

DOKUZ EYLÜL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YAPAY SİNİR AĞLARI İLE ÇAĞRI MERKEZİ
YÜK TAHMİNİ

Yunus SUR

Ekim, 2024

İZMİR

YAPAY SİNİR AĞLARI İLE ÇAĞRI MERKEZİ YÜK TAHMİNİ

Dokuz Eylül Üniversitesi Fen Bilimleri Enstitüsü

Yüksek Lisans Tezi

İstatistik Anabilim Dalı, Veri Bilimi Programı

Yunus SUR

Ekim, 2024

İZMİR

YÜKSEK LİSANS TEZİ SINAV SONUÇ FORMU

YUNUS SUR tarafından DOÇ. DR. ENGİN YILDIZTEPE yönetiminde hazırlanan “YAPAY SİNİR AĞLARI İLE ÇAĞRI MERKEZİ YÜK TAHMİNİ” başlıklı tez tarafımızdan okunmuş, kapsamı ve niteliği açısından bir Yüksek Lisans tezi olarak kabul edilmiştir.

Doç. Dr. Engin YILDIZTEPE

Danışman

Prof. Dr. Femin YALÇIN KÜÇÜKBAYRAK

Jüri Üyesi

Prof. Dr. A. Fırat ÖZDEMİR

Jüri Üyesi

Prof. Dr. Okan FISTIKOĞLU

Müdür

Fen Bilimleri Enstitüsü

TEŞEKKÜR

Bu çalışmayı yapma fırsatını bana sunan, değerli fikirleri ve tecrübeleriyle rehberlik eden, farklı bakış açıları kazandıran, sabrı ve anlayışıyla her zaman yanımda olan saygıdeğer danışmanım Doç. Dr. Engin YILDIZTEPE'ye en içten teşekkürlerimi sunarım.

Ayrıca her zaman yanımda olup beni destekleyen, aileme, arkadaşlarıma ve gelişimime katkı sağlayan tüm İstatistik Bölümü akademisyenlerine en içten teşekkürlerimi sunarım.

Yunus SUR

YAPAY SINIR AĞLARI İLE ÇAĞRI MERKEZİ YÜK TAHMİNİ

ÖZ

Çağrı merkezleri, kurumların bireyler veya diğer kurumlarla iletişimlerini sürdürebilmeleri için hizmet veren birimlerdir. Bu merkezler, telefon, e-posta veya diğer iletişim kanalları ile müşteri taleplerini karşılamak amacıyla doğru ürün veya hizmeti, doğru zamanda sunmayı hedefler. Çağrı merkezleri, müşteri memnuniyetini sağlamak ve iş gücünü etkin bir şekilde kullanmak adına yük tahmini yaparak kaynaklarını optimize etme gereksinimi duyarlar. Bu çalışmada, çağrı merkezlerinin iş yükünün daha verimli bir şekilde yönetilmesi amacıyla, yapay sinir ağları kullanılarak çağrı yoğunluğunun tahmin edilmesi hedeflenmiştir. Çalışmada, bir çağrı merkezinin faaliyetlerini yansıtan çağrı sayıları, ortalama çağrı süreleri ve çalışan sayısı gibi çeşitli değişkenleri içeren veriler kullanılmıştır. Veri ön işleme süreçlerinin ardından, yapay sinir ağları modellerinin eğitim ve test verileri belirlenmiştir. Çağrı sayısını ve ortalama çağrı süresini tahmin etmek amacıyla iki model geliştirilmiştir. Tahmin edilen çağrı sayıları ile gerçekleşen ortalama çağrı sürelerinin değerleri ile Erlang C analizi kullanarak ihtiyaç duyulan personel sayısı hesaplanmıştır. Uygulama sonucunda, yapay sinir ağları modellerinin çağrı merkezi yük tahmininde oldukça başarılı sonuçlar verdiği görülmüştür. Yapay sinir ağları ile oluşturulan modeller, çağrı merkezi yöneticilerinin iş gücü planlamasını daha isabetli bir şekilde yapmalarına yardımcı olarak sunulan hizmetin kalitesini artırabilir. Ayrıca, uygulanan yaklaşım operasyonel maliyetlerin düşürülmesine ve müşteri memnuniyetinin artırılmasına da katkı sağlayabilir.

Anahtar kelimeler: Yapay Sinir Ağları, Çağrı Merkezi, Erlang C

CALL CENTRE LOAD PREDICTION WITH ARTIFICIAL NEURAL NETWORKS

ABSTRACT

Call centres are units that provide services for companies to maintain their communication with individuals or other companies. These centres aim to provide the right product or service at the right time to meet customer demands via phone, e-mail or other communication channels. Call centres need to optimize their resources by making load predictions in order to ensure customer satisfaction and use their workforce efficiently. In this study, we aim to predict call load using artificial neural networks in order to manage the workload of call centres more efficiently. In the study, data reflecting the activities of a call centre, including various variables such as the number of calls, average call duration and number of employees, was used. After data preprocessing, training and test data for artificial neural network models were specified. Two separate models were developed to predict the number of calls and the average call duration. The number of agents required was calculated by using Erlang C analysis with the values of the predicted number of calls and the actual average call duration. The result of the application shows that artificial neural network models give very successful results in call centre load prediction. The models developed with artificial neural networks can help call centre managers to make workforce planning more accurately and improve the quality of the service provided. Moreover, the applied approach can also contribute to reducing operational costs and increasing customer satisfaction.

Keywords: Artificial Neural Networks, Call Centre, Erlang C

İÇİNDEKİLER

	Sayfa
YÜKSEK LİSANS TEZİ SINAV SONUÇ FORMU	ii
TEŞEKKÜR.....	iii
ÖZ.....	iv
ABSTRACT.....	v
İÇİNDEKİLER	vi
ŞEKİLLER LİSTESİ.....	viii
TABLolar LİSTESİ	x

BÖLÜM BİR - GİRİŞ 1

1.1 Tez Çalışmasının Amacı ve Önemi	1
1.2 Çağrı Merkezi	4
1.2.1 Geçmişten Günümüze Çağrı Merkezleri	4
1.2.2 Gelen ve Giden Çağrılar	5
1.3 Çağrı Merkezi İş Yükü ve Performans Ölçütleri.....	6
1.4 Çağrı Merkezinde Çalışanların İş Yükü ve Performans İlişkileri	8
1.5 Çağrı Merkezi İş Yükü Analizinin Rolü	9
1.6 Erlang C.....	9

BÖLÜM İKİ - YAPAY SİNİR AĞLARI.....11

2.1 Nöron Yapısı ve İşlevi	13
2.2 Aktivasyon Fonksiyonları	14
2.3 Geri Yayılım Algoritması.....	16
2.4 Derin Yapay Sinir Ağları	17
2.4.1 Evrişimli Sinir Ağları.....	18
2.4.2 Tekrarlayan Sinir Ağları.....	19
2.4.3 Uzun Kısa Süreli Bellek Sinir Ağları.....	21

BÖLÜM ÜÇ - UYGULAMA24

3.1 Yöntem.....	24
-----------------	----

3.2 Veri.....	24
3.3 Eğitim - Test Ayrımı	29
3.4 Modelleme	31
3.5 Tahminleme	35
3.6 Hata Ölçütleri	37
3.7 Erlang C ile Personel Sayısını Belirleme	39
3.8 Yapay Veri Örneği	41
BÖLÜM DÖRT - SONUÇLAR VE ÖNERİLER.....	47
KAYNAKLAR	49

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 2.1 Yapay sinir ağları yapısı	12
Şekil 2.2 Sigmoid fonksiyonu	14
Şekil 2.3 Tanh fonksiyonu	15
Şekil 2.4 ReLU fonksiyonu.....	16
Şekil 2.5 Evrişimli sinir ağları	19
Şekil 2.6 Tekrarlayan sinir ağları	20
Şekil 2.7 Uzun kısa süreli bellek sinir ağları	22
Şekil 3.1 Kullanılan Python kütüphaneleri	24
Şekil 3.2 Veriler	25
Şekil 3.3 Veri türleri	27
Şekil 3.4 Tanımlayıcı istatistikler.....	28
Şekil 3.5 Hedef değişkenlerin grafiği	29
Şekil 3.6 Çağrı sayısı için eğitim - test grafiği.....	30
Şekil 3.7 Ortalama çağrı süresi için eğitim - test grafiği.....	30
Şekil 3.8 Eğitim - test verileri	31
Şekil 3.9 Uzun kısa süreli bellek sinir ağları ile kurulan model	32
Şekil 3.10 Kayıp değerler	34
Şekil 3.11 Tahmini değerler.....	36
Şekil 3.12 Nisan 2024 çağrı sayıları grafiği	37
Şekil 3.13 Sonuç değerler	40

Şekil 3.14 Yapay veriler	42
Şekil 3.15 Yapay verilerde kayıp değerleri	43
Şekil 3.16 Yapay verilerde çağrı sayıları grafiği	45
Şekil 3.17 Yapay veriler ile elde edilen sonuç değerleri	46



TABLÖLAR LİSTESİ

Sayfa

Tablo 3.1 Gerçek veriler ile elde edilen ölçütler.....	38
Tablo 3.2 Yapay veriler ile elde edilen ölçütler.....	44



BÖLÜM BİR

GİRİŞ

1.1 Tez Çalışmasının Amacı ve Önemi

Çağrı merkezleri, müşteri ilişkileri yönetiminde hayati bir rol oynar ve müşteri memnuniyeti ile doğrudan ilişkilidir. Bu tez çalışmasının amacı, bir çağrı merkezinin iş yükünü yapay sinir ağları yöntemleriyle tahminleyerek, elde edilen değerlerle Erlang C analizi yardımıyla ihtiyaç duyulan personel sayısını belirlemektir. Bu araştırmanın önemi, çağrı merkezi operasyonlarını daha verimli hale getirerek müşteri deneyimini iyileştirmeye ve işletme maliyetlerini düşürmeye yönelik pratik çözümler sunmasıdır. Ayrıca bu çalışma, çağrı merkezi çalışanlarının iş yükünü yönetme ve müşteri taleplerine daha iyi yanıt verme konusunda bir rehber sağlamayı amaçlamaktadır. İş yükü analizinin sonuçları, çağrı merkezlerinin gelecekteki stratejik planlamalarına ve karar verme süreçlerine katkıda bulunabilecektir.

Çağrı merkezleri, günümüzün hızla değişen iş dünyasında, müşteri hizmetleri ve destek hizmetleri için önemli bir rol oynar. Müşterilerle ilk temas noktası olarak, çağrı merkezlerinin verimliliği, bir işletmenin genel başarısında yer alan faktörler arasındadır. Bu nedenle, çağrı merkezi operasyonlarının sürekli olarak iyileştirilmesi gerekmektedir (Aksin, Armony, ve Mehrotra, 2007).

Çalışma, çağrı merkezi çalışanlarının karşılaştığı zorlukları ve bu zorlukların üstesinden gelmek için kullanılabilecek yenilikçi çözümleri ortaya koymayı hedeflemektedir. Ayrıca, iş yükü analizi, müşteri hizmetleri süreçlerinin daha verimli hale getirilmesi için gerekli olan veriye dayalı kararları destekleyecektir.

Çağrı merkezi iş yükü analizi, müşteri hizmetleri ve destek hizmetlerinin kalitesini artırmak için kritik bir araçtır. Bu analiz, çağrı merkezi çalışanlarının iş yükünü daha etkin bir şekilde yönetmelerine ve müşteri taleplerine daha hızlı ve doğru yanıtlar vermelerine olanak tanır. Ayrıca, iş yükü analizi, çağrı merkezi yöneticilerine, kaynakların daha etkin kullanılması ve operasyonel maliyetlerin düşürülmesi için stratejik planlama yapma imkanı sunar.

Bu tez çalışması, çağrı merkezi operasyonlarının verimliliğini ve etkinliğini artırmak için gerekli bilgileri ve stratejileri sağlamayı hedeflemektedir. Çalışma, çağrı merkezi yöneticilerine, çalışanlarına ve müşteri hizmetleri sektöründeki diğer profesyonellere, müşteri memnuniyetini artırmak ve işletme maliyetlerini düşürmek için değerli görüşler sunacaktır.

Çalışmada, çağrı merkezi verimliliğini artırmayı hedefleyen veri odaklı iş yükü tahmini ve işgücü optimizasyonu konuları ele alınmıştır. Bu bağlamda, çağrı merkezi süreçlerinde veri analitiğinin kritik önemi vurgulanmakta ve işgücü planlamasında veri tabanlı yaklaşımların etkinliği detaylandırılmaktadır. Özellikle, veri analitiğinin çağrı merkezi operasyonlarının performansını artırma ve iş gücü yönetimini iyileştirme üzerindeki etkileri incelenmiştir. Kadioglu ve Alatas (2023) tarafından gerçekleştirilen bu çalışma, veri odaklı stratejilerin çağrı merkezi süreçlerinin optimizasyonuna nasıl katkı sağladığını ayrıntılı bir şekilde ortaya koymaktadır.

Hizmet sektöründe kapasite ve talebi yönetmek için operasyonlar ve pazarlamanın entegrasyonunu ele alan bir çalışmada, işletmelerin karşılaştığı kapasite ve talep yönetimi zorluklarına odaklanılmıştır. Klassen ve Rohleder (2001) tarafından gerçekleştirilen bu çalışma, operasyon ve pazarlama stratejilerinin bir araya getirilmesinin, hizmet sektöründeki işletmelerin rekabetçiliğini artırmada önemli bir rol oynayabileceğini vurgulamaktadır.

Telefon çağrı merkezlerinin işleyişi üzerine kapsamlı bir inceleme sunan bir çalışmada, çağrı merkezlerinin operasyonel süreçleri, performans ölçütleri ve yönetim stratejileri detaylı bir şekilde ele alınmıştır. Gans vd. (2003) tarafından yayımlanan bu çalışma, çağrı merkezlerinin işleyişi hakkında kapsamlı bir kılavuz sunmakta ve ayrıca gelecekteki araştırma alanlarına yönelik önerilerde bulunmaktadır.

Çağrı merkezi gelişmelerinin tahmin edilmesine odaklanan bir çalışmada, sabit etkiler, karışık etkiler ve ikili modellerin kullanımı incelenmiştir. Ibrahim ve L'Ecuyer (2013) tarafından gerçekleştirilen bu araştırma, çağrı merkezi varışlarının doğru bir şekilde tahmin edilmesi için çeşitli model türlerinin etkinliğini ortaya koymaktadır. Çalışma, farklı tahmin yöntemlerinin karşılaştırılmasına ve model türlerinin performansının değerlendirilmesine yönelik önemli bulgular sunmaktadır.

