



Araştırma Makalesi / Research Article

TAŞIT KREDİLERİ TALEP TAHMİNİNİN YAPAY SINIR AĞLARI KULLANILARAK ANALİZ EDİLMESİ

Burçin TUTCU¹

Öz

Kişilerin finansman ihtiyacını karşılamada kullandıkları tüketici kredilerinin içerisinde taşıt kredileri önemli bir yer tutmaktadır. Birden fazla sektöre ekonomik anlamda etki eden taşıt kredileri banka ve finans kurumlarının ana gelir kalemlerinden birini oluşturmaktadır. Taşıt kredilerinin tahmin edilebilirliği banka ve finans kurumlarının rekabet gücünü doğrudan etkileyebilmektedir. Otomotiv sektörü de taşıt kredilerinden etkilenen bir diğer sektördür. Otomotiv sektörünün dünyanın her yerinde ciddi bir tüketici talebi bulunmaktadır. Türkiye’de otomotiv sektörü son yıllarda hızlı bir büyüme göstermektedir. Çalışmada Türkiye’nin 2006 Ocak ayı ile 2022 Haziran ayı arasındaki dönemdeki aylık frekanslı veriler kullanılarak, yapay sinir ağları makine öğrenim tekniği ile taşıt kredisi büyüklüğünün tahmini amaçlanmıştır.

Anahtar Kelimeler: Finans, taşıt kredisi, yapay sinir ağları.

JEL Kodları: C45, G17

ANALYSIS OF VEHICLE LOANS DEMAND FORECAST USING ARTIFICIAL NEURAL NETWORKS

Abstract

Vehicle loans within consumer loans play a significant role in meeting the individuals financing needs. Vehicle loans, which have an economic impact on multiple sectors, constitute a major source of income for banks and financial institutions. The predictability of vehicle loans can directly affect the competitiveness of banks and financial institutions. The automotive industry is also another sector that is affected by the loans, and there is substantial consumer demand for the automotive industry worldwide. The automotive industry has shown a rapid growth recently in Turkey. In this study, monthly frequency data from January 2006 to June 2022 in Turkey were used, and the aim was to estimate the size of vehicle loans using artificial neural networks as a machine learning technique.

Keywords: Finance, vehicle loan, artificial neural networks.

JEL Codes: C45, G17.

¹ Dr. Öğr. Üyesi, Akdeniz Üniversitesi Korkuteli MYO, burcintutcu@akdeniz.edu.tr, ORCID: 0000-0003-1427-0741.
Başvuru Tarihi (Received): 18.05.2023 **Kabul Tarihi** (Accepted): 19.10.2023

Giriş

Banka ve finans kurumları tarafından verilen krediler bu kurumlarının ana gelir kalemini oluşturmaktadır. Bu kalemin tahmin edilebilirliği bankaların kârlılığını, rekabet edebilme gücünü, pazarlama stratejilerini önemli derecede etkilemektedir. Krediler içerisinde önemli büyüklüğe sahip olan taşıt kredileri aynı zamanda ekonominin temel sektörlerinden olan otomotiv sektörü için de büyük önem taşımaktadır.

Otomotiv sektörü; demir-çelik, petro-kimya, cam, plastik, tekstil, elektronik gibi sanayilerin başlıca alıcısı olma özelliğinin yanında tarım, turizm, savunma, ulaştırma, altyapı, inşaat gibi alt sektörlerle ihtiyaç duydukları motorlu araçları tedarik etmeleri sebebi ile önemli bir rol üstlenmektedir. Geri ve ileri bağlantı sayısı oldukça fazla olan otomotiv sektörü, hammadde ve yan sanayi ile nihai ürünlerin tüketiciye ulaşmasını sağlayan pazarlama, bayi, servis, akaryakıt, finans ve sigorta sektörleriyle yakından ilişkili olmasından dolayı lokomotif görevi üstlenmektedir. Otomotiv sektörünün dünyanın her yerinde ciddi bir tüketici talebi bulunmaktadır. Otomotiv sektörünün üretiminde meydana gelen artışlar taşıt kredilerini doğrudan etkilemektedir. Bu nedenle tüketici ve konut kredilerinden farklı olarak ülke ekonomisinin birden fazla sektörüne pozitif yönlü katkılar sağlamaktadır.

