



JOURNAL of SOCIAL and HUMANITIES SCIENCES RESEARCH (JSHSR)

Uluslararası Sosyal ve Beşeri Bilimler Araştırma Dergisi

Received/Makale Geliş 25.06.2022
Published/Yayınlanma 31.08.2022
Article Type/Makale Türü Research Article

Citation/Alıntı: Eşidir, K.A., Gür, Y.E. & Yoğunlu, A. (2022). Multilayer Perceptron (MLP) ve Radial Basis Function (RBF) tahmin modelleri ile Elazığ turizm memnuniyet analizi sonuçlarının tahmini. *Journal of Social and Humanities Sciences Research*, 9(86), 1682-1703.
<http://dx.doi.org/10.26450/jshsr.3193>

Kâmil Abdullah EŞİDİR
<https://orcid.org/0000-0002-8106-1758>
Fırat Kalkınma Ajansı, Elazığ Yatırım Destek Ofisi, Elazığ / TÜRKİYE

Arş. Gör. Yunus Emre GÜR
<https://orcid.org/0000-0001-6530-0598>
Fırat Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, Yönetim Bilişim Sistemleri Bölümü, Elazığ / TÜRKİYE

Abdulvahap YOĞUNLU
<https://orcid.org/0000-0003-1214-1014>
Fırat Kalkınma Ajansı, Malatya / TÜRKİYE

MULTİLAYER PERCEPTRON (MLP) VE RADIAL BASIS FUNCTION (RBF) TAHMİN MODELLERİ İLE ELAZIĞ TURİZM MEMNUNİYET ANALİZİ SONUÇLARININ TAHMİNİ

ESTIMATION OF ELAZIĞ TOURISM SATISFACTION ANALYSIS RESULTS USING WITH MULTILAYER PERCEPTRON (MLP) AND RADIAL BASIS FUNCTION (RBF) PREDICTION MODELS

Issue/Sayı: 86

Volume/Cilt: 9

jshsr.org

ISSN: 2459-1149

ÖZET

Turistlerin ziyaret ettikleri mekânlardan memnun ayrılmaları; yerel, ulusal ve uluslararası turizm faaliyetlerinin sürdürülebilirliği açısından önemlidir. Elazığ'da 2021 yılı sonbahar aylarında 400 kişilik yerli turist üzerinde bir araştırma gerçekleştirilmiştir. Araştırmada, yerli turistlerin yörede kalmış oldukları süre içerisinde sunulan hizmetlere ilişkin memnuniyet düzeyleri araştırılmıştır.

Bu çalışmanın amacı, yapılan anket çalışmasından ortaya çıkan "Memnuniyet" durumunu; MultiLayer Perceptron (MLP) ve Radial Basis Function (RBF) modelleri ile tahmin etmektir. Çalışmada, MLP modelinin eğitim aşamasındaki hata oranı %7,7 olurken, modelin test aşamasındaki hata oranı %7,8 çıkmıştır. RBF modelinin eğitim aşamasındaki hata oranı ise %18,8 ve test aşamasındaki hata oranı %11,6 olarak elde edilmiştir. Eğitim aşamasında MLP modeli, RBF'ye kıyasla 2,41 kat ve test aşamasında ise 1,49 kat başarı göstermiştir. Anketlerden elde edilen veriler kullanılarak, her iki modelin mimarisi ve diğer çeşitli parametreleri belirlenmiş, modellerin başarısı karşılaştırılmıştır. Çalışmanın sonunda, MLP'nin RBF modeline kıyasla daha iyi sonuç verdiği tespit edilmiştir.

Anahtar Kelimeler: Yapay Zekâ, Yapay Sinir Ağları, MLP, RBF ve Tahmin.

ABSTRACT

It is important for the sustainability of local, national, and international tourism activities when tourists leave satisfied with the places they have visited. A study was conducted on 400 local tourists in the autumn of 2021 in Elazığ. In the research, the satisfaction levels of domestic tourists regarding the services provided during their stay in the region were investigated.

The aim of this study is the "Satisfaction" situation that emerged from the survey study; Estimating with MultiLayer Perceptron (MLP) and Radial Basis Function (RBF) models. In the study, while the error rate in the training phase of the MLP model was 7.7%, the error rate in the testing phase of the model was 7.8%. The error rate in the training phase of the RBF model was 18.8% and the error rate in the testing phase was 11.6%. In the training phase, the MLP model was 2.41 times more successful than the RBF model and in the testing phase, it was more successful 1.49 times than the RBF. Using the data obtained from the questionnaires, the architecture and various other parameters of both models were determined and the success of the models was compared. In the study, it was found that the MLP model gave better results compared to the RBF model.

Keywords: Artificial Intelligence, Artificial Neural Networks, MLP, RBF, and Forecasting.

1. GİRİŞ

Sürekli olarak gelişme eğilimi içerisinde olan turizm sektörü, etkilediği sektörler itibari ile de dünyanın en önde gelen sektörleri arasında yer almaktadır. Artan bir döviz kazancı kaynağı olarak birçok ülkede önemli bir sektör haline gelen turizm, birçok ülkede yaşanan ödemeler dengesi sorunlarının giderilmesi ve döviz getirisi sağlamanın yanı sıra istihdam da oluşturmaktadır. Turizmin; ekonomik kalkınma ve ticaret performansı üzerindeki önemi göz önüne alındığında, hükümetler, uygulayıcılar ve araştırmacılar turizm talebini modellemek ve tahmin etmekle ilgilenmektedir. Turizm talebi, turizmle ilgili tüm iş kararlarının temelini oluşturmaktadır. Havayolları, tur operatörleri, oteller, yolcu gemileri vb. işletmeler, turistlerin ürünlerine olan talebiyle ilgilenmektedirler. Birçok işletmenin başarısı büyük ölçüde veya tamamen turizm talebinin durumuna bağlıdır ve nihai yönetim başarısızlığı pazar talebini karşılayamamaktan kaynaklanmaktadır. Talebin işletme kârlılığının belirleyicisi olma noktasındaki kilit rolü nedeniyle, gelecekte beklenen talep tahminleri tüm planlama faaliyetlerinde önemli bir unsur teşkil etmektedir. Özellikle turizm ürününün “bozulabilirliği” göz önüne alındığında, işletmelerin verimli planlama için turizm talebini doğru tahmin etmeleri gerekmektedir (Çuhadar, Cogurcu & Kukrer, 2014: 12).

Günümüzde turizm talep tahminine artan bir ilgi olduğu bilinmektedir. Bu artışın nedenlerinden bazıları, dünya turizminin sürekli büyümesi, daha gelişmiş tahmin tekniklerinin mevcudiyeti ve varış yeri düzeyinde turizm talebinin daha doğru tahmin edilmesi gerekliliğidir. Destinasyon düzeyinde turizm talep tahmini, destinasyonların altyapı geliştirme ihtiyaçlarını tahmin etmelerini sağladığı için turizm planlamasında önemli bir rol oynamaktadır (Claveria, Monte & Torra, 2013: 2).

Turizm işletmelerinin daha doğru tahminleri geliştirme ihtiyacı ve bunlara karşılık gelen faydaların tanınması konusunda, tahmin doğruluğu açısından öne çıkan tek bir model bulunmamaktadır (Song ve Li, 2008: 204). Turizm talep tahmini çalışmaları nedensel ekonometrik modeller ve nedensel olmayan zaman serisi modelleri olarak ikiye ayrılabilir. Bununla birlikte, zaman serilerinde mevsimsel ve trend bileşenlerinin nasıl modelleneceği ile ilgili tartışmalı konular ve doğrusal yöntemlerin sınırlamaları nedeniyle Yapay Sinir Ağlarına (YSA) artan bir ilgi olduğu görülmektedir. YSA, birçok alanda uygulanmaktadır, ancak son zamanlarda turizm talep tahmininde de kullanılmaktadır (Teixeira ve Fernandes, 2012: 446).

YSA, öğrenme stratejilerine göre üç türe ayrılabilir. Bunlar, denetimli öğrenme, denetimsiz öğrenme ve ilişkisel öğrenmedir. Turizm talep tahmininde en yaygın olarak kullanılan nöral ağ mimarisi, denetimli öğrenmeye dayalı çok katmanlı algılayıcı (MLP) modelidir (Tsaur, Chiu & Huang, 2002: 399). MLP sinir ağları, katmanlı bir bağlantıya sahip farklı nöron katmanlarından oluşmaktadır. Bu modelin bir diğer alternatifi ise, Radial Basis Function-Radyal Temelli Fonksiyon (RBF) mimarisidir. RBF ağları, belirli bir yayılma ile radyal tabanlı fonksiyonların doğrusal bir kombinasyonundan oluşmaktadır. Lin, Chen & Lee (2011), RBF ağlarının tahmin doğruluğunu MLP ve Destek Vektör Regresyon (SVR) ağlarınınki ile karşılaştırmıştır. MLP ve RBF ağlarında, bağlamla ilgili bilgiler, birkaç gözlem vektörünün birleştirilmesiyle girdi vektörüne dâhil edilmektedir. Bu çalışmadaki bağlam, zaman serilerinin geçmiş değerlerinden oluşmuştur.

Turizm talep tahmininde MLP sinir ağları daha fazla kullanılırken, Elman sinir ağı gibi hesaplama açısından daha pahalı olan diğer mimariler nadiren kullanılmaktadır. Elman ağları, Tekrarlayan Sinir Ağları-Recurrent Neural Networks (RNN) sınıfının özel bir mimarisidir. Elman ağlarının topolojisi, gizli katman nöronunun aktivasyonundan gelen geri bildirim ile bir MLP ağına topolojisine uygundur. Elman mimarisi, gizli katmanın aktivasyonlarının bir geri bildirim aracılığıyla zaman serisinin zamansal yapısını hesaba katmaktadır. Bu doğrultuda Cho (2003), farklı ülkelerden Hong Kong'a gelenlerin sayısını tahmin etmek için Elman mimarisini kullanmıştır.

Günümüzde, turistlerin ziyaret ettikleri mekânlardan memnun ayrılmaları; yerel, ulusal ve uluslararası turizm faaliyetlerinin sürdürülebilirliği açısından önemlidir. Turistlerin ziyaret ettikleri destinasyonlardan memnun ayrılmalarının, turizm talebini önemli ölçüde etkileyeceği değerlendirilmektedir. Bu amaç doğrultusunda, Elazığ'da 2021 yılı sonbahar aylarında Elazığ'ı ziyaret eden 400 yerli turist üzerinde bir araştırma gerçekleştirilmiştir. Yerli turistlerin yörede kalmış oldukları süre içerisinde sunulan hizmetlere ilişkin memnuniyet düzeyleri araştırılmıştır. Yapılan anket çalışmasından ortaya çıkan “Memnuniyet” durumu, bu çalışmada Veri Madenciliği Modellerinden MultiLayer Perceptron (MLP) ve Radial Basis Function (RBF) modelleri ile tahmin edilmeye çalışılmıştır.

Zaman serisi tahmini için makine öğrenme yöntemlerine artan ilgiye rağmen, turizm talep tahmini için farklı sinir ağları mimarilerinin doğruluğunu karşılaştıran çok az çalışma vardır. Ek olarak, bölgesel düzeyde mevcut olan kıt bilgi, bu tür verileri kullanan sınırlı sayıda yayınlanmış makale ile sonuçlanmaktadır. Bu durum, Elazığ'a gelen yerli turistlerin memnuniyet durumlarını tahmin etmek için iki farklı yapay sinir ağı mimarisinin (MLP ve RBF) tahmin performansını karşılaştırmamıza yol açmıştır.

