



Sosyal Bilimler Enstitüsü Dergisi  
 The Journal of Social Sciences Institute  
 Yıl/Year: 2019 – Kış / Winter Sayı/Issue: Ek-1 Özel Sayı  
 Sayfa / Page:241-255  
 ISSN: 1302-6879 VAN/TURKEY  
 Makale Bilgisi / Article Info - Geliş/Received: 08.10.2019  
 Kabul/Accepted: 14.11.2019 - Araştırma Makalesi / Research Article

**VERİ MADENCİLİĞİ  
 ARAÇLARI KULLANILARAK  
 TÜRKİYE’NİN TURİZM  
 GELİRLERİNİN AYLARA GÖRE  
 YAPAY SİNİR AĞLARI İLE  
 TAHMİNLENMESİ**

***ESTIMATION USING THE  
 DATA MINING TOOLS  
 WITH ARTIFICIAL NEURAL  
 NETWORKS TURKEY’S  
 TOURISM REVENUES BY  
 MONTHS***

**Öğr. Gör. Serpil SEVİMLİ DENİZ**

Van Yüzüncü Yıl Üniversitesi  
 Gevaş Meslek Yüksek Okulu

ORCID: 0000-0002-8559-1107, sdeniz@yyu.edu.tr

**Öz**

Verilerden faydalı bilgilere erişme ve bilgileri inceleme süreci veri madenciliğidir. Yapay sinir ağları, veri madenciliği çalışmalarında kullanılan yöntemlerden biridir. Yapay sinir ağları ile nöron şekilsel ve işlevsel olarak taklit edilerek programlar oluşturulur. Matematiksel yöntemlere dayanan yapay sinir ağları tahminleme amaçlı kullanılabilir. Sebep ve sonuç ilişkisine dayanan bir tahmin probleminde, yapay sinir ağının girdileri bağımsız değişken, çıktısı ise bağımlı değişkendir. Doğrusal olmayan bir regresyon modeli olarak düşünülebilir.

Bu çalışmada, turizm sektöründe bir tahmin probleminin çözümü amacıyla yapay sinir ağı kullanılarak veri madenciliği aracı WEKA ile modelleme ve çözümleme yapılmıştır. Türkiye İstatistik Kurumu tarafından yayınlanan, 1969-2017 yılları arası aylık turizm gelirleri verilerinden yararlanılmıştır. Bu veriler yapay sinir ağları ile modellenerek, 2018 verileri tahminlenmiştir. Gerçek veriler kullanıldığı için modelden elde edilen hata miktarları için 2019 da aylık elde edilebilecek turizm gelirleri tahminlenebilir. Turizm sektöründe değişime uyum sağlayıp, rekabeti yönetebilmek adına uygun tahminlemeler yapabilmek önemlidir. Merkezi ve yerel kamu yönetimlerinin hazırlayacakları turistik gelişme planları için yapılacak tahminler zemin oluşturulabilir. Türkiye’de turizm literatürüne katkı sağlanabilir. Bu tahmin çalışmaları, ileriye dönük karar verme ve planlamada turizm yöneticilerine ve yerel yönetimlere rehberlik edecektir.

**Anahtar Kelimeler:** yapay sinir ağı, tahmin, turizm gelirleri.

**Abstract**

Data mining is the process of accessing and examining useful information from data. Artificial neural networks are one of the methods used in data

mining studies. With artificial neural networks, programs are created by imitating the neuron formally and functionally. Artificial neural networks based on mathematical methods can be used for estimation purposes. In a prediction problem based on the relationship between cause and effect, the inputs of the artificial neural network are independent variables and the output is dependent variables. It can be considered as a nonlinear regression model.

In this study, in order to solve a prediction problem in the tourism sector, modeling and analysis are made with WEKA data mining tool using an artificial neural network. Published by Turkey's Statistics Institute, it has benefited from 1969- 2017 tourism revenues between monthly data. These data were modeled with artificial neural networks and 2018 data were estimated. Since the actual data is used, it is possible to estimate the tourism revenues that can be obtained monthly in 2019 for the error amounts obtained from the model. It is important to adapt to change in the tourism sector and to make appropriate predictions in order to manage the competition. Estimates to be made for the touristic development plans to be prepared by the central and local public administrations can form the basis. It could contribute to the tourism literature in Turkey. These forecasting studies will guide tourism managers and local governments in future decision-making and planning.

**Keywords:** artificial neural network, estimation, tourism incomes.

## Giriş

Turizm işletmeleri birçok ekonomik, politik ve çevresel faktörden ciddi bir şekilde etkilenmesine rağmen yoğun rekabet ve turistik talep ile faaliyet göstermeye devam etmektedir. Turizm işletmeleri tarafından turistik talebin tahmin edilmesi önemlidir. Çünkü bu sayede işletme yöneticileri yatırım miktarını, bütçe ve kaynak tahsisini ve turizm gelişim planlarını doğru ve verimli bir şekilde belirleyebileceklerdir (Çuhadar, 2006: 53). Nitel ve nicel yöntemlerin yanı sıra, gelecekteki tahmin çalışmalarında gelişen teknoloji ile geliştirilen makine öğrenme yöntemleri ile geleneksel tahmin yöntemlerine alternatif olarak kullanılacak yeni yöntemler araştırılmaya başlanmıştır. Bu yöntemlerden biri yapay sinir ağı modelidir. İnsan beynindeki sinir hücrelerinin çalışma prensipleri ilham alınarak yapılandırılan yapay sinir ağları, insan beyninin öğrenme yapısını tam olarak modelleyen bir teknik olarak kullanılır (Elmas, 2010: 28).