Banka ve finans kurumları binlerce müşteri ile karşı karşıya durmaktadır. Bu kurumlar müşterilerine kredi sunarken belirli kriterleri istemektedirler. Hangi müşterinin taşıt kredisine ihtiyacı olup olmadığını belirleyebilmek için kredi eğilimi yüksek müşterileri de belirlemeleri gerekmektedir. Bu kredi tahminlemesinin yapılabilmesi için farklı yöntemler kullanılabilir.

Bu çalışma kapsamında taşıt kredisi tahmini makine öğrenmesi yöntemlerinden yapay sinir ağları kullanılarak gerçekleştirilmiştir. Geliştirilen modeli analiz etmek ve değerlendirmek için R^2 , MAE ve MSE metrikleri hesaplanmıştır. Literatürde yapılan çalışmalar incelendiği zaman çalışmaların daha çok genel çerçevede yapıldığı ve tüketici kredilerinin esas alındığı tespit edilmiştir. Taşıt kredilerinin tahmini ile daha spesifik bir model kurulmuştur.

Literatür incelendiği zaman yapılan çalışmaların yapılan çalışmaların çoğunlukla tüketici kredisi perspektifinde olduğu tespit edilmiştir. (Zhou, 2017), çalışmalarında tüketici kredisi için veri madenciliği kullanarak tahminleme yapmışlardır. Karakış vd. (2017), çalışmalarında ticari kredi taleplerinin değerlendirilmesinde kullanılan bulanık TOPSIS ve bulanık AHP yöntemlerinin uygulanabilir olup olmadığını ortaya koymaya çalışmışlardır. (Sayjadah et al., 2018), çalışmalarında kredi kartı, kredi temerrüdünü tahmin etmede lojistik regresyon modelini ve random forest modelini kullanmışlardır. Analiz sonuçlarına göre random forestin %80 doğru tahminleme yaptığına ulaşmışlardır. Tigrak vd. (2020), çalışmalarında bankacılık sektöründe müşterilerin kredi ihtiyacının büyük veri işleme ve analizi platformları üzerinde makine öğrenmesi modelleri kullanılarak tahmin edilebilmesi için bir yöntem önermektedirler. Taşıt kredileri ile ilgili çalışmaların literatürde yer almaması sebebi ile literatüre katkı sağlaması beklenmektedir.

1. Materyal ve Yöntem

1.1. Veri Seti

Çalışmada Türkiye'nin 2006 Ocak ayı ile 2022 Haziran ayı arasındaki dönemdeki aylık frekanslı verileri kullanılmıştır. Veriler, Türkiye İstatistik Kurumu Merkezi Dağıtım Sistemi (TÜİK BİRÜNİ) ve Türkiye Cumhuriyet Merkez Bankası Elektronik Veri Dağıtım Sistemi'nden (TCMB EVDS) edinilmiştir. Modelin tasarımında, taşıt kredisi büyüklüğünü başarılı bir şekilde tahmin edilebilmesi için Türkiye'nin ekonomik durumunu ortaya koyan değişkenler ile taşıt kredisinin büyüklüğüne etkileyecek değişkenler kullanılmıştır. Böylece yapay sinir ağları makine öğrenim tekniğinin başarılı

bir şekilde taşıt kredisi büyüklüğünü tahmini amaçlanmıştır. Kurulan modelde giriş ve çıkış değişkenleri aşağıdaki Tablo 1'deki gibidir.

