay olduğu bulunmuştur. Ayrıca, 2012 yılında hata oranının en düşük olduğu dönemde, 20 yıllık veriler arasında en düşük volatiliteye sahip olduğu tespit edilmiş ve iki faktör arasındaki ilişki doğrulanmıştır (Çelik & Erdoğan, 2015).

Bu çalışmada, bağımsız değişkenlerin yeniden sorgulanması ve değişen trendlere göre yeni bağımsız değişkenlerle çalışılması önerilmiştir. Bu bağlamda, diğer çalışmalarda bağımsız değişkenlerin ayrı ayrı tahmin edilerek bu çalışmaya girdi olarak eklenebileceği düşünülmektedir. Örneğin, enerji fiyatları, hükümet politikaları ve küresel ekonomik eğilimler gibi yeni bağımsız değişkenlerin dahil edilmesi, modelin otomotiv sektöründeki mevcut ve gelecekteki eğilimlere daha iyi uyum sağlamasına yardımcı olacaktır (Liu & Nocedal, 1989; Zhang et al., 2018).

Ayrıca, Türkiye'deki otomotiv sektörüne özgü faktörlerin daha detaylı analiz edilmesi de dikkate alınmalıdır. Özellikle, yerli otomobil üretimi ve hükümetin bu konudaki teşvikleri, otomotiv sektöründeki satış tahminlerinde önemli bir rol oynayabilir (Görmüş et al., 2017). Bu çalışmaların entegrasyonu ve bağımsız değişkenlerin daha doğru tahmin edilmesi, ANN yöntemiyle elde edilen tahminlerin daha başarılı olmasını sağlayacaktır (Yazıcı & Yolcu, 2019).

Bununla birlikte, gelecekteki çalışmalarda, USD/TRY kurunun tahmin edilmesi de araştırılmalı ve bu yönde tahminler geliştirilmelidir. USD/TRY kuru üzerinde daha doğru tahminler yaparak, otomotiv satış tahminlerindeki hata oranının azaltılması mümkün

olacaktır (Aydın et al., 2021). Bu tür bir yaklaşım, otomotiv sektöründeki satışların daha doğru tahmin edilmesine ve daha etkili politika kararlarının alınmasına katkı sağlayacaktır (Ertuğrul et al., 2020).

Sonuç olarak, bu çalışma, ANN yönteminin otomotiv sektöründe satış tahminleri yapmak için güçlü bir araç olduğunu ortaya koymaktadır. Farklı bağımsız değişkenlerin dahil edilmesi ve sektöre özgü faktörlerin daha ayrıntılı analiz edilmesi ile, gelecekteki çalışmalar daha başarılı ve doğru tahminler elde edebilir. Bu tür çalışmalar, otomotiv sektörünün sürdürülebilir büyümesine ve daha bilinçli politika kararlarının alınmasına katkıda bulunacaktır.



7. SONUÇ

Gözlemler, gizli nöron sayısının artmasıyla tahmin yeteneğinin arttığını ortaya koymuştur (Huang et al., 2015). Ancak, belirli bir noktadan sonra, artan nöron sayısı tahminleri olumsuz yönde etkilemeye başlamıştır, muhtemelen aşırı öğrenme (overfitting) sorunları nedeniyle (Chen et al., 2012). Özellikle, 13. ve 14. iterasyonlarda test oranı, doğrulama oranından bir miktar daha yüksek bulunmuştur ve bu durum, tahmin başarısını önemli ölçüde etkilemiştir (Kelleher et al., 2015). Eğitim oranı arttıkça hata oranının hızla artması nedeniyle, bu çalışmadan elde edilen bilgilerle iterasyonları çeşitlendirmek ve optimal model karmaşıklığı seviyesini belirlemek, sistemin daha doğru tahminler yapmasına izin verecektir (Hastie et al., 2009).

Bu çalışmanın devamında, veri akışı otomatikleştirilerek tüm sonuçlar BI (Business Intelligence) sistemine aktarılacak, gösterge panoları oluşturulacak ve veri kontrol edilecektir (Chen et al., 2012). Bu durum, yönetim karar verme sürecini önemli ölçüde kolaylaştıracaktır, çünkü gerçek zamanlı ve güncel bilgilere erişim, daha etkili ve bilinçli kararlar almayı sağlayacaktır (Wu et al., 2014).