Çağrı merkezleri için iş yükü tahminine odaklanan bir çalışmada, iş yükünü tahmin etmek için kullanılan metodoloji ve bir vaka çalışması ele alınmıştır. Aldor-Noiman vd. (2009) tarafından gerçekleştirilen bu araştırma, çağrı merkezlerinin verimliliğini artırmak ve kaynakları daha etkin bir şekilde yönetmek için önemli bir araç sunmaktadır. Çalışmanın sonuçları, iş yükü tahmininde kullanılan yöntemlerin etkinliğini ve önemini vurgulamaktadır.

Çağrı merkezlerinin iş yükünü tahmin etmek için ayırıklaştırma tabanlı bir yaklaşımı ele alan bir çalışmada, iş yükünün tahmin edilmesinde ayırıklaştırma yöntemlerinin etkinliği vurgulanmıştır. Moreira-Matias vd. (2014) tarafından gerçekleştirilen bu araştırma, iş yükü tahmininde ayırıklaştırma yöntemlerinin sağladığı avantajları detaylı bir şekilde incelemektedir.

Çağrı merkezi çalışanlarının performanslarının tahminlenmesi konusunda yapay sinir ağlarının etkinliğini değerlendirmeyi amaçlayan bir çalışmada, yapay sinir ağlarının çağrı merkezi performans tahminindeki başarısı incelenmiştir. Ortakaya (2019) tarafından gerçekleştirilen bu araştırma, yapay sinir ağlarının performans tahmininde etkili bir yöntem olduğunu göstermektedir. Çalışma, çağrı merkezi yöneticilerine performans değerlendirmesi ve iyileştirmesi konularında önemli bir yol haritası sunmaktadır.

Yapay sinir ağları kullanarak 112 Acil Çağrı Merkezine gelen çağrı sayılarını tahmin etmek için bir model öneren bir çalışmada, bu modelin geliştirilmesi, acil çağrı merkezlerinin daha etkili bir şekilde yönetilmesine ve hizmet kalitesinin artırılmasına katkı sağlamayı hedeflemektedir. Aydemir vd. (2014) tarafından gerçekleştirilen araştırmanın sonuçları, yapay sinir ağları tahminleme modelinin 112 Acil Çağrı Merkezine gelen çağrı sayılarını doğru bir şekilde belirlemede potansiyel bir araç olabileceğini göstermektedir.

Çağrı merkezi çalışanlarının iş yükü düzeyi ile iş doyumu arasındaki ilişkiyi inceleyen bir çalışmada, iş yükü düzeyinin artmasıyla iş doyumu arasında negatif bir ilişki bulunmuştur. Keser (2006) tarafından gerçekleştirilen bu araştırma, iş yükü arttıkça çalışanların iş doyumlarının azaldığını tespit etmiştir. Bu sonuç, çağrı merkezi çalışanlarının iş koşullarının ve iş yüklerinin iyileştirilmesini vurgulamakta ve iş yükü

düzeyinin iş doyumu üzerindeki etkisini anlamak için önemli adımlar sunmaktadır. Araştırma, çalışanların memnuniyetini artırmak amacıyla gerekli iyileştirmelerin yapılması gerektiğini ortaya koymaktadır.

Çalışan performansını etkileyen çeşitli faktörleri incelemeyi amaçlayan bir araştırmada, çağrı merkezlerinde çalışanların performansını belirleyen unsurlar detaylı bir şekilde ele alınmıştır. Bulut ve Ataay (2017) tarafından gerçekleştirilen bu çalışma, çağrı merkezlerindeki çalışan performansını etkileyen faktörlerin kapsamlı bir analizini sunmaktadır. Çalışmanın özeti, bu faktörlerin etkilerini ve performans üzerindeki rollerini ayrıntılı bir biçimde incelemektedir.

1.2 Çağrı Merkezi

Çağrı merkezi, müşteriler veya potansiyel müşteriler ile iletişime geçilen ve genellikle telefon, e-posta, sohbet, sosyal medya ve diğer iletişim kanalları aracılığıyla gelen (inbound) ve giden (outbound) iletişimleri verimli bir şekilde hizmet vermeyi amaçlayan bir kuruluş veya departmandır. Çağrı merkezleri, müşteri hizmetleri, teknik destek, satış, pazarlama, bilgi verme ve çeşitli müşteri ilişkileri yönetimi görevlerini yerine getirir (Gans vd., 2003).

1.2.1 Geçmişten Günümüze Çağrı Merkezleri

Çağrı merkezlerinin tarihsel gelişimi ve evrimi, önemli teknolojik ve yapısal değişiklikleri kapsamaktadır. İlk çağrı merkezleri 1960'larda telefon teknolojisinin yaygınlaşmasıyla ortaya çıkmıştır. Bu dönemdeki çağrı merkezleri, genellikle manuel olarak çalışan ve yalnızca telefon görüşmeleriyle sınırlı olan basit yapılar olarak karşımıza çıkmıştır. Müşteri etkileşimleri, bu dönemde telefonla sınırlıydı ve çağrı yönetimi oldukça basit bir şekilde yapılmaktaydı.

1980'lerde, çağrı merkezlerinde önemli bir dönüşüm yaşanmış ve Otomatik Çağrı Dağıtıcı (Automatic Call Distributor - ACD) sistemleri geliştirilmiştir. Bu sistemler, gelen çağrıları otomatik olarak uygun temsilcilere yönlendirme yeteneğine sahipti (Harvey, Hogan, ve Payseur, 1991). Aynı dönemde, İnteraktif Sesli Yanıt (Interactive Voice Response - IVR) teknolojisi de devreye girmiştir. IVR sistemleri, müşterilerin

belirli tuşlamalar yaparak kendilerine uygun hizmete yönlendirilmesine imkân tanımış ve bu sayede müşteri hizmetleri sürecini hızlandırarak verimliliği artırmıştır.

1990'ların sonlarına doğru internetin yaygınlaşmasıyla birlikte çağrı merkezleri, e-posta ve web tabanlı sohbet destek hizmetleri sunmaya başlamıştır. Bu dönemde, Müşteri İlişkileri Yönetimi (CRM) yazılımları da kullanılmaya başlanmış olup, müşteri verilerinin daha etkin bir şekilde yönetilmesini ve analiz edilmesini sağlamıştır. İnternet ve e-posta iletişiminin entegrasyonu, müşteri hizmetleri süreçlerini genişletmiş ve çeşitlendirmiştir.

2000'lerden itibaren çağrı merkezleri, telefon ve e-posta dışında sosyal medya, SMS ve mobil uygulamalar gibi farklı iletişim kanallarını da entegre etmeye başlamıştır. Bu gelişme, müşteri hizmetlerinin her yerden ve her cihazdan erişilebilir olmasını sağlamıştır. Şirketler sosyal medya platformları üzerinden müşterileriyle etkileşime geçmeye ve destek sunmaya başlamış, böylece müşteri etkileşimleri daha dinamik ve çeşitli hale gelmiştir.

Son yıllarda, 2010'ların başından itibaren bulut teknolojileri çağrı merkezlerinin esnekliğini ve ölçeklenebilirliğini önemli ölçüde artırmıştır. Bulut tabanlı çağrı merkezleri, coğrafi bağımsızlık ve düşük maliyet avantajları sunmuştur. Aynı zamanda yapay zeka (AI) ve makine öğrenimi teknolojileri de müşteri hizmetlerinde otomasyonu mümkün kılmıştır. Chatbotlar ve sanal asistanlar, müşteri taleplerini hızlı ve verimli bir şekilde karşılamaya başlamış ve gelişmiş veri analitiği sayesinde müşteri davranışlarını analiz ederek daha kişiselleştirilmiş ve proaktif hizmet sunulmuştur.

1.2.2 Gelen ve Giden Çağrılar

Çağrı merkezleri, sağladıkları işlevler bakımından büyük farklılıklar gösterebilir. Bu farklılıklar genellikle merkezlerin büyüklüğü, coğrafi dağılımı ve uzmanlık alanlarıyla ilişkilidir. Çağrı merkezlerinin çoğu, inbound veya outbound çağrılar konusunda uzmanlaşmıştır.

Inbound ve outbound çağrı merkezleri, farklı operasyonel odaklara sahip iki temel çağrı merkezi türüdür ve her biri belirli işlevlere hizmet etmek üzere yapılandırılmıştır.

Inbound çağrı merkezleri, müşterilerden gelen çağrılara odaklanır. Bu tür çağrı merkezleri, genellikle yardım, destek veya bilgi vermek amacıyla müşterilere hizmet vermek amacıyla donatılmıştır. Müşteri sorularını yanıtlamak, sorunları çözmek ve ürün ya da hizmetler hakkında destek sağlamak bu merkezlerin temel görevlerindendir. Inbound çağrı merkezleri, müşteri deneyimini iyileştirmek ve müşterilerin ihtiyaçlarına doğrudan yanıt vermek için tasarlanmıştır. Bu merkezlerde çalışan temsilciler, müşteri etkileşimlerini yönetme ve sorunları çözme konusundaki becerileri ile ön plandadır (Jansen ve Callaghan, 2014).

Öte yandan, outbound çağrı merkezleri müşterilere giden aramalar yapar ve genellikle satış, tele-pazarlama, anketler veya randevu planlama gibi faaliyetler için kullanılır. Bu merkezler, müşterilere proaktif olarak ulaşarak çeşitli hizmetler sunar ve şirketlerin pazar araştırması, yeni ürün tanıtımı veya müşteri ilişkilerini geliştirme gibi hedeflerine ulaşmalarına yardımcı olur. Outbound çağrı merkezleri, genellikle stratejik hedeflere ulaşmak için kullanılan veri tabanları ve müşteri segmentasyon yöntemleri ile yönetilir.

1.3 Çağrı Merkezi İş Yükü ve Performans Ölçütleri

Çağrı merkezleri, müşteri hizmetleri ve destek operasyonlarının kritik bir parçasıdır. Bu merkezlerde iş yükü yönetimi ve performans ölçütlerinin doğru bir şekilde belirlenmesi, müşteri memnuniyetini ve operasyonel verimliliği doğrudan etkiler. İş yükü, genellikle gelen çağrı sayısı, çağrı başına geçen süre ve çözüm süresi gibi faktörlerle ölçülür. Performans ölçütleri ise, çağrı çözüm oranı, müşteri memnuniyeti anketleri ve servis seviyesi anlaşmaları (SLA) uyumu gibi kriterlere dayanır (Koole ve Li, 2023).

Çağrı merkezi performansının temel ölçütlerinden biri olan Ortalama Çözüm Süresi (Average Handling Time - AHT), bir müşteri çağrısının başlangıcından sonuna kadar geçen toplam süreyi ifade eder. Bu ölçüt, çağrı süresi, bekleme süresi ve sonrasındaki işlem süresini içerir. Düşük AHT değerleri genellikle yüksek verimlilikle ilişkilendirilirken, çok düşük AHT değerleri müşteri memnuniyetini olumsuz etkileyebilir, çünkü bu durum yeterince bilgi verilmediği veya sorunun tam olarak çözülmediği anlamına gelebilir.

Bir diğerk önemli ölçüt olan İlk Çağrıda Çözüm Oranı (First Call Resolution - FCR), müşterilerin sorunlarının ilk aramada çözölme yüzdesini gösterir. Yüksek FCR oranları, müşteri memnuniyetini artırır ve iş yükünü azaltır, çünkü müşterilerin sorunları tekrar aramalarını gerektirmez. Ayrıca, FCR, çağrı merkezi çalışanlarının yetkinliğinin ve eğitiminin bir göstergesi olarak da kullanılabilir.

Çağrı Abandon Oranı (Call Abandon Rate - CAR), müşterilerin bekleme süresinden dolayı çağrıyı bırakma oranını ifade eder. Yüksek CAR değerleri, yetersiz personel veya kaynakların bir işareti olabilir ve müşteri memnuniyetini olumsuz etkileyebilir. Bu nedenle, çağrı merkezleri genellikle CAR'ı düşük tutmak için personel planlamasına önem verir.

Servis seviyesi (Service Level - SL), çağrı merkezlerinin belirli bir zaman diliminde, belirli bir yüzdelikte çağrıya yanıt verme performansını ölçen bir ölçüttür. Genellikle *Gelen çağrıların %X'ini Y saniye içerisinde yanıt verme* olarak ifade edilir. Örneğin, *Gelen çağrıların %80'ini 20 saniye içerisinde yanıt verme* yaygın bir servis seviyesi hedefidir (van de Laar, 2007).

Servis seviyesi, çağrı merkezi yazılımları ve performans izleme araçlarıyla düzenli olarak izlenir (Brown vd., 2005). Bu ölçümler, çağrı merkezi yönetiminin verimliliği artırmak ve müşteri memnuniyetini sağlamak için kritik öneme sahiptir. Servis seviyesine ait formül Denklem 1.1'de verilmiştir.

$$Servis Seviyesi = \frac{Hedeflenen süre içerisinde karşılanan çağrı adedi}{Toplam gelen çağrı adedi} \quad (1.1)$$

Performans ölçütlerinin etkin bir şekilde kullanılması, çağrı merkezi operasyonlarının sürekli iyileştirilmesine olanak tanır. İş yükü analizi ve performans ölçütlerinin düzenli olarak gözden geçirilmesi, müşteri hizmetlerinin kalitesini artırırken operasyonel maliyetleri optimize etmeye yardımcı olur. Çağrı merkezi iş yükü ve performans ölçütleri, müşteri memnuniyetini ve işletme başarısını artırmak için önemli bir rol oynar.

1.4 Çağrı Merkezinde Çalışanların İş Yükü ve Performans İlişkileri

Çalışanlar genellikle ağır iş yükünden, motivasyon ve performansın azalması sonucu orta ve uzun vadede tükenmişlik gibi olumsuz tepkilerden şikayetçidir. İş yükünün başlıca etkileri stres ve tükenmişliktir. İş yükü arttıkça çalışanların tükenmişlik eğilimlerinin de arttığı görülmektedir (Keser, 2006).

Günümüzün iş ortamında çalışanların performansı bir kuruluşun başarısı açısından oldukça kritik bir role sahiptir. Araştırmalar, organizasyonlardaki çeşitli bağlamsal ve davranışsal faktörlerin çalışan performansı üzerinde önemli bir etkiye sahip olduğunu göstermektedir. Bu faktörlerin en önemlilerinden biri strestir. Çalışanların, meslektaşları ve müşteriler ile olan ilişkilerinin bir stres kaynağı olduğunu gözlemlenmektedir. Diğer bir stres kaynağı ise iş yükü olarak yer almaktadır.