Tablo 1: *Modelin Giriş ve Çıkış Değişkenleri*

Çıkış Değişkeni	Taşıt Kredisi Büyüklüğü (Bin TL)
	Tüketici Fiyat Endeksi
	Taşıt Kredisi Faiz Oranı (%)
	1 Amerikan doları (TL cinsinden)
Giriş Değişkenleri	1 euro (TL Cinsinden)
	Tüketici Güven Endeksi
	Trafiğe Kaydedilen Binek Araç Sayısı (Adet)
	Trafikten Silinen Binek Araç Sayısı (Adet)

1.2. Yapay Sinir Ağları

Yapay sinir ağı (YSA) analizi, insan beyninin çalışma şeklini taklit eden bir veri analizi yöntemidir. Karmaşık sorunları çözmek için kullanılan geniş bir kullanım alanına sahip bir yapay zekâ tekniğidir. Günümüzde görüntü ve ses tanıma, tıp, haberleşme ve ekonomik model tahminlerinde sıklıkla kullanılmaktadır (Drew & Monson, 2000; Kayakuş v.d., 2022).

Bir yapay sinir ağı giriş, gizli ve çıktı katmanları olmak üzere üç temel katmandan oluşmaktadır. Giriş katmanı, bir sinir ağının ilk katmanı olup, dış dünyadan gelen bilgileri ağa iletir. Bu katmanda herhangi bir hesaplama yapılmaz, düğümler yalnızca bilgiyi gizli katmana iletir. Çıkış katmanı, ağın dış dünyaya yaptığı hesaplamaların sonuçlarını gösterir. Bu katmandaki nöron sayısı, tahmin edilmesi istenen çıktı sayısına karşılık gelmektedir. Tek bir çıktı değerinin beklendiği bir regresyon probleminde, çıktı katmanında bir nöron olacaktır. Bununla birlikte, sınıflandırma işlemlerinde her sınıf için bir tane olmak üzere birden fazla nöron olacaktır. Giriş ve çıkış katmanları arasındaki karmaşık ilişkiyi çözmek için bu katmanlar arasında gizli katmanlar bulunmaktadır. Ayrıca gizli katmanlar nöronlar içermektedir. Bu nöronlar bitişik katmanlardaki diğer nöronlarla bağlanmaktadır (Islam & Murase, 2001; Yetiz et al., 2021).

İnsan beyninde birbirine bağlı nöronlar olduğu gibi, yapay sinir ağlarında da her katmanda birbiriyle ilişkili nöronlar bulunmaktadır. Beyin hücrelerinin çekirdeğine benzer şekilde, girdi katmanı dışında her nöron, sinir ağının eğitim sürecinde öğrendiği ve ayarlandığı bias diye adlandırılan sapma parametresine sahiptir. Bu bias değerleri rastgele sayılarla başlatılmaktadır. Sinir ağı hesaplanan ve gerçek değer arasındaki farkı en aza indirmek için bu değerler üzerinde ayarlamalar yapılmaktadır (Erdoğan et al., 2021; Zhang & Morris, 1998).

Bir sinir ağındaki nöronlar arasındaki bağıntılar öğrenme süreci için çok önemlidir. Bir katmandaki her nöron, bitişik katmanlardaki her nörona bağlıdır. Bu bağlantılar, o bağlantının önemini ve etkisini belirleyen bir ağırlık değeri ile temsil edilir. Ağırlık değerleri, eğitim veri seti üzerinde yinelenerek öğrendiği eğitilebilir parametrelerdir. Bu ağırlıkların değerleri pozitif, negatif veya sıfır olabilir.

Ağırlığı sıfır olan girdilerin çıktı üzerinde herhangi bir etkisi olmamaktadır. Bu ağırlık değerlerinin optimizasyonu sinir ağının performansı ve başarısı için çok önemlidir (Jain et al., 1996; White, 1989).