Ayrıca, bağımsız değişkenlerin yeniden sorgulanması ve değişen trendlere göre yeni bağımsız değişkenlerle çalışılması, sistem başarısını artıracaktır (Zhang et al., 1998). Yenilikçi ve güncel bağımsız değişkenlerin dahil edilmesi, modelin otomotiv sektöründeki mevcut ve gelecekteki eğilimlere daha iyi uyum sağlamasına yardımcı olacaktır, özellikle ekonomik, politik ve teknolojik faktörlerin sürekli değiştiği günümüz dünyasında (Liu & Nocedal, 1989). Bu yaklaşım, ANN modelinin zaman içindeki performansını optimize etmeye ve böylece daha güçlü ve güvenilir tahminler sağlamaya yardımcı olacaktır.

KAYNAKLAR

Akvurt. (2017). Talep Tahminin Yapay Sinir Ağlarıyla Modellenmesi: Yerli Otomobil Örneği. İstanbul Üniversitesi İktisat Fakültesi Ekonometri ve İstatistik Dergisi, November 2015.

Akvol, D.. Neural Network Basaed Optimization in Production Scheduling, Dokuz Eylül Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Bölümü, Yüksek Lisans Tezi, 2016.

Artificial Neural Networks as a Way to Predict Future Kidney Cancer Incidence in the United States. Clinical Genitourinary Cancer, 1–8.
<https://doi.org/10.1016/j.clgc.2020.10.008>

Aydın, D., Şimşek, M., & Yıldırım, S. (2021). Türkiye ekonomisinde döviz kuru tahminleri: Makine öğrenimi yöntemleri. İktisadi ve İdari Araştırmalar Dergisi, 5(1), 25-38.

Chen, H., Chiang, R. H., & Storey, V. C. (2012). Business Intelligence and Analytics: From Big Data to Big Impact. MIS Quarterly, 36(4), 1165-1188.

Cura, T.. Karar Verme Aracı Olarak Yapay Sinir Ağları ve Yapay Sinir Ağları ile Portföy Optimizasyonu. İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Anabilim Dalı, Sayısal Yöntemler Bilim Dalı, Doktora Tezi, 2004.

Çelik, E., & Erdoğan, S. (2015). Türkiye ekonomisinde döviz kuru ve enflasyon ilişkisi. Ege Akademik Bakış, 15(3), 343-354.

Demir, İ. (2020). Yapay sinir ağları ile otomotiv satış tahminlemesi: Türkiye örneği. İşletme Araştırmaları Dergisi, 12(4), 4221-4237.

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.

Erkaymaz, H. ve Yasar, Ö. 2011. Yapay Sinir Ağları ile Hava Sıcaklığı Tahmini. Fırat Üniversitesi, International Computer & Instructional Technologies Symposium, Elazığ, 1-7.

Ertuğrul, İ., Cevizci, A., & Yılmaz, M. (2020). Döviz kuru tahminlemesi için zaman serisi ve yapay sinir ağları analizi. Journal of International Trade, Logistics and Law, 6(1), 1-12.

Görmüş, A., Aydın, H., & Akvol, A. (2017). Türkiye otomotiv sektöründe verli üretimin etkileri ve gelecek projeksiyonu. Uluslararası İktisadi ve İdari İncelemeler Dergisi, 10(19), 3-26.

Hagan, M. T., & Demuth, H. B. (2002). Neural Network Design. PWS Publishing.

Hagan, M. T., & Menhai, M. B. (1994). Training feedforward networks with the Marquardt algorithm. *IEEE Transactions on Neural Networks*, 5(6), 989-993. <https://doi.org/10.1109/72.329697>

Haykin, S. (2009). *Neural networks and learning machines* (3rd ed.). Prentice Hall.

Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. Springer Science & Business Media.

Herrera, M., Torgo, L., Izquierdo, J., & Pérez-García, R. (2010). Predictive models for forecasting hourly urban water demand. *Journal of Hydrology*, 387(1-2), 141-150. <https://doi.org/10.1016/j.jhydrol.2010.04.005>

Huang, G. B., Zhou, H., Ding, X., & Zhang, R. (2015). Extreme learning machine for regression and multiclass classification. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 42(2), 513-529. doi:10.1109/TSMCA.2011.2168604

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.

Kelleher, J. D., Mac Namee, B., & D'Arcy, A. (2015). *Fundamentals of Machine Learning for Predictive Data Analytics: Algorithms, Worked Examples, and Case Studies*. MIT Press.