Çağrı merkezleri için belirlenen yasal gereklilikler, hizmet kalitesini standartlaştırmak ve müşteri memnuniyetini sağlamak amacıyla önemli bir rol oynamaktadır. Türkiye'deki çağrı merkezleri için özellikle Bilgi Teknolojileri Kurumu tarafından belirlenen bazı düzenlemeler bulunmaktadır. Bu düzenlemelerden biri, gelen çağrılarının %80'inin 20 saniye içinde cevaplanması kuralıdır. Bu hedef, çağrı merkezlerinin operasyonel verimliliğini artırma ve müşteri hizmetlerindeki etkinliği maksimize etme çabası içinde olduklarını göstermektedir. Kurumlar, bu hedeflere ulaşmak için gerekli olan müşteri temsilcisi sayısını ve iş yüklerini hesaplamakta, operasyonel verimlilik için %75-%80 seviyelerinde bir performans hedeflemektedirler. Ancak %80'in üzerindeki bir operasyonel verimlilik, daha az sayıda müşteri temsilcisi ile çalışılabileceğini ve bu durumun kurum maliyetlerini düşürse de hizmet kalitesi hedeflerine ulaşmayı riske atabileceğini göstermektedir. Diğer taraftan, %75'in altındaki bir operasyonel verimlilik, gereğinden fazla müşteri temsilcisi ile çalışılmasını gerektirir ki bu da kurum maliyetlerinin artmasına yol açar. Bu yasal gereklilikler, çağrı merkezlerinin hem maliyet hem de hizmet kalitesi açısından dengeli bir operasyonel strateji geliştirmelerini zorunlu kılmaktadır (Kaya ve Deniz, 2021).

1.5 Çağrı Merkezi İş Yüğü Analizinin Rolü

Çağrı merkezleri, kurumlar için kritik öneme sahip iletişim birimleridir. Müşteri talepleri, geri bildirimleri, önerileri ve şikayetleri gibi konularda hizmet veren bu merkezler, yöneticilerin erken karar almalarında tahmin yapmalarını gerektirir. Çağrı merkezi sistemlerindeki günlük, haftalık ve aylık raporlamalarda beklenen çağrı sayıları ve çağrı sürelerinin tahmini, bu nedenle büyük önem taşır (Ortakaya, 2019).

Çağrı merkezi iş yükü analizi, müşteri aramalarının hacmi, süresi ve doğası gibi çeşitli ölçütleri içerir. Bu ölçütler, çağrı merkezi operasyonlarının mevcut durumunu anlamak ve gelecekteki talepleri tahmin etmek için kullanılır. Analiz, çağrı merkezi çalışanlarının iş yükünü daha etkin bir şekilde yönetmelerine ve müşteri taleplerine daha hızlı ve doğru yanıtlar vermelerine olanak tanır. Ayrıca, iş yükü analizi, çağrı merkezi yöneticilerine, kaynakların daha etkin kullanılması ve operasyonel maliyetlerin düşürülmesi için stratejik planlama yapma imkanı sunar (Aldor-Noiman vd., 2009).

Ayrıca, iş yükü analizi, müşteri hizmetleri süreçlerinin daha verimli hale getirilmesi için gerekli olan veriye dayalı kararları destekler. Örneğin, analiz sonuçları, en yoğun çağrı saatlerini ve müşteri taleplerinin mevsimsel dalgalanmalarını gösterebilir. Bu bilgiler, personel planlaması ve kaynak tahsisinde kullanılabilir, böylece müşteri talepleri en etkili şekilde karşılanabilir.

Sonuç olarak, iş yükü analizi, çağrı merkezi operasyonlarının verimliliğini ve etkinliğini artırmak için gerekli bilgileri ve stratejileri sağlamaktadır.

1.6 Erlang C

Erlang C kuyruk teorisinde temel bir modeldir, özellikle görevlerin rastgele geldiği ve sınırlı sayıda personelden hizmet almayı gerektiren sistemleri analiz etmek için kullanışlıdır. Çoğunlukla çağrı merkezlerinde ve telekomünikasyonda, bekleme sürelerini en aza indirirken gelen çağrıları karşılamak için gerekli personel sayısını belirlemek için kullanılır. Erlang C, müşterilerin, müşteri temsilcilerine bağlanmadan önceki IVR sırasındaki çağrının terk edilme olasılığını hesaba katmamaktadır (Nag ve Helal, 2017).

Genel olarak, Erlang C modeli, özellikle müşteri bekleme sürelerini yönetmenin kritik olduğu ortamlarda, hizmet sistemlerini optimize etmek için kullanılan etkili bir yöntemdir.

A.K. Erlang tarafından 1917'de geliştirilen bu formül, birden fazla personelin bulunduğu bir kuyruk sisteminde gecikme olasılığını hesaplamak için kullanılır (van den Berg, 2005). Aşağıdaki varsayımlar kullanılmıştır:

- Varışların Poisson sürecini takip ettiği varsayılır.
- Hizmet süreleri üstel olarak dağıtılır.
- Sunucuların (aracıların) sayısı sabittir.

Tüm personellerin meşgul olması durumunda, müşteriler herhangi bir personelin müsait olmasını bekleyecektir.

Formül Denklem 1.2'deki gibi ifade edilmektedir.

$$P(W > 0) = \frac{\frac{A^N}{N!} \times \frac{N}{N-A}}{\sum_{k=0}^N \frac{A^k}{k!} + \frac{A^N}{N!} \times \frac{N}{N-A}} \quad (1.2)$$

Burada, A iş yükünü, N personel sayısını, W bekleme süresini ifade etmektedir. $P(W>0)$, gelen bir müşterinin hizmet için beklemek zorunda kalma olasılığını verir.

Çağrı merkezi yöneticileri için, gelen çağrı sayıları ve ortalama çağrı süresi tahminleri, kaynakların daha etkin yönetilmesi, personel planlaması, hizmet kalitesinin artırılması ve müşteri memnuniyetinin sağlanması açısından kritik öneme sahiptir. Bu çalışmada, Yapay Sinir Ağları (YSA) yöntemini kullanarak çağrı merkezi iş yükünün tahmin edilmesi, elde edilen iş yükü tahmini ile ihtiyaç duyulan personel sayısının Erlang C ile elde edilmesi hedeflenmektedir.

BÖLÜM İKİ

YAPAY SİNİR AĞLARI

YSA, biyolojik sinir sistemlerinin bilgi işleme yöntemlerinden esinlenerek geliştirilmiş matematiksel bir modeldir. Bu modelde bilgi, bir dizi bağlı, basit ve doğrusal olmayan yapay nöronlardan geçirilerek işlenir. Her bir bağlantı, giriş sinyalinin gücünü ayarlayan ve öğrenme süreci boyunca değiştirilebilen ağırlıklara ve yanlılıklara sahiptir. YSA'lar, hesaplamayı bir dizi bağlı yapay nöron aracılığıyla gerçekleştiren ve ileri beslemeli çok katmanlı algılayıcı gibi mimariler kullanan yapılar olarak bilinir (Emmert-Streib vd., 2020).

İlk YSA, 1943 yılında McCullough ve Pitts tarafından önerilmiştir. Bu model, basit birimlerin ikili bir şekilde aktive olduğu ve çıktılarının, girdilerin ağırlıklı toplamalarının belirli bir eşiğin üzerinde olup olmadığına göre hesaplandığı bir yapıyı temel alıyordu (Wang ve Raj, 2015). Ancak, bu temel model, biyolojik nöronların ateşleme hızları gibi karmaşık özellikleri açıklamakta yetersiz kalmıştır. Bunun sonucunda, 1958 yılında Rosenblatt, ağırlıkları basit gradyan inişiyle öğrenebilen ve böylece daha karmaşık problemlerin modellenmesini mümkün kılan Perceptron adında bir yapay nöron önerdi. McCullough-Pitts modelinin basit nöronları, $[0, 1]$ aralığında sürekli çıkış değerlerine sahip daha gelişmiş modellerle değiştirildi. Perceptron, ikili örüntülere sahip ilişkisel bellek birimlerinin ağlar aracılığıyla nasıl öğrenebileceğini açıkça göstermiştir.


Bu temel fikir, kısa süre içinde genişletilerek, basit aktivasyon fonksiyonlarına sahip çok katmanlı algılayıcıların genellikle adım fonksiyonlarına sahip algılayıcılardan daha fazla ifade gücüne sahip olduğu bulunmuştur. Bu genişletme, iki boyutlu bir nesnenin yüksek boyutlu bir uzayda bir çizgiye veya noktaya dönüştürülebileceği ve daha detaylı modellere dönüştürülebileceği önerisini ortaya koymuştur. Biyolojik sinir ağlarından esinlenerek, bir aktivasyon modelinin bağlantılar boyunca ilerleyebileceği ve ağırlık bir bölümündeki ateşleme oranlarındaki değişikliklerin diğer bölümleri etkileyebileceği Tekrarlayan Sinir Ağları tasarlanmıştır.

1980'lerin sonlarına gelindiğinde, çok katmanlı algılayıcılarda ağırlıkları öğrenmek için geliştirilen geri yayılım (backpropagation) algoritması, bu tür ağlarda yeniden keşfedilmiştir. Sigmoid aktivasyon fonksiyonlarına ve uygun bir ağırlık ayarlama stratejisine sahip ağların, ifade gücü, karmaşıklık ve yakınsama açısından iyi bir denge sağladığı ve karmaşık problemleri etkili bir şekilde çözebildiği bulunmuştur. Bu bulgular, YSA'nın karmaşık verileri işleme yeteneğini önemli ölçüde artırmıştır.

Bir sinir ağının temel işlem elemanı bir nörondur. İnsan bilincinin bu yapı taşı bazı genel yetenekleri kapsar. Temel olarak, biyolojik bir nöron diğer kaynaklardan girdiler alır, bunları bir şekilde birleştirir, sonuç üzerinde genellikle doğrusal olmayan bir işlem gerçekleştirir ve ardından nihai sonucu çıktı olarak verir (Anderson ve McNeill, 1992).

Yapay Sinir Ağları (YSA), doğal sinir ağlarını taklit eden matematiksel model ağlardır. Bu ağlar, veri işleme ve öğrenme yetenekleriyle bilinir. Sinir ağları, sinir hücrelerinden (nöron) ve bunların birbirine bağlantılarından oluşur. Bu yapay nöronlar bilgisayar programları üzerinde analiz, tanıma, tahmin gibi görevleri gerçekleştirebilir. YSA, karmaşık işlemleri yüksek performanslı bir şekilde gerçekleştirebilir ve bu özellikleriyle geniş bir uygulama alanına sahiptir (Yegnanarayana, 2009).

YSA, diğer istatistiksel yöntemlere karşılık bir varsayıma gerek duymamaktadır. YSA'nın en önemli özelliği ve sorumluluğu, veri içerisindeki yapıyı öğrenmek ve istenilenlere göre genelleştirmeler yapması durumudur.



Şekil 2.1 Yapay sinir ağları yapısı (Öztemel, 2003)

Şekil 2.1’de YSA’nın hücre yapısı yer almaktadır. İleri beslemeli YSA, basit bağlantılar ve uyarlanabilir elemanlardan oluşan bir yapıdır. Her bir bağlantı, öğrenme süreci boyunca ayarlanabilen bir ağırlığa sahiptir. Bu ağırlıklar, yapay nöronların girdileri toplamasına ve doğrusal olmayan bir aktivasyon fonksiyonu uygulayarak çıktıyı hesaplamasına olanak tanır. Nöron tarafından hesaplanan çıktı, bir sonraki katmandaki elemanlara iletilir.

Bu ağlarda iki ana katman türü bulunur: giriş katmanı, gizli katman(lar) ve çıkış katmanları. Giriş katmanı, modelin aldığı veri özelliklerinin değerlerini alır. Gizli ve çıkış katmanları ise, giriş verilerinden işlenmiş bilgiyi alır ve bu bilgiyi işler.

Başlangıçta ağırlıklar ve yanlılıklar genellikle rastgele atanır. Eğitim süreci sırasında, bu ağırlıklar ve yanlılıklar, ağın çıktısındaki hatayı minimize edecek şekilde güncellenir. Bu süreçte hata monoton olarak azalır ve bu, modelin farklı çıktı sınıflarını daha iyi ayırt etmeye başladığını gösterir. Eğitim tamamlandığında, sinir ağı, yeni verileri sınıflandırmak üzere kullanılabilir. Bu süreç, sinir ağlarının verileri öğrenme ve sınıflandırma yeteneğini etkin bir şekilde geliştirmektedir.

2.1 Nöron Yapısı ve İşlevi

Her yapay sinir ağının temel yapı taşı nörondur. Bir nöron, bazı girdi bilgilerini alan, bunları işleyen ve çıktı olarak bilgi sağlayan matematiksel olarak güdümlenmiş bir fonksiyon olarak tanımlanabilir. Burada, daha önce sunulan biyolojik nöron ve yapay nöron kavramlarının arkasındaki genel fikir oldukça benzerdir. Biyolojik nöronlar insan beyninde elektrokimyasal darbeleri alan, bunları işleyen ve diğer nöronlara daha fazla sinyal darbesi yayan yapılar iken, yapay nöronlar girdileri alır, matematiksel bir fonksiyon kullanarak bunları işler ve çıktı sinyallerini diğer nöronlara yayar (Gustineli, 2022).


Bireysel nöronlar, katmanlar oluşturacak şekilde bağlanır. Bir katmanın bir nöronu genellikle bir önceki ve bir sonraki katmanın her nöronuna bağlanır. YSA’ların katmanları şu anda üç kategoriye ayrılmıştır: giriş, gizli ve çıkış katmanları. Giriş katmanı, sinir ağına beslenen giriş değerlerini temsil eder. Giriş katmanındaki her nöron bir giriş değerini temsil eder. Dolayısıyla, gizli katmandaki veya çıktı katmanındaki her nöronun girdisi, sinir ağının girdisiyle aynıdır. Gizli

katman, girdi ve çıktı arasındaki nöronları temsil eder; burada her nöron, girdilerden veya çıktıdan doğrudan erişilemeyen bilgileri temsil eder. Çıktı katmanı, sinir ağı kararının çıktı değerlerini temsil eder. Çıktı katmanındaki nöron sayısı genellikle çözülmekte olan görevin türüne bağlıdır (Epelbaum, 2017).

2.2 Aktivasyon Fonksiyonları

Aktivasyon fonksiyonları, YSA'ların temel bir yönüdür ve doğru şekilde çalışmalarını sağlamada önemli bir rol oynar. Daha spesifik olarak, aktivasyon fonksiyonları ağı doğrusal olmayan bir özellik katar ve bu da gelen veri akışlarının çoğu karmaşık olduğu için kritik önem taşır. Doğrusal olmama, ağı bu tür karmaşıklıkları öğrenmesini ve modellemesini sağlar ve bu nedenle YSA'ların en önemli özelliklerinden biridir (Godfrey, 2018). Aktivasyon fonksiyonunun seçimi genellikle ağı mimarisine bağlıdır. Çokça kullanılan bazı aktivasyon fonksiyonları Sigmoid fonksiyonu, Hiperbolik tanjant (tanh) fonksiyonu, Doğrultulmuş doğrusal birim (Rectified Linear Unit - ReLU) fonksiyonudur.