Yapay sinir hücresine gelen bilgiler geldikleri nöronun bağlantılarının ağırlığıyla çarpılarak çekirdeğe iletilir. Toplama fonksiyonu bir yapay sinir hücresine ağırlıklarla çarpılarak gelen girdileri toplayarak o hücrenin net girdisini hesaplayan bir fonksiyondur. Bu net girdi değeri bir aktivasyondan fonksiyonundan geçirilerek çıkış katmanına aktarılır (Karlık & Olgac, 2011). Aktivasyon fonksiyonları, bir sinir ağında girdilerin ve sapmaların ağırlıklı toplamını hesaplamak için kullanılan işlevlerdir. Aktivasyon fonksiyonu bir nöronun etkinleştirilip etkinleştirilemeyeceğine karar vermek için kullanılmaktadır. Doğrusal ve doğrusal olmayan aktivasyon fonksiyonları bulunmaktadır. Doğrusal bir fonksiyon, aktivasyonun girdiyle, yani nöronlardan gelen ağırlıklı toplamla orantılı olduğu düz çizgi fonksiyonu olarak da bilinir. Doğrusal olmayan fonksiyonların en çok kullanılan aktivasyon fonksiyonları olduğu bilinmektedir. Bir sinir ağı modelinin çeşitli verilerle uyum sağlamasını ve sonuçlar arasında ayırım yapmasını kolaylaştırır. En çok kullanılan aktivasyon fonksiyonu sigmoid aktivasyon fonksiyonudur (Kayakuş & Terzioğlu, 2021; Sharma et al., 2017).

Yapay sinir ağları eğitim ve öğrenme şekillerine göre ileri ve geri beslemeli yapay sinir ağları olmak üzere ikiye ayrılmaktadır. İleri beslemeli sinir ağı girdi verilerinin yalnızca bir yönde hareket ettiği, yapay sinir düğümlerinden geçtiği ve çıkış düğümlerinden çıktığı ağıdır. Katman sayısı, işlevin karmaşıklığına bağlıdır. Tek yönlü ileri yayılımı sahiptir, ancak geriye doğru yayılım yoktur. Ağırlıklar burada statiktir. Bir aktivasyon fonksiyonu, ağırlıklarla çarpılan girdilerle beslenir. Geri beslemeli sinir ağları hataları çıkış düğümlerinden giriş düğümlerine geri yayan bir algoritmadır. Ağın tahminlerini daha doğru hale getirmek için parametreleri güncellemek üzere geriye doğru yayılım gösterir (Wythoff, 1993).

1.3.Normalizasyon Teknikleri

Normalizasyon, farklı özellikleri benzer ölçeğe indirgeyerek sinir ağlarının eğitilmesine yardımcı olmaktadır. Burada, değer aralığındaki farklılıkları bozulmadan tüm özellikler ortak bir değer aralığına uyarlanmaktadır. Bu, modelin performansını ve eğitim kararlılığını artırmaktadır. Verilerin normalizasyonu genellikle öğrenmeyi hızlandırır ve daha hızlı yakınsama sağlamaktadır (Shen et al., 2021; Yavuz & Deveci, 2012).

Min-max normalizasyonu, orijinal verilerin minimum ve maksimum değerlerini kullanarak veri değerlerini 0 ile 1 arasında yeniden ölçeklendiren bir istatistik tekniktir. Ortaya çıkan normalizasyon değerleri, orijinal verileri 0-1 ölçeğinde temsil eder. Min-max normalizasyonda her özellik için minimum değeri 0'a, maksimum değeri 1'e dönüşür. Aradaki tüm değerler, minimum ve maksimuma göre orijinal değere göre 0-1 aralığında olacak şekilde ölçeklenir (Saif vd., 2017). Denklem 1'de min-max normalizasyon formülü görülmektedir.

$$X^I = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

Burada X^I normalize edilmiş veriyi, X normalize edilecek veriyi, X_{\min} veri setindeki en küçük değeri, X_{\max} veri setindeki en büyük veriyi göstermektedir.

1.4.Değerlendirme Yöntemleri

Belirleme katsayısı (R^2), bağımsız değişken(ler)den tahmin edilebilen bağımlı değişkendeki varyansın oranı olarak tanımlanır. Bağımlı değişkende meydana gelen değişimin, bağımsız değişken(ler)deki değişimle açıklanabilecek yüzdesini gösteren bir istatistiktir. Belirleme katsayısı genellikle bir değişkendeki değişikliğin ikinci bir değişkendeki değişiklik ile nasıl açıklanabileceğini analiz etmek

için kullanılır. Belirleme katsayısı, tahmin edilen y puanları ile gerçek y puanları arasındaki korelasyonun karesidir. Bu nedenle 0 ile 1 aralığında yer alır (Kayacı Çodur, 2021). Bu değer 1'e yakın olması istenen bir durumdur.