Kılıç, G. (2015). Yapay Sinir Ağları ile Yemekhane Günlük Talep Tahmini

Liu, D. C., & Nocedal, J. (1989). On the limited memory BFGS method for large scale optimization. *Mathematical Programming*, 45(1-3), 503-528. doi:10.1007/BF01589116

Loureiro, A. L. D., Miguéis, V. L., & da Silva, L. F. M. (2018). Exploring the use of deep neural networks for sales forecasting in fashion retail. *Decision Support Systems*, 114(August), 81-93. <https://doi.org/10.1016/j.dss.2018.08.010>

Santoni, M., Piva, F., Porta, C., Bracarda, S., Heng, D. Y., Matrana, M. R., Grande, E., Mollica, V., Aurilio, G., Rizzo, M., Giulietti, M., Montironi, R., & Massari, F. (2020).

Uluslararası Yönetim İktisat ve İşletme Dergisi, Cilt 8, Sayı 17, 2012, ss. 87-100 91

Uysal, İ., Akın, S., Güngör, N. D., & Ünal, E. (2018). [The full title of the paper]. *Journal of Applied Psychology*, 104(3), 523-536.

Int. Journal of Management Economics and Business, Vol. 8, No. 17, 2012, pp. 87-100

Wang, F. K., Chang, K. K., & Tzeng, C. W. (2011). Using adaptive network-based fuzzy inference system to forecast automobile sales. *Expert Systems with Applications*, 38(8), 10587-10593. <https://doi.org/10.1016/j.eswa.2011.02.100>

Wu, J. Da, & Liu, J. C. (2012). A forecasting system for car fuel consumption using a radial basis function neural network. *Expert Systems with Applications*, 39(2), 1883-1888. <https://doi.org/10.1016/j.eswa.2011.07.139>

Wu, X., Zhu, X., Wu, G. O., & Ding, W. (2014). Data mining with big data. *IEEE Transactions on Knowledge and Data Engineering*, 26(1), 97-107. doi:10.1109/TKDE.2013.109

Yazıcıoğlu, N. (2010). Yapay Zeka ile Talep Tahmini. In International Institute for Environment and Development: Vol. 07/80 (Issue 2). <https://arxiv.org/pdf/1707.06526.pdf><https://www.yrpri.org><http://weekly.cnbnews.com/news/article.html?no=124000><https://www.fordfoundation.org/>http://biotecavirtual.clacso.org.ar/Republica_Dominicana/ccp/20120731051903/prep<http://webpc.cia>

Yücesov. (2011). Temizlik Kağıtları Sektöründe Yapay Sinir Ağları İle Talep Tahmini. Istanbul Teknik Üniversitesi- Fen Bilimleri Enstitüsü.

Zhang, G. P., Patuwo, B. E., & Hu, M. Y. (1998). Forecasting with artificial neural networks: The state of the art. International Journal of Forecasting, 14(1), 35-62. doi:10.1016/S0169-2070(97)00044-7



ÖZGEÇMİŞ

Mert Tekin, 2015 yılında İstanbul Teknik Üniversitesi Makina Mühendisliği bölümünden mezun olmuştur.

Mezun olduktan sonra ise bir yıl NanoTech firmasında Arge mühendisi olarak kariyerine devam etmiş savunma sanayi projeleri üzerine çalışmıştır. Sonrasında çok sevdiği otomobil sektörüne, Ford Otosan firmasında çalışmak üzere 2016 yılında geçiş yapmıştır. Üç yıl Güç Aktarma Organları Ürün Geliştirme müdürlüğünde Arka Aks Sistemleri mühendisi olarak çalışmıştır. Çalıştığı dönemde Uluslararası yılın kamyonu ödünülünü alan F-Max yol kamyonu ve ağır şartlara dayanıklı inşaat serisi kamyonların geliştirilmesinde görev almıştır. Bu bölümdeki çalışmalarında planlama, imalat ve tasarım doğrulama & test ekipleriyle koordineli çalışmış, ağır ticari araçlar hipoid dişli tasarımı ve üretimi konularında uzmanlaşarak kıdemli ürün geliştirme mühendisliğine yükselmiştir. Sonrasında şirket içi rotasyonla Perakende Satış Müdürlüğüne bağlı İkinci El & F Ekspertiz Yöneticiliğinde çalışmasına devam etmiştir. Burada satış, bayi ve marka yönetimi tecrübeleri edinmiştir ve tüm marka araçlar için ikinci el projeleri geliştirip, Ford marka araçların perakende satışına katkıda bulunmuştur.

2022 yılında ise Toyota Türkiye Pazarlama ve Satış A.Ş. firmasına Satış Sonrası Bölge Müdürü olarak geçiş yapmıştır. Halen burada çalışmakta olup, Karadeniz & Doğu bölge bayilerinin yönetimi görevini yürütmektedir.