Çalışma kapsamında; 16 Eylül - 5 Ekim 2021 tarihlerinde, "Algoritma Araştırma ve Danışmanlık" firması tarafından Elazığ ilinde 400 yerli turist üzerinde uygulanmış anket çalışmasının sonuçları kullanılmış ve analiz edilmiştir.

Uygulanan anket çalışmasında; Elazığ'ın yoğunlukla 35-44 yaş arası başta olmakla birlikte, her yaşta turist çeken bir şehir olduğu görülmektedir. Elazığ'da İstanbul, Ortadoğu Anadolu ve Güneydoğu Anadolu bölgelerinden gelen turistler çoğunluğu oluşturmaktadır. Elazığ, bölgenin kavşak noktası konumunda olup, bölgedeki diğer illerin turist hareketliliğine de katkı sağlamaktadır. Bu minvalde, Elazığ'a yönelik yapılacak her türlü tanıtım ve turizm geliştirme faaliyetinin bölgedeki diğer illere de faydalı olacağı değerlendirilmektedir. Uygulanan anket çalışmasında, Elazığ'da turistik amaçlı ziyaretlerde en etkili faktörün tanıdık tavsiyeleri olduğu görülmektedir. Kültürel aktiviteler de şehrin ziyaret edilmesinde önemli bir etkidir.

2. LİTERATÜR İNCELEMESİ

Turizm talep tahmini kapsamında YSA'lar ilk olarak 1990'ların sonlarına doğru kullanılmaya başlanmıştır. Pattie & Snyder (1996), ABD milli parklarındaki konaklamaları, aylık olarak tahmin etmek için bir YSA modeli geliştirmiştir. Çalışmada, tahminlerin, diğer klasik zaman serisi modellerinden elde edilen sonuçlardan daha doğru olduğu tespit edilmiştir. Uysal & El Roubi (1999), Amerika Birleşik Devletleri'nde Kanada turizm harcamalarını kullanan bir YSA geliştirmiştir. Bulgular, sinir ağının yüksek ayarlanmış korelasyonlar ve düşük hata terimleriyle oldukça doğru sonuçlar elde ettiğini göstermiştir. Bununla birlikte Law (2000), Tayvan'ın Hong Kong turizmi talebini modellemek ve tahmin etmek için bir ileri-geri yayımlı sinir ağı (MutiLayer Perceptron olarak da adlandırılır) geliştirmiştir. Palmer, Montaño & Sesé (2006), İspanya'nın Balear Adaları'ndaki turist harcamalarını tahmin etmek için YSA modelleri geliştirmiştir. Modeller ham verilerle iyi performans göstermese de önceden işlenmiş veriler için çok düşük MAPE değerlerine ulaşmıştır. Bunun yanı sıra Cho (2009), Asya Pasifik bölgesine gelen turist sayılarını tahmin etmek için iki zaman serisi modeliyle birlikte geriye doğru yayımlı YSA modelini kullanmıştır.

Teixeira ve Fernandes (2012), bir bölgedeki otellerde aylık misafir sayısını tahmin etmek için YSA, doğrusal regresyon modelleri, Box-Jenkins metodolojisi ve ARIMA modellerine dayalı birkaç model geliştirmiştir. Çalışmaları, YSA modellerinin performanslarını her zaman en iyi modellerin en üstünde olduğunu göstermiştir. Goh ve Law (2011), YSA'ların turizm talep modellemesi ve tahmini üzerindeki uygulamalarının kapsamlı bir incelemesini sağlamıştır. Çuhadar (2013), Türkiye'ye gelen turizm talebini tahmin etmek için, İleri Geri Besleme Yayımlı (MLP), Radyal Temel Fonksiyonu (RBF) ve Zaman Gecikmesinin (TDNN) ex-post tahmin doğruluklarını analiz etmiştir. Çeşitli denemeler sonucunda [4-5-1-] mimarisine sahip, 12 gecikmeli MLP modelinin en iyi tahmin performansını sunduğu gözlemlenmiştir. Turizm talebini modelleme ve tahmin etme konusundaki çalışmaların çoğu, YSA'ların farklı veri periyodikliğini göz önünde bulundurarak klasik modeller kadar iyi veya önemli ölçüde daha iyi puan verdiğini göstermiştir.

Turizm talep tahmini ile ilgili literatür incelendiğinde; YSA'ların tahmin performansını, regresyon tabanlı ve otoregresif tümlşik hareketli ortalama (ARIMA) modelleri gibi geleneksel istatistiksel modellerle karşılaştıran çalışmaların çok geniş ve büyüekte olduğu görülmektedir. Son çalışmalarda, Lin vd. (2011) ile Claveria ve Torra (2014), talep tahmininde ARIMA modellerinin YSA modellerinden daha iyi performans gösterdiğini bulmuşlardır; yine de çoğu çalışma, YSA'ların lehine ampirik kanıtlar sunmaktadır (Tang, Almeida & Fishwick, 1991; Weigend ve Gershenfeld, 1993; Zhang, Putuwo & Hu, 1998; Marcellino, 2005). Teräsvirta, van Dijk & Medeiros (2005)'ne göre YSA modelleri ile uzun dönemli talep tahminleri daha sağlıklı yapılmaktadır.

1990'lardan beri birçok farklı YSA modeli geliştirildiği görülmektedir. Sinir ağları, farklı katmanların bağlantı modellerine bağlı olarak iki ana mimari tipinde sınıflandırılabilir. Bunlar; bilginin yalnızca bir yönde çalıştığı ileri beslemeli ağlar ve dış katmanlardan geri besleme bağlantılarının olduğu tekrarlayan ağlardır. İleri beslemeli sinir ağları, tasarlanan ilk YSA'dır. Zaman serisi

tahmininde en yaygın olarak kullanılan ileri beslemeli topoloji MLP ağıdır. Bu çalışmalar, özellikle belirgin örüntüleri olmayan seriler için, sinir ağlarının tahmin doğruluğu açısından regresyon modellerinden ve zaman serisi modellerinden daha iyi performans gösterdiğini gösteren deneysel sonuçlar sağlamaktadır. Bununla birlikte, iki katmanlı işleme ile çok katmanlı ileri besleme mimarisinin özel bir sınıfı RBF ağıdır. RBF ağlarının, MLP ağları gibi yerel minimumlardan etkilenmeye avantajına sahip olması, turizm talep tahmininde tercih edildiğini açıklamaktadır (Claveria, Monte & Torra, 2015: 493).

Chen (2011), Tayvan'ın turizm talebini tahmin etmek için geri yayılım ve destek vektör regresyon (SVR) ağlarının birleşimlerini kullanmış ve SVR birleşim modelleriyle en iyi performansı elde etmiştir. Cang (2013), Birleşik Krallık'a gelen turist ziyaretlerini tahmin etmek için MLP, RBF ve SVR ağlarına girdi olarak farklı zaman serisi doğrusal modelleri birleştirmiştir. Çalışmada, genel doğrusal birleşim modelleri ile ilgili olarak tüm doğrusal olmayan birleşim modellerin lehine kanıtlar bulunmuştur.

İleri beslemeli ağların aksine, tekrarlayan sinir ağları, çift yönlü veri akışına sahip modellerdir. İleri beslemeli bir ağ, verileri girdiden çıktıya doğrusal olarak yayarken, tekrarlanan ağlar; ayrıca dış katmanlardan, alt katmanlara geçici bir geri bildirim yaymaktadır. Ayrıca tekrarlayan ağların özel bir durumu Elman ağlarıdır. MLP, tahmin amacıyla daha fazla kullanılırken, Elman ve benzeri mimariler, turizm talep tahmininde nadiren kullanılmaktadır.

3. YÖNTEM

Bu çalışmada, 2021 yılında Elazığ ilini ziyaret eden 400 yerli turiste uygulanan “Elazığ Turizm Memnuniyet Analizi” anket çalışmasındaki seyahat memnuniyet sonuçları, YSA modellerinden MultiLayer Perceptron (MLP) modeli ve Radial Basis Function (RBF) modeli kullanılarak tahmin edilmiştir. Bu modeller detaylı bir şekilde açıklanmaya çalışılmıştır.

3.1. Yapay Sinir Ağları (YSA)

Son yıllarda, turizm talep tahmin modellerinin doğruluğunu artırmak için YSA'ların uygulanabilirliği büyük ilgi görmektedir. Bu ilginin nedeni, YSA'ların herhangi bir doğrusal veya doğrusal olmayan işlevi işleme yeteneğine sahip olmasıdır. YSA'lar çok yönlü olmakla birlikte modelin resmi olarak belirtilmesini gerektirmemektedir. Veriye dayalı yapıları nedeniyle, sistem hakkında ön varsayım olmaksızın, karmaşık kalıplarla başa çıkabilmekte ve doğrusal olmayan ilişkileri yansıtan modeller oluşturabilmektedirler. YSA'lar, genelleme yetenekleri ile eksik verilerde bile iyi performans göstermektedirler. YSA'ların tüm bu özellikleri, onları tahmin görevleri için çok kullanışlı bir araç haline getirmektedir. YSA'lar, geçmiş eğitim verilerinde gözlemlenen kalıplara dayalı olarak gelecekteki olayları tahmin etmek için kullanılabilir (Çuhadar vd., 2014: 16).

YSA'lar, temel olarak insan beyninin işlevini taklit eden, devasa paralel hesaplama modelleridir. Bir YSA, ağırlıklı bağlantılarla birbirine bağlanan çok sayıda basit işlemciden oluşmaktadır ve işlem düğümleri “nöronlar” olarak adlandırılmaktadır. Her düğüm çıkışı ya dâhili olarak depolanan ya da ağırlıklı bağlantılar yoluyla gelen bilgilere bağlıdır. Her birim diğer birçok düğümden girdi almakta, çıktısını başka bir düğüme iletmektedir. Bir işleme ögesi tek başına güçlü değildir. Öge girdileri, doğrusal olmayan ve basit bir fonksiyonu olan tek sayısal değere sahip skaler bir çıktı üretmektedir. İstenen yanıt ile sistem çıktısı arasındaki farktan bir hata oluşmuştur. Bu hata bilgisi sisteme geri beslenmekte ve parametreleri sistematik bir şekilde ayarlamaktadır. Bu işlem, performans kabul edilebilir olana kadar tekrarlanmaktadır. Bu açıklamadan, performansın büyük ölçüde verilere bağlı olduğu açık bir şekilde görülmektedir. Çalışma koşullarının önemli bir bölümünü kapsayan veriler yoksa sinir ağı teknolojisi doğru çözüm olmayacaktır. Öte yandan, bol miktarda veri varsa ve sorun yeterince anlaşılmadıysa, sinir ağı teknolojisi iyi bir seçim olacaktır. Bu işletim prosedürü, kapsamlı alt sistem spesifikasyonlarından ve iletişim protokollerinden oluşan geleneksel mühendislik tasarımı ile karşılaştırılmalıdır. YSA, sorunu matematiksel anlamda çözmemektedir, ancak belirli bir soruna yaklaşık bir çözüm veren bilgi işleme özelliklerini göstermektedir. YSA'lar karmaşık doğrusal olmayan fonksiyon haritalama, görüntü işleme, örüntü tanıma ve sınıflandırma vb. alanlarda yaygın olarak kullanılmaktadır. İleri beslemeli ağlar, yaygın sinir ağları türlerinden biridir. İleri beslemeli bir ağ; problem girdilerinin alındığı bir girdi katmanı, girdiler ve çıktılar arasındaki ilişkinin belirlendiği, sinaptik ağırlıklarla temsil edildiği gizli katmanlar ve problemin çıktılarını yayan bir çıktı katmanı içermektedir. İleri beslemeli sinir ağı, üç temel unsurla modellenmiştir: a) sinaptik ağırlıklarla karakterize edilen bir sinaps kümesi, b) giriş sinyallerini toplamak için bir toplayıcı veya doğrusal

birleştirici, c) nöronun çıktısının genliğini sonlu bir değerle sınırlamak için bir aktivasyon fonksiyonu. Aktivasyon fonksiyonunun girişi, bir önyargı terimi kullanılarak artırılabilir (Dongare, Kharde & Kachare, 2012: 190).