$$R^2 = 1 - \frac{\text{Açıklanamayan Değişkenler}}{\text{Toplam Değişkenler}} \quad (2)$$

Ortalama Karesel Hata (Mean Square Error - MSE), gerçek ve tahmin edilen değerler arasındaki kare farklarının ortalaması veya ortalaması olarak tanımlanmaktadır. MSE, istatistiksel bir modeldeki hata miktarını ölçmektedir. Geliştirilen modelde hata yoksa MSE değeri sıfırdır. Hesaplama farkın karesi alındığı için MSE değeri hiçbir zaman negatif olmayacaktır. Modelin hatası arttıkça MSE değeri de artacaktır (Taşar et al., 2018). MSE denklemi:

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

Ortalama Mutlak Hata (Mean Absolute Error - MAE), bir gözlemin tahmini ile o gözlemin gerçek değeri arasındaki farkın büyüklüğünü ifade eder. Veri setinin tüm örneklerinde her tahmin hatasının mutlak değerlerinin ortalamasını ifade eder. Tahmin hatası, o örnek için gerçek değer ile tahmin edilen değer arasındaki farktır. İstatistiksel olarak, MAE, iki sürekli değişken arasındaki farkı ölçmenin sonuçlarını ifade eder. MAE, regresyon problemleri için anlaşılması kolay, ölçülebilir bir hata ölçümü işlevi görmektedir. MAE puanı ne kadar düşükse o kadar iyidir. Bunun nedeni, MAE'nin tahminler ve amaçlanan hedefler arasındaki ortalama hatanın bir ölçüsü olmasıdır (Aydemir, 2019).


$$MAE = \frac{\sum_{i=1}^n |y_i - x_i|}{n} \quad (4)$$

Burada n toplam veri sayısını, i veri numarasını, y_i i. gerçek değeri, x_i i. tahmin değerini, y_{ave} ortalama gerçek değeri göstermektedir.

2. Bulgular ve Tartışma

Çalışmada Türkiye'deki taşıt kredisini tahmin etmek için Ocak 2006 ile Haziran 2022 tarihleri arasındaki veriler kullanılmıştır. Modelde verilerin %70'i eğitim, %30'u test amaçlı olmak üzere rastgele seçilerek tasarlanan ağa aktarılmıştır.

Yapay sinir ağları yöntemi için geri beslemeli bir yapay sinir ağları modeli oluşturulmuştur. Yapay sinir ağlarında gizli katman ve nöron sayısına karar verilirken bir kural bulunmamaktadır. Modelin başarısını doğrudan etkileyen bu parametrelerin seçimi için deneme yanılma yöntemi kullanılmıştır. Gizli katman ve her katmandaki nöron sayısını belirlemek için testler sonucu model için en başarılı sonuç iki gizli katman ve her gizli katmanda dört nörondan oluşan model olduğu belirlenmiştir. Modelde en iyi sonucu almak için 100 iterasyon gerçekleştirilmiştir. Tasarlanan model Şekil 1'de görülmektedir.

Şekil 1: *Tasarlanan Yapay Sinir Ağları Modeli*


Eğitim verileri rastgele seçildiği için model 10 kez çalıştırılmış ve ortalama değerler alınmıştır. Yapay sinir ağları kullanılarak taşıt kredisi tahmin edilmesi için geliştirilen modelin istatistiksel değerlendirmesi Tablo 2’de görülmektedir.

Tablo 2: *Modellerin Değerlendirmesi*

	R ²	MSE	MAE
Ortalama	0,804	0,003	0,046

Tablo 2’de yapay sinir ağları modelinin istatistiksel değerlendirmesi görülmektedir. Bu tabloya göre R2 değeri ortalama %80,4 olduğu görülmektedir. Bu değer kabul edilebilir değer aralığında olup bağımsız değişkenlerin %80,4’ünün bağımlı değişkeni açıklayabildiğini göstermektedir. MSE hata değeri 0,003 olmuştur ve istenen değerlere çok yakın değer elde edilmiştir. MAE değeri ise 0,046 olarak hesaplanmıştır ve ideal değerlere çok yakındır. Tablo 1’deki ortalama sonuçlara göre taşıt kredi değerinin tahmin edilmesinde yapay sinir ağlarının başarılı bir sonuç gösterdiği görülmektedir. Aktivasyon fonksiyonu için çeşitli fonksiyonların test edilmesinden sonra en başarılı sonucu verdiği için sigmoid fonksiyonu tercih edilmiştir. Şekil 2’de YSA modelinin iterasyon sayısına göre hata değişimi görülmektedir.