Veri madenciliği; veriler arasındaki bağlantıları ortaya çıkarmak, veri ambarlarında tutulan veriler arasındaki ilişkileri keşfetmek şeklinde tanımlanır. Bu tanımları kullanarak, veri madenciliğinin de istatistiksel bir süreç olduğunu söylemek mümkündür. Veri madenciliği, büyük miktarlarda veriyle karar almak için potansiyel olarak yararlı olabilecek uygulanabilir ve anlamlı bilgileri çıkarmanın adıdır. Veri madenciliği kapsamlı bir veri kümesinde analiz teknikleri kullanılarak çıkarım, tahminleme çalışmaları

yapılmasıdır. İnsan beyninin çalışma şeklini taklit eden yapay sinir ağları birçok alanda yaygın olarak kullanılmaktadır. Verilerden öğrenme, genelleme ve birçok değişkenle çalışma gibi önemli özelliklere sahiptir. Yapay sinir ağları, farklı uygulamalarda hassas hesaplamalar yapmak için bugün mevcut en hızlı bilgisayarlardan daha hızlıdır. Karmaşık veya belirsiz verileri açıklar. Bu özelliklerden dolayı, bilgi sınıflandırma ve yorumlama gibi birçok farklı sorunun çözümünde ve işletme, finans, endüstri ve eğitim veya doğrusal olmayan sistemlerde mevcut yöntemlerde kullanılır (Yurtoğlu, 2005: 27). Nöronlar matematiksel modellenir. Transfer fonksiyonu olarak adlandırılan denklemin çözümüdür. Bu işleme elemanı, diğer nöronlardan gelen sinyalleri alır: onları birleştirir, dönüştürür ve sayısal bir sonuç oluşturur. Genel olarak, işleme elemanları kabaca gerçek nöronlara karşılık gelir ve bir ağ içinde birbirine bağlanır: Bu yapı aynı zamanda sinir ağları da yaratır (Bahadır ve Özdemir, 1996: 45). Yapay sinir ağı teknolojisi, yapay zeka çalışma alanının alt alanlarından biridir ve yapay zekanın incelenmesine destek vermektedir. İnsan beyninin temel fonksiyonunu sağlayan nöronu (nöron) basit ve işlevsel bir şekilde simüle eden yapay sinir ağları, biyolojik sinir sisteminin basit bir simülasyonudur. Bu sayede, bilgisayar ortamında insan öğrenme yeteneğini deneyimleyerek taşıdığı düşünülen yapay sinir ağları teknolojisi, girdi verilerinden bilgisayar kapasitesine kadar inanılmaz bir öğrenme sağlar ve birçok avantaj sunar. Çeşitli avantajlar sunan ve günden güne gelişen bu teknoloji, birçok alanda olduğu kadar ekonomi ve istatistik alanlarında da kullanılmaktadır. Genellikle tahmin gibi veri yapısının tanımlanmasını gerektiren alanlarda kullanılırlar (Yurtoğlu, 2005: 10). Yapay sinir ağlarının tarihi, nörobiyolojiye ve bilginin bilgisayar bilimine uyarlanmasına dayanır. Yapay sinir ağları üzerindeki çalışmalar incelendiğinde, çalışmaların çoğunun birbirinin devamı olduğu görülmektedir. Diğer bir deyişle, günümüzde en eski geliştirilen sinir ağı yapıları ve öğrenme algoritmaları halen kullanılmaktadır ve bu alandaki gelişmeler önceki gelişmelerle yakından ilgilidir. Bu çalışmaların birbirini takip etmesi nedeniyle, yapay sinir ağları çalışmaları hızla gelişmiştir, ancak daha sonra yapılan çalışmalar önceki çalışmaların yetersiz olduğunu ve bu problemler çözülene kadar, yapay sinir ağları alanındaki çalışmaların bu çalışmalara destek verdiğini göstermiştir (Öztemel, 2012: 25).

Günümüzde bilgisayarların büyüklüğü ve kapasitesinin artması ile birlikte yapay sinir ağları teorik ve laboratuvar çalışmaları olmaktan çıkmış, günlük hayatta kullanılan ve pratikte insanlara faydalı olacak sistemler yaratmaya başlamıştır (Öztemel, 2012: 27). Yapay sinir ağlarının kullanımının finans alanındaki yaygınlaşması, Rumelhart ve McClelland tarafından geri yayılma algoritmasının geliştirilmesine paraleldir. Finansal problemleri doğrusal olmayan bir yapı olduğu gibi doğrusal bir yapı içerdi-



ğinden, finansal problemlerin çözümünde çok katmanlı ağlara ihtiyaç duyulur. Daha önce geliştirilen çok katmanlı ağlar olmasına rağmen, bu ağlar eğitilememiştir. Ancak Rumelhart ve McClelland tarafından geliştirilen bu algoritma sayesinde bu problemin üstesinden gelinmiş ve yapay sinir ağları finans alanında da kullanılmaya başlanmıştır (Yurtoğlu, 2005: 32).