Günümüzde YSA'lar, biyolojik sinir sistemleri, özellikle de insan beynini modellemeye yönelik araştırmalarda kullanılmaktadır. Bir YSA, nöronlar, düğümler veya hücreler olarak adlandırılan, birbiriyle yüksek düzeyde bağlantılı ve katmanlar halinde organize edilmiş birçok basit bilgi işlem biriminden oluşan bir ağıdır. Her nöron, alınan girdileri işlenmiş çıktılara dönüştürerek basit bilgi işleme görevini yerine getirmektedir. Bu nöronlar arasındaki bağlantı yayları aracılığıyla, farklı düğümler arasındaki ilişkinin gücü hakkında bilgi üretilebilmekte ve saklanabilmektedir (Zhang, 2004:9).

Tipik bir yapay nöron ve çok katmanlı bir sinir ağının modellenmesi Görsel 1'de gösterilmiştir. Görsel 1'e bakıldığında, x_1 , girişlerinden gelen sinyal akışı x_1, \dots, x_n bir nöronun çıkış sinyali akışı (O) gibi oklarla gösterilip tek yönlü olarak kabul edilir. Nöron çıkış sinyali O, aşağıdaki ilişki ile verilmektedir:

$$O = f(\text{net}) = f\left(\sum_{j=1}^n w_j x_j\right) \quad (1)$$

Burada w_j ağırlık vektörüdür ve $f(\text{net})$ fonksiyonu bir aktivasyon (transfer) fonksiyonu olarak adlandırılır. Değişken net, ağırlık ve girdi vektörlerinin skaler bir ürünü olarak tanımlanır,


$$\text{net} = w^T x = w_1 x_1 + \dots + w_n x_n \quad (2)$$

T bir matrisin devrik olduğu ve en basit durumda, çıkış değeri O olarak hesaplanır,

$$O = f(\text{net}) = \begin{cases} 1 & \text{if } w^T x \geq \theta \\ 0 & \text{otherwise} \end{cases} \quad (3)$$

Burada θ eşik seviyesi olarak adlandırılır ve bu tip düğüme lineer eşik birimi denir.

Bir YSA'nın temel elemanları; ağırlıklar, yanlılık ve aktivasyon fonksiyonu olmak üzere üç ana bileşenden oluşmaktadır. Şekil 1'de yapay bir nöronun temel unsurları gösterilmiştir.




Şekil 1. Yapay Bir Nöronun Mimarisi ve Çok Katmanlı Bir Sinir Ağı, **Kaynak:** (Abraham, 2005)

3.1.1. Multilayer Perceptron (MLP) Modeli

Çok katmanlı algılayıcı ağları (MLP), ileri beslemeli bir şekilde birbirine bağlı çok sayıda hesaplama birimi katmanından oluşmaktadır. MLP ağları, basit bir algılayıcı modelini yapı taşı olarak kullanan denetimli sinir ağlarıdır. Bu topoloji, optimal bağlantıları içeren katmanlar arasındaki bağlantılarla paralel algılayıcı katmanlarından oluşmaktadır. Gizli katmandaki nöronların sayısı, MLP ağının belirli bir fonksiyona yaklaşma kapasitesini belirlemektedir. Aşırı uyum sorununu çözmek için, çapraz doğrulama ile nöron sayısı tahmin edilmektedir (Claveria vd., 2015: 494).

MLP sinir ağları, katmanlar halinde düzenlenmiş birimlerden oluşmaktadır. Her katman düğümlerden oluşmakta ve her düğüm sonraki katmandaki diğer düğüme bağlanmaktadır. Her MLP, bir girdi katmanı, gizli katman(lar) ve bir çıktı katmanı olmakla birlikte en az üç katmandan meydana gelmektedir. Giriş katmanı, girdileri sonraki katmanlara dağıtmaktadır. Giriş düğümleri doğrusal etkinleştirme işlevlerine sahiptir ve eşikleri yoktur. Her gizli birim ve çıkış düğümü, sinyallere ek

olarak kendileriyle ilişkili eşiklere sahiptir. Gizli birim düğümleri doğrusal olmayan etkinleştirme işlevlerine, çıkışlar ise doğrusal etkinleştirme işlevlerine sahiptir. Tipik bir üç katmanlı MLP ağı, Şekil 2'de gösterilmiştir (Delashmit ve Manry, 2005: 2).



Şekil 2. Tipik Bir Üç Katmanlı MultiLayer Perceptron (MLP) Ağı, **Kaynak:** Delashmit ve Manry, 2005: 2

Eğitim verileri, p'nin model numarasını temsil ettiği bir dizi N_p eğitim modelinden (X_p, T_p) oluşur. Görsel 2'de X_p , pth eğitim modelinin N-boyutlu girdi vektörüne karşılık gelmektedir. Y_p ise, pth modeli için eğitilmiş ağdan M-boyutlu çıktı vektörüne karşılık gelmektedir. Notasyon ve analiz kolaylığı için, gizli birimler ve çıktı birimleri üzerindeki eşikler, $X_p(N+1)$ ile gösterilen artırılmış bir vektör bileşenine bir değeri atanarak ele alınmaktadır. Çıkış ve giriş birimlerinin doğrusal aktivasyonları vardır. Gizli birimin girdisi $net_p(j)$, şu şekilde ifade edilmektedir:

$$net_p(j) = \sum_{k=1}^{N+1} w_{hi}(j,k) \cdot x_p(k) \quad 1 \leq j \leq N_h \quad (4)$$

pth eğitim modeli için çıktı aktivasyonu $O_p(j)$ ile ifade edilmektedir:

$$O_p(j) = f(net_p(j)) \quad (5)$$

Doğrusal olmayan aktivasyon tipik olarak sigmoidal fonksiyon olarak seçilir.

$$f(net_p(j)) = \frac{1}{1 + e^{-net_p(j)}} \quad (6)$$

(4) ve (5)'te, N giriş birimi k indeksi ile temsil edilir ve $w_{hi}(j,k)$, k. giriş birimini j. gizli birime bağlayan ağırlıkları belirtir.

MLP'nin genel performansı, şu şekilde ifade edilen ortalama kare hatası (MSE) ile ölçülmektedir:

$$E = \frac{1}{N_v} \sum_{p=1}^{N_v} E_p = \frac{1}{N_v} \sum_{p=1}^{N_v} \sum_{i=1}^M [t_p(i) - y_p(i)]^2$$

$$E_p = \sum_{i=1}^M [t_p(i) - y_p(i)]^2 \quad (7)$$

E_p , pth modeli için hataya karşılık gelmekte ve t_p , pth modeli için istenen çıktıdır. Bu durum aynı zamanda i. çıktı birimi için eşleme hatasının hesaplanmasına da izin vermektedir.


$$E_i = \frac{1}{N_v} \sum_{p=1}^{N_v} [t_p(i) - y_p(i)]^2 \quad (8)$$

pth eğitim modelinin i. çıktısı şu şekilde ifade edilmektedir:

$$y_p(i) = \sum_{k=1}^{N+1} w_{oi}(i,k) \cdot x_p(k) + \sum_{j=1}^{N_h} w_{oh}(i,j) \cdot O_p(j) \quad (9)$$

(9)'da $w_{oi}(i,k)$ girdi düğümlerinden çıktı düğümlerine olan ağırlıkları, $w_{oh}(i,j)$ ise gizli düğümlerden çıktı düğümlerine olan ağırlıkları temsil etmektedir.

MLP, turizm talep tahmin çalışmalarında en yaygın kullanılan sinir ağı topolojisi olmuştur. Bir MLP, katmanlarla ayrılmış ve sinyallerle birbirine bağlanan nöron gruplarından oluşmaktadır. Bir ağın sinyallerini belirlemek için ağ eğitilmektedir. Burada değerler ve aktivasyon fonksiyonları ağdan hangi ilişkilerin geçtiğini belirlemektedir. Şekil 3'te dört katmanlı bir MLP örneği gösterilmiştir. Bu diyagramda, düz çizgiler uyarı sinyallerini (veya pozitif ağırlıkları), kesikli çizgiler engelleyici sinyalleri (veya negatif ağırlıkları) temsil etmekte ve çizgi kalınlığı sinyalin büyüklüğünü yansıtmaktadır. Şekil 3'te gösterilen MLP ağı, hiperbolik tanjant aktivasyon fonksiyonlarının kullanıldığı dört katmandan oluşmaktadır. Bu ağda soldan sağa hareketle, ilk katman (veya giriş katmanı) ilk gizli katmana bağlanır, gizli katmanın çıktısı daha sonra gizli katmanları besler ve sonuçlar çıktı katmanına iletilir. Ardından sinyal çıkış katmanına ulaşana kadar ikinci gizli katmana geçirilir. Bir yapay sinir ağı içerisinde çeşitli aktivasyon fonksiyonlarını keşfetmek önemli olduğu gibi, gizli katmanların sayısını değiştirmek de önemlidir (Young, Bihl & Weckman, 2014: 195-196).




Şekil 3. Dört Katmanlı MultiLayer Perceptron (MLP) Ağı **Kaynak:** Young vd., 2014: 196

3.1.2. Radial Basis Function (RBF) Modeli

Son zamanlarda, yapay sinir ağlarına (YSA) dayalı modeller farklı araştırma alanlarında yaygın olarak uygulanmaktadır. YSA'ların farklı yapıları arasında, geri yayılım ağı (BPN) olarak adlandırılan hata-geri yayılım eğitim algoritmasına sahip çok katmanlı algılayıcı en popüler olanıdır. Öte yandan, çok katmanlı algılayıcıya bir alternatif olarak radyal tabanlı işlevli (RBF) sinir ağı, daha basit yapısı nedeniyle son yıllarda birçok pratik uygulamada büyük ilgi görmüştür. RBF, model tanımlamalarında ve fonksiyon yaklaşımlarında yaygın olarak benimsenmesine rağmen, harmonik algılama uygulamalarına nadiren rastlanılmaktadır.

Fonksiyonel tahmin, veri analizi ve örüntü tanıma uygulamalarında önemli bir problemdir. Radyal temel fonksiyonların (RBF'ler) özellikleri, onları evrensel yaklaşımıcılar olarak kullanılmaya uygun hale getirmektedir. RBF, BPN'den çok daha basit bir yapıya sahip ileri beslemeli bir sinir ağıdır. Giriş katmanı, tek bir gizli katman ve çıkış katmanı dâhil olmak üzere tipik bir RBF yapısı Şekil 4'te gösterilmiştir. RBF, fonksiyon yaklaşımı gerçekleştirmek için kompakt olarak desteklenen temel bir fonksiyonu temsil eden bir şemadır. Girdi ve merkez arasındaki Öklid mesafesi ile birkaç temel fonksiyon $\phi(\|x - C_j\|)$ oluşturularak, girdiler ve çıktılar arasındaki eşleştirme ilişkisi elde edilebilir, burada $\phi(\bullet)$ RBF olarak adlandırılır ve C_j , j. nöronun merkezini temsil etmektedir (Chang, Chen & Teng, 2009: 2172).



