

e-ISSN:2587-2168



Year: 2024

Vol: 10 Issue: 5

pp 154-158

Article ID

77546

Arrival

22 July 2024

Published

26 October 2024

DOI NUMBER<https://doi.org/10.5281/zenodo.13995786>**How to Cite This****Article**

Çakıroğlu, H. & Topal, K. H. (2024). "Çağrı Merkezlerinde İşgücü Planlaması ve Performans Geliştirmede Çağrı Hacmi Tahminleri: ARIMA, Üstel Düzeltme Ve Karar Ağacı Regresyonu", International Journal of Disciplines Economics & Administrative Sciences Studies, (e-ISSN:2587-2168), Vol:10, Issue:5; pp: 154-158.



International Journal of Disciplines Economics & Administrative Sciences Studies is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License.

Çağrı Merkezlerinde İşgücü Planlaması ve Performans Geliştirmede Çağrı Hacmi Tahminleri: ARIMA, Üstel Düzeltme Ve Karar Ağacı Regresyonu *

The Call Volume Estimates in Workforce Planning And Performance Improvement in Call Centers: ARIMA, Exponential Smoothing and Decision Tree Regression

Hüseyin Çakıroğlu ¹ Kadriye Hilal Topal ²

¹ Öğr. Gör., İstanbul Nişantaşı Üniversitesi, Bilgisayar Programcılığı Pr., İstanbul, Türkiye

² Dr. Öğr. Üyesi, İstanbul Nişantaşı Üniversitesi, Bilgisayar Programcılığı Pr., İstanbul, Türkiye

ÖZET

Çağrı merkezleri, müşteri hizmetleri, satış, teknik destek, şikayet yönetimi ve pazar araştırması gibi bazı işlevleri yerine getirmektedir. Bu nedenle çağrı merkezlerinde sistemselsel bir iş yoğunluğu görülmektedir. İş yoğunluğunun fazla olduğu çağrı merkezlerinde vardiya planlaması ve performans değerlendirmeleri iki önemli konudur. Vardiya planlaması işgücü kaynağının verimli kullanımına olanak sağlar. Doğru vardiya planlaması ve bu sayede gerçekleştirilen işgücü kaynağının tahsisi, çağrı merkezlerinin müşteri memnuniyetini ve operasyonel verimliliğini artırmada kritik bir öneme sahiptir. Bu çalışmanın amacı, çağrı merkezi alanında faaliyet gösteren işletmelere veri odaklı karar verme süreçlerinde yardımcı olacak en uygun çağrı hacmi tahminini veren modeli belirlemektir. Bu amaç için gerçek çağrılar ele alınarak hem küçük hem de büyük veri setleri (uzun data) oluşturulmuştur. Çağrı hacmi veri setlerine klasik zaman serisi modellerinden ARIMA ve Üstel Düzeltme, makine öğrenmesi yöntemlerinden Karar Ağacı Regresyonu yöntemi uygulanmış ve tahmin performansları hatalara dayalı kriterler kullanılarak karşılaştırılmıştır. Gerçek çağrı merkezi verileri kullanılarak yapılan bu çalışmada, büyük veri setlerinde Karar ağacı Regresyonu modelinin ARIMA ve Üstel Düzeltme klasik zaman serisi modellerine göre daha iyi performans gösterdiği sonucuna ulaşılmıştır. Fakat küçük veri setlerinde Üstel Düzeltme klasik zaman serisi modelinin daha başarılı olduğu bulgusuna ulaşılmıştır. Sonuçlar, çağrı hacmi tahminlerinde hacim açısından veri bazlı model seçiminin çağrı merkezi operasyonlarının daha etkin ve esnek hale getirilmesindeki önemini ortaya çıkartmaktadır.

Anahtar Kelimeler: Makine Öğrenmesi, Çağrı Merkezi Yönetimi, Vardiya Planlaması.

ABSTRACT

The call centers perform some functions such as customer service, sales, technical support, complaint management and market research. For this reason, there is a systematic workload in call centers. Shift planning and performance evaluations are two important issues in the call centers with high workload. Shift planning provides efficient use of labor resources. Optimum shift planning and the distribution of workforce resources provided by this planning have critical importance in order to increase the operational efficiency and customer satisfaction in call centers. The aim of this study is to determine the model that provides the most appropriate call volume prediction to assist businesses in the call center area in data based decision-making processes. To this aim, classical ARIMA and Exponential Smoothing time series models and Decision Tree Regression which is a machine learning method, are applied to call volume datasets and their prediction performances are compared by using error based criteria. For this, both small and tall datasets are created by taking real calls. In this study, used real call center data, it is concluded that the Decision Tree Regression model performs better than ARIMA and Exponential Smoothing classical time series models in tall datasets. However, the Exponential Smoothing classical time series model is more successful in small datasets. The results are revealed the importance of data driven model selection in call volume predictions in making call center operations more effective and flexible.