Biyolojik sinir sisteminden ilham alan yapay sinir ağları, veriler arasındaki ilişkiyi öğrenme, saklama ve açığa çıkarma yeteneğine sahiptir. Yapay sinir ağları biyolojik sinir sistemlerinin yapısına benzer şekilde yapay sinir hücrelerinden oluşur. Yapay bir sinir hücresi, biyolojik sinirin temel fonksiyonlarını taklit eden basit bir yapıdır. Ağdaki nöronlar bir veya daha fazla girdi alır ve tek bir çıktı üretir. Bu çıktı, yapay sinir ağından bir çıktı olabilir veya diğer nöronlara girdi olarak kullanılabilir. Yapay sinir hücrelerine mühendislik bilimindeki süreç elemanları (nöronlar) denir. Geliştirilen hücre modellerinde farklılıklar olsa da, genel olarak her işlem elemanı beş ana bileşenden oluşur: girdiler, ağırlıklar, toplama fonksiyonu, etkinleştirme fonksiyonu ve hücre çıkışı (Öztemel, 2012: 35). Türkiye’de tüketimin ve kentleşmenin artması kentlerde işsizlik probleminin ortaya çıkmasına neden olmuştur. Turizm, emek yoğun üretim yapısıyla işsizliğe çare olarak görülmeye başlanmıştır. Bu yüzden Türkiye gibi gelişmekte olan ülkelerin dikkatini çeken turizme, ekonomik etkileri nedeniyle önem verilmeye başlanmıştır (Aktaş, 2002: 24).

### **Yapay Sinir Ağlarının Gelişimi**

Tarihte veri madenciliği faaliyetleri, sayma için ilk bilgisayarların kullanılmasıyla 1950’lerde başlamıştır. 1960’lı yıllarda istatistikçiler, veri madenciliğinin ilk adımlarını oluşturan regresyon analiziyle olasılık tahmin algoritmalarının en iyisini keşfettiler (Şaylan, 2013: 3). 1970’lerde, bilgisayar uzmanları tarafından basit kurallara dayalı uzman sistemler geliştirmek için ilişkisel Veri Tabanı Yönetim Sistemleri metodolojisi geliştirildi ve basit makine öğrenmesi bulundu. 1980’lerde veritabanı yönetim sistemleri genişletildi ve bilimsel alanlarda geliştirildi ve kullanıldı. Bu dönemde şirketler, rakipleri, müşterileri ve ürünleri ile ilgili büyük miktarda veri tabanı oluşturmaya başladılar. Bu veri tabanlarına SQL veritabanı sorgu dili ve benzer diller kullanılarak erişilmiştir (Savaş, 2012: 4). 1990’ dan beri veri tabanları ve veri ambarları geliştirilmiştir. Ayrıca, zaman içinde teknolojiyle gelişen veri madenciliği, yaygın olarak kullanılan standart bir işin parçası haline gelmiştir. Veritabanındaki veriler üzerinde 1990’ ların başında yapılan çalışmalar daha sonra genişletilmiş ve veri tabanında tutulmayan verileri içerecek şekilde genişletilmiştir (Can ve Diğ, 2012: 3). Günümüzde bilgisayarların yaygın olarak kullanılması ve dijital teknolojilerin gelişmesiyle birlikte veri yığınları meydana gelmiştir. Bu mevcut veri kütleleri arasındaki kalıpların, ilişkilerin ve eğilimlerin doğru tahmin

edilmesi, gelecek için sağlam kararlar almak için önemlidir. Bu ihtiyaçların ortaya çıkması ile istatistiksel analizde ve yapay zeka modellemesinde kullanılan veri madenciliği uygulamaları artmıştır. Veri madenciliğine artan ilgi ile kullanım alanları farklılaşmıştır (Çuhadar vd., 2009: 111).

### Yapay Sinir Ağı Yapısı

Milyonlarca biyolojik sinir hücresi (nöron), beynin bağlantılar yoluyla bağlanmasıyla oluşur. Başka bir deyişle, katmanlar aynı yönde bir araya gelen nöronlar tarafından oluşturulur ve bu birkaç katmanın birleştirilmesiyle yapay sinir ağları oluşturulur. Bu yapının bazı nöronları girdi almak için dış alana ve çıktılarını iletmek için diğerlerine bağlanır. Diğer tüm nöronlar gizli katmanlardır. Bu durumda, katmanların farklı şekillerde birbirine bağlanması farklı ağ mimarileri ile sonuçlanır. Yapay sinir ağlarının ilk yıllarında, bazı araştırmacılar rastgele nöronlar arasında bağlantılar kurmuş ve olumsuz sonuçlar vermiştir (Yurtoğlu, 2005: 44).

Bir yapı tasarlanmanın en kolay yolu, elemanları yerleştirmektir. Katmanlamanın üç bölümü vardır. Bunlar nöronları katmanlara ayırmak, katmanlar arasındaki bağlantıları gruplandırmak ve son olarak kümeleme ve transfer fonksiyonlarını gruplandırmaktır. Başka bir deyişle, sinir hücrelerinin kombinasyonu rastgele olamaz. Genel olarak, üç katmanda bir araya gelirler: giriş katmanı, gizli katman veya ara katman ve çıktı katmanı. Ağı oluşturmak için paralel bağlanırlar (Öztemel, 2012: 58). Bu katmanlar:

*Giriş Katmanı:* Bu katmandaki nöronlar dış dünyadan bilgi alır ve gizli katmanlara aktarır. Bazı ağlar, giriş katmanındaki hiçbir bilgiyi işlemez. Giriş değerlerini bir sonraki katmana iletirler. Bu nedenle, bazı araştırmacılar bu katmanı ağ katmanlarının sayısına eklememektedir.

*Gizli (Orta) Katman:* Giriş katmanından gelen bilgiler işlenir ve çıkış katmanına gönderilir. Bu bilgi gizli katmanlar halinde işlenir. Bir ağda, giriş ve çıkış katmanı tek bir katmandan oluşurken, gizli katman birden fazla katmandan oluşabilir. Gizli katmanlar, diğer nöronlarla tamamen bağlantılı olan çok sayıda nöron içerir. Gizli katmandaki nöron sayısının seçimi, ağın boyutunu tanımlamak ve performansı bilmek için çok önemlidir. Ek olarak, latent katmandaki nöronların ve katmanların sayısının artırılması ya da azaltılması ağın basit ya da karışık olup olmadığını etkiler.