Şekil 4. Tipik Bir Radial Basis Function (RBF) Yapısı **Kaynak:** Chang vd., 2009: 2172

Basitlik adına, Şekil 4'teki yapıda sadece bir çıktı değişkeni (y) düşünülmüş ve RBF'deki çözüm prosedürünü göstermek için kullanılmıştır. Bu nedenle, ağın çıkışı y olmaktadır.

$$y = \sum_{j=1}^M w_j \cdot \phi(\|x - c_j\|) \quad (10)$$

w_j gizli katman ile çıktı katmanı arasındaki ağırlıktır. " p " zaman indeksinde istenen ve tahmin edilen sinyaller arasındaki fark " e " dir.

$$e(p) = d(p) - y(p). \quad (11)$$

Daha sonra, (11) hatası için amaç fonksiyonu şu şekilde tanımlanabilir:

$$E(p) = \frac{1}{2} e^2(p) = \frac{1}{2} (d(p) - y(p))^2. \quad (12)$$

Genel olarak, en yaygın temel fonksiyon Gauss fonksiyonudur.

$$\phi(\|x - c_j\|) = \exp\left(-\frac{\|x - c_j\|^2}{2\sigma_j^2}\right) \quad (13)$$

Burada σ_j , j . Gauss fonksiyonunun standart sapmasıdır. Genel olarak, varyans basitçe şu şekilde tanımlanabilir:

$$\sigma = \frac{d_{\max}}{\sqrt{M}} \quad (14)$$

Burada M merkez sayısıdır ve d_{\max} merkezler arasındaki en büyük mesafedir. Ardından, ağına karşılık gelen parametreleri, aşağıdakileri karşılayan gradyan iniş yöntemi kullanılarak tahmin edilir.

$$\frac{\partial E(p)}{\partial w_j} = 0 \quad \frac{\partial E(p)}{\partial c_j} = 0 \quad \frac{\partial E(p)}{\partial \sigma_j} = 0. \quad (15)$$

Böylece, güncellenen parametreler aşağıdakilere göre elde edilebilir:

$$w_j(p+1) = w_j(p) + \eta_1 e(p) \phi(\|x(p) - c_j(p)\|)$$

$$c_j(p+1) = c_j(p) + \eta_2 \frac{w_j(p) e(p)}{\sigma_j^2(p)} \quad (16)$$

$$\times \phi(\|x(p) - c_j(p)\|) (x(p) - c_j(p)) \quad (17)$$

$$\sigma_j(p+1) = \sigma_j(p) + \eta_3 \frac{w_j(p)e(p)}{\sigma_j^3(p)} \times \phi(\|x(p) - c_j(p)\|) \|x(p) - c_j(p)\|^2 \quad (18)$$

Burada n1, n2 ve n3 sırasıyla ağırlık, merkez ve standart sapmanın öğrenme oranlarıdır.

Bir tür kümeleme algoritması olan K-ortalamalar, birçok uygulamada kullanılmıştır. K-ortalamalar yöntemi, örnek uzayı birkaç bölüme ayırmak ve uygun merkezleri belirlemek için benimsenmiştir.

$$J(k) = \sum_{i=1}^M J_i = \sum_{i=1}^M \sum_{j=1}^n w_{ji} \|X_j - C_i\|^2 \quad (19)$$

Burada k yinleme sayısının indeksi, M kümelerin sayısıdır (yani merkez veya tahmin sırası), n kümelenecek örnek sayısıdır, X_j j. girde vektörüdür, C_i i. kümesinin merkezidir, J_i i. kümesinin amaç fonksiyonudur ve W_j, veri noktalarını karşılık gelen kümeye atayan ağırlıkları belirtir.

$$w_{ji} = \begin{cases} 1, & \text{if } \|X_j - C_i\| \leq \|X_j - C_m\| \quad \forall m \neq i \\ 0, & \text{others} \end{cases} \quad (20)$$

RBF ağlarında, öğrenme aşamasından sonra her gizli birime veri örneği yerel yoğunluklarına göre bir aktivasyon bölgesi atanır. RBF ağırlıkları, verilen denklem sistemi çözülerek ve eğitim seti için istenen değerler dikkate alınarak bulunur. Bu yaklaşımın uygulaması, k-ortalama kümeleme algoritması ve öğrenme vektör nicelme gibi kümeleme teknikleri ile ilgilidir (Borş ve Pitas, 1996: 1351).

3.2. Araştırmada Veri Toplama Yöntemi

Araştırmada öncelikle turizmde müşteri memnuniyeti-önemi konularına ilişkin kaynak taraması yapılmıştır. Elazığ'a gelen yerli turist özelliklerinin belirlenmesi ve Elazığ'da kaldıkları süre içerisinde almış oldukları hizmetlerden memnuniyet düzeylerine ilişkin görüşlerinin alınmasında ise anket tekniğinden yararlanılmıştır. Söz konusu anket çalışması için uzman görüşlerine başvurularak anket soruları oluşturulmuş ve anketin saha uygulaması 16 Eylül-5 Ekim 2021 yılı tarihleri arasında uygulanmıştır.

Ankette, Elazığ'ı ziyaret eden yerli turistlerin demografik özelliklerine ilişkin bazı sorular (cinsiyet, yaş vs.) sorulmuştur. Bu soruların yanı sıra, yerli turistlerin eğilimlerini belirleyebilmek adına turistlere; yöreyi ziyaret amacı, konaklama yaptığı işletme türü, yöreye geliş sıklığı, konakladığı gün sayısı, seyahatini organize ediş biçimi, yöre hakkındaki bilgi kaynakları, yöreye birlikte gelen kişi ve yöreye gelirken kullandığı ulaşım aracını benzeri sorular sorulmuştur.

Anket uygulaması, Algoritma Araştırma Firması tarafından Fırat Kalkınma Ajansı için yürütülmüştür. Araştırma kapsamında Elazığ'da 400 kişi ile görüşülmüştür. Araştırma CAPI (Bilgisayar Destekli Yüz Yüze Anket) yöntemi kullanılarak gerçekleştirilmiştir. Anket görüşmelerinin süre ortalaması 6 dakikadır. Elazığ'da 7 noktada sahaya çıkılmış ve toplamda 400 adet anket uygulaması gerçekleştirilmiştir. Anket uygulaması gerçekleştirilen yerler ve örneklem sıklığı aşağıdaki Tablo 1'de gösterilmiştir.

Tablo 1. Elazığ'da Anket Görüşmesi Yapılan Yerler ve Örneklem Sıklığı

Görüşme Sahası	Frekans	Yüzde (%)
Dedeman Oteli	30	7,5
Harput Kalesi	259	64,8
Kapalı Çarşı	35	8,8
Keban Çırcır Şelalesi	26	6,5
Hilton Double Tree Oteli	12	3,0
Akgün Oteli	13	3,3
Elazığ Arkeoloji ve Etnografya Müzesi	25	6,3
Toplam	400	100

3.2.1. Verilerin Tanımı

Uygulanan anket kapsamında, Elazığ ilini ziyaret eden 400 yerli turiste sorulan bazı sorular seçilmiş ve SPSS 25 Paket Programı ile analiz edilmiştir. Bu kapsamda Elazığ ilini ziyaret eden yerli

turistlerin, yaptıkları turistik ziyaretten memnuniyet durumu bağımlı değişken olarak belirlenmiştir. Anket katılımcılarına “Elazığ seyahatinizden memnuniyetinizi 1 ile 10 arasında puanlar mısınız?” sorusu sorulmuş ve verilen cevaplardaki 1 ile 6 arasındaki puanlama durumu “0:Memnun Değilim” ve 7 ile 10 arasındaki puanlama ise “1:Memnunum” şeklinde SPSS’e tanıtılmış ve “Memnuniyet” isimli kategorik değişken oluşturulmuştur.

Bağımlı Değişken:

Y: Memnuniyet (“0=Memnun Değilim, 1=Memnunum”).

Uygulanan anket çalışmasından en uygun olan 12 adet soru seçilmiş ve bu sorular bağımsız değişkenleri oluşturmuştur. Aşağıda sıralanan bağımsız değişkenlerin hepsi de kategorik özellik barındırmaktadır.

Bağımsız Değişkenler:

X1: Cinsiyet (1=erkek, 2=kadın).

X2: Yaş (1=“18-24 yaş”, 2=“25-34 yaş”, 3=“35-44 yaş”, 4=“45-54 yaş”, 5=“55-64 yaş”, 6=“65 yaş üzeri”).

X3: İkamet Edilen İl (1=“Akdeniz”, 2=“Batı Anadolu”, 3=“Batı Karadeniz”, 4=“Batı Marmara”, 5=“Doğu Karadeniz”, 6=“Doğu Marmara”, 7=“Ege”, 8=“Güneydoğu Anadolu”, 9=“İstanbul”, 10=“Kuzeydoğu Anadolu”, 11=“Orta Anadolu”, 12=“Ortadoğu Anadolu”).

X4: Turistik Faktör (1=“İnternette turizm sitelerini incelemek”, 2=“Sosyal medya”, 3=“Tanıdık tavsiyeleri”, 4=“TV veya ilan reklamları”, 99=“Diğer”).

X5: Varış Noktası (1=“Başka şehirleri de kapsayan rotanın bir parçası”, 2=“Şehir merkezi ve ilçeler”, 3=“Yalnızca şehir merkezi”).

X6: Elazığ’a Kaçınıcı Geliş (1=“İlk geliş”, 2=“2-5”, 3=“5-10”, 4=“10’dan daha fazla”).

X7: Seyahat Süresi (1=“1-2 Saat”, 2=“Yarım gün”, 3=“Tam Gün”, 4=“1 gece-2 gün”, 5=“2 gece-3 gün”, 6=“4-6 gün”, 7=“1 haftadan fazla”).

X8: Konaklama Şekli (1=“Akraba, tanıdık evi”, 2=“Apart”, 4=“Kamp”, 5=“Konaklama yok”, 6=“Otel”, 7=“Pansiyon”, 8=“Tesis”).

X9: Eğlence Mekanları Memnuniyet (1=“Hiç memnun değilim”, 2=“Memnun değilim”, 3=“Ne memnunum ne memnun değilim”, 4=“Memnunum”, 5=“Çok memnunum”, 6=“Fikrim yok”).

X10: Yeme İçme Hizmetleri Memnuniyet (1=“Hiç memnun değilim”, 2=“Memnun değilim”, 3=“Ne memnunum ne memnun değilim”, 4=“Memnunum”, 5=“Çok memnunum”, 6=“Fikrim yok”).

X11: Kültürel ve Tarihi Çekicilikler Memnuniyet (1=“Hiç memnun değilim”, 2=“Memnun değilim”, 3=“Ne memnunum ne memnun değilim”, 4=“Memnunum”, 5=“Çok memnunum”, 6=“Fikrim yok”).

X12: Doğal Güzellikler Memnuniyet (1=“Hiç memnun değilim”, 2=“Memnun değilim”, 3=“Ne memnunum ne memnun değilim”, 4=“Memnunum”, 5=“Çok memnunum”, 6=“Fikrim yok”).