Şekil 2: Modelin Hata Eğrisi



Şekil 2’de hata eğrisinin doğrusal olmayan bir şekilde azaldığını göstermektedir. Hata eğrisi 70. ve 94. iterasyonlar arasında sabitlenmekte ve ideal değere ulaştığı görülmektedir.

3. Sonuçlar

Banka ve finans kurumları kârlılıklarını arttırabilmek için müşterilerine kullandırdıkları kredi miktarını da arttırmak zorundadırlar. Taşıt kredileri, tüketici kredilerinin içerisinde önemli bir yer tutmaktadır. Artan taşıt kredisi sadece kerdi veren sektörü değil aynı zamanda otomotiv sektörünü de doğrudan etkilemektedir. Otomotiv sektörü gün geçtikçe gelişim gösteren, ülke ekonomileri içerisinde payı artan bir sektördür. Bu sektörde firmalar arası rekabet hızla yükselmekte ve buna bağlı olarak verimlilik artışı, kaynakların etkin kullanımı, idari ve teknik organizasyon gibi unsurlar büyük önem kazanmaktadır. Otomotiv sanayi sahip olduğu yapı nedeni ile birçok sektörle bağlantısı olan bir sektördür. Bu sektörler üzerinde oldukça fazla etkisi olması; otomotiv sektörünün, bulunmuş olduğu ülkenin ekonomisi üzerinde büyük bir etkiye sahip olmasına neden olmaktadır. Günümüzde otomotiv sektöründe uluslararası boyutta çok ciddi bir rekabet yaşanmaktadır. Geçmişte ağırlıklı olarak fiyat rekabeti söz konusu iken, günümüzde fiyatla beraber kalite, ürün çeşitliliği ve geleceğe yatırım rekabet açısından önemli unsurlar haline almıştır. Sektördeki üretim artışı kullanılacak taşıt kredisi miktarını doğrudan etkileyecektir. Tüm bu sebeplerle hem finans sektörü hem de otomotiv sektörü için taşıt kredilerinin tahmin edilebilmesi büyük önem taşımaktadır. Bu çalışmada, Türkiye'deki taşıt kredisi tahmini makine öğrenmesi yöntemlerinden yapay sinir ağları kullanılarak başarılı bir şekilde gerçekleştirilmiştir. Geliştirilen modeli analiz etmek ve değerlendirmek için R^2 , MAE ve MSE metrikleri hesaplanmıştır. Analiz sonuçlarına göre, modelin başarısının yüksek olduğu ve hatanın kabul edilebilir aralıkta olduğu görülmektedir. Tasarlanan modelin başarılı olarak çalışması başta bankacılık ve otomotiv sektöründeki kuruluşların kısa ve uzun dönemli stratejilerin belirlenmesinde uygulanabilir olduğunu göstermektedir. Aynı zamanda politika karar alıcıları ve uygulayıcıları bu modeli kullanarak ekonomik dalgalanmaların meydana geldiği dönemlerde taşıt kredilerine yönelik yapacakları düzenlemeler ile ekonominin aşırı büyümesi ve aşırı küçülmesine önlem alabileceklerdir. Türkiye’ye gibi otomotiv sektöründeki ithalat oranının yüksek olduğu ülkelerde özellikle dış ödemeler dengesi bakımından bu modelin daha isabetli politikaların oluşturulmasında faydalı olacağı düşünülmektedir. Gelecekteki yapılacak benzer çalışmalar için çalışmadaki modelin benzerlerinin farklı teknikler ile yapılması bu konudaki literatürün zenginleşmesine fayda sağlayacaktır.