Keywords: Machine Learning, Call Center Management, Shift Planning.

1. GİRİŞ

Günümüzde çağrı merkezleri, modern işletmelerin müşteri hizmetleri stratejilerinin merkezi bir parçası olarak vazgeçilmez bir rol oynamaktadır. Müşteri hizmetleri, satış, teknik destek, şikayet yönetimi ve pazar araştırması gibi bir dizi önemli işlevi yerine getirmektedir. Teknolojinin ilerlemesiyle birlikte çağrı merkezleri sadece telefon iletişim hizmeti vermekle kalmamakta, aynı zamanda birden fazla iletişim kanalını kapsayan çok kanallı bir hizmet de sunmaktadır. Bu çok kanallı yaklaşım, müşteri memnuniyetinin artırılması, müşteri sadakatinin güçlendirilmesi ve şirketlerin rekabet avantajının sürdürülmesi açısından kritik bir öneme sahiptir. Bu nedenle, çağrı merkezlerinin yönetimi, müşteri memnuniyetinin artırılması ve operasyonel maliyetlerin optimize edilmesi açısından stratejik bir konudur.

Çağrı merkezlerinde gelen çağrı tahminleri yönetim stratejilerinin oluşturulmasında önemli bir kaynak olabilmektedir. Ayrıca, mevcut işletmelere iş gücü planlaması ve iş performanslarının ölçülmesi açısından çeşitli bilgiler sağlamaktadır. Bu tahminler, mevcut çağrı merkezlerine iş gücü verimliliğinin artırılması,

* Yüksek Lisans tezinden üretilmiş bu çalışma, 9-11 Mayıs 2024 tarihinde Mersin'de gerçekleştirilen IERFM isimli kongrede sözlü olarak sunulan bildirinin geliştirilmiş halidir.

personel memnuniyetinin yükseltilmesi, maliyetlerin azaltılması ve karar verme süreçlerinin optimize edilmesi gibi faydalar sağlamaktadır. Bunun yanı sıra, tahminler doğrultusunda çalışanların tercihleri ve yeterlilikleri dikkate alınarak daha adil ve etkili vardiya dağılımları yapılabilmektedir.

Literatürde çağrı merkezi tahminleri ile ilgili sınırlı sayıda çalışma bulunmaktadır. Bu çalışmalardan Ahmed, Sivarajah, Irani, Mahroof, Charles (2024) çalışmasında, her çağrı merkezinde, çağrıları değerlendirme amacıyla etkileşimlerin temsili bir örneğini sıralamak, seçmek ve analiz etmek için geleneksel olarak kullanılan manuel süreci yeterli görmemiş, çoklu sınıflandırma problemi için Derin Sinir Ağı'nı (DNN) yöntemini kullanarak bir emlak çağrı merkezinden gelen yedi saatlik kayıtlı çağrılardan oluşan bir veri setini analiz etmişlerdir. Çalışma %75'lik bir doğruluk oranıyla öznellik tespiti çalışmalarının temelini oluşturarak, en iyi performans değerlendirmesine ulaşmak için subjektif çağrıların değerlendirme sürecinden çıkarılması veya subjektif puanların genel sonuçlardan çıkarılması gerektiği önermektedir. Baldon, N. (2019), çağrı merkezlerinde çağrı hacmini ARIMA, Rassal Orman veya LSTM ağları gibi makine öğrenmesi algoritmaları da dahil olmak üzere çeşitli modeller ile tahmin etmiştir. Çağrı hacmini tahmin etmek için doğru ve güvenilir modeller geliştirmiştir. Shetty, Singh, Patil, Arora, & Arcot (2022), çağrı merkezlerinde günlük çağrıların tahmin edilmesinde 3 yıllık veri setine Holt Winter's, ARIMA, SARIMA ve Neuralprophet olmak üzere dört farklı algoritma kullanmış ve bu yöntemlerin işgücü planlamasında ne kadar etkili olduğunu değerlendirmişlerdir. Sonuç olarak, çağrıya dayalı personel belirlemede çağrıların gelme zamanı, ortalama çağrı işleme süresi ve mevsimsellik, tatiller ve yıl sonu çağrıları gibi takvim etkilerinin modellenerek tahmin doğruluğunun artırılmasına yardımcı olduğu sonucuna ulaşmışlardır. Ayrıca, Neuralprophet makine öğrenmesi yönteminin çağrı varışlarını tahmin etmede diğer modellerden etkili olduğu sonucuna ulaşmışlardır. Li, Wang ve Koole (2018) çalışmasında çağrı merkezlerinde müşteri hizmeti memnuniyetini artırmak için Karar Ağaçları Regresyon Modelini kullanmışlar ve karar ağaçlarının çağrı merkezi operasyonlarında etkin bir araç olabileceğini göstermişlerdir.