Katılımcılara “Elazığ’daki seyahatinizden memnuniyetinizi 1 ile 10 arasında puanlar mısınız?” sorusu sorulmuştur. Bu soruya verilen cevapların tanımlayıcı istatistikleri Tablo 2’de sunulmuştur. Tanımlayıcı istatistik; bir veri setinin istatistiksel olarak genel özelliklerini tanımlayan ölçülerdir. Tablo 2’den 1 ile 10 arasında verilen 400 cevabın, aritmetik ortalamasının 7,75 ve ortanca değerinin 8 olduğu okunmaktadır.

Tablo 2. Seyahat Memnuniyet Puanı Tanımlayıcı İstatistikleri

Aritmetik Ortalama (Mean)	7,75
Ortanca Değer (Median)	8,00
Standart Sapma (Standard Deviation)	1,513
Değer Aralığı (Range)	9
En Küçük Değer (Minimum)	1
En Büyük Değer (Maximum)	10

1 ile 10 arasında değişen “Memnuniyet Puanları” kategorik değişkene çevrilmiş ve “0:Memnun Değil” veya “1:Memnun” şeklinde kategorize edilmişlerdir. Tablo 3’te Kategorik Değişkene çevrilen memnuniyet durumu tanımlayıcı istatistikleri sunulmuştur. Tablo 3’te görüldüğü üzere 67 kişi (%16,8) memnun değil, 333 kişi (83,3) ise memnun şeklinde 2 sınıfa ayrılmışlardır.

Tablo 3. Kategorik Değişkene Çevrilen Memnuniyet Durumu Tanımlayıcı İstatistikleri

	Frekans	Yüzde (%)	Kümülatif Yüzde
Memnun Değil	67	16,8	16,8
Memnun	333	83,3	100
Toplam	400	100	

Aşağıdaki tablolarda bağımsız değişkenleri oluşturan veri setleri ile ilgili detaylı açıklayıcı bilgiler yer almaktadır. Tablo 4'te ankete katılım sağlayıp cevap veren ve Elazığ'ı ziyaret eden yerli turistlerin cinsiyet dağılımı görülmektedir. Cinsiyet dağılımı 211 erkek (%52,8) ve 189 (47,3) kadın şeklinde olup, katılımcıların cinsiyet oranları birbirlerine yakındır.

Tablo 4. Elazığ'ı Ziyaret Eden Yerli Turistlerin Cinsiyet Dağılımı

	Frekans	Yüzde (%)	Kümülatif Yüzde
Erkek	211	52,8	52,8
Kadın	189	47,3	100
Toplam	400	100	

Tablo 5'te Elazığ'ı ziyaret eden yerli turistlerin yaş dağılımı görülmektedir. 35-44 yaş aralığı 127 kişi ve %31,8 ile en yüksek yerli turist yaş aralığını ifade etmektedir. 9 kişi ve %2,3 ile 65 yaş ve üzeri katılım guruplarındaki en düşük yaş aralığını temsil etmektedir.

Tablo 5. Elazığ'ı Ziyaret Eden Yerli Turistlerin Yaş Dağılımı

	Frekans	Yüzde (%)	Kümülatif Yüzde
18-24 yaş	43	10,8	10,8
25-34 yaş	103	25,8	36,5
35-44 yaş	127	31,8	68,3
45-54 yaş	57	14,3	82,5
55-64 yaş	61	15,3	97,8
65 yaş ve üzeri	9	2,3	100
Toplam	400	100	

Tablo 6'da Elazığ'ı ziyaret eden yerli turistlerin ikametleri coğrafi bölgelere göre görülmektedir. En yüksek ziyaretler 88 kişi ve %22 ile İstanbul ve Ortadoğu Anadolu olmuştur. En düşük ziyaret ise 6 kişi (%1,5) ile Batı Karadeniz Bölgesi'nden gerçekleşmiştir.

Tablo 6. Elazığ'ı Ziyaret Eden Yerli Turistlerin İkametlerini Belirten Dağılım

	Frekans	Yüzde (%)	Kümülatif Yüzde
Akdeniz	29	7,3	7,3
Batı Anadolu	20	5,0	12,3
Batı Karadeniz	6	1,5	13,8
Batı Marmara	11	2,8	16,5
Doğu Karadeniz	19	4,8	21,3
Doğu Marmara	11	2,8	24
Ege	18	4,5	28,5
Güneydoğu Anadolu	60	15	43,5
İstanbul	88	22	65,5
Kuzeydoğu Anadolu	20	5	70,5
Orta Anadolu	30	7,5	78
Ortadoğu Anadolu	88	22	100
Toplam	400	100	

Tablo 7'de Elazığ'ı ziyaret eden yerli turistlerin turistik seyahatleri için gideceği yeri belirleyen en etkili faktörleri gösteren dağılım ifade edilmektedir. Katılımcıların %53'ü (212 kişi) tanıdık tavsiyelerinin seyahatleri için en etkili faktör olduğunu belirtmişlerdir. TV veya ilan reklamları 3 kişi (%0,8) ile en etkisiz faktör olmuştur.

Tablo 7. Elazığ'ı Ziyaret Eden Yerli Turistlerin Turistik Seyahatleri İçin Gideceği Yeri Belirleyen En Etkili Faktörler

	Frekans	Yüzde (%)	Kümülatif Yüzde
İnternette turizm sitelerini incelemek	127	31,8	31,8
Sosyal medya	49	12,3	44,0
Tanıdık tavsiyeleri	212	53	97
TV veya ilan reklamları	3	0,8	97,8
Diğer	9	2,3	100
Toplam	400	100	

Tablo 8'de Elazığ'ı ziyaret eden yerli turistlerin mekânsal varış noktalarını gösteren dağılım belirtilmiştir. %66,8 ile 267 kişi Elazığ ziyaretlerini, başka şehirleri de kapsayan rotanın bir parçası olarak belirtmişlerdir. Katılımcıların %8,3'ü olan 33 kişi yalnızca Elazığ şehir merkezini ziyaret edeceklerini belirtmişlerdir.

Tablo 8. Elazığ'ı Ziyaret Eden Yerli Turistlerin Mekânsal Varış Noktalarını Gösteren Dağılım

	Frekans	Yüzde (%)	Kümülatif Yüzde
Başka şehirleri de kapsayan rotanın bir parçası	267	66,8	66,8
Elazığ şehir merkezi ve ilçeler (en az 1 ilçe varsa)	100	25,0	91,8
Yalnızca Elazığ şehir merkezi	33	8,3	100
Toplam	400	100	

Tablo 9'da Elazığ'ı ziyaret eden yerli turistlerin Elazığ'a geliş sayılarına ilişkin dağılım gösterilmektedir. 205 kişi ilk defa Elazığ'a geldiklerini belirtmiştir. Ankete katılanların %4'ü olan 16 kişi ise 10 defadan daha fazla Elazığ'ı ziyaret ettiklerini ifade etmişlerdir.

Tablo 9. Elazığ'ı Ziyaret Eden Yerli Turistlerin Elazığ'a Geliş Sayılarına İlişkin Dağılım

	Frekans	Yüzde (%)	Kümülatif Yüzde
İlk geliş	205	51,3	51,3
2-5 kez	149	37,3	88,5
5-10 kez	30	7,5	96
10'dan daha fazla	16	4	100
Toplam	400	100	

Tablo 10'da Elazığ'ı ziyaret eden yerli turistlerin seyahatlerinde Elazığ'da geçirdikleri süreye ilişkin dağılım gösterilmiştir. En fazla tercih edilen süre 112 kişi ve %28'lik oran ile "Tam Gün" olmuştur. 12 kişi ve %3'lük kesim ise Elazığ'da "1-2 Saat" şeklinde en az vakit geçiren kesim olmuştur.

Tablo 10. Elazığ'ı Ziyaret Eden Yerli Turistlerin Seyahatlerinde Elazığ'da Geçirdikleri Süreye İlişkin Dağılım

	Frekans	Yüzde (%)	Kümülatif Yüzde
1-2 Saat	12	3	3
Yarım gün	48	12	15
Tam Gün	112	28	43
1 gece-2 gün	34	8,5	51,5
2 gece-3 gün	73	18,3	69,8
4-6 gün	66	16,5	86,3
1 haftadan fazla	55	13,8	100
Toplam	400	100	

Tablo 11'de Elazığ'ı ziyaret eden yerli turistlerin Elazığ'daki konaklamalarına ilişkin veriler görülmektedir. En fazla tercih edilen konaklama şekli 139 kişi ve %34,8 ile otel seçeneği olmuştur. En az tercih edilen konaklama şekli ise 8 kişi (%2) ile tesis tipi konaklama olmuştur.

Tablo 11. Elazığ'ı Ziyaret Eden Yerli Turistlerin Elazığ'daki Konaklamalarına İlişkin Dağılım

	Frekans	Yüzde (%)	Kümülatif Yüzde
Akraba, tanıdık evi	128	32	32
Apart otel	6	1,5	33,5
Kamp	3	0,8	34,3
Konaklama yok	87	21,8	56
Otel	139	34,8	90,8
Pansiyon	29	7,3	98
Tesis	8	2	100
Toplam	400	100	

Tablo 12'de yerli turistlerin Elazığ'daki eğlence mekânlarından memnuniyetlerine ilişkin görüşler yer almaktadır. 181 kişi ile %45,3'lük kesim ankete "Memnunum" şeklinde cevap vermişlerdir. Elazığ'daki eğlence mekânlarından "Hiç memnun değilim" diyen 16 kişi ise %4'lük kesimi oluşturmaktadır.

Tablo 12. Elazığ'ı Ziyaret Eden Yerli Turistlerin Elazığ'daki Eğlence Mekânlarından Memnuniyetlerine İlişkin Görüşlerin Dağılımı

	Frekans	Yüzde (%)	Kümülatif Yüzde
Hiç memnun değilim	16	4	4
Memnun değilim	28	7	11
Ne memnunum ne memnun değilim	25	6,3	17,3
Memnunum	181	45,3	62,5
Çok memnunum	52	13	75,5
Fikrim yok	98	24,5	100
Toplam	400	100	

Tablo 13'te Elazığ'daki yeme içme hizmetlerine ilişkin memnuniyetlere ait görüşler yer almaktadır. %59,3 ile 237 kişi Elazığ'daki yeme içme hizmetlerinden "Memnun" olduklarını ifade ederken, %1,5 ile 10 kişi "Hiç memnun değilim" şeklinde beyanda bulunmuşlardır.

Tablo 13. Elazığ'ı Ziyaret Eden Yerli Turistlerin Elazığ'daki Yeme İçme Hizmetlerinden Memnuniyetlerine İlişkin Görüşlerin Dağılımı

	Frekans	Yüzde (%)	Kümülatif Yüzde
Hiç memnun değilim	10	2,5	2,5
Memnun değilim	16	4	6,5
Ne memnunum ne memnun değilim	39	9,8	16,3
Memnunum	237	59,3	75,5
Çok memnunum	92	23	98,5
Fikrim yok	6	1,5	100
Toplam	400	100	

Tablo 14'te Elazığ'ı ziyaret eden yerli turistlerin Elazığ'daki kültürel ve tarihi çekiciliklerden memnuniyetlerine ilişkin görüşler belirtilmiştir. %58 ile 232 kişi Elazığ'ın kültürel ve tarihi çekiciliklerden "Memnun" olduklarını belirtmişlerdir. 131 kişi (%32,8) ise Elazığ'ın kültürel ve tarihi çekiciliklerden "Çok memnunum" ifadesini beyan etmişlerdir.