Sigmoid fonksiyonları, YSA'larda kullanılan en eski aktivasyon fonksiyonlarından biridir. Sigmoid fonksiyonu lojistik bir aktivasyon fonksiyonudur. Sigmoid fonksiyonun grafiği Şekil 2.2'de yer almaktadır.




Şekil 2.2 Sigmoid fonksiyonu

Sigmoid aktivasyon fonksiyonu, çıkış değerlerini 0 ile 1 arasında sınırlayan bir fonksiyondur. Bu özellik, türevinin basitçe hesaplanabilmesi sayesinde sigmoid aktivasyon fonksiyonuna önemli bir avantaj sağlar. Ancak, sigmoid fonksiyonunun bu özellikleri bazı dezavantajları da beraberinde getirir. Özellikle, sigmoid fonksiyonunun çıkış aralığı, gradyan değerlerinin (yani türevlerinin) küçük olmasına yol açar. Bu durum, ağırlıkların etkili bir şekilde güncellenmesini kısıtlayabilmektedir.

Ayrıca, ağırlıklı toplamın aşırı şekilde büyümesi veya küçülmesi durumunda, sigmoid fonksiyonu gradyan kaybı sorununa maruz kalabilir. Bu problem, özellikle derin sinir ağlarında, öğrenme sürecini zorlaştırabilir ve dolayısıyla sigmoid fonksiyonunu daha az uygun hale getirebilmektedir (Gustineli, 2022).

Tanh fonksiyonu, genellikle sigmoid fonksiyonundan daha iyi eğitim performansı sağladığı için daha popüler hale gelmiştir. Tanh fonksiyonunun sıfır merkezli olması, modelin eğitim sürecinde gereken epoch sayısını azaltabilmektedir. Bu, öğrenme sürecini hızlandırarak genel eğitim verimliliğini artırır. Tanh fonksiyonun grafiği Şekil 2.3'te yer almaktadır.




Şekil 2.3 Tanh fonksiyonu

Tanh fonksiyonu, çıkış değerlerini -1 ile 1 arasında sınırlayan bir aktivasyon fonksiyonudur. Ancak, tanh fonksiyonunun da sigmoid fonksiyonunda olduğu gibi

gradyan kaybı sorunuyla karşılaşma ihtimali bulunmaktadır.

ReLU fonksiyonu, en yaygın kullanılan aktivasyon fonksiyonlarından biridir. ReLU aktivasyon fonksiyonu, çok basit bir matematiksel ifadeye sahiptir ve genellikle öğrenme sürecinde daha etkili sonuçlar vermektedir.



Şekil 2.4 ReLU fonksiyonu

Şekil 2.4'teki grafikte de görüleceği üzere ReLU fonksiyonu, giriş değeri sıfırdan küçük veya eşitse çıkış değeri sıfır olur, giriş değerleri sıfırdan büyük ise çıkış değeri girdi değerine eşit olur. Bu özellik, ReLU fonksiyonunu sıfır merkezli hale getirir ve böylece gradyan kaybı sorununu azalmaktadır. Ayrıca, ReLU'nun hesaplama maliyeti düşüktür ve üstel işlevler içermediği için, sınır ağları için etkili bir aktivasyon fonksiyonu olarak öne çıkar.

Ancak, ReLU fonksiyonunun da bazı dezavantajları vardır. Örneğin, büyük negatif başlangıç ağırlıkları durumunda, ReLU fonksiyonu yeterince etkili olamayabilir ve nöronların çoğunun sürekli olarak sıfır çıktı verdiği *ölmüş ReLU* problemlerine yol açabilir. Bu sorunlar, ağırlıkların uygun şekilde başlangıç değerlerinin seçilmesini ve eğitim sırasında dikkat edilmesi gerekir.

2.3 Geri Yayılım Algoritması

Geri Yayılım, YSA'ları eğitmek için kullanılan denetimli bir öğrenme

algoritmasıdır. Geri yayılımın amacı, Ortalama Hata Karelerinin (MSE) kaybını en aza indirmek için ileri besleme sırasında üretilen hataya dayalı olarak ağırlıkların ve yanlılıklarını güncelleme işlemidir (Boué, 2018).

Modelin çıkış nöronundan elde edilen tahmin, gerçek değerle karşılaştırıldığında bir hata hesaplanır. Bu hata, modelin çıktısından girişlerine doğru geriye doğru yayılır. Bu işlem sırasında, her ağırlığın ve yanlılığın hata üzerindeki etkisi hesaplanır. Bu işlem fonksiyonunun her ağırlığa ve yanlılığa göre türevleri belirlenir.

Geri yayılım sırasında hesaplanan türevler, her bir ağırlığı ve yanlılığı, belirli bir öğrenme oranı kullanarak güncellemek için kullanılır. Öğrenme oranı, ağırlıkların ne kadar değiştirileceğini belirler ve bu şekilde ağırlıklar sürekli olarak iyileştirilir. Bu süreç, ağırlık tahminlerinin zamanla daha doğru hale gelmesi için tekrar tekrar yapılır. Sonuç olarak, geri yayılım, sinir ağlarının öğrenmesini sağlayarak daha iyi performans göstermesine yardımcı olmaktadır (Avrutskiy, 2017).

2.4 Derin Yapay Sinir Ağları

Derin öğrenme, beynimizin çalışma şekline ilham alan güçlü bir veri işleme yöntemidir. Amacı, birçok işlem katmanını üst üste koyarak modeller oluşturmaktır. Bu işlem katmanlarının her biri farklı temsil seviyeleri çıkarır ve tüm bu katmanları birbirine bağlayarak derin modeller hem girdiler ile istenilen çıktılar arasında verimli dönüşümler öğrenebilir. Bu uygulamalar görüntü analizi ve tanıma, zaman serisi veya sıralı veri tahmini, karmaşık fiziksel sistemlerin modellenmesi gibi modelleri içerir. Derin öğrenme teknikleri üç farklı kategoriye ayrılabilir: YSA, evrişimli sinir ağları ve tekrarlayan sinir ağları (Wang ve Raj, 2015).


Evrişimli sinir ağı (ESA), evrişim ve havuzlama katmanları içeren hiyerarşik bir yapıdır. ESA'lar, girdilerle filtrelerin evrimi yoluyla uzamsal korelasyonları verimli bir şekilde yakalayabilir, bu da giderek daha karmaşık özelliklerin otomatik olarak çıkarılmasına olanak tanır. Evrişim ve havuzlama işlemlerinden elde edilen sonuçlar, doğrusal olmayan aktivasyon fonksiyonlarından geçirilir. Yeterli hiyerarşik seviyelere ulaşıldığında, evrişimli katmanlardan gelen veriler düzleştirilir ve ardından ileri beslemeli çok katmanlı algılayıcılara yönlendirilir. ESA'lar genellikle iki boyutlu

görüntü verilerini işlemek için tasarlanmış olmakla birlikte, tek boyutlu verilere de başarılı bir şekilde uygulanabilir.

Öte yandan, Tekrarlayan Sinir Ağları (TSA), sıralı verilerin işlenmesi için uygundur. Bir TSA, hem ileri hem de geri besleme yönlerinde bağlantılara sahip bir ağ yapısıdır. Basit bir TSA'da, gizli katmandaki düğümler, mevcut zaman adımındaki girdileri ve önceki zaman adımındaki kendi faaliyetlerini dikkate alır. TSA'ların eğitimi, belirli bir zamandaki gerçek değerlerin sıralı olarak ağa beslenmesiyle yapılır. Sıralı görevlerde sıra uzunluğunun sabit olduğu basit örnekler genellikle kullanılır. Bununla birlikte, TSA'nın en yaygın türü olan Uzun Kısa Süreli Bellek (UKSB), değişken uzunluktaki girdilere sahip birçok probleme başarılı bir şekilde uygulanabilir. Bu sayede zaman serileri gibi sıralı veriler modellenenirler.

2.4.1 Evrişimli Sinir Ağları

Evrişimli Sinir Ağları (ESA), evrişim ve havuzlama katmanlarından oluşan bir yapay sinir ağı türüdür. Tam bağlantılı sinir ağlarının aksine, ESA'lar nöronlar arasındaki yerel bağlantı desenlerini kullanarak özelliklerin mekansal hiyerarşilerini yakalar. Bu özellik, ESA'ların görüntü sınıflandırma, nesne konumlandırma ve segmentasyon gibi bilgisayarla görüntüleme görevlerinde büyük başarılarla imza atmasını sağlamıştır. Son yıllarda, bu modeller çeşitli Doğal Dil İşleme (NLP) görevlerine de uyarlanmıştır; metin sınıflandırma, duygu analizi, cümle modelleme ve hedefe yönelik duygu analizi gibi alanlarda başarılı sonuçlar elde edilmiştir. Bir boyutlu filtreler kullanarak, ESA'lar kelimelerin yerel düzenlerini etkili bir şekilde yakalayabilir, bu da onların bu görevlerde umut verici performans sergilemelerine olanak tanımaktadır (Gong ve Ji, 2018).




Şekil 2.5 Evrişimli sinir ağı

Şekil 2.5'te ESA modelinin matris boyutundan vektör boyutuna evrildiği gözlemlenebilmektedir. Tipik bir ESA modeli, üç temel katmandan oluşur: evrişim katmanı, havuzlama katmanı ve tam bağlantılı katman. Girdi, genellikle 3 boyutlu bir matrisle temsil edilen n boyutlu bir sinyaldir. Her katman, gelen sinyali bir koordinat sisteminden diğerine dönüştürür. Örneğin, standart bir konfigürasyonda bir giriş görüntüsünün çeşitli katmanlardan geçişi gözlemlenebilir. İlk katmanda, görüntü RGB renk koordinat sisteminden gri tonlama koordinat sistemine dönüştürülür. Ardından, ayrık kosinüs dönüşümünden (DCT) sonra DCT katsayıları koordinat sistemine, renkleri gri tonlamaya dönüştürmeden sonra ise dalga boyu koordinat sistemine dönüşür. Bu süreçte, ESA ve TSA'nın işleme adımları genellikle şöyle sıralanır: paylaşılan ağırlık katmanı, ardından nokta bazlı doğrusal olmayan katmanı ve son olarak bir alt örnekleme alt katmanı, bu adımlar birkaç kez tekrar edilebilir. Bu yapı, verinin farklı katmanlarda işlenmesini ve özelliklerinin hiyerarşik olarak çıkarılmasını sağlar.

2.4.2 Tekrarlayan Sinir Ağları

Tekrarlayan Sinir Ağları (TSA), sıralı bağımlılıkları ve zamansal davranışları modellemek için kullanılan derin sinir ağı sınıfına aittir. Bu ağlar, özellikle dil modelleme ve makine çevirisi gibi görevlerde büyük öneme sahiptir. Bunun nedeni,

TSA'ların deęiřken uzunluktaki giriř dizilerini iřleme yeteneęi saęlaması ve dizilerdeki verilerin uzun vadeli baęımlılıklarını öğrenebilmesidir (Yin, Kann, Yu, ve Schütze, 2017). TSA'lar, ileri beslemeli sinir aęlarının mimarisini takip eder ve bir giriř katmanı, bir veya daha fazla gizli katman ve bir çıkıř katmanı ierir. Geleneksel ileri beslemeli sinir aęlarında gizli katman yalnızca bir önceki katmandan gelen giriřleri alır. Buna karřın, TSA'ların gizli katmanı, sadece bir önceki katmandan deęil, aynı katmandan bir önceki zaman adımından da giriř alır. oktan-ok yapısında, TSA her zaman adımında bir çıkıř üretebilir ve tahminleri paralel olarak gerekleřtirebilir. Örneęin, verilen giriř kelime dizilerine karřılık olarak, TSA çıkıř kelime dizilerini üretebilir (Lipton vd., 2015).



řekil 2.6 Tekrarlayan sinir aęları (Yılmaz, 2023)

řekil 2.6'da x_t olarak gösterilen zaman adımındaki girdi verisi, hücre iinde bir aęırlık matrisi U ile arpılarak iřlenir. Bu iřlenmiř veri, bir aktivasyon fonksiyonu olan $\tanh$ ile nöronlar arası baęlantılara uygulanır. Bu aktivasyon fonksiyonu, aędaki nöronların ıktısını sınırlamak ve doęrusal olmayanları eklemek iin kullanılmaktadır.

Aktivasyon fonksiyonundan ıkan deęer, hücre ıktısı h_t ve hücredeki bařka bir aęırlık matrisi olan V ile birleřtirilir. Bu süreç, mevcut zaman adımındaki ıktı olan

o_t değerini üretir. Aynı zamanda bu çıktı, bir sonraki zaman adımına aktarılacak olan yeni gizli durum h_t olarak da görev yapar. Bu yapı, TSA'nın her bir zaman adımında önceki zaman adımlarının bilgisini nasıl taşıdığını ve işlediğini göstermektedir.


Ayrıca, TSA'nın karakteristik bir özelliği olarak, bu hücre yapısında ağırlıklar W , U ve V zamanla öğrenilir ve bu sayede ağ, zaman serisi verilerini daha etkili bir şekilde modellenebilmektedir. Şekil 2.6'daki yapı, TSA'ların dizisel verilerdeki karmaşık ilişkileri nasıl öğrendiğini ve zaman içindeki bağımlılıkları nasıl koruduğunu açıklamaktadır. Bu nedenle, TSA'lar özellikle dil modelleme, konuşma tanıma ve zaman serisi analizi gibi uygulamalarda yaygın olarak kullanılmaktadır.

Öte yandan YSA ile uzun diziler üzerinde çalışırken karşılaşılan temel bir sınırlama, bu ağların kısa süreli bellek özelliklerinden kaynaklanır. Bu sınırlama, çıkış sinyalinin birçok katmandan geçerken bozulmasına neden olur. TSA'lar, ardışık veri üzerinde herhangi bir uzunlukta işlem yapabilme kapasitesine sahip olsalar da, uzun vadeli bağımlılıkları işlemek söz konusu olduğunda bu yetenekleri sınırlıdır. Özellikle, uzun diziler 1000 kelimayı aştığında, geri yayılım sürecinde ortaya çıkan gradyanlar ya patlama ya da kaybolma eğilimindedir. Bu sorunu çözmek için Uzun Kısa Süreli Bellek (UKSB) mimarisi geliştirilmiştir. UKSB'ler, standart doğal dil işleme görevlerinde (Cherian vd., 2018) değerlendirilmiş ve bu görevlerde oldukça etkili bulunmuştur. Basitçe söylemek gerekirse, UKSB mimarisi birkaç yüz verinin ötesinde bağlam öğrenme yeteneğine sahiptir ve aynı anda birden fazla bellek sinyalini dinamik olarak koruyabilir.