Bu çalışmanın amacı, makine öğrenmesi modellerinin çağrı merkezi veri setlerine uygulanmasında elde edilen bulguları analiz ederek, en uygun modelin seçilmesine rehberlik etmektir. Çalışmanın çağrı merkezi veri setlerinin analizi ve modellemesinde önemli bir kaynak noktası oluşturarak, işletmelerin bu alandaki yönetim stratejilerinin belirlemelerine yardımcı olacak teorik ve pratik katkılar sunması amaçlanmaktadır. Bunun için, çağrı merkezlerindeki çağrı hacmi tahminlerinin gerçek zamanlı veri analizi ve makine öğrenmesi modellerinin kullanımı ile tahmin doğruluğunun araştırılması sağlanmıştır. Tahminleri optimize etmek için klasik zaman serisi modellerinden ARIMA ve Üstel Düzeltme, makine öğrenmesi modellerinden Karar Ağacı Regresyonu olmak üzere üç farklı modelin karşılaştırmalı analizi yapılarak ve her bir modelin tahmin performansı ve uygulanabilirliği kapsamlı bir şekilde değerlendirilmiştir. ARIMA, Karar Ağacı Regresyonu ve Üstel Düzeltme modellerinin çağrı merkezi veri setlerine uygulanmasında elde edilen bulgular analiz ederek, çağrı merkezlerine gelen çağrıların tahmininde kullanılabilecek en uygun modelin seçimi gerçekleştirilmiştir.

Çalışmanın giriş bölümünü takiben 2. bölümünde kullanılan tekniklerin ve yaklaşımların metodolojisi detaylandırılmaktadır. 3. bölümde her bir modelinin eğitilme, doğrulanma, test sonuçları ile performans karşılaştırmaları olmak üzere ampirik bulgularına, 4. bölümde ise değerlendirme ve sonuçlara değinilmiştir.

2. METODOLOJİ

Çalışmada ARIMA, Karar Ağacı Regresyonu ve Üstel Düzeltme olmak üzere 3 farklı model kullanılmıştır.

2.1. ARIMA

ARIMA (Oto regresif Entegre Hareketli Ortalama), zaman serileri için kullanılan klasik bir tahmin modelidir. ARIMA modelleri genel olarak ARIMA (p,d,q) olarak gösterilir; burada p oto regresif sürecin derecesi, d integrasyon derecesi ve q hareketli ortalama derecesidir. Farklı bir ifadeyle ARIMA modeli, oto regresif (AR), entegre (I) ve hareketli ortalama (MA) terimlerini içerir. ARIMA(p,d,q) modeli,

$$\hat{y}_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t \quad (1)$$

eşitliği ile ifade edilir. Burada c sabit parametre, p oto regresif gecikme uzunluğu, ϕ oto regresif parametre işlemcisi, q hareketli ortalama derecesi, θ hareketli ortalama parametresi ve ε_t hata terimidir (Box, Jenkins, Reinsel ve Ljung, 2015: 115).

2.2. Karar Ağacı Regresyonu

Karar Ağacı Regresyonu, veri kümesini kök düğümlerle başlayarak belirli kararlar temelinde bölen ve her bir yaprak düğümünde bir tahmin yaparak dallanmış bir ağaç sistemiyle çalışan bir algoritmadır. Bölme işlemi her

bir aşamada veri kümesini en iyi bölen değişkenin seçimi ile başlar. Karar ağacı regresyonunda her bir ağaç karara bağlı olarak iki düğüme bölünen ağaçlardır.