Tablo 14. Elazığ'ı Ziyaret Eden Yerli Turistlerin Elazığ'daki Kültürel ve Tarihi Çekiciliklerden Memnuniyetlerine İlişkin Görüşlerin Dağılımı

	Frekans	Yüzde (%)	Kümülatif Yüzde
Hiç memnun değilim	5	1,3	1,3
Memnun değilim	8	2	3,3
Ne memnunum ne memnun değilim	19	4,8	8
Memnunum	232	58	66
Çok memnunum	131	32,8	98,8
Fikrim yok	5	1,3	100
Toplam	400	100	

Tablo 15'te Elazığ'ı ziyaret eden yerli turistlerin Elazığ'daki doğal güzelliklerden memnuniyetlerine ilişkin görüşler ifade edilmiştir. 236 kişi %59 ile Elazığ'ın doğal güzelliklerinden memnun olduğunu belirtirken, 128 kişi ise %32 ile çok memnun olduklarını ifade etmişlerdir.

Tablo 15. Elazığ'ı Ziyaret Eden Yerli Turistlerin Elazığ'daki Doğal Güzelliklerden Memnuniyetlerine İlişkin Görüşlerin Dağılımı

	Frekans	Yüzde (%)	Kümülatif Yüzde
Hiç memnun değilim	2	0,5	0,5
Memnun değilim	4	1	1,5
Ne memnunum ne memnun değilim	21	5,3	6,8
Memnunum	236	59	65,8
Çok memnunum	128	32	97,8
Fikrim yok	9	2,3	100
Toplam	400	100	

4. UYGULAMA

4.1. MLP Modeli ile Memnuniyet Sonuçlarının Tahmin Edilmesi

Uygulamada öncelikli olarak YSA analiz modellerinden MLP modeli ile anket uygulamasındaki memnuniyet sonuçları tahminleme işlemine tabi tutulmuştur. Model SPSS 25 paket programında, Neural Network MultiLayer Perceptron kullanılarak kurulmuştur. MultiLayer Perceptron Modeli (MLP) başarısını ispatlamış bir YSA modelidir. MLP modelinde temel amaç, ağdan beklenen çıktı ile üretilen çıktı arasındaki hatayı, minimum seviyedeki değerlere indirmektir. MLP ağlarının tahmin amacı ile kullanılmasında, tasarlanan YSA mimarisi önem arz etmektedir. Ağın mimarisi tasarlanırken, ağın kaç katmandan oluşacağı, katmanlarda kaç sinir hücrelerinin bulunacağı ve hangi aktivasyon fonksiyonunun kullanılacağı hesaba katılmalıdır. MLP modeli özellikle sınıflandırma ve genelleme işlemlerinde etkindir. Çalışmada tasarlanan modelin; 12 giriş katmanı, bir gizli katmanı ve bir de çıktı katmanı vardır (Bias birimi hariç). Bias değeri, aktivasyon fonksiyonunu sağa veya sola ötelenmesini (shift) sağlamaktadır. Giriş sinyallerinin toplamı 0 olduğunda öğrenme gerçekleşmemektedir. Çıkış değerleri hep 1 olan bias nöronları, nöronların giriş sinyallerinin sürekli sıfırdan farklı olmasını sağlamaktadır.

Tablo 16'da MLP modelinde, işleme tabi tutulan test ve eğitim verileri gösterilmiştir. Çalışmada ele alınan 12 seriye ait 400 adet veri setinden, program tarafından rastgele seçilen %67,8'i (271 adet) eğitim, yine rastgele seçilen %32,3'i (129 adet) test seti olarak belirlenmiştir. Modelde, hariç tutulan (excluded) veri seti olmamıştır.

Tablo 16. MLP Modelinde İşleme Tabi Tutulan Test ve Eğitim Verileri

		Adet	Yüzde (%)
Örneklem	Eğitim Verisi	271	%67,8
	Test Verisi	129	%32,3
Geçerli Veriler		400	%100
Hariç Tutulan Veriler		0	%0
Toplam Veri Seti		400	

Tablo 17’de tasarlanan MLP modelinin; giriş, çıkış ve gizli katmanları ve diğer detay bilgileri gösterilmiştir. Giriş katmanında 12 adet bağımsız değişken kullanılmış ve bu bağımsız değişkenler, toplamda 70 adet birim oluşturmuştur. Gizli katmandaki birim sayısı bir adettir. Gizli katmanda, aktivasyon fonksiyonu olarak Hiperbolik Tanjant kullanılmıştır. Eğer aktivasyon fonksiyonu uygulanmazsa, çıkış sinyali basit bir doğrusal fonksiyon olacaktır. Doğrusal fonksiyonlar, yalnızca tek dereceli polinomlardır. Aktivasyon fonksiyonu kullanılmayan bir sinir ağı, sınırlı öğrenme gücüne sahip bir doğrusal bağlanım (linear regression) gibi davranacaktır. Fakat YSA’ların doğrusal olmayan durumları da öğrenmesi istenmektedir. Hiperbolik Tanjant Fonksiyonun değer aralığı (-1,+1) olarak tanımlanmaktadır.

Çıktı katmanındaki bağımlı değişken sayısı birdir. Çıktı katmanı birim sayısı ise ikidir (“0:Memnun Değil”, 1:Memnun). Çıkış katmanı aktivasyon fonksiyonu olarak, Softmax kullanılmıştır. Softmax Fonksiyonu, sınıflayıcı olarak kullanıldığında oldukça iyi bir performans sergilemektedir. Çalışmada olduğu gibi, ikiden fazla sınıflandırma gereken durumlarda, özellikle derin öğrenme modellerinin çıkış katmanında tercih edilmektedir. Girdinin belirli sınıfa ait olma olasılığını, 0–1 aralığında değerler üretmek belirlemesini sağlar. Yani olasılıksal bir yorumlama gerçekleştirir. MLP Modelinde kullanılan hata fonksiyonu ise Çapraz Entropidir. Çapraz Entropi; iki olasılık dağılımı arasındaki farkı ölçmek için yaygın bir şekilde kullanılmaktadır. Çapraz Entropi kaybı veya log kaybı, çıktısı 0 ile 1 arasında bir olasılık değeri olan bir sınıflandırma modelinin performansını ölçmektedir. Öngörülen olasılık, gerçek değerden uzaklaştıkça, Çapraz Entropi kaybı artmaktadır. İyi bir model, sıfır log kaybı ile sonuçlanmalıdır.

Tablo 17. MLP Modelinde Giriş-Gizli-Çıkış Katmanlarının Tanımlaması

Giriş Katmanı	Bağımsız Değişkenler (Faktörler)	1	Cinsiyet
		2	Yaş
		3	İkamet Edilen İl
		4	Turistik Faktör
		5	Varış Noktası
		6	Elazığ’a Kaçınıcı Geliş
		7	Seyahat Süresi
		8	Konaklama Şekli
		9	Eğlence Mekanları
		10	Yeme İçme Hizmetleri
		11	Kültürel ve Tarihi Memnuniyet
		12	Doğal Güzellikler
	Giriş Katmanı Birim Sayısı ^a		70
Gizli Katman	Gizli Katman Sayısı	1	
	Gizli katmandaki birim sayısı ^a	1	
	Aktivasyon Fonksiyonu	Hiperbolik Tanjant	
Çıktı Katmanı	Bağımlı Değişken sayısı	1	
	Çıktı katmanındaki birim sayısı	2	
	Aktivasyon Fonksiyonu	Softmax	
	Hata Fonksiyonu	Çapraz Entropi (Cross-Entropy)	

a: Bias birimi hariç

Tablo 18’de MLP modelinin, eğitim ve test aşamalarındaki hataların özet bilgileri yer almaktadır. Veriler eğitime tabi tutulurken, Çapraz Entropi Hatası 72,981 değerinde olurken, hatalı yapılan tahmin oranı %7,7 olmuştur. İşlemlerin test aşamasında ise Çapraz Entropi Hatası 34,298 olurken, hatalı yapılan tahmin oranı %7,8 olmuştur.

Tablo 18. MLP Modelinin Eğitim ve Test Aşamasındaki Hata Özeti

Eğitim	Çapraz Entropi Hatası	72,981
	Hatalı Tahminler (Yüzde)	%7,7
	Kullanılan Durdurma Kuralı	1 ardışık adım, hatada azalma yok ^a
Test	Çapraz Entropi Hatası	34,298
	Hatalı Tahminler (Yüzde)	%7,8

Bağımlı Değişken: Memnuniyet -a. Hata hesaplamaları test örneğine dayanmaktadır.


Tablo 19’da MLP modelinin sınıflandırması görülmektedir. Örneklem eğitim aşamasında doğruluk oranı %92,3 olurken, test aşamasındaki doğruluk oranı ise %92,2 şeklinde gerçekleşmiştir.

Tablo 19. MLP Modelinin Sınıflandırması

Örneklem		Tahminleme		
		Memnun Değil	Memnun	Doğruluk (Yüzde)
Eğitim	Memnun Değil	28	21	%57,1
	Memnun	0	222	%100
	Toplamdaki Yüzde	%10,3	%89,7	%92,3
Test	Memnun Değil	9	9	%50
	Memnun	1	110	%99,1
	Toplamdaki Yüzde	%7,8	%92,2	%92,2

Bağımlı Değişken: Memnuniyet

Şekil 5'te MLP Modelinin hassasiyeti yani ROC eğrisi gösterilmiştir. ROC eğrisi; x eksenini (Specificity: Seçicilik) ve y eksenini (Sensitivity: Duyarlılık) üzerinde belirli eşik değerindeki noktaların oluşturduğu bir eğridir. ROC eğrisi altında kalan alanın fazla olması, tanı testinin iyi ölçümler yaptığının da göstergesidir.

**Şekil 5.** MLP Modelinin Hassasiyeti (ROC Eğrisi)

Tablo 20'de MLP modelinde eğri altında kalan alan değeri gösterilmiştir. ROC eğrisi altında kalan alanlar şu şekilde yorumlanmaktadır:

- 0.90-1.00 = Mükemmel
- 0.90-0.80 = İyi
- 0.70-0.80 = Orta
- 0.60-0.70 = Zayıf
- 0.50-0.60 = Kötü

MLP modeli 0,715 değeri ile orta sınıfta yer almaktadır.

Tablo 20. MLP Modelinde Eğri Altındaki Alan Değeri


		Alan Değeri
Memnuniyet	Memnun Değil	0,715
	Memnun	0,715

Tablo 21'de MLP modelinde bağımsız değişkenlerin önemi ifade edilmiştir. En fazla önem arz eden değişken "Yeme İçme Hizmetleri Memnuniyeti" olmuştur. Bu bağımsız değişkenin önemi 0,164 iken, değişkenin normalize edilmiş önemi %100 olmuştur. "Doğal Güzellikler Memnuniyeti" değişkeninin normalize önemi ise %99,9'dur. MLP modelinin başarısına en az etki eden değişken ise "Varış Noktası" olmuştur. "Varış Noktası"nın önemi 0,010 ve normalize edilmiş önemi ise %5,9 olarak gerçekleşmiştir.