*Çıktı Katmanı:* Bu katmandaki nöronlar, gizli katmandan gelen bilgileri işler ve giriş katmanından sunulan giriş seti (örnek) için ağın üretmesi gereken çıkışı üretir. Üretilen çıktı dış dünyaya gönderilir.

Yapay sinir ağları, öğrenme, sınıflandırma, genelleme, tahmin, özellik belirleme ve optimizasyon işlemlerini gerçekleştirebilir. Yapay sinir ağları, öğrenme sürecinde verilen bilgileri düzenleyerek daha fazla gir-



di için doğru kararlar alma yeteneğine sahiptir. Günümüzde birçok alanda kullanılan yapay sinir ağları, aşağıdaki genel özelliklerden dolayı birçok alanda etkin bir şekilde kullanılmaktadır (Öztemel, 2012: 17).

Makine öğrenme süreci de yapay sinir ağları ile gerçekleştirilebilir. Ağların temel görevi bilgisayarlara öğrenme sağlamaktır. Olayları öğrenerek, benzer olaylara karşı benzer kararlar almaya çalışırlar. Programların çalışma tarzı bilinen programlama yöntemlerine benzemez. Geleneksel programlama ve yapay zeka yöntemlerinden farklı bilgi işlem yöntemleri vardır.

*Bilgi tutma:* Yapay sinir ağlarında bilgi, ağ bağlantılarının değerleri ile ölçülür ve bağlantılarda depolanır (Odabaş, 2017: 65).

*Doğrusal olmayan yapı:* Yapay sinir ağlarının temel işlem elemanı olan nöron doğrusal değildir. Bu nedenle, nöronların birleştirilmesiyle oluşan yapay sinir ağları doğrusal değildir. Kullanılan aktivasyon fonksiyonu doğrusal bir fonksiyon değildir. Bu nedenle yapay sinir ağları, gerçek hayatta doğrusal olmayan problemleri çözmek için kullanılabilir (Odabaş, 2017: 66).

*Öğrenme:* Yapay sinir ağları gerçek olaylar olan örnekleri kullanmayı ve problem çözmeyi öğrenir. Olayları öğrenebilmek için ilgili örneklerin belirlenmesi gerekir. Örneklerle olay hakkında genellemeler yapabilmek yeteneği kazanır. Yapay sinir ağlarının istenen davranışı elde etmek için programlanması gerekir. Başka bir deyişle, nöronlar arasında doğru bağlantılar yapılmalı ve bağlantılar uygun ağırlıklara sahip olmalıdır. Yapay sinir ağlarının karmaşık yapısı nedeniyle, bağlantılar ve ağırlıklar önceden ayarlanamaz veya tasarlanamaz. Bu nedenle yapay sinir ağları, istenen davranışı göstermek için ilgilendikleri problemde eğitim örnekleri kullanarak sorunu öğrenmelidir (Güvenç ve Diğ, 2007: 1).

Yapay sinir ağlarını güvenli bir şekilde kullanabilmek için eğitimleri ve performanslarının test edilmeleri gerekir: ağın eğitimi, mevcut örneklerin bireysel ağa gösterildiği anlamına gelir ve ağ, olaylar arasındaki ilişkileri belirlemek için kendi mekanizmalarını kullanır. Örnekler iki gruba ayrılır: eğitim ve test seti. Her ağ ilk önce bir eğitim seti ile eğitilir ve ağ tüm örneklerle doğru cevaplar vermeye başladığında, eğitim tamamlanır. Görülmemiş örnekler hakkında bilgi elde edebilmek için: ağ hakkında bilgi üretebildiği örneklerle genellemeler yapar (Güvenç ve ark., 2007:2).

*Algılama olaylarında kullanılabilirlik:* Ağlar çoğunlukla algılama bilgilerini işlemek için kullanılır.

*Örüntü birleştirme ve sınıflandırma:* Çoğu ağın amacı, kendilerine örnek olarak verilen örüntüleri veya başkalarını ilişkilendirmektir. Diğer

amaç sınıflandırmadır (Haykin, 1999: 78).

Kendi kendini organize etme ve öğrenme yeteneği: Sürekli yeni olaylar öğrenmesi ve ağıın yeni durumlara adapte olması mümkündür (Haykin, 1999: 78).

*Eksik bilgilerle çalışabilme becerisi:* Ağlar, eğitildikten sonra eksik bilgilerle çalışabilir ve yeni örneklerdeki bilgi eksikliğine rağmen sonuç üretebilir. Bu onların performansını düşürmez. Ağıın kendisi eğitim sırasında hangi bilgilerin önemli olduğunu öğrenebilir.

*Hata toleransı:* Ağların eksik bilgi ile çalışabilmesi onları hatalara karşı toleranslı kılar. Yapay sinir ağları, çok sayıda nöron çeşitli şekillerde bağlandığı ve ağıın bilgileri ağdaki tüm bağlantılar üzerine dağıtıldığı için paralel bir dağınık yapıya sahiptir. Bu nedenle, eğitilmiş bir yapay sinir ağıının bazı bağlantıları, hatta bazı nöronlar bile, ağıın doğru bilgi üretme yeteneğini önemli ölçüde etkilemeyen etkisiz hale gelir. Bu nedenle, hata giderme yetenekleri diğer yöntemlerden daha yüksektir (Balkin, 1997: 7)

*Belirsiz tamamlanmamış bilgileri işleme yeteneği:* Olayları öğrendikten sonra, belirsizlik altında ağlar öğrendikleri olaylar hakkında ilişkiler kurarak kararlar alabilir ( Haykin, 1999: 57).