Veri kümesini en iyi bölen hedef değişkenin, terminal düğümün sürekli değerler (reel sayı değerleri) alabildiği karar ağaçlarına regresyon ağaçları adı verilir. Hedef değişken kesikli bir değer (belirli bir aralıkta tamsayı değerleri) alabiliyorsa bu ağaçlara sınıflandırma ağaçları denilmektedir (Breiman, Friedman, Olshen ve Stone, 1984: 83).

2.3. Üstel Düzeltme

Üstel Düzeltme yöntemi, genellikle mevsimsellik veya sistematik eğilimler gibi önceki varsayımlara dayalı tahminlerde kullanılır. Yöntem, geçmiş gözlemlere üstel olarak azalan ağırlıklar atayarak çalışır. Her talep gözlemine atanan ağırlık katlanarak azaldığı için bu şekilde adlandırılmıştır. talebin zamanda değiştiği ortalama değer düzeyidir ve bu değer geçmiş değerlerden öğrenilmektedir. Üstel Düzeltme yönteminin 3 temel çeşidi bulunmaktadır:

1. Basit veya Tek Üstel Düzeltme: Trendsiz ve mevsim etkisi olmayan tek değişkenli bir modeldir. Geçmiş gözlemlerin etkisinin katlanarak azalma hızını kontrol eden düzleştirme faktörü (α) kullanılır ve bu değer genellikle 0 ile 1 arasında bir değer alır. Basit üstel düzeltme,

$$s_t = \alpha x_t + (1 - \alpha)s_{t-1} = s_{t-1} + \alpha(x_t - s_{t-1}) \quad (2)$$

eşitliği ile gösterilir.

2. Çifte Üstel Düzeltme: Holt'un trend modeli veya ikinci dereceden üstel düzeltme olarak da adlandırılmaktadır. Serinin doğrusal bir trendi olduğu, fakat mevsimselliğin olmadığı zaman serilerinde kullanılır. Geçmiş gözlemlerin hızını kontrol eden düzleştirme faktörü (α) ve azalan trend etkisini kontrol eden beta (β) olmak üzere iki parametredir. Çifte üstel düzeltme formülleri;

$$s_t = \alpha x_t + (1 - \alpha)(s_{t-1} - b_{t-1}) \quad (3)$$

$$\beta_t = \beta(s_t - s_{t-1}) + (1 - \beta)b_{t-1} \quad (4)$$

olarak gösterilir.

3. Üçlü Üstel Düzeltme: Literatürde Holt-Winters Üstel Düzeltme yöntemi olarak da adlandırılmaktadır. Seride doğrusal eğilimler ve mevsimsellik olduğunda zaman serisi tahmini için kullanılır. Yöntemde seviye düzeltme, trend düzeltme ve mevsimsel düzeltme olmak üzere 3 tip düzeltme uygulanır. Bu yöntemde α ve β 'ya ek olarak mevsimselliğin etkisini kontrol etmek için gama (γ) adı verilen yeni bir düzleştirme parametresi kullanılır (Taylor, 2003: 799).

3. AMPİRİK BULGULAR

Bu çalışmada, gerçek çağrı merkezi operasyonlarından elde edilen 2022 ve 2023 yıllarına ait çağrı kayıtlarını içeren geniş kapsamlı iki farklı veri seti kullanılmıştır. Veri Seti 1, toplamda 187570 kayıt ile 334 gün boyunca 65 farklı kuyruğa gelen toplam 6909764 saatlik çağrı sayısından, Veri Seti 2 ise 79600 kayıt ve 705 gün üzerinden 226 farklı kuyruktan toplam 382685 saatlik çağrı sayısından oluşmaktadır. Veri setleri (80:20) oranlarında öğrenme ve test veri setlerine ayrılmıştır. Öğrenme veri setleri modellerin parametre tahmincilerinin elde edilmesinde, test veri setleri ise örneklem dışı tahmin başarısının ölçülmesinde kullanılmıştır. Veri setlerine ilişkin bilgiler Tablo 1'de yer almaktadır.

Tablo 1. Test Veri Seti Tablosu

	N	Test Veri Seti (n)
Veri Seti 1	187570	37514
Veri Seti 2	79600	15920

Veri seti 1'in %20'si olan 15920 adet gözlem test için geriye kalan 63680 adet gözlem ise öğrenme verisi olarak; Veri seti 2'nin %20'si olan 37514 gözlem test için geriye kalan 150056 adet gözlem ise öğrenme verisi olarak kullanılmıştır.