Tablo 21. MLP Modelinde Bağımsız Değişkenlerin Önemi

Bağımsız Değişkenler	Değişkenin Önemi	Değişkenin Normalize Edilmiş Önemi
Cinsiyet	0,036	%22,1
Yaş	0,060	%36,6
İkamet Edilen İl	0,069	%41,9
Turistik Faktör	0,108	%65,8
Varış Noktası	0,010	%5,9
Elazığ'a Kaçınıcı Geliş	0,063	%38,3
Seyahat Süresi	0,029	%17,5
Konaklama Şekli	0,083	%50,4
Eğlence Mekânları Memnuniyeti	0,160	%97,2
Yeme İçme Hizmetleri Memnuniyeti	0,164	%100
Kültürel ve Tarihi Memnuniyeti	0,053	%32,5
Doğal Güzellikler Memnuniyeti	0,164	%99,9

MLP modelinde, bağımsız değişkenlerin normalize edilmiş önemi, Şekil 6'da grafik olarak gösterilmiştir. “Yeme İçme Hizmetleri Memnuniyeti”, “Doğal Güzellikler Memnuniyeti” ve “Eğlence Mekânları Memnuniyeti”nin MLP modeline en fazla etki eden bağımsız değişkenler oldukları grafikten okunmaktadır.

**Şekil 6.** MLP Modelinde Bağımsız Değişkenlerin Normalize Edilmiş Önemi

4.2. RBF (Radial Basis Function) Modeli İle Memnuniyet Sonuçlarının Tahmin Edilmesi

Uygulamada daha sonra, YSA modellerinden RBF modeli ile anket uygulamasındaki memnuniyet sonuçları tahminleme işlemine tabi tutulmuştur. Model SPSS 25 paket programında Radial Basis Function (RBF) kullanılarak kurulmuştur. RBF ağları da MLP gibi bir giriş katmanı, etkinlik fonksiyonu olarak ağı ismini veren radyal fonksiyonların kullanıldığı tek bir gizli katman ve çıkış katmanı olmak üzere 3 katmanlı mimariden oluşmaktadır. Çalışmada tasarlanan RBF modelinin 12 giriş katmanı, bir gizli katmanı ve bir de çıktı katmanı vardır.

Tablo 22'de RBF modelinde işleme tabi tutulan test ve eğitim verileri ile ilgili istatistik bilgileri görülmektedir. RBF modelinde 288 adet (%72) veri seti eğitime tabi tutulurken, 112 adet (%28) veri seti ise test verisi olarak kullanılmıştır. Modelde hariç tutulan (excluded) veri seti olmamıştır.

Tablo 22. RBF Modelinde İşleme Tabi Tutulan Test ve Eğitim Verileri

Örneklem	Adet		Yüzde (%)
	Eğitim Verisi	288	%72
	Test Verisi	112	%28
Geçerli Veriler	400	%100	
Hariç Tutulan Veriler	0	0	
Toplam Veri Seti	400		

Tablo 23'te tasarlanan RBF modelinin giriş, çıkış ve gizli katmanları ve diğer detay bilgileri gösterilmiştir. RBF modelinde giriş katmanında 12 faktör bulunurken, birim sayısı 70 adet olmuştur. Tasarlanan RBF modelinde gizli katmandaki birim sayısı 3'tür. Gizli katmanda aktivasyon fonksiyonu olarak Softmax kullanılmıştır. Çıktı katmanında bir adet bağımlı değişken bulunurken, çıkış katmanı birim sayısı ise 2'dir. Çıktı katmanı hata fonksiyonu ise “Kareler Toplamı”dır. Çıktı katmanında aktivasyon fonksiyonu olarak Identity kullanılmıştır. Identity Fonksiyonu değişken üzerinde herhangi

bir deęişiklik yapmamaktadır. Aktivasyon fonksiyonları, nöronların toplam fonksiyonunda üretilen çıktılarının nasıl bir deęişimden geçmesi gerektiğini belirler.

Tablo 23. RBF Modeli Giriş-Gizli-Çıkış Katmanlarının Tanımlaması

Giriş Katmanı	Faktörler	1	Cinsiyet
		2	Yaş
		3	İkamet Edilen İl
		4	Turistik Faktör
		5	Varış Noktası
		6	Elazığ'a Kaçınıcı Geliş
		7	Seyahat Süresi
		8	Konaklama Şekli
		9	Eğlence Mekânları
		10	Yeme İçme Hizmetleri
		11	Kültürel ve Tarihi Memnuniyet
		12	Doğal Güzellikler
	Giriş Katmanı Birim Sayısı		70
Gizli Katman	Gizli katmandaki birim sayısı		3 ^a
	Aktivasyon Fonksiyonu		Softmax
Çıktı Katmanı	Bağımlı Değişken Sayısı	1	Memnuniyet
		Çıkış Katmanı Birim Sayısı	2
	Aktivasyon Fonksiyonu		Identity
	Hata Fonksiyonu		Kareler Toplamı (Sum of Squares)

a. Test verisi kriteri tarafından belirlenir: "En iyi" gizli birim sayısı, test verilerinde en küçük hatayı verir.

Tablo 24'te RBF modeli ile ilgili özet istatistik bilgileri yer almaktadır. Modelin eğitim aşamasında Hata Kareler Toplamı (SSE) 43,043 olmuş ve yanlış yapılan tahminler %18,8 olarak gerçekleşmiştir. Modelin test aşamasında ise Hata Kareler Toplamı (SSE) 11,811 olarak gerçekleşmiş ve yanlış yapılan tahminler %11,6 olmuştur.

Tablo 24. RBF Modelinin Özeti

Eğitim	Hata Kareler Toplamı (SSE)	43,043
	Yanlış Yapılan Tahminler (Yüzde)	%18,8
Test	Hata Kareler Toplamı (SSE)	11,811 ^a
	Yanlış Yapılan Tahminler (Yüzde)	%11,6

Bağımlı Değişken: Memnuniyet

Gizli birimlerin sayısı, test verisi kriteri tarafından belirlenir: "En iyi" gizli birim sayısı, test verilerinde en küçük hatayı verir.


Tablo 25'te RBF modelinin sınıflandırması gösterilmiştir. Eğitim aşamasındaki doğruluk %81,3 olmuş ve test aşamasındaki doğruluk ise %88,4 olmuştur.

Tablo 25. RBF Modelinin Sınıflandırması

Örneklem		Tahminleme		
		Memnun Değil	Memnun	Doğruluk (Yüzde)
Eğitim	Memnun Değil	0	54	%0
	Memnun	0	234	%100
	Toplamdaki Yüzde	%0	%100	%81,3
Test	Memnun Değil	0	13	%0
	Memnun	0	99	%100
	Toplamdaki Yüzde	%0	%100	%88,4

Bağımlı Değişken: Memnuniyet

Şekil 7’de RBF modelinin hassasiyeti ifade edilmiştir. RBF modelinin hassasiyetinin MLP’ye kıyasla daha düşük olduğu Şekil 7’den anlaşılmaktadır.



Şekil 7. RBF Modelinin Hassasiyeti

Tablo 26’da RBF modelinde eğri altındaki alan değeri gösterilmiştir. Eğri altındaki alan değeri 0,574 olarak bulunmuştur. Bu değer 0,50-0,60 arasında yer almakta ve kötü olarak sınıflandırılmaktadır.

Tablo 26. RBF Modelinde Eğri Altındaki Alan Değeri

		Alan Değeri
Memnuniyet	Memnun Değil	0,574
	Memnun	0,574


Tablo 27’de RBF modelinde bağımsız faktörlerin önem sıralaması görülmektedir. “Doğal Güzellikler Memnuniyeti” 0,258 önem derecesi ve normalize edilmiş haliyle %100 önem derecesine sahiplikle, modeli etkileyen en etkili bağımsız faktör olmuştur.

Daha sonra, “Kültürel ve Tarihi Güzellikler Memnuniyeti” 0,238 önem derecesi (Normalize önem:%92,1) ile ikinci en önemli faktör olmuştur. Modele en az etki eden faktör ise 0,019 (Normalize:%7,4) “Cinsiyet” değişkeni olmuştur.

Tablo 27. RBF Modelinde Bağımsız Faktörlerin Önem Sıralaması

Bağımsız Değişkenler	Değişkenin Önemi	Değişkenin Normalize Edilmiş Önemi
Cinsiyet	0,019	%7,4
Yaş	0,056	%21,9
İkamet Edilen İl	0,053	%20,5
Turistik Faktör	0,042	%16,1
Variş Noktası	0,065	%25
Elazığ’a Kaçınıcı Geliş	0,031	%11,9
Seyahat Süresi	0,049	%19,1
Konaklama Şekli	0,029	%11,1
Eğlence Mekânları Memnuniyeti	0,070	%27,1
Yeme İçme Hizmetleri Memnuniyeti	0,091	%35,1
Kültürel ve Tarihi Güzellikler Memnuniyeti	0,238	%92,1
Doğal Güzellikler Memnuniyeti	0,258	%100

Şekil 8’de RBF modelinde bağımsız değişkenlerin normalize edilmiş önem dereceleri en yüksekte en düşüğe doğru sıralanmıştır.



Şekil 8. RBF Modelinde Bağımsız Değişkenlerin Normalize Edilmiş Önemi

4.3. MLP ve RBF Modellerinin Tahminleme Başarılarının ve Performanslarının Karşılaştırılması

Tablo 28’de MLP ve RBF modellerinin eğitim ve test aşamasındaki hata değerleri ifade edilmiştir. MLP modelinde, hatalı tahminleme oranı %7,7 olarak bulunurken, bu oran RBF modelinde %18,8 şeklinde olmuştur. MLP’de test aşamasında hatalı tahmin oranı %7,8 olurken, RBF’de bu oran %11,6 olmuştur.

Tablo 28. MLP ve RBF Modellerinin Eğitim ve Test Aşamasındaki Hata Özeti

	MLP		RBF	
Eğitim	Çapraz Entropi Hatası	72,981	Hata Kareler Toplamı (SSE)	43,043
	Hatalı Tahminler (Yüzde)	%7,7	Hatalı Tahminler (Yüzde)	%18,8
Test	Çapraz Entropi Hatası	34,298	Hata Kareler Toplamı (SSE)	11,811
	Hatalı Tahminler (Yüzde)	%7,8	Yanlış Yapılan Tahminler (Yüzde)	%11,6

Bağımlı Değişken: Memnuniyet

Tablo 29’da MLP ve RBF modellerinin tahminlemedeki başarı durumları karşılaştırılmıştır. Tablo 29’dan okunduğu üzere eğitim ve test aşamalarındaki tahminleme değerlerinde MLP modeli RBF’ye kıyasla daha başarılı olmuştur.

Tablo 29. MLP ve RBF Modellerinin Tahminlemedeki Başarı Karşılaştırması

Örneklem		MLP Modeli			RBF Modeli		
		Memnun Değil	Memnun	Doğruluk (Yüzde)	Memnun Değil	Memnun	Doğruluk (Yüzde)
Eğitim	Memnun Değil	28	21	%57,1	0	54	%0
	Memnun	0	222	%100	0	234	%100
	Toplamdaki Yüzde	%10,3	%89,7	%92,3	%0	%100	%81,3
Test	Memnun Değil	9	9	%50	0	13	%0
	Memnun	1	110	%99,1	0	99	%100
	Toplamdaki Yüzde	%7,8	%92,2	%92,2	%0	%100	%88,4

Bağımlı Değişken: Memnuniyet

Tablo 30’da modellerin eğri altındaki alan değerleri karşılaştırılmıştır. 0,715 değeri 1’e daha yakındır. MLP modeli, RBF modeline kıyasla daha başarılıdır.