*Dağıtılmış bellek:* Yapay sinir ağlarında, bilgi ağa yayılır. Nöronların birbirine bağlanmasının değerleri ağıın bilgisini gösterir. Tek bir bağlantının anlamı yoktur. Tüm ağ, öğrendiği olayın tamamını karakterize eder. Bu nedenle, bilgi ağa dağıtılır. Bu, dağıtılmış bir belleğin ortaya çıkmasına neden olur.

*Yalnızca sayısal bilgilerle çalışmak:* Sembolik ifadelerle temsil edilen bilgilerin, çözümleri yorumlamak ve üretmek için sayısal gösterime dönüştürülmesi gerekir.

*Donanım ve Hız:* Yapay sinir ağları büyük ölçekli entegre devre (VLSI) teknolojisi nedeniyle paralel yapıya sahiptir. Bu özellik yapay sinir ağıının bilgiyi hızlı bir şekilde işleme yeteneğini artırır ve gerçek zamanlı uygulamalarda istenir ( Kabalcı, 2019: 18-19).

Tahmin, bir değişkenin gelecekteki değerlerinin yaklaşık belirlenmesi olarak tanımlanabilir. Tahmin, işletme, finans, yönetim bilimi, siyaset bilimi, planlama ve daha birçok alanda karşılaşılan bir kavramdır. Daha doğrusu, gelecekteki karar vermenin gerekli olduğu yerlerde karar vermede yardımcı olacaktır. Tahminin amacı karar verme riskini azaltmaktır (Zhang ve diğ., 1998). Veri madenciliği için kullanılan temel teknikler: Sınıflandırma ve tahmin, kümeleme, ilişki kuralları, aykırı değer analizi, sıralı dizi analizi, zaman serisi analizi, metin madenciliği, web madencili-



ği ve sosyal ağların analizi olarak sıralanabilir (Zhao, 2013: 11). Katman sayısına göre yapay sinir ağları tek katmanlı sinir ağlarına ve çok katmanlı sinir ağları olarak ayrılır.

### **Tek Katmanlı Yapay Sinir Ağları**

Sadece girdi ve çıktı katmanlarından oluşan yapay sinir ağı mimarisi tek katmanlı yapay sinir ağlarıdır. Her ağı bir veya daha fazla giriş ve çıkışı vardır. Çıkış birimleri tüm giriş birimlerine bağlanır. Her bağlantının bir ağırlığı vardır. Bu ağlarda ağı çıktısının sıfır olmasını önleyen bir eşik değeri vardır. Eşik değerinin giriş her zaman  $+1$ 'dir. Gizli bir tabaka vardır. Bu ağlar, çoğunlukla lineer problemler için kullanılır (Öztemel, 2012: 69).

### **Çok Katmanlı Yapay Sinir Ağları**

Birçok nöronun birbirine bağlandığı çeşitli katmanlardan oluşan tipik bir ağıdır. Çok katmanlı yapay sinir ağlarında, giriş katmanı, çıkış katmanı arasında ve bu iki katman arasında bir veya daha fazla gizli katman vardır. Bu özellik, çok katmanlı yapay sinir ağlarını tek katmanlı yapay sinir ağlarından ayıran ana özelliktir. Çok katmanlı yapay sinir ağları, özellikle öngörülerde, karmaşık sorunların çözümünde kullanılır. Çünkü bu ağlarda, gizli katmanın yapısındaki bir dizi işlemin kendiliğinden doğrusal olmayan bir yapıya dönüşme kabiliyeti vardır (Zhang ve Diğ., 1998: 37-38).


Tek katmanlı sensörlerin doğrusal problemleri çözmedeki yetersizliği yapay sinir ağlarının çalışmadığı fikrine yol açmıştır. Bununla birlikte, XOR problemini çözme çalışmaları sonucunda geliştirilen çok katmanlı sensörler, yapay sinir ağlarının tarihsel gelişiminde önemli bir adım olmuştur. Araştırmalar, çok katmanlı ağların ortaya çıkması ve öğrenme kuralı, geri yayılma algoritması ile sonuçlanmıştır. Çok Katmanlı Sensör Modeli “Hata Yayılım Modeli ” veya “Geri Yayılım Modeli ” olarak da adlandırılır (Hamzaçebi ve Kutay, 2004: 229).

Çok katmanlı ağlar ile elde edilen doğrusal olmayan problemleri çözüme başarılı sonuçlar ve geri yayılım algoritması, işletme bilimi de dahil olmak üzere birçok alanda kullanımında bir artışa yol açmıştır. Çok katmanlı ağlar, özellikle sınıflandırma, tanıma ve genelleme gerektiren problemler için çok önemli bir çözüm aracıdır. Asıl amacı “ ağı beklenen çıkışı ile ürettiği çıktı arasındaki hata arasındaki farkı en aza indirmektir (Öztemel, 2012: 57). Parçalama Vektörü Doğrusal Model ( Doğrusal Vektör Kantitatif, LVQ ) ve Çok Katmanlı Algılayıcı ( Çok Katmanlı Algı ) modeli çok katmanlı sinir ağlarının örnekleridir. Çok katmanlı ağlarda en sık kullanılan transfer fonksiyonları sigmoid fonksiyon ve hiperbolik teğet



fonksiyondur (Odabaş, 2017: 67).