2.4.3 Uzun Kısa Süreli Bellek Sinir Ağları

Uzun Kısa Süreli Bellek Sinir Ağları (UKSB), 1997 yılında Sepp Hochreiter ve Jürgen Schmidhuber tarafından geliştirilen bir tür TSA mimarisidir. UKSB, standart TSA'ların uzun vadeli bağımlılıkları modelleme konusundaki eksikliklerini gidermek amacıyla tasarlanmıştır. Bu mimari, her biri üç kapı içeren UKSB hücrelerinden oluşur: bir giriş kapısı, bir unutma kapısı ve bir çıkış kapısı. Bu kapılar, bir bellek hücresi ile birlikte çalışarak bilginin akışını kontrol eder. Giriş kapısı, mevcut girdinin ne kadarının bellek hücresinde saklanacağını belirlerken, unutma kapısı bellek hücresinden ne kadar bilginin çıkarılacağını belirler. Çıkış kapısı ise

bellek hücresindeki bilginin bir sonraki katmana veya UKSB hücresine ne kadarının aktarılacağına karar verir (Cherian vd., 2018). Bu kapılar, eğitim süreci boyunca değiştirilen ağırlıklarla kontrol edilir.



Şekil 2.7 Uzun kısa süreli bellek sinir ağı (Yılmaz, 2023)

Şekil 2.7’de, UKSB hücresinin iç yapısını ve akışını göstermektedir. Bu modelde, önceki hücre durumu c_{t-1} ve önceki gizli durum h_{t-1} ile birlikte mevcut giriş x_t kullanılarak, yeni hücre durumu c_t ve gizli durum h_t hesaplanmaktadır.

Diyagramda üç ana kapı mekanizması gösterilmiştir: Unutma kapısı (f_t), giriş kapısı (i_t), ve çıkış kapısı (o_t). Unutma kapısı, önceki hücre durumunun hangi kısmının korunacağını belirlemektedir. Bu işlem, sigmoid fonksiyonu (σ) ile gerçekleştirilir ve sonuç, c_{t-1} ile çarpılır. Giriş kapısı, hangi yeni bilginin hücre durumuna ekleneceğini belirler ve yine sigmoid fonksiyonu ile hesaplanmaktadır. Hücre durumu, $\tanh$ ile elde edilen yeni bilgi ile güncellenir. Son olarak, çıkış kapısı, güncel hücre durumu c_t ve çıkış olarak kullanılacak gizli durum h_t arasında bir bağlantı kurmaktadır.

Bu yapı, özellikle uzun süreli bağımlılıkların bulunduğu veri dizilerinde geçmiş

bilgileri unutmadan yeni bilgilerle g ncellemeyi bařarmaktadır. UKSB'nin bu  zellikleri, modelin zaman i indeki bilgi akıřını nasıl kontrol ettiğini ve karmařık zaman serisi verilerinde nasıl etkili olduğunu a ık a ortaya koyar.

UKSB, uzun vadeli bağımlılıkları modellemek  zere tasarlanmıřtır ve belleęi koruyarak geleneksel TSA ile karřılařılan *unutma* problemlerini   zmede b y k bir avantaj saęlamaktadır. Geleneksel TSA'larda, gradyanların kaybolması veya patlaması gibi sorunlar yařanabilirken, UKSB bu t r problemleri  nleyerek uzun diziler  zerinde etkili bir  ęrenme s reci ger ekleřtirmektedir (Kent ve Salem, 2019).

Bu mimari, uzun vadeli bağımlılıkları modellemek i in gerekli olan uzun s reli hafızayı korur ve bilgi akıřını s rekli olarak g ncelleyerek, modelin ge miř bilgileri unutmadan mevcut verilerle etkileřimde bulunmasını saęlar. UKSB'nin bu avantajı,  zellikle karmařık ve uzun s reli veri dizilerinde performansı artırmakta ve modelin genel bařarısını  nemli  l  de iyileřtirmektedir.

BÖLÜM ÜÇ

UYGULAMA

3.1 Yöntem

Bu çalışmada, Python programlama dili kullanılarak ve Şekil 3.1'de gösterilen numpy, pandas, keras, tensorflow ve sklearn gibi kütüphanelerden yararlanılarak çeşitli yapay sinir ağları yöntemleri incelenmiştir. Bu yöntemler arasında YSA, ESA, TSA ve UKSB sinir ağları bulunmaktadır. Çalışmada, bir çağrı merkezinin yaklaşık 1 yıllık inbound verileri ile UKSB sinir ağları kullanılarak çağrı merkezinin yükü tahmin edilmiş ve bu tahmini yük değerleri ile Erlang C formülü uygulanarak ihtiyaç duyulan personel sayısı hesaplanmıştır. Ayrıca, yaklaşık bir yıllık gerçek veriler yapay olarak genişletilmiş ve aynı modelin bu genişletilmiş verilerdeki performansı incelenmiştir.

```
import pandas as pd
import numpy as np
from sklearn.preprocessing import MinMaxScaler
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import LSTM, Dense
from sklearn.metrics import mean_absolute_percentage_error, mean_squared_error, mean_absolute_error
import matplotlib.pyplot as plt
```

Şekil 3.1 Kullanılan Python kütüphaneleri

3.2 Veri

Veriler, Şekil 3.2’de görüldüğü gibi bir çağrı merkezinin bir yıllık tarih aralığındaki günlük olarak gelen çağrıların adetlerini, tarihleri, personel sayılarını ve çağrı merkezi ölçütlerini içeren değerlerden oluşmaktadır.

	DATE	NUMBER OF CALLS	NUMBER OF CALLS ANSWERABLE	NUMBER OF CALLS ANSWERED	NUMBER OF CALLS ABANDONED	NUMBER OF CALLS ROUTED TO CallBack IVR	NUMBER OF AGENTS	NUMBER OF CALLS ROUTED TO ANSWERING MACHINE	NUMBER OF CALLS DISSUADED	NUMBER OF CALLS ABANDONED BEFORE ENTERING IN QUEUE	...
0	2023-03-01	759	758	607	151	0	10	0	0	1	...
1	2023-03-02	913	911	642	269	0	11	0	0	2	...
2	2023-03-03	783	782	547	235	0	10	0	0	1	...
3	2023-03-04	306	306	183	123	0	3	0	0	0	...
4	2023-03-05	0	0	0	0	0	0	0	0	0	...
...	...	...	...	...	...	...	...	...	...	...	...
422	2024-04-26	445	445	445	0	0	21	0	0	0	...
423	2024-04-27	122	121	117	4	0	9	0	0	1	...
424	2024-04-28	0	0	0	0	0	0	0	0	0	...
425	2024-04-29	506	506	497	9	0	22	0	0	0	...
426	2024-04-30	405	405	399	6	0	20	0	0	0	...

427 rows x 29 columns

Şekil 3.2 Veriler

Şekil 3.2’de görüldüğü gibi, incelenen verilerde pazar günleri çağrı merkezinin kapalı olması nedeniyle sıfır değerlerin olduğu günler verilerden çıkarılmıştır. Bu düzenleme sonucunda veriler, 427 gözlem ve 29 değişkenden oluşmaktadır. Başlıca değişkenlerin anlamları aşağıdaki gibidir:

- **DATE:** Her veri satırına karşılık gelen tarihi,
- **NUMBER OF CALLS:** Günlük alınan toplam çağrı sayısını,
- **NUMBER OF CALLS ANSWERABLE:** Yanıtlanabilir çağrı sayısını,
- **NUMBER OF CALLS ANSWERED:** Yanıtlanan çağrı sayısını,
- **NUMBER OF CALLS ABANDONED:** Terk edilen çağrı sayısını,
- **NUMBER OF CALLS DISSUADED:** Görüşmeden vazgeçen müşterilerin çağrı sayısını,
- **NUMBER OF AGENTS:** Günlük çalıştırılan personel sayısını,
- **AVERAGE WAITING TIME:** Ortalama bekleme süresini (saniye),
- **AVERAGE TALKING TIME:** Ortalama çağrı süresini (saniye),
- **AVERAGE AFTER CALL WORK TIME:** Çağrı sonu ortalama işlem süresini (saniye),

- **NUMBER OF AVERAGE PUT ON HOLD:** Ortalama olarak bekletilen çağrı sayısını,
- **NUMBER OF PUT ON HOLD:** Bekletilen toplam çağrı sayısını,
- **TOTAL TALKING TIME:** Toplam çağrı süresini (saniye),
- **TOTAL HANDLING TIME:** Toplam işleme süresini (saniye),

ifade etmektedir.

DATE değişkeninin tarih-saat cinsine dönüştürülmesi ve dizin olarak ayarlanması sağlanmış, ardından veri türleri ve eksik değerler kontrol edilmiştir. İncelenen verilerde pazar günleri çağrı merkezinin kapalı olması nedeniyle sıfır değerlerin olduğu günler verilerden çıkarılmıştır. Bu düzenleme sonucunda, Şekil 3.3'te görüldüğü üzere, veriler 359 gözlem ve 28 değişkenden oluşan bir yapıya kavuşmuştur.

```

<class 'pandas.core.frame.DataFrame'>
DatetimeIndex: 359 entries, 2023-03-01 to 2024-04-30
Data columns (total 28 columns):
#   Column                                                                 Non-Null Count  Dtype
---  -
0   NUMBER OF CALLS                                                         359 non-null    int64
1   NUMBER OF CALLS ANSWERABLE                                              359 non-null    int64
2   NUMBER OF CALLS ANSWERED                                                359 non-null    int64
3   NUMBER OF CALLS ABANDONED                                               359 non-null    int64
4   NUMBER OF CALLS ROUTED TO CallBack IVR                                 359 non-null    int64
5   NUMBER OF AGENTS                                                         359 non-null    int64
6   NUMBER OF CALLS ROUTED TO ANSWERING MACHINE                           359 non-null    int64
7   NUMBER OF CALLS DISSUADED                                               359 non-null    int64
8   NUMBER OF CALLS ABANDONED BEFORE ENTERING IN QUEUE                    359 non-null    int64
9   NUMBER OF REJECTED BY THE SYSTEM                                       359 non-null    int64
10  NUMBER OF CALLS TRANSFERED TO EXTERN SERVICE BY IVR                   359 non-null    int64
11  NUMBER OF CALLS UNDEFINED                                               359 non-null    int64
12  RATE OF CALLS ANSWERED                                                  359 non-null    float64
13  RATE OF CALLS ABANDONED                                                 359 non-null    float64
14  AVERAGE RINGINT TIME                                                    359 non-null    int64
15  AVERAGE WAITING TIME                                                    359 non-null    float64
16  AVERAGE ABANDONED TIME                                                  359 non-null    float64
17  AVERAGE TALKING TIME                                                    359 non-null    float64
18  AVERAGE AFTER CALL WORK TIME                                            359 non-null    float64
19  NUMBER OF AVERAGE PUT ON HOLD                                           359 non-null    int64
20  AVERAGE PUT ON HOLD TIME                                                359 non-null    float64
21  AVERAGE PROCESSING TIME                                                 359 non-null    float64
22  TOTAL WAITING TIME IN QUEUE                                              359 non-null    float64
23  TOTAL TALKING TIME                                                       359 non-null    float64
24  TOTAL AFTER CALL WORK TIME                                               359 non-null    float64
25  NUMBER OF PUT ON HOLD                                                    359 non-null    int64
26  TOTAL ON HOLD TIME                                                       359 non-null    float64
27  TOTAL HANDLING TIME                                                      359 non-null    float64
dtypes: float64(13), int64(15)
memory usage: 81.3 KB
None

```


Şekil 3.3 Veri türleri

Şekil 3.4'teki tanımlayıcı istatistikler incelendiğinde, değişkenlerin ortalamaları, standart sapmaları, en küçük değerleri, çeyreklikleri ve en büyük değerleri elde edilmiştir.

	count	mean	std	min	25%	50%	75%	max
NUMBER OF CALLS	359.0	437.089136	222.557074	40.0	286.00	410.00	561.50	1494.0
NUMBER OF CALLS ANSWERABLE	359.0	436.676880	222.350763	40.0	285.50	410.00	561.00	1494.0
NUMBER OF CALLS ANSWERED	359.0	362.077994	148.129245	22.0	265.00	366.00	451.50	888.0
NUMBER OF CALLS ABANDONED	359.0	74.598886	145.034635	0.0	9.00	20.00	70.50	1338.0
NUMBER OF CALLS ROUTED TO CallBack IVR	359.0	0.000000	0.000000	0.0	0.00	0.00	0.00	0.0
NUMBER OF AGENTS	359.0	14.270195	4.458621	3.0	11.00	15.00	18.00	23.0
NUMBER OF CALLS ROUTED TO ANSWERING MACHINE	359.0	0.000000	0.000000	0.0	0.00	0.00	0.00	0.0
NUMBER OF CALLS DISSUADED	359.0	0.000000	0.000000	0.0	0.00	0.00	0.00	0.0
NUMBER OF CALLS ABANDONED BEFORE ENTERING IN QUEUE	359.0	0.412256	0.674736	0.0	0.00	0.00	1.00	5.0
NUMBER OF REJECTED BY THE SYSTEM	359.0	0.000000	0.000000	0.0	0.00	0.00	0.00	0.0
NUMBER OF CALLS TRANSFERED TO EXTERN SERVICE BY IVR	359.0	0.000000	0.000000	0.0	0.00	0.00	0.00	0.0
NUMBER OF CALLS UNDEFINED	359.0	0.000000	0.000000	0.0	0.00	0.00	0.00	0.0
RATE OF CALLS ANSWERED	359.0	0.874513	0.153736	0.1	0.83	0.94	0.97	1.0
RATE OF CALLS ABANDONED	359.0	0.125571	0.153798	0.0	0.03	0.06	0.17	0.9
AVERAGE RINGINT TIME	359.0	0.000000	0.000000	0.0	0.00	0.00	0.00	0.0
AVERAGE WAITING TIME	359.0	69.050139	64.449562	1.0	16.50	47.00	108.50	277.0
AVERAGE ABANDONED TIME	359.0	55.604457	106.765993	0.0	2.00	14.00	62.00	928.0
AVERAGE TALKING TIME	359.0	260.796657	50.062591	42.0	235.00	268.00	293.00	406.0
AVERAGE AFTER CALL WORK TIME	359.0	53.459610	26.643475	8.0	36.00	50.00	65.50	301.0
NUMBER OF AVERAGE PUT ON HOLD	359.0	0.000000	0.000000	0.0	0.00	0.00	0.00	0.0
AVERAGE PUT ON HOLD TIME	359.0	23.674095	15.640056	0.0	13.00	20.00	32.00	94.0
AVERAGE PROCESSING TIME	359.0	363.526462	49.387350	154.0	333.50	358.00	388.50	650.0
TOTAL WAITING TIME IN QUEUE	359.0	38788.481894	56095.354473	59.0	5645.00	16069.00	47042.50	414522.0
TOTAL TALKING TIME	359.0	107863.412256	43402.477021	8545.0	81224.00	108416.00	136228.00	268736.0
TOTAL AFTER CALL WORK TIME	359.0	22665.579387	13717.113123	1628.0	14071.50	20927.00	29588.50	120059.0
NUMBER OF PUT ON HOLD	359.0	47.740947	31.680180	0.0	27.00	42.00	61.00	194.0
TOTAL ON HOLD TIME	359.0	8588.220056	6139.941240	0.0	4326.50	7479.00	12220.50	39645.0
TOTAL HANDLING TIME	359.0	130528.991643	53674.888389	10285.0	96724.50	132310.00	163444.00	376845.0

Şekil 3.4 Tanımlayıcı istatistikler


Şekil 3.5'te hedef değişkenler olan çağrı sayısı ve ortalama çağrı süresinin grafiklerine yer verilmiştir.