Tablo 30. Modellerin Eğri Altındaki Alan Değerleri Karşılaştırması

Memnuniyet	MLP		RBF	
	Memnun Değil	0,715	0,574	0,574
	Memnun	0,715	0,574	0,574

5. SONUÇ ve DEĞERLENDİRME

Turizm sektörü ile ilgili talep tahmin uygulamalarına olan ilgi her geçen gün artış göstermektedir. Yerli ve yabancı turistlerin ziyaret ettikleri yerlerden ve bölgelerden memnun ayrılmaları, o bölgelerde gerçekleşen turizm faaliyetleri açısından çok önemlidir. Bu çalışmada öncelikle, Elazığ ilini turistik amaçla ziyaret eden, yerli turistlere uygulanan 400 adet anketten elde edilen veriler, SPSS paket programına aktarılmıştır. Yerli turistlerin anket sorularına verdiği cevaplar analiz edilmiştir. Ankette; Elazığ'ı ziyaret eden yerli turistlere, Elazığ ziyaretlerinden memnun kalıp kalmadıkları sorulmuştur. Alınan cevaplar "0:Memnun değil, 1:Memnun" şeklinde kategorik veriye çevrilmiştir. Yerli turistlerin Elazığ İlini ziyaretlerindeki memnuniyet durumu, analizin bağımlı değişkenini oluşturmuştur. Diğer anket sorularından seçilen 12 adet soru, analizin 12 bağımsız değişkenini meydana getirmiştir. 12 bağımsız değişken kullanılarak, yerli turistlerin Elazığ ziyaretlerinden memnuniyet sonucu tahmin edilmiştir. Tahminlemede YSA modellerinden, MLP ve RBF modelleri kullanılmıştır. Çalışmada, iki farklı sınıflandırma modelinin tahmin başarıları ve performansları değerlendirilmiş ve modeller arasında teknik analizler ve karşılaştırmalar yapılmıştır.

Tahmin modelleri, SPSS 25 paket programında, Neural Network Multilayer Perceptron (MLP) ve Radial Basis Function (RBF) modelleri kullanılarak oluşturulmuştur. 400 adetten oluşan veri setinden, MLP modelinde; yaklaşık %67,8'i eğitim seti (271 adet), %32,3'ü ise test seti (129 adet) için ayrılırken, RBF modelinde; veri setinin yaklaşık %72'si eğitim seti (288 adet), %28'i ise test seti (112 adet) için ayrılmıştır. Her iki modelde de çok katmanlı YSA yapısı kullanılmıştır. Modellerde, giriş katmanında 12 adet bağımsız değişken kullanılmış ve bu bağımsız değişkenler 70'er adet birim oluşturmuştur. Modellerin, çıktı katmanındaki bağımlı değişken sayısı birdir. Çıktı katmanı birim sayısı ise ikidir ("0:Memnun Değil", 1:Memnun).

MLP modelinin eğitim aşamasındaki hata oranı %7,7 olurken, modelin test aşamasındaki hata oranı %7,8 çıkmıştır. RBF modelinin eğitim aşamasındaki hata oranı ise %18,8 ve test aşamasındaki hata oranı %11,6 olarak elde edilmiştir. YSA modellerinin eğitim aşamasında, MLP modeli RBF'ye kıyasla 2,41 kat ve test aşamasında ise 1,49 kat başarı göstermiştir. Modellerde, hariç tutulan (excluded) veri seti olmamıştır.

MLP modelinde, en fazla önem arz eden bağımsız değişken "Yeme İçme Hizmetleri Memnuniyeti" olmuştur. Bu bağımsız değişkenin önemi 0,164 iken, değişkenin normalize edilmiş önemi %100 olmuştur. "Doğal Güzellikler Memnuniyeti" değişkeninin normalize önemi ise %99,9 olmuştur. MLP modelinin başarısına en az etki eden değişken ise "Varış Noktası" olmuştur. "Varış Noktası"nın önemi 0,010 ve normalize edilmiş önemi ise %5,9 şeklinde gerçekleşmiştir. RBF modelinde; bağımsız değişkenlerden "Doğal Güzellikler Memnuniyeti" 0,258 önem derecesi ve normalize edilmiş haliyle %100 önem derecesine sahiplikle, modeli etkileyen en etkili bağımsız değişken olmuştur. Daha sonra ise "Kültürel ve Tarihi Güzellikler Memnuniyeti" 0,238 önem derecesi (Normalize önem:%92,1) ile ikinci en önemli bağımsız değişken olmuştur. RBF modeline en az etki eden faktör ise 0,019 (Normalize:%7,4) "Cinsiyet" değişkeni olmuştur. "Doğal Güzellikler Memnuniyeti" her iki modelde de sonuca en fazla etki eden bağımsız değişken olmuştur.

Bununla birlikte, oluşturulan her iki analiz modeli de 3 katmanlı bir mimariye sahiptir. Çalışma sonuçlarına göre her iki analiz modelinin de geçerli ve güvenli sonuçlar ürettiği görülmüştür. Fakat çalışma özelinde, MLP modelinin, RBF'ye kıyasla daha başarılı sonuçlar ürettiği tespit edilmiştir. Sonuç olarak, uygun ağ yapısı ve yeterli sayıda veri kullanıldığında, sınıfsal tahminlemede RBF ve MLP analiz modelleri, istatistiksel yöntemlere alternatif bir yöntem olarak kullanılabilir.

Her iki analiz modelinin de önümüzdeki süreçte farklı birçok uygulama alanında kullanılması öngörülmektedir. Yeni model ve tekniklerle oluşturulacak farklı ve değişik yapılar, analiz modelleri ve tasarımlar, bilimsel çalışmaların gelişimine katkılar sağlayacaktır. Gelecek çalışmalarda, derin öğrenme gibi farklı makine öğrenme modelleri kullanılabilir ve nitelik seçici algoritmalar çeşitlendirilebilir. Yapılan çalışmanın, bu alanda yapılabilecek olan yeni çalışmalara ilham verebileceği değerlendirilmektedir.

KAYNAKLAR

- Abraham, A. (2005). Artificial Neural Networks. *Handbook of Measuring System Design*, 901-908.
- Borş, A. G. & Pitas, I. (1996). Median radial basis function neural network. *IEEE transactions on Neural Networks*, 7(6), 1351-1364.
- Cang S. (2013). A comparative analysis of three types of tourism demand forecasting models: individual, linear combination and non-linear combination. *International Journal of Tourism Research*, 15. DOI: 10.1002/jtr.1953.
- Chang, G. W., Chen, C. I. & Teng, Y. F. (2009). Radial-basis-function-based neural network for harmonic detection. *IEEE Transactions on Industrial Electronics*, 57(6), 2171-2179.
- Chen, K. (2011). Combining linear and nonlinear model in forecasting tourism demand. *Expert Systems with Applications*, 38, 10368–10376.
- Cho, V. (2003). A comparison of three different approaches to tourist arrival forecasting. *Tourism Management*, 24, 323-330.
- Cho, V. (2009). A study on the temporal dynamics of tourism demand in the Asia Pacific region. *International Journal of Tourism Research*, 11 (5) 465–485.
- Claveria, O. & Torra, S. (2014). Forecasting tourism demand to Catalonia: Neural networks vs. time series models. *Economic Modelling*, 36, 220–228.
- Claveria, O., Monte, E. & Torra, S. (2013). Tourism demand forecasting with different neural networks models. *Research Institute of Applied Economics*, 2013(21), 1-20.
- Claveria, O., Monte, E. & Torra, S. (2015). Tourism demand forecasting with neural network models: different ways of treating information. *International Journal of Tourism Research*, 17(5), 492-500.
- Çuhadar, M. (2013). Modeling and Forecasting Inbound Tourism Demand to Turkey by MLP, RBF and TDNN Artificial Neural Networks: A Comparative Analysis. *Journal of Yasar University*, 8(31), 5274-5295.
- Çuhadar, M., Cogurcu, I. & Kukrer, C. (2014). Modelling and forecasting cruise tourism demand to Izmir by different artificial neural network architectures. *International Journal of Business and Social Research*, 4(3), 12-28.
- Delashmit, W. H. & Manry, M. T. (2005, May). *Recent developments in multilayer perceptron neural networks*. In Proceedings of the seventh Annual Memphis Area Engineering and Science Conference, MAESC, 1-15.
- Dongare, A. D., Kharde, R. R. & Kachare, A. D. (2012). Introduction to artificial neural network. *International Journal of Engineering and Innovative Technology (IJEIT)*, 2(1), 189-194.
- Goh, C. & Law, R. (2011). The Methodological Progress of Tourism Demand Forecasting: A Review of Related Literature. *Journal of Travel & Tourism Marketing*, 28(3), 296-317.
- Law, A. (2000). Back-Propagation Learning in Improving The Accuracy Of Neural Network-Based Tourism Demand Forecasting. *Tourism Management*, 21 (4), 331-340.
- Lin, C.J., Chen, H.F. & Lee, T. S. (2011). Forecasting tourism demand using time series, artificial neural networks and multivariate adaptive regression splines: Evidence from Taiwan. *International Journal of Business Administration*, 2, 14-24.
- Marcellino M. (2005). *Instability and non-linearity in the EMU*. In Milas C, Rothman P, van Dijk D (eds). *Nonlinear Time Series Analysis of Business Cycles*. Elsevier: Amsterdam.
- Palmer, A., Montaña, J. J. & Sesé, A. (2006). Designing an artificial neural network for forecasting tourism time-series. *Tourism Management*, 27(5) 781-790.
- Pattie, D.C. & Snyder, J. (1996). Using A Neural Network To Forecast Visitor Behavior. *Annals of Tourism Research* 23(1), 151–164.

- Song, H. ve Li, G. (2008). Tourism demand modelling and forecasting – a review of recent research. *Tourism Management*, 29, 203-220.
- Tang, Z., Almeida, C. & Fishwick, P.A. (1991). Time series forecasting using neural networks vs. Box-Jenkins methodology. *Simulation*, 57, 303–310.
- Teixeira, J.P. & Fernandes, P.O. (2012). Tourism Time Series Forecast – Different ANN Architectures with Time Index Input. *Procedia Technology*, 5, 445-454.
- Teräsvirta, T., van Dijk, D. & Medeiros, M.C. (2005). Linear models, smooth transition autoregressions, and neural networks for forecasting macroeconomic time series: A re-examination. *International Journal of Forecasting*, 21, 755–774.
- Tsaur, S.H., Chiu, Y.C. & Huang, C.H. (2002). Determinants of guest loyalty to international tourist hotels: a neural network approach. *Tourism Management*, 23, 397-405.
- Uysal, M. & El Roubi, M.S. (1999). Artificial neural Networks versus multiple regression in tourism demand analysis. *Journal of Travel Research*, 38, 111–118.
- Weigend, A.S. & Gershenfeld, N.A. (1993). *Time Series Prediction: Forecasting the Future and Understanding the Past*. Addison Wesley: Reading, MA.
- Young, W. A., Bihl, T. J. & Weckman, G. R. (2014). *Artificial Neural Networks for Business Analytics*. In Encyclopedia of business analytics and optimization (pp. 193-208). IGI Global.
- Zhang, G., Putuwo, B.E. & Hu, M.Y. (1998). Forecasting with artificial neural networks: the state of the art. *International Journal of Forecasting*, 14, 35–62.
- Zhang, G. P. (2004). *Business Forecasting with Artificial Neural Networks: An Overview*. In Zhang P. (Ed.) *Neural Networks in Business Forecasting*, Idea Group Publishing, 1-22.