Çok Katmanlı sensör (MLP), giriş ve çıkış katmanları arasında bir veya daha fazla katman içeren ileriye dönük bir sinir ağıdır. Feedforward, verilerin girdiden çıktı katmanına (ileri) bir yönde aktığı anlamına gelir. Bu ağ türü, geri yayılım öğrenme algoritması ile eğitilmiştir. MLP'ler örüntü sınıflandırma, tanıma, tahmin ve yaklaşım için yaygın olarak kullanılır. Çok Katmanlı Perceptron doğrusal olarak ayrılmamış problemleri çözebilir (Elmas, 2010: 85). Feedforward Networks: Veriler, girdi gizli ve çıktı katmanlarından tek yönde iletilir (Akpınar, 2014: 57).



**Şekil 1:** MLP

**Kaynak:**(<https://machinelearningmastery.com/when-to-use-mlp-cnn-and-rnn-neural-networks>)

### Geriyeye doğru yayılım:

Katmanlar arasında bağlantı kurarak çok katmanlı algılayıcıyı bağlayan, ileriye dönük ve yapay sinir ağları modelinin eğitimini denetler (Akpınar, 2014: 59).

### Çapraz Doğrulama

Uygulanan yöntemin başarısını test etmek için, veri seti eğitim ve test setlerine bölünür. Bu ayırma çeşitli şekillerde yapılabilir. Örneğin, veri setinin % 66'sı eğitim için ayrılmıştır ve % 33'ü test içindir. Eğitim seti ve sistem eğitildikten sonra, test seti ile başarısını test etmek için yöntemlerden biri kullanılabilir. Bu eğitim ve test setlerinin rastgele atanması da farklı bir yöntemdir. Ancak bu çalışmada eğitim ve test kümeleri katlanmış ve değiştirilmiştir. Amaç verileri bir eğitim ve test kümesi olarak ayırmak



ve aşırı uyumu önlemek için modelin daha önce görmediği bir veri seti üzerinde nasıl performans göstereceğini anlamaktır. Ancak, modelimizin eğitim ve test aşamasında dağılmasından dolayı bazı hatalar olabilir. Bu hataları en aza indirmek için K - Fold Cross Validation tekniği kullanılmaktadır. Eğitim verileri set içine rastgele k segmentlerinde böler. Eğitim için k -1, test seti için 1 kısım kullanılır ve k bu kez tekrarlanır. Elde edilen değerler, her bir turda, toplanır ve ortalaması modelinin performansını değerlendirilir (Şeker, 2019).

Turizm, ülkeler için ekonomik, siyasi ve sosyo-kültürel dinamiklerini olumlu yönde etkileyen, yarattığı katma değer ve istihdam ile dünyada en hızlı gelişen sektör konumundadır. Türkiye açısından turizm sektörü, milli gelire olan katkısının yanı sıra sağladığı döviz geliri ile ödemeler dengesine katkısı, etki alanına giren iş kolları ve yarattığı istihdam ile büyük bir öneme sahiptir (Kandır ve Diğ, 2008: 214).

Turizmin, Türkiye ekonomisine katkısını irdelemek amacıyla yıllar itibariyle elde edilen gelirlere ve ziyaretçi sayılarına bakıldığında, genel olarak bir artış olduğu görülmektedir. Bu artış, yurt dışında yaşayan vatandaşlar ile yabancıların yaptıkları harcamaların toplamında ve sadece yabancı ziyaretçilerin yaptıkları harcamaların toplamında benzer şekilde görülmektedir. Özellikle son yıllardaki ziyaretçi sayısı ve turizm gelirindeki artış sayesinde, Türkiye dünyada en çok ziyaret edilen ülkeler arasında yer almaya başlamış ve uluslararası rekabet gücünü maksimize etme yolunda önemli adımlar atmıştır. 2010 yılında ülkelere gelen uluslararası ziyaretçi sıralamasında yedinci sırada yer alan Türkiye, gelişimini devam ettirerek 2012 yılı sonu itibariyle altıncı sıraya yükselmiştir (TÜİK, 2019).

### **Çalışmanın Amacı ve Önemi**

Bu çalışmanın amacı, turizm alanında klasik yöntemlere alternatif olarak farklı sektörlerde etkin bir tahmin yöntemi olarak kullanılan yapay sinir ağlarını kullanmak ve turizm gelirleri için etkin bir tahmin yapmaktır. Yerel kamu idareleri tarafından hazırlanan turistik gelişim planlarına temel teşkil etmek, ilgili işletme yöneticilerinin aylık planlarında karar vermeyi kolaylaştırmak ve Türkiye’de turizm literatürüne katkıda bulunmak bu çalışmanın amaçları olarak sıralanabilir. Turizm talebine etki eden, talebi belirleyen faktörlerin irdelendiği çalışmaların önemli bir kısmında turizm talep tahmini gerçekleştirilmiştir. Bu açıdan da yeni bir tahmin yöntemi sunmak adına çalışma önemlidir.

## Araştırma Yöntemi ve Kullanılan Veriler

Yapay sinir ağlarının öngörme amaçlı ağ yapısı olarak kullanılan Çok Katmanlı Perceptron modeli, kantitatif verilerle kestirimsel çalışmalarda en yaygın kullanılan ağ mimarisi olması nedeniyle çalışmamızda tercih edilen yöntem olmuştur. Hem doğrusal hem de doğrusal olmayan yapılarda çok başarılı olduğundan bu çalışmada uygulanan yöntemdir. Bir diğer avantajı ise diğer mimarilere göre çok dahakullanışlı bir yöntem olmasıdır. Bu sayede daha az çaba ile yeterli derecede başarılı sonuçlar elde edebilen ağ mimarisi olarak dikkat çekmektedir. Çalışmada kullanılan veriler Türkiye İstatistik Kurumu'ndan alınmış 1969-2017 yılları arasındaki Türkiye aylık turizm gelirleri verileridir.