Şekil 3.5 Hedef değişkenlerin grafiği

3.3 Eğitim - Test Ayrımı

Verileri eğitim ve test olarak ayırmak için önce X değişkeni oluşturulmuştur. Bu veriler, hedef değişkenler olan NUMBER OF CALLS ve AVERAGE TALKING TIME değişkenleri hariç tüm diğer değişkenleri içermektedir; bu değişkenler modelin tahmin yaparken kullanacağı özellikleri temsil eder. Ayrıca y değişkeni ise, hedef değişkenleri içerir ve modelin tahmin etmeye çalışacağı değerleri temsil eder. Sonuç olarak, elde edilmek istenen 1 aylık tahmin değerleri test veriler olarak ayrılmıştır. Geriye kalan 333 gözlem ise eğitim verileri olarak kullanılmıştır. Şekil 3.6'da NUMBER OF CALLS değişkenine ait grafik, Şekil 3.7'de ise AVERAGE TALKING TIME değişkenine ait grafik sunulmuştur.



Şekil 3.6 Çağrı sayısı için eğitim - test grafiği



Şekil 3.7 Ortalama çağrı süresi için eğitim - test grafiği

Son aşamada, verilerdeki özelliklerin ölçeklendirilmesi gerçekleştirilmiştir. Bu işlem, özelliklerin belirli bir aralığa, genellikle $[0, 1]$ aralığına, dönüştürülmesini sağlayan MinMaxScaler yöntemi ile yapılmıştır. İlk olarak, eğitim verileri üzerinde *scaler.fit* komutu uygulanarak scaler'ın eğitim verilerinin minimum ve maksimum değerlerini öğrenmesi sağlanmıştır. Bu işlem, verilerin uygun bir ölçek aralığına

dönüştürülmesi için gerekli parametreleri belirler. Daha sonra, hem eğitim hem de test verileri, aynı ölçekleme parametrelerine göre *scaler.transform* komutları ile dönüştürülmüştür. Bu ölçeklendirme süreci, eğitim ve test aşamalarında verilerin tutarlı bir ölçekte olmasını sağlar ve bu da modelin performansının daha güvenilir ve geçerli bir şekilde değerlendirilmesine olanak tanır. Özelliklerin standartlaştırılması, modelin genelleme yeteneğini artırarak, farklı ölçeklerdeki verilerle çalışırken performans sapmalarını minimize eder ve analiz sonuçlarının doğruluğunu artırır. Bu işlemler Şekil 3.8'de detaylı olarak sunulmuştur.

```
from sklearn.model_selection import train_test_split

X = df.drop(columns=['NUMBER OF CALLS', 'AVERAGE TALKING TIME'])
y = df[['NUMBER OF CALLS', 'AVERAGE TALKING TIME']]

X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.07, shuffle=False)

scaler = MinMaxScaler()
scaler.fit(X_train)
X_train_scaled = scaler.transform(X_train)
X_test_scaled = scaler.transform(X_test)
```

Şekil 3.8 Eğitim - test verileri

3.4 Modelleme

Verilerin ölçeklendirilmesinden sonra, özellikle zaman serisi verileriyle çalışırken modelin doğru bir şekilde eğitim ve tahmin yapabilmesi için veri biçimlendirmesi gerekmektedir. Bu bağlamda, eğitim ve test verilerinin şekillerini değiştirmek amacıyla aşağıdaki işlemler gerçekleştirilmiştir.

Öncelikle, test verilerin tarih indeksindeki en küçük değeri elde edilmiştir. Daha sonra, eğitim ve test verileri, üç boyutlu hale getirilmiştir. Bu dönüşüm, özellikle zaman serisi verileriyle çalışan modellerde (örneğin, UKSB veya GRU gibi derin öğrenme modelleri) gereklidir.

```

from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import LSTM, Dense

model = Sequential()
model.add(LSTM(128, activation='relu', input_shape=(X_train.shape[1], 1), return_sequences=True))
model.add(Dropout(0.1))
model.add(LSTM(64, activation='relu', return_sequences=True))
model.add(Dropout(0.1))
model.add(LSTM(16, activation='relu', return_sequences=False))
model.add(Dropout(0.1))
model.add(Dense(2))
model.compile(optimizer='adam', loss='mse')

```

Şekil 3.9 Uzun kısa süreli bellek sinir ağları ile kurulan model

Şekil 3.9’da modelin oluşturulması ve yapılandırılması sürecinde öncelikle bir Sequential model oluşturulmuştur. Bu model, katmanların sıralı bir şekilde eklenebileceği bir yapıyı temsil eder. İlk olarak, 128 nörondan oluşan bir UKSB katmanı eklenmiştir. Bu katmanda ReLU aktivasyon fonksiyonu kullanılmıştır. Ayrıca, *return_sequences=True* parametresi ile bu katmandan çıkan tüm zaman adımları, bir sonraki UKSB katmanına iletilmiştir.

İlk UKSB katmanının ardından, aşırı uyumu (overfitting) önlemek amacıyla 0.1 oranında bir Dropout katmanı eklenmiştir. Bu dropout uygulaması, modelin genelleme yeteneğini artırmaya yönelik bir önlem olarak kullanılmıştır. Ardından, 64 nörondan oluşan ikinci bir UKSB katmanı eklenmiş ve bu katman da ReLU aktivasyon fonksiyonu ile yapılandırılmıştır. *return_sequences=True* parametresi, bu katmandan çıkan zaman adımlarının bir sonraki UKSB katmanına iletilmesini sağlar.

Üçüncü olarak, 16 nörondan oluşan bir UKSB katmanı eklenmiştir ve bu katmanda *return_sequences=False* parametresi kullanılarak sadece son zaman adımının çıktısı döndürülmüştür. Bu, modelin son çıkış katmanına yalnızca tek bir zaman adımı ile veri sağlamasını sağlar. Son olarak, 0.1 oranında bir Dropout katmanı daha eklenmiş, bu da modelin aşırı uyum riskini daha da azaltmaya yönelik bir adım olarak değerlendirilmiştir.

Modelin çıkış katmanı, iki nöron içeren bir Dense katmanı ile tamamlanmıştır. Bu çıkış katmanı, modelin iki hedef değişken için tahminlerde bulunmasını sağlar. Model, Adam optimizasyon algoritması ve Ortalama Hata Karesi (Mean Squared Error, MSE)

kayıp fonksiyonu kullanılarak derlenmiştir. Adam, öğrenme oranlarını dinamik olarak ayarlayarak verimli bir optimizasyon sağlar, MSE ise regresyon problemlerinde yaygın olarak kullanılan bir kayıp fonksiyonudur. Bu yapı, zaman serisi verilerinin etkili bir şekilde işlenmesini ve tahmin edilmesini amaçlayan bir UKSB ağı oluşturmaktadır.

Model eğitiminde aşırı uyumu (overfitting) önlemek ve en iyi performansı elde etmek amacıyla EarlyStopping callback fonksiyonu kullanılmıştır. Bu fonksiyon, modelin doğrulama kaybını (validation loss) izleyerek eğitim sürecinde belirli bir noktada durdurulmasını sağlar. Özellikle, EarlyStopping sınıfı aşağıdaki parametrelerle yapılandırılmıştır.

Öncelikle, *monitor="val_loss"* parametresi ile doğrulama kaybı izlenmiştir. Bu, modelin doğrulama setindeki performansını değerlendirerek kaybın minimuma çekilmesini hedefler. *verbose=2* ayarı, eğitim sırasında erken durdurma işlemlerinin detaylı bir şekilde raporlanmasını sağlar, böylece eğitim sürecindeki değişiklikler hakkında daha fazla bilgi edinilmiştir. *mode='min'* parametresi, doğrulama kaybının en düşük seviyeye indirilmesini amaçlar ve modelin en iyi doğrulama kaybına sahip ağırlıkları kullanmasını destekler. Ayrıca, *patience=30* değeri ile doğrulama kaybında 30 epoch süresince bir iyileşme gözlemlenmediğinde eğitim sürecinin sonlandırılacağı belirlenmiştir. Bu, modelin eğitim sürecinde gereksiz yere devam etmesini önleyerek erken durdurmayı sağlar. Son olarak, *restore_best_weights=True* parametresi ile eğitim tamamlandığında en iyi doğrulama kaybına sahip modelin ağırlıkları geri yüklenmiştir. Bu sayede, en iyi performans gösteren modelin ağırlıkları kullanılarak son model elde edilmiştir. Bu yapılandırma, eğitim sürecinde modelin genel performansını optimize etmeye yardımcı olmuş ve aşırı uyum riskini en aza indirmiştir.

Modelin eğitilmesi sürecinde, *model.fit* fonksiyonu kullanılarak aşağıdaki parametrelerle eğitim işlemi gerçekleştirilmiştir. Model, toplamda 200 epoch süresince eğitilecektir. Her epoch için, veriler 8 örneklilik batch'ler halinde işlenecektir. Bu batch boyutu, modelin her adımda güncelleme yaparken kullanılan veri miktarını belirler.

Ayrıca, *validation_split=0.15* parametresi ile eğitim verinin %15'i doğrulama (validation) verisi olarak ayrılmıştır. Bu doğrulama seti, modelin eğitim sürecindeki performansını değerlendirmek için kullanılır ve modelin genel doğruluğunu test eder. Eğitim süreci boyunca, *earlyStop callback* fonksiyonu devrede olacaktır. Bu fonksiyon, doğrulama kaybında iyileşme gözlemlenmediğinde eğitim sürecini durdurarak aşırı uyumu önlemeyi amaçlar ve en iyi model ağırlıklarını geri yükler.

Bu yapılandırma ile model, eğitim süreci boyunca sürekli olarak doğrulama performansını izleyerek en uygun ağırlıklarla eğitilir ve en iyi genel performansın elde edilmesi hedeflenir.



Şekil 3.10 Kayıp değerler

Modelin eğitim sürecinde elde edilen performans verileri Şekil 3.10'de gösterilmektedir. Eğitim tamamlandıktan sonra, eğitim ve doğrulama ölçütlerinin zaman içindeki değişimini ele almaktadır. Bu grafik, modelin eğitim ve doğrulama ölçütlerinin zaman içindeki değişimini açıkça gösterir. Özellikle, eğitim kaybı ve doğrulama kaybının nasıl azaldığını, ayrıca eğitim ve doğrulama doğruluğunun nasıl

iyileştğini gözlemlemek mümkün olur. Bu görselleştirme, modelin eğitim sürecindeki performansını değerlendirmenin yanı sıra, aşırı uyum veya yetersiz uyum gibi sorunların varlığını da belirlemede yardımcı olur. Grafik üzerinden, modelin öğrenme sürecindeki ilerlemesi, performansındaki dalgalanmalar ve 179. adımda durdurma noktası gözlemlenmektedir. Bu sayede modelin ne kadar iyi öğrenip öğrenmediğini tespit edilmiştir.

3.5 Tahminleme

Model ile test verileri üzerinde tahminler yapılmıştır. Yapılan tahminleme modelin eğitim sırasında öğrendiği bilgileri kullanarak, daha önce görmediği test verileri üzerinde nasıl performans gösterdiğini değerlendirmektedir. Elde edilen tahminler, modelin genel doğruluğunu ve performansını analiz etmek için kullanılmıştır.


Modelin test verisindeki tahminlerini elde etmek amacıyla *model.predict()* komutu kullanılmıştır. Bu işlem, eğitim sürecinde öğrenilen modelin, ölçeklendirilmiş test verileri üzerinde tahminler yapmasını sağlar. Tahminler, modelin test verileri üzerindeki performansını değerlendirmek için kritik öneme sahiptir ve modelin eğitim sırasında öğrendiği ilişkiler doğrultusunda üretilir.

Elde edilen *predicted_values* değişkeni, test verisindeki her bir örnek için model tarafından tahmin edilen sonuçları içerir. Bu tahminler, gerçek hedef değerlerle karşılaştırılarak modelin ne derece başarılı olduğunu ve doğruluğunu analiz etmemize olanak tanır. Modelin tahmin performansını değerlendirmek için, tahminler genellikle çeşitli performans ölçütleri kullanılarak analiz edilir. Bu ölçütler, modelin pratik uygulamalardaki başarısını ve genel genelleme yeteneğini ölçmede önemli veriler sunar. Elde edilen tahmini değerler Şekil 3.11’de gösterilmektedir.

	DATE	NUMBER OF CALLS	AVERAGE TALKING TIME	PREDICTED NUMBER OF CALLS	PREDICTED AVERAGE TALKING TIME
0	2024-03-30	173	305	190.742279	263.720001
1	2024-04-02	394	306	393.179657	268.004852
2	2024-04-03	285	292	303.670837	279.662170
3	2024-04-04	511	280	504.890106	254.449875
4	2024-04-05	806	261	813.616089	187.961548
5	2024-04-06	206	316	218.335068	264.318512
6	2024-04-08	576	285	574.143494	248.128723
7	2024-04-09	450	263	442.840912	262.616821
8	2024-04-10	344	251	340.575623	275.732605
9	2024-04-11	401	257	390.077271	269.811859
10	2024-04-12	357	254	353.439178	274.217438
11	2024-04-13	92	318	149.736038	231.921616
12	2024-04-15	338	322	341.540924	274.763184
13	2024-04-16	280	321	292.148834	280.698273
14	2024-04-17	269	279	281.277283	278.347137
15	2024-04-18	251	289	269.150757	273.329437
16	2024-04-19	248	304	260.217010	270.945251
17	2024-04-20	84	310	145.895599	226.230927
18	2024-04-22	228	292	243.982925	266.272583
19	2024-04-23	466	314	464.918549	259.839813
20	2024-04-24	687	274	698.691833	218.453278
21	2024-04-25	555	321	555.092651	251.355225
22	2024-04-26	445	324	442.187714	262.459991
23	2024-04-27	122	338	165.079132	249.923584
24	2024-04-29	506	286	502.944702	254.397446
25	2024-04-30	405	285	401.139282	266.595978

Şekil 3.11 Tahmini değerler

Sonuçların görselleştirilmesi amacıyla, tahmin edilen ve gerçek değerlerin karşılaştırılabilmesi için bir grafik oluşturulmuştur. Elde edilen grafik, modelin tahminlerinin gerçek değerlerle ne derece örtüştüğünü ve tahminlerin doğruluğunu görsel olarak değerlendirmeye olanak tanımaktadır. Şekil 3.12’de Nisan 2024 ayında gerçekleşen çağrı sayıları ile bu çağrı sayılarına yönelik tahminlerin karşılaştırıldığı görülmektedir. Genel olarak, her iki çizginin de benzer bir desen izlediği gözlenmekte, bu da tahminlerin gerçek çağrı sayılarıyla büyük ölçüde örtüştüğünü göstermektedir.