Kaynakça

- Aydemir, E. (2019). Ders geçme notlarının veri madenciliği yöntemleriyle tahmin edilmesi. *Avrupa Bilim ve Teknoloji Dergisi*, 15, 70-76.
- Drew, P. J., & Monson, J. R. (2000). Artificial neural networks. *Surgery*, 127(1), 3-11.
- Erdoğan, H., Terzioğlu, M., & Kayakuş, M. (2021). Almanya'dan konaklama amacıyla Türkiye'ye gelen turist sayısının yapay zekâ teknikleri kullanılarak tahmin edilmesi. *Avrupa Bilim ve Teknoloji Dergisi*, 27, 961-971.
- Islam, M. M., & Murase, K. (2001). A new algorithm to design compact two-hidden-layer artificial neural networks. *Neural Networks*, 14(9), 1265-1278.
- Jain, A. K., Mao, J., & Mohiuddin, K. M. (1996). Artificial neural networks: A tutorial. *Computer*, 29(3), 31-44.
- Karlık, B., & Olgac, A. V. (2011). Performance analysis of various activation functions in generalized MLP architectures of neural networks. *International Journal of Artificial Intelligence and Expert Systems*, 1(4), 111-122.
- Kayacı Çodur, M. (2021). Ulaştırma enerji talebinin yapay sinir ağları ile modellenmesi. *Journal of the Institute of Science and Technology*, 11(4), 2706-2715.
- Kayakuş, M., & Terzioğlu, M. (2021). Yapay sinir ağları ve çoklu doğrusal regresyon kullanarak emeklilik fonu net varlık değerlerinin tahmin edilmesi. *Bilişim Teknolojileri Dergisi*, 14(1), 95-103.
- Kayakuş, M., Terzioğlu, M., & Yetiz, F. (2022). Forecasting housing prices in Turkey by machine learning methods. *Aestimum*, 80, 33-44.
- Saif, A. S., Garba, A. G., Awwalu, J., Arshad, H., & Zakaria, L. Q. (2017). Performance comparison of min-max normalisation on frontal face detection using haar classifiers. *Pertanika Journal of Science and Technology*, 25(S), 163-172.
- Sayjadah, Y., Hashem, I. A. T., Alotaibi, F., & Kasmiran, K. A. (2018). *Credit card default prediction using machine learning techniques*. 2018 Fourth International Conference on Advances in Computing, Communication & Automation (ICACCA).
- Sharma, S., Sharma, S., & Athaiya, A. (2017). Activation functions in neural networks. *Towards Data Sci*, 6(12), 310-316.
- Shen, Y., Wang, J., & Navlakha, S. (2021). A correspondence between normalization strategies in artificial and biological neural networks. *Neural computation*, 33(12), 3179-3203.
- Taşar, B., Fatih, Ü., Demirci, M., & Kaya, Y. Z. (2018). Yapay sinir ağları yöntemi kullanılarak buharlaşma miktarı tahmini. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 9(1), 543-551.
- White, H. (1989). Learning in artificial neural networks: A statistical perspective. *Neural computation*, 1(4), 425-464.
- Wythoff, B. J. (1993). Backpropagation neural networks: a tutorial. *Chemometrics and Intelligent Laboratory Systems*, 18(2), 115-155.

- Yavuz, S., & Deveci, M. (2012). İstatiksel normalizasyon tekniklerinin yapay sinir ađın performansına etkisi. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*(40), 167-187.
- Yetiz, F., Terziođlu, M., & Kayakuş, M. (2021). Makina öğrenmesi yöntemleri ile Türk mevduat bankalarının müşteri tahminine yönelik bir uygulama. *Sosyoekonomi*, 29(50), 413-432.
- Zhang, J., & Morris, A. J. (1998). A sequential learning approach for single hidden layer neural networks. *Neural Networks*, 11(1), 65-80.
- Zhou, J. (2017). *Data mining for individual consumer credit default prediction under e-commerce context: a comparative study* International Conference on Information Systems (ICIS) Seoul, Güney Kore. <http://aisel.aisnet.org/icis2017/DataScience/Presentations/22>