### Yazılım

Veri madenciliği çalışmalarında yapay sinir ağlarını çözmek için geliştirilmiş birçok yazılım vardır. Araştırmacılar ya bu yazılımları ya da probleme özgü olarak kendi geliştirdikleri yazılımları kullanmaktadırlar. Bu çalışmada WEKA kullanılmıştır. WEKA, açık kaynak kodlu Java ile yazılmış bir veri madenciliği aracıdır.

### Yöntemin Uygulanması

Veriler WEKA için uygun formata dönüştürüldükten sonra, Çok Katmanlı Perceptron seçilir ve 10 Çapraz Doğrulama ile test edilir

**Tablo 1:** Çapraz Doğrulama sonuçları

|                                    |             |
|------------------------------------|-------------|
| ==== Predictions on test data ==== |             |
| ==== Cross-validation ====         |             |
| ==== Summary ====                  |             |
| Correlation coefficient            | 0.9774      |
| Mean absolute error                | 275126.0657 |
| Root mean squared error            | 310788.503  |
| Relative absolute error            | 19.2181 %   |
| Root relative squared error        | 19.6969 %   |
| Total Number of Instances          | 12          |

Multi Layer Perceptron kullanılarak modellenen veriler için tahminlenen değerler, gerçek veriler ve hata değerlerini içeren sonuçlar aşağıda çizelge 2'de verilmiştir.

| AYLAR   | 2018-GER-<br>ÇEK<br>(bin dolar) | TAHMİN-<br>LENEN<br>(bin dolar) | HATA<br>(bin dolar) |
|---------|---------------------------------|---------------------------------|---------------------|
| OCAK    | 1 461 570                       | 1 307 858                       | -153711             |
| ŞUBAT   | 1 527 070                       | 1 740194                        | 213124              |
| MART    | 2 139 766                       | 1 578 470                       | - 561295            |
| NİSAN   | 2 655 561                       | 2 858 724                       | 173808              |
| MAYIS   | 3 678 440                       | 4 286 763                       | 608323              |
| HAZİRAN | 4 505 594                       | 4 215 392                       | - 290201            |
| TEMMUZ  | 5 671 801                       | 5 456 428                       | - 215372            |
| AĞUSTOS | 5 383 332                       | 5 179 760                       | - 203571            |
| EYLÜL   | 4 792 818                       | 5 012 134                       | 219316              |
| EKİM    | 3 755 467                       | 3 463 770                       | - 291696            |
| KASIM   | 1 966 277                       | 2 134 203                       | 167926              |
| ARALIK  | 1 950 705                       | 2 124 513                       | 173808              |

**Çizelge 2:** MLP sonucu bulunan değerler

### Sonuç ve Öneriler

Turizm ekonomik sonuçları açısından değerlendirildiğinde, tüm ülkelerin bu sonuçlardan yararlanmak için büyük çaba harcadığı bir faaliyet olarak kabul edilmektedir. Özellikle, ödemeler dengesine ve ekonomik uygulanabilirliğe olan katkısı, turizmi birçok ülkede cazip hale getirmiş ve kalkınma planlarına yaygın olarak dahil edilmiştir. Gelir ve döviz girdisi olarak ulusal bir ekonomi için turizm, bölgeler arası ekonomik dengesizliğin ortadan kaldırılması, yeni işlerin açılmasıyla işsizliğin azaltılması, tarım, taşımacılık, hizmetleri ve diğer turizm ile doğrudan ve dolaylı olarak ilişkili olan ticari faaliyetlerin parasal olmayan etkileri kadar hayati öneme sahiptir.

Bununla birlikte, turizmin belirtilen özelliklerinden yararlanmak için, hem kamu hem de özel sektörde gelecekteki kararların alınmasında turizm talebine ilişkin tahminler çok önemlidir. Turizmdeki gelişmeleri bilimsel yöntemlerle tahmin etmek, yönetici pozisyonundaki bireylerin karar vermelerini kolaylaştıracaktır. Ancak: güvenilir ve doğru talep tahminleri ve turizm sektörüyle ilgili her türlü konaklama, ulaşım ve seyahat faaliyetleri. Bu nedenle, kullanılan veri setleriyle uyumlu ve en doğru tahmin sonuçlarını veren metodun belirlenmesi, gelecekte yapılacak talep tahminlerinin güvenilirliği için de önemlidir. Turizm sektöründe hızla

gelişen dünyanın değişimlerine uyum sağlayıp, rekabeti yönetmek ve değişimleri avantaja dönüştürebilmek giderek zorlaşmaktadır. Yaşamın her alanındaki başarılı tahminlemelerin geleceğimizi önemli ölçüde etkilediği gerçektir. Hayatın getirdiği risklerin farkına varabilme, ileriye yönelik planlamalar yapabilme ve istikrar açısından, başarılı tahminlemelerin önemi bütün dünya tarafından kabul edilmektedir.

Turizmdeki gelişmeleri bilimsel yöntemlerle tahmin etmek yöneticilerin karar vermelerini kolaylaştırır. Talep, turizm yatırımlarının itici gücüdür vesayisal ve niteliksel özelliklerin bir işlevi olarak ortaya çıkar. Çok büyük yatırımlarda turizm projelerinin başarısı, talep ve arz yapısına göre değişir. Kullanılan veriler ve en doğru tahminleri veren yöntemi belirlemek, talep tahminlerinin güvenilirliği için son derece önemlidir.