Şekil 3.12 Nisan 2024 çağrı sayıları grafiği

3.6 Hata Ölçütleri

Elde edilen modelin tahminlerinin doğruluğunu değerlendirmek amacıyla çeşitli hata ölçütlerini hesaplamak üzere bir fonksiyon geliştirilmiştir. Bu fonksiyon, gerçek değerlerle tahmin edilen değerler arasındaki performansı kapsamlı bir şekilde analiz etmek için kullanılmaktadır. Hesaplanan ölçütler, Ortalama Mutlak Hata Yüzdesi (MAPE), Ortalama Hata Karelerinin Kökü (RMSE), Ortalama Mutlak Hata (MAE), Ortalama Hata Kareleri (MSE) ve R-Kare (R^2) şeklindedir.

Ortalama Mutlak Hata Yüzdesi (MAPE): Tahminlerin gerçek değerlere ne kadar yakın olduğunu yüzdesel olarak ölçer. Formülü Denklem 3.1'deki gibidir.

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| \times 100 \quad (3.1)$$

Ortalama Hata Karelerinin Kökü (RMSE): Tahmin edilen değerlerin hatalarının karelerinin ortalamasının karekökünü alarak hesaplanır ve hataların büyüklüğünü ölçer. Formülü Denklem 3.2'deki gibidir.

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2} \quad (3.2)$$

Ortalama Mutlak Hata (MAE): Tahmin edilen değerlerin hatalarının mutlak değerlerinin ortalamasını alarak hesaplanır. Formülü Denklem 3.3'teki gibidir.

$$MAE = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t| \quad (3.3)$$

Ortalama Hata Kareleri (MSE): Tahmin edilen değerlerin hatalarının karelerinin ortalamasını alır. Formülü Denklem 3.4'deki gibidir.

$$MSE = \frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2 \quad (3.4)$$

R-Kare (R^2): Modelin açıklayıcılığını ölçer ve tahminlerin gözlemler üzerindeki varyansı ne kadar iyi açıkladığını belirtir. Formülü Denklem 3.5'teki gibidir.

$$R^2 = \frac{\sum_{t=1}^n (\hat{y}_t - \bar{y})^2}{\sum_{t=1}^n (y_t - \bar{y})^2} \quad (3.5)$$

Burada;

- t : gözlem numarasını (1, 2, 3, ..., n)
- y_t : gözlem değerlerini
- $\hat{y}_t$: tahminlenen değerleri
- $\bar{y}$: gözlem değerlerinin ortalamasını
- n : gözlem sayısını

ifade etmektedir.

Hesaplanan ölçütler Tablo 3.1'de verilmiştir. Bu değerler modelin performansını detaylı bir şekilde değerlendirmeye olanak sağlamaktadır. Modelin tahmin performansını değerlendirmek amacıyla iki hedef değişken için çeşitli hata ölçütleri hesaplanmıştır. Burada MAPE, RMSE, MAE, MSE ve R^2 değerleri yer almaktadır.

Tablo 3.1 Gerçek veriler ile elde edilen ölçütler

Ölçütler	NUMBER OF CALLS	AVERAGE TALKING TIME
<i>MAPE</i>	0.09	0.13
<i>RMSE</i>	20.88	47.44
<i>MAE</i>	13.45	40.32
<i>MSE</i>	436.35	2251.40
<i>R²</i>	0.87	0.23

İlk olarak, NUMBER OF CALLS değişkeni için elde edilen ölçütler incelendiğinde, MAPE değeri 0.09 olarak bulunmuştur. Bu değer, tahminlerin gerçek değerlere ortalama olarak yaklaşık %9 doğrulukla yakın olduğunu göstermektedir. RMSE 20.88 olarak hesaplanmış, bu ölçüt tahmin edilen değerlerle gerçek değerler arasındaki ortalama hata büyüklüğünü ölçer ve büyük hataları daha belirgin hale getirir. MAE 13.45 olarak belirlenmiş olup, tahminler ile gerçek değerler arasındaki ortalama mutlak farkı ifade eder. MSE 436.35 olarak hesaplanmış ve bu değer büyük hataların etkisini vurgular. R^2 değeri 0.87 olarak bulunmuş olup, modelin gerçek değerlerin varyansının %87'sini açıkladığını ve verilerdeki yüksek açıklanabilirliği gösterdiğini ortaya koymaktadır.

İkinci olarak, AVERAGE TALKING TIME değişkeni için yapılan hesaplamalarda MAPE 0.13 olarak bulunmuş, bu da tahminlerin gerçek değerlere ortalama olarak yaklaşık %13 doğrulukla yakın olduğunu göstermektedir. RMSE 47.44 olarak belirlenmiş ve bu ölçüt, tahmin edilen değerlerle gerçek değerler arasındaki ortalama hata büyüklüğünü ifade eder. MAE 40.32 olarak hesaplanmış ve tahminler ile gerçek değerler arasındaki ortalama mutlak farkı yansıtır. MSE 2251.40 olarak bulunmuş, büyük hataların etkisini vurgular. R^2 değeri ise 0.23 olarak hesaplanmış ve bu değer, modelin gerçek değerlerin varyansını yeterince açıklamadığını ve performansının zayıf olduğunu gösterir.

Bu ölçütler, modelin her iki hedef değişken üzerindeki tahmin performansını kapsamlı bir şekilde değerlendirir. NUMBER OF CALLS için elde edilen yüksek R^2 değeri, modelin bu hedef değişken üzerinde başarılı olduğunu belirtirken; AVERAGE TALKING TIME için düşük R^2 değeri, modelin bu hedef üzerinde başarısız olduğunu ortaya koymaktadır. Bu nedenle Erlang C analizinde tahminlenen ortalama çağrı süreleri yerine gerçekleşen değerler ile hesaplama gerçekleştirilmiştir.

3.7 Erlang C ile Personel Sayısını Belirleme

Erlang C formülünü kullanarak çağrı merkezi personel ihtiyaçlarını hesaplamak üzere bir fonksiyon geliştirilmiştir. Bu fonksiyon, çağrı merkezinin personel ihtiyacını belirlemek için birkaç temel parametreyi dikkate almaktadır. İlk adım olarak, günlük çağrı sayısı, ortalama çağrı süresi ve çalışma saatleri göz önünde bulundurularak trafik

yoğunluğu hesaplanmıştır. Sonrasında, Erlang C formülü kullanılarak gerekli personel sayısı hesaplanmıştır.

Özetle, UKSB modeli ile yapılan tahminler sonucu 26 günlük tahmini çağrı sayıları ile gerçekleşen ortalama çağrı süreleri ele alınarak, servis seviyesi %80, gelen çağrının 20 saniye içerisinde yanıtlama hedefi ile 26 gün için gereken tahmini personel sayıları Erlang C ile hesaplanmıştır.

	DATE	NUMBER OF CALLS	AVERAGE TALKING TIME	PREDICTED NUMBER OF CALLS	PREDICTED AVERAGE TALKING TIME	DAILY AGENTS
0	2024-03-30	173	305	195.559631	290.397308	4
1	2024-04-02	394	306	404.280426	290.191895	7
2	2024-04-03	285	292	294.259491	291.767090	6
3	2024-04-04	511	280	525.407471	269.796844	8
4	2024-04-05	806	261	821.037781	220.880814	10
5	2024-04-06	206	316	229.876129	299.274780	5
6	2024-04-08	576	285	594.194397	258.412720	9
7	2024-04-09	450	263	462.482239	279.854584	8
8	2024-04-10	344	251	348.518219	295.351593	7
9	2024-04-11	401	257	401.097351	287.870514	7
10	2024-04-12	357	254	366.580750	293.609772	7
11	2024-04-13	92	318	158.836044	264.971161	3
12	2024-04-15	338	322	352.539490	296.949127	7
13	2024-04-16	280	321	294.239929	300.252106	6
14	2024-04-17	269	279	284.550751	299.873810	6
15	2024-04-18	251	289	268.879456	294.967377	5
16	2024-04-19	248	304	263.448914	298.811737	5
17	2024-04-20	84	310	136.745300	184.368881	2
18	2024-04-22	228	292	249.059891	297.565399	5
19	2024-04-23	466	314	481.366669	274.819092	8
20	2024-04-24	687	274	709.468628	238.106644	10
21	2024-04-25	555	321	578.289917	260.500153	9
22	2024-04-26	445	324	460.397156	280.788666	8
23	2024-04-27	122	338	171.833298	281.423126	4
24	2024-04-29	506	286	521.896118	271.669281	8
25	2024-04-30	405	285	412.897644	289.996185	7

Şekil 3.13 Sonuç değerler

Şekil 3.13'te, 30 Mart 2024 ile 30 Nisan 2024 tarihleri arasında, 1 aylık gerçek verilere ait çağrı sayıları, ortalama çağrı süreleri, tahmin edilen çağrı sayıları ve ortalama çağrı süreleri ile tahmin edilen personel sayıları sunulmaktadır.

Erlang C ile gelen çağrılarının %80'inin 20 saniye içinde cevaplanabilmesi için bu 1 aylık süreçte günlük ortalama 7 personele ihtiyaç duyulduğu görülmektedir. Bu tarih aralığı için gerçek verilere bakıldığında gelen çağrılarının %97'sinin 10 saniye içinde günlük ortalama 16 personelle cevaplandığı gözlemlenmektedir. Bu da gelen çağrılarının %80'inin 20 saniye içinde cevaplanması durumu göz önünde bulundurulduğunda mevcut personel sayısının yaklaşık %43'ünün yeterli olacağı anlamına gelmektedir.

Gerçek verilerin yalnızca 1 yıllık verilerden oluşması nedeniyle, modelin daha geniş veriler üzerindeki performansını değerlendirebilmek amacıyla yapay veriler üretilmiştir. Bu yapay veriler, aynı model kullanılarak işlenmiş ve sonuçlar elde edilmiştir. Böylece, modelin büyük ölçekli veriler ile nasıl performans gösterdiği incelenmiş ve modelin genelleme yeteneği hakkında daha kapsamlı bir değerlendirme yapılmıştır.

3.8 Yapay Veri Örneği

Yapay veriler, gerçek verilere dayanarak rassal olarak üretilen veriler ile oluşturulmuştur. İlk olarak, mevcut veri *MinMaxScaler* kullanılarak [0, 1] aralığına ölçeklendirilmiştir.

Ardından, belirlenen veri seviyesinde rastgele veriler eklenmesi amacıyla bir fonksiyon kullanılmıştır. Bu fonksiyon, her döngüde *np.random.normal* fonksiyonu aracılığıyla normal dağılıma dayalı rastgele veriler üretmektedir. Üretilen veriler, ölçeklendirilmiş verilere eklenerek yeni veriler oluşturulmuştur.

Bu süreç beş kez tekrarlanmış ve her bir döngüde elde edilen veriler, gerçek verilerin aralığına geri dönüştürülmüştür. Böylece, her seferinde yeni bir veri oluşturulmuş ve toplamda 3085 gözlem elde edilmiştir.


Son olarak, bu yeni verilerin zaman indeksi belirlenerek gün bazında bir zaman dizisi oluşturulmuştur. Elde edilen verilerin önizlemesi Şekil 3.14'te sunulmaktadır.

	NUMBER OF CALLS	NUMBER OF CALLS ANSWERABLE	NUMBER OF CALLS ANSWERED	NUMBER OF CALLS ABANDONED
t0	755.0	764.0	604.0	155.0
t1	884.0	911.0	650.0	253.0
t2	790.0	777.0	545.0	208.0
t3	267.0	294.0	174.0	106.0
t4	825.0	822.0	423.0	444.0
...	...	...	...	...
t3080	563.0	554.0	562.0	2.0
t3081	463.0	454.0	455.0	11.0
t3082	126.0	114.0	118.0	25.0
t3083	503.0	482.0	488.0	1.0
t3084	402.0	391.0	388.0	9.0

3085 rows x 28 columns

Şekil 3.14 Yapay veriler

Elde edilen yapay veriler, Şekil 3.9’da yer alan UKSB modeli ile eğitilmiştir. Bu sürecin sonunda, Şekil 3.15’te modelin eğitim sürecinde kaydedilen kayıp ve doğrulama kaybı değerlerinin değişimi görselleştirilmiştir.



Şekil 3.15 Yapay verilerde kayıp değerleri

Şekil 3.15'te yer alan grafikte ilk göze çarpan unsur, eğitim sürecinin başında hem eğitim kaybının hem de doğrulama kaybının oldukça yüksek olduğu, ancak birkaç epoch sonrası bu değerlerin hızlı bir düşüş gösterdiğidir. Bu durum, modelin başlangıçta veriyi anlamakta zorlandığını, ancak öğrenme sürecinin etkili bir şekilde devreye girmesiyle birlikte veriye uyum sağladığını ortaya koymaktadır.

Takip eden epoch'larda ise kayıp değerlerinin belirgin bir şekilde azalarak, yaklaşık 75. epoch'tan sonra yatay bir seyir izlediği gözlemlenmektedir. Bu durum, modelin öğrenme sürecinin yavaşladığını ve artık belirli bir düzeye ulaştığını işaret etmektedir. Eğitim kaybı ve doğrulama kaybı değerleri arasındaki farkın oldukça düşük olması, modelin eğitim verisine aşırı uyum sağlama eğiliminde olmadığını göstermektedir.

Şekil 3.10'daki gerçek veriler ile eğitilen modelin kayıp değerlerine kıyasla yapay verilerle eğitilen modelin kayıp değerlerinde kayda değer bir iyileştirme gözlemlenmektedir.


Oluşan bu modelin tahminlerinin doğruluğunu değerlendirmek amacıyla, yapay değerlerle tahmin edilen değerlerin performansını kapsamlı bir şekilde analiz etmek için MAPE, RMSE, MAE, MSE ve R^2 ölçütleri hesaplanmıştır. Hesaplanan ölçütler Tablo 3.2’de yer almaktadır.

Tablo 3.2 Yapay veriler ile elde edilen ölçütler

Ölçütler	NUMBER OF CALLS	AVERAGE TALKING TIME
<i>MAPE</i>	0.09	0.11
<i>RMSE</i>	25.38	42.21
<i>MAE</i>	18.94	32.13
<i>MSE</i>	644.45	1782.05
<i>R²</i>	0.91	0.53

Elde edilen yapay verilerle yapılan model değerlendirmesi sonucunda, çeşitli hata ölçütleri hesaplanmıştır. İlk olarak, NUMBER OF CALLS için hesaplanan hata ölçütleri, MAPE 0.09, RMSE 25.38, MAE 18.94, MSE 644.45 ve R^2 0.91 olarak bulunmuştur. Bu sonuçlar, modelin çağrı sayısı tahminlerinde yüksek bir doğruluk ve düşük hata oranı sağladığını göstermektedir.

Diğer taraftan, AVERAGE TALKING TIME için hesaplanan hata ölçütleri MAPE 0.11, RMSE 42.21, MAE 32.13, MSE 1782.05 ve R^2 0.53 olarak elde edilmiştir. Bu ölçütler, ortalama çağrı süresi tahminlerinde çağrı sayısı tahminine göre daha yüksek hata oranları ve daha düşük doğruluk seviyeleri elde edildiğini göstermektedir. Ancak gerçek veri sonuçları (Tablo 3.1) ile kıyaslandığında, özellikle R^2 değerinin, daha iyi olduğu, daha büyük boyutta veri ile çağrı süresi tahmin modelinin daha başarılı sonuçlar verdiğini göstermektedir.



Şekil 3.16 Yapay verilerde çağrı sayıları grafiği

Sonuçların görselleştirilmesi amacıyla, tahmin edilen ve yapay değerlerin karşılaştırılabilmesi için bir grafik oluşturulmuştur. Elde edilen grafik, modelin tahminlerinin gerçek değerlerle ne derece örtüştüğünü ve tahminlerin doğruluğunu görsel olarak değerlendirmeye olanak tanımaktadır. Şekil 3.16’da 463 günlük çağrı sayıları ile bu çağrı sayılarına yönelik tahminlerin karşılaştırıldığı görülmektedir. Genel olarak, her iki çizginin de benzer bir desen izlediği gözlenmekte, bu da tahminlerin gerçek çağrı sayılarıyla büyük ölçüde örtüştüğünü göstermektedir.

Yapay verilerle oluşan UKSB modeli ile yapılan tahminler sonucu 463 günlük tahmini çağrı sayıları ile gerçekleşen ortalama çağrı süreleri ele alınarak, servis seviyesi %80, gelen çağrının 20 saniye içerisinde yanıtlama hedefi ile 463 gün için gereken tahmini personel sayıları Erlang C ile hesaplanmıştır. Son olarak elde edilen değerler Şekil 3.17’de verilmiştir.

	index	NUMBER OF CALLS	AVERAGE TALKING TIME	PREDICTED NUMBER OF CALLS	PREDICTED AVERAGE TALKING TIME	DAILY AGENTS
0	t2622	476.0	235.0	476.658936	249.405960	7
1	t2623	245.0	190.0	212.745453	297.103424	3
2	t2624	381.0	260.0	405.365417	267.223633	7
3	t2625	368.0	298.0	363.820984	248.805939	7
4	t2626	364.0	264.0	339.234741	256.154663	6
...	...	...	...	...	...	...
458	t3080	563.0	315.0	567.926147	280.954590	10
459	t3081	463.0	322.0	465.354370	244.782867	9
460	t3082	126.0	339.0	154.046844	251.527832	4
461	t3083	503.0	282.0	498.752899	257.399536	8
462	t3084	402.0	285.0	401.220795	265.003906	7

463 rows x 6 columns

Şekil 3.17 Yapay veriler ile elde edilen sonuç değerleri



BÖLÜM DÖRT

SONUÇLAR VE ÖNERİLER

Çağrı merkezleri, kurumların bireyler veya diğer kurumlarla iletişimlerini sürdürebilmeleri için hizmet veren birimlerdir. Bu merkezler, telefon, e-posta veya diğer iletişim kanalları ile müşteri taleplerini karşılamak amacıyla doğru ürün veya hizmeti, doğru zamanda sunmayı hedefler. Genel olarak çağrı merkezleri, müşteri hizmetleri ve destek sağlama konusunda kritik rol oynar ve gelişen teknoloji ile müşteri beklentilerine uyum sağlamak için evrilir. Çağrı merkezleri, müşteri memnuniyetini sağlamak ve iş gücünü etkin bir şekilde kullanmak adına yük tahmini yaparak kaynaklarını optimize etme gereksinimi duyarlar.

Bu çalışmada, çağrı merkezi iş yükünü daha etkili bir şekilde yönetmek amacıyla bir çağrı merkezinin yaklaşık bir yıllık inbound verileriyle UKSB yöntemi kullanılarak çağrı sayıları ve ortalama çağrı süresi tahminleri elde edilmiştir. Gerçek verilerin yalnızca bir yıllık verilerden oluşması nedeniyle, modelin daha geniş veriler üzerindeki performansını değerlendirebilmek amacıyla yapay veriler de üretilmiştir. Bu yapay veriler, aynı model kullanılarak denenmiş ve daha iyi sonuçlar elde edilmiştir. Modelleme süreci sonucunda elde edilen tahminlerin yüksek doğruluk oranı, çağrı merkezi iş yükünün daha hassas bir şekilde belirlenmesine yardımcı olabilecektir. Bu konu, kaynakların etkin yönetilmesi ve personel planlamasının iyileştirilmesi açısından kritik bir öneme sahiptir.

Model tahminleri, Erlang C hesaplamaları ile birleştirilerek, çağrı merkezi için ihtiyaç duyulan personel sayısının belirlenmesinde bir araç olarak kullanılmıştır. Erlang C analizi sonucunda gelen çağrıların %80'inin 20 saniye içinde yanıtlanabilmesi için, 1 aylık süreçte günlük ortalama 7 personele ihtiyaç duyulduğu hesaplanmıştır. Buna karşılık aynı zaman dilimi için, gerçek verilerde gelen çağrıların %97'sinin 10 saniye içinde yanıtlandığı ve günlük ortalama 16 personel kullanıldığı gözlemlenmiştir. Bu bulgular, incelenen dönem için mevcut personel sayısının yaklaşık %43'ünün yeterli olabileceğini ortaya koymaktadır.

Özellikle büyük veriler ile çalışırken, UKSB gibi derin öğrenme yöntemleri ile zaman serisi verilerinin tahminlenmesi önerilmektedir. Modelin genelleştirme yeteneğini artırmak için çapraz doğrulama ve hiperparametre ayarlama yöntemlerinin uygulanması önemlidir. Bu, modelin aşırı uyum ve eksik uyum gibi problemlerine karşı korunmasına yardımcı olabilir. Ayrıca, veri temizleme ve ön işleme süreçlerinin etkili bir şekilde yürütülmesi, eksik veriler ve anomalilerle başa çıkma stratejileriyle modelin güvenilirliğini artırabilir. Verilerin standartlaştırılması, modelin öğrenme sürecini daha tutarlı hale getirebilir.

Çağrı merkezi iş gücü planlaması açısından, tahmin sonuçlarının operasyonel stratejilere dönüştürülmesi önemlidir. İş gücü planlama stratejilerinin geliştirilmesi ve gerçek zamanlı izleme uygulamaları, hizmet kalitesini artırabilir. Son olarak, müşteri geri bildirimlerinin düzenli olarak analiz edilmesi, model performansını değerlendirmek ve iyileştirme alanlarını belirlemek için kullanılmalıdır. Geri bildirimler, hizmet kalitesini sürekli olarak iyileştirme konusunda önemli bir kaynak olabilir. Bu öneriler, çağrı merkezi iş yükü tahmin modellerinin performansını artırarak operasyonel verimliliği ve müşteri memnuniyetini geliştirmelerine olanak sağlayabilir.

KAYNAKLAR

- Abdolrasol, M. G., Hussain, S. S., Ustun, T. S., Sarker, M. R., Hannan, M. A., Mohamed, R. vd. (2021). Artificial neural networks based optimization techniques: A review. *Electronics*, 10(21), 2689. <https://doi.org/10.3390/electronics10212689>
- Aksin, Z., Armony, M. ve Mehrotra, V. (2007). The modern call center: A multi-disciplinary perspective on operations management research. *Production and Operations Management*, 16(6), 665–688. <https://doi.org/10.1111/j.1937-5956.2007.tb00288.x>
- Aldor-Noiman, S., Feigin, P. D. ve Mandelbaum, A. (2009). Workload forecasting for a call center: Methodology and a case study. *The Annals of Applied Statistics*, 3(4), 1403–1447. <https://doi.org/10.1214/09-AOAS255>
- Anderson, D. ve McNeill, G. (1992). *Artificial neural networks technology*. Kaman Sciences Corporation.
- Aydemir, E., Karaatlı, M., Yılmaz, G. ve Aksoy, S. (2014). 112 Acil çağrı merkezine gelen çağrı sayılarını belirleyebilmek için bir yapay sinir ağı tahminleme modeli geliştirilmesi. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 20(5), 145–149.
- Boué, L. (2018). Deep learning for pedestrians: backpropagation in CNNs. arXiv preprint. <https://doi.org/10.48550/arXiv.1811.11987>
- Braverman, A. ve Dai, J. G. (2016). High order steady-state diffusion approximation of the Erlang-C system. arXiv preprint. <https://doi.org/10.48550/arXiv.1602.02866>
- Brown, L., Gans, N., Mandelbaum, A., Sakov, A., Shen, H., Zeltyn, S. ve Zhao, L. (2005). Statistical analysis of a telephone call center: A queueing-science perspective. *Journal of the American Statistical Association*, 100(469), 36–50. <https://doi.org/10.1198/016214504000001808>
- Bulut, U. ve Ataay, A. (2017). Çağrı merkezlerinde çalışan performansını etkileyen faktörler: Bir inceleme. *İşletme Araştırmaları Dergisi*, 9(4), 1–16. <https://doi.org/10.20491/isarder.2017.318>

- Cherian, T., Badola, A. ve Padmanabhan, V. (2018). Multi-cell LSTM based neural language model. arXiv preprint. <https://doi.org/10.48550/arXiv.1811.06477>
- Emmert-Streib, F., Yang, Z., Feng, H., Tripathi, S. ve Dehmer, M. (2020). An introductory review of deep learning for prediction models with big data. *Frontiers in Artificial Intelligence*, 3(4), 1–23. <https://doi.org/10.3389/frai.2020.00004>
- Epelbaum, T. (2017). Deep learning: Technical introduction. arXiv preprint. <https://doi.org/10.48550/arXiv.1709.01412>
- Gans, N., Koole, G. ve Mandelbaum, A. (2003). Telephone call centers: a tutorial and literature review. *Manufacturing and Service Operations Management*, 5(2), 79–141. <https://doi.org/10.1287/msom.5.2.79.16071>
- Godfrey, L. B. (2018). *Parameterizing and aggregating activation functions in deep neural networks* [Doktora Tezi]. University of Arkansas.
- Goyal, S. ve Benjamin, P. (2014). Object recognition using deep neural networks: A survey. arXiv preprint. <https://doi.org/10.48550/arXiv.1412.3684>
- Gustineli, M. (2022). A survey on recently proposed activation functions for Deep Learning. arXiv preprint. <https://doi.org/10.48550/arXiv.2204.02921>
- Harvey, D. E., Hogan, S. M. ve Payseur, J. Y. (1991). Call center solutions. *AT&T Technical Journal*, 70(5), 36–44. <https://doi.org/10.1002/j.1538-7305.1991.tb00128.x>
- Ibrahim, R. ve L'Ecuyer, P. (2013). Forecasting call center arrivals: Fixed-effects, mixed-effects, and bivariate models. *Manufacturing ve Service Operations Management*, 15(1), 72–85. <https://doi.org/10.1287/msom.1120.0405>
- Jansen, A., & Callaghan, C. W. (2014). Call centre job differences. *Mediterranean Journal of Social Sciences*, 5(20), 466-478. <https://doi.org/10.5901/mjss.2014.v5n20p466>
- Kadioglu, M. A. ve Alatas, B. (2023). Enhancing Call Center Efficiency: Data Driven Workload Prediction and Workforce Optimization. *The Eurasia Proceedings of*

- Science Technology Engineering and Mathematics*, 24, 96–100.
<https://doi.org/10.55549/epstem.1406245>
- Kaya, Ç. ve Deniz, A. (2021). Çağrı merkezlerinde iş yükünün işte tükenmişlik duygusu üzerindeki etkisi. *Journal of Life Economics*, 8(1), 81–92.
<https://doi.org/10.15637/jlecon.8.1.08>
- Keser, A. (2006). Çağrı merkezi çalışanlarında iş yükü düzeyi ile iş doyumunu ilişkisinin araştırılması. *Kocaeli Üniversitesi Sosyal Bilimler Dergisi*, (11), 100–119.
<https://dergipark.org.tr/tr/download/article-file/251995>
- Klassen, K. J. ve Rohleder, T. R. (2001). Combining operations and marketing to manage capacity and demand in services. *Service Industries Journal*, 21(2), 1–30.
<https://doi.org/10.1080/714005019>
- Koole, G. M. ve Li, S. (2023). A practice-oriented overview of call center workforce planning. *Stochastic Systems*, 13(4), 479–495.
<https://doi.org/10.1287/stsy.2021.0008>
- Lipton, Z. C., Berkowitz, J. ve Elkan, C. (2015). A critical review of recurrent neural networks for sequence learning. arXiv preprint.
<https://doi.org/10.48550/arXiv.1506.00019>
- Moreira-Matias, L., Nunes, R., Ferreira, M., Mendes-Moreira, J. ve Gama, J. (25-27 Haziran 2014). *On Predicting a Call Center's Workload: A Discretization-Based Approach* [Bildiri Özeti]. Foundations of Intelligent Systems: 21st International Symposium, ISMIS 2014, Proceedings, Roskilde, Denmark.
https://doi.org/10.1007/978-3-319-08326-1_59
- Nag, K. ve Helal, M. (10 Aralık 2017). *Evaluating erlang C and erlang A models for staff optimization: A case study in an airline call center* [Bildiri Özeti]. 2017 IEEE International Conference on Industrial Engineering and Engineering Management (IEEM), Singapore. <https://www.ijerd.com/paper/vol18-issue2/D18022128.pdf>
- Nøkland, A. (2016). *Direct feedback alignment provides learning in deep neural networks* [Bildiri Özeti]. Proceedings of the 30th International Conference on

- Neural Information Processing Systems (NIPS 2016), Barcelona.
https://proceedings.neurips.cc/paper_files/paper/2016/file/d490d7b4576290fa60eb31b5fc917ad1-Paper.pdf
- Ortakaya, S. (2019). *Yapay sinir ağıları yöntemi ile çağrı merkezi çalışanlarının performanslarının tahmin edilmesi* [Yüksek Lisans Tezi]. Van Yüzüncü Yıl Üniversitesi.
- Otto, A. S., Szymanski, D. M. ve Varadarajan, R. (2020). Customer satisfaction and firm performance: insights from over a quarter century of empirical research. *Journal of the