Bu çalışmada bulgular, Intel (R) Core (TM) i7-10510U CPU @ 1.80GHz işlemci ve 8 GB RAM özelliklerine sahip bir bilgisayar kullanılarak elde edilmiştir. Kodlama süreci, Visual Studio Code ve Google Colab gibi araçlar kullanılarak yürütülmüştür. Analiz için Python programlama dili ve ARIMA modeli için, Karar Ağacı

Regresyonu için sklearn.tree, Üstel Düzeltme modeli için ise statsmodels.tsa.holtwinters, sonuçların görselleştirilmesi için matplotlib.pyplot python kütüphanelerinden yararlanılmıştır.

Üç farklı modelin sonuçlarının kıyaslanabilmesi için, ve bu modellerin performanslarını kesin olarak değerlendirebilmek için hata metrikleri gibi nicel kriterlere ihtiyaç duyulmaktadır. (MAE, RMSE, vb.). Görsel karşılaştırma ile bazı önemli sonuçlar elde edilmiştir.

Sonuç olarak, her bir modelin avantajları ve sınırlılıkları göz önünde bulundurularak ve spesifik hata metrikleri incelenerek en uygun model seçilebilir. Ancak, kesin bir karar vermek için her modelin tahmin başarısını doğrulayan hata metrikleri incelenmelidir. Bu metrikler, modeller arasında daha objektif bir karşılaştırma yapılmasını sağlayacak ve hangi modelin gerçek veriye en iyi uyduğunu gösterecektir. Bu çalışmada kullanılan RMSE (Kök Ortalama Hata Kareleri) hata metriği;

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{n}} \quad (5)$$

eşitliği ile ifade edilebilir. y_t gerçek değerleri, \hat{y}_t tahmin değerlerini ($t = 1, \dots, n$) zaman boyutunu belirtmektedir. Tablo 2' de her 3 modele ait RMSE değerleri sunulmuştur.

Tablo 2. Model Performansları Karşılaştırma Tablosu

	ARIMA	Karar Ağacı Regresyonu	Üstel Düzeltme
Veri Seti 1	85,422	85,006*	121,507
Veri Seti 2	13,45	9,43	8,33*

Tablo 2 incelendiğinde büyük veri setlerinde (Veri Seti 1) (85,006) RMSE değeri ile Karar Ağacı Regresyonu başarılıyken; daha küçük veri setlerinde (Veri Seti 2) (8,33) RMSE değeri ile Üstel Düzeltme Modelinin daha iyi performas sergilediği görülmektedir.

4. DEĞERLENDİRME VE SONUÇ

Bu çalışma ile çağrı merkezi operasyonlarında çağrı hacmi tahmininin geçerliliği incelenmiştir. üç farklı modelin (ARIMA, Karar Ağacı Regresyonu ve Üstel Düzeltme) performansları değerlendirilmiştir. Her bir modelin çağrı hacmi üzerindeki tahmin performansı gerçek çağrı kayıtlarından oluşan hem büyük hem de küçük veri setleri kullanılarak karşılaştırmalı olarak incelenmiştir. Veri Setilerinden birisi geniş kapsamlı veri hacmi, yoğun trafik ve karmaşık çağrı desenlerinin analizine imkan tanıırken, diğeri daha uzun süreyi kapsaması, çağrı merkezi performansındaki dönemsel eğilimleri ve uzun vadeli değişimleri gözlemleme olanağı sağlamaktadır. Her bir model, bu iki veri seti için eğitilmiş ve test edilmiş, performans karşılaştırmaları yapılmıştır. Çalışmada, farklı modellerin avantajları ve performansı, öğrenme verileri üzerindeki uyumu ve test verileri üzerindeki genelleme kabiliyeti temelinde karşılaştırılmıştır.

Karşılaştırma sonuçları, klasik zaman serisi yöntemlerinden olan Üstel Düzeltme yönteminin çok fazla gözlemin olmadığı veri setlerinde uygulanabilir olduğunu, büyük veri setleri, bir diğer ifadeyle uzun veri setleri (Tall Data) için Karar Ağacı Regresyonu gibi makine öğrenmesi yöntemlerinin gerekliliğini ortaya koymuştur. Ayrıca Üstel Düzeltme ve ARIMA modellerinin kısa vadeli ve durağan olmayan veri analizleri için uygulanabileceği söylenebilir. ARIMA modeli durağan olmayan serilerde güçlü bir seçenek olurken, Üstel Düzeltme modeli takvim etkilerini modellemede diğer iki modelden daha başarılı olmuştur.

Elde edilen sonuçlar literatürde yer alan Shetty, Singh, Patil, Arora, & Arcot (2022), çağrı merkezlerinde günlük çağrıların tahmin edilmesinde Holt Winter's, ARIMA, SARIMA ve Neuralprophet olmak üzere 4 farklı modelin kullanıldığı ve model karşılaştırma sonuçlarına göre Neuralprophet makine öğrenmesi modelinin çağrı varışlarını tahmin etmede diğer modellere göre daha etkili olduğunu sonucuyla; Li, Wang ve Kooler (2018)'in çağrı merkezlerinde müşteri hizmeti memnuniyetini artırmak için Karar Ağaçları Regresyon modelini kullandığı ve karar ağaçlarının çağrı merkezi operasyonlarında değerli bir analiz aracı olabileceğini gösterdiği çalışmalarıyla benzerlik göstermektedir.

Çalışmanın sonuçları, makine öğrenmesi modellerinin sadece matematiksel tahminler yapmadığını, aynı zamanda işletme kararlarına ve planlamasına stratejik katkılar sağladığını ortaya koymuştur. Bu bulgular ışığında, makine öğrenmesi modellerinin çağrı merkezlerindeki iş gücü planlaması ve performans yönetimi üzerinde önemli katkıları olabileceği öngörülmektedir. Ayrıca, veriye dayalı karar alma süreçlerinin operasyonel zorluklarla karşılaşan farklı sektörlerde de kullanılması önerilebilir. Önümüzdeki yıllarda, makine öğrenmesi ve yapay zeka teknolojileri, çağrı merkezi operasyonlarının geleceğini şekillendirmede kritik bir rol oynayabilir ve işletmelerin bu alandaki yatırımlarını artırmasının etkili sonuçları olabilir.

KAYNAKÇA

- Ahmed, A., Sivarajah, U., Irani, Z., Mahroof, K. & Charles, V. (2024). "Data-Driven Subjective Performance Evaluation: An Attentive Deep Neural Networks Model Based on a Call Centre Case", *Annals of Operations Research*, 333(2):939–970.
- Baldon, N. (2019). "Çağrı Merkezlerinde Çağrı Hacminin İstatistiksel ve Makine Öğrenimi Yöntemlerinin Kullanılarak Tahmin Edilmesi", Yüksek Lisans Tezi, Kraliyet Teknoloji Enstitüsü, Stockholm-İsveç.
- Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time Series Analysis: Forecasting and Control*. John Wiley & Sons.
- Breiman, L., Friedman, J. H., Olshen, R. A., & Stone, C. J. (1984). *Classification and Regression Trees*. CRC press, New York.
- Bryant, R., & Madsen, J. (2006). *Asterisk VoIP Server*. Packt Publishing Ltd, Birmingham.
- Gomillion, L. & Dempster, B. (2011). *Building Telephone Systems with Asterisk*, Packt Publishing Ltd, Birmingham.
- Li, S., Wang, Q., & Koole, G. (2018). "Call Center Performance with Machine Learning", *Springer Proceedings in Business and Economics*, 193–199.
- Sharp, J. (2020). *Microsoft visual C# step by step*. Microsoft Press.
- Skeet, J. (2020). *C# 9 and .NET 5 – Modern Cross-Platform Development: Build Intelligent Apps, Websites, And Services with Blazor, Asp.Net Core, And Entity Framework Core Using Visual Studio Code*. Packt Publishing, Birmingham.
- Smith, C., Madsen, J., & Madsen, M. (2009). *Asterisk: The Definitive Guide*. O'reilly media.
- Taylor, J. W. (2012). "Density Forecasting of Intraday Call Center Arrivals Using Models Based on Exponential Smoothing", *Management Science*, 58(3):534-549.
- Shetty, V., Singh, A., Patil, A. B., Arora, H. S., & Arcot, T. K. (2022). "Çağrı Merkezi İş Gücü Yönetiminin Otomasyonunda Neuralprophet Kullanımı" 2022 IEEE Kuzey Karnataka Alt Bölümü Amiral Gemisi Uluslararası Konferansı (NKCon), IEEE, 1-7, Karnataka.