Bu çalışmada 1967-2017 arası Türkiye turizm gelirleri yapay sinir ağı ile modellenerek, yüksek başarılı bir model ile 2018 turizm gelirleri tahmin edilmiştir. Modeldeki hatanın önemsenmeyecek düzeyde olduğu görülmektedir. Benzer şekilde 2019 verileri belli bir güven aralığında tahmin edilebilir. Bu da turizm sektöründe alınması gereken önlemler için bir fikir oluşturabilir. Bu da büyük verinin ne kadar önemli olduğunun göstergesidir. Sektörde verilerin bu tür veri madenciliği çalışmaları yapılabilmesi için daha ayrıntılı depolanması önemli bir konudur. Benzer çalışmalar iler bazında yapılarak, daha yerel önlemlerin alınması sağlanabilir. Yapılan tahminler ile merkezi ve yerel kamu yönetimleri tarafından hazırlanan turistik gelişme planları için bir zemin oluşturulabilir. İlgili işletme yöneticilerinin aylık planlamalarında karar almaları kolaylaştırılabilir.

### **Kaynakça**

- Akpınar, H. (2014). *Data*. İstanbul: Papatya Yayıncılık.
- Aktaş, A. (2002). *Turizm İşletmeciliği ve Yönetimi*. Ankara: Detay Yayıncılık.
- Bahadır, E. ve Özdemir, A.Ş. (1996). *Akademik Başarı Tahmininde Yapay Sinir Ağları*. İstanbul: Burç Yayınevi.
- Balkin, S. D. (1997). Using Recurrent Neural Networks For Time Series Forecasting. *Working Department of Management Science and Information Systems Pennsylvania State University*, 97-111.
- Can, M., Çamur, B., Kuru, E., Özkan, Ö. ve Rzayeva, Z. (2012). Veri Kümelerinden Bilgi Keşfi: *Veri Madenciliği, XIV. Öğrenci Sempozyumu Çalışma Grubu Sunumları* içinde, Başkent Üniversitesi, Tıp Fakültesi, (ss. 1-14).
- Çuhadar, M. (2006). *Turizm Sektöründe Talep Tahmini İçin Yapay Sinir*

*Ağları Kullanımı ve Diğer Yöntemlerle Karşılaştırmalı Analizi.* (Yayımlanmamış Doktora Tezi). Süleyman Demirel Üniversitesi, Isparta.

Çuhadar, M., Güngör, İ. ve Göksu, A. (2009). Turizm Talebinin Yapay Sinir Ağları ile Tahmini ve Zaman Serisi Yöntemleri ile Karşılaştırmalı Analizi: Antalya İline Yönelik Bir Uygulama. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 14(1), 99-114.

Elmas, Ç. (2010). *Yapay Zeka Uygulamaları*. İstanbul: Seçkin Yayıncılık.

Güvenç, U., Biroğul, S., Sönmez, Y. (2007). Yapay Sinir Ağları Eğitim Seti. 7. *Uluslararası Eğitim Teknolojileri Konferansı Bildirileri* (ss. 1 – 6).

Hamzaçelebi, C., Kutay, F.(2004). Yapay Sinir Ağları ile Türkiye Elektrik Enerjisi Üretimiminin 2010 Yılına Kadar Tahmini. *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 19, 227- 233.

Haykin, S. (1999). *Neural Networks. A Comprehensive Coundation*. New Jersey, U.S.A: Prentice Hall.

Kabalıcı, E. (2019). *Yapay Sinir Ağları*. <https://ekblc.files.wordpress.com/2013/09/ysa.pdf>. Erişim Tarihi: 17.09.2019.

Kandır, S., Karadeniz, Y., Özmen, E., Önal, M. ve Beyazıt, Y. (2008). Türk Turizm Sektöründe Büyüme Göstergelerinin Turizm İşletmelerinin Finansal Performansına Etkisinin İncelenmesi. *Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 10 1/2.

Odabaş, Ö. (2017). *Veri Madenciliği Teknikleri ile Telekom Sektöründe Ayrılan Müşteri Analizi*. (Yayımlanmamış Yüksek Lisans Tezi). İstanbul Ticaret Üniversitesi/Fen Bilimleri Enstitüsü, İstanbul.

Öztemel, E. (2012). *Yapay Sinir Ağları*. İstanbul: Papatya Yayıncılık Eğitim.

Savaş, S. (2012). Veri Madenciliği ve Türkiye'deki Uygulama Örnekleri. İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi. 21, 1-23.

Şaylan, Ç. A. (2013). *Böbrek Nakli Geçirmiş Hastalarda Akıllı Yöntem TabanlıYeni Öznitelik Seçme Algoritması Geliştirilmesi*. Kadir Has Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi.

Şeker, Ş. E. (2019). <http://bilgisayarkavramlari.sadievrenseker.com/2008/12/15/k-ortalama-algoritmasi-k-means-algorithm>. Erişim Tarihi: 18.09.2109.

Yurtođlu, H. (2005). *Yapay Sinir Ağları Metodolojisi İle Öngörü Modellemesi: Bazı Makroekonomik Deđişkenler İçin Türkiye Örneđi*. (Uzmanlık Tezi). Ekonomik Modeller ve Stratejik Araştırmalar Genel Müdürlüğü.

Zhang, G., Patuwo, G. E., Hu, M.Y. (1998). Forecasting with Artificial Neural Networks: The State of The Arts. *International Journal of Forecasting*. Volume:4, No: 1, 1998, s. 35-62.

Zhao, Y. (2013). *R and Data Mining: Examples and Case Studies*. Burlington: Academic Press, 225.

<http://www.tuik.gov.tr> Erişim Tarihi: 25.09.2019.

<https://machinelearningmastery.com/when-to-use-mlp-cnn-and-rnn-neural-networks> Erişim Tarihi: 21.07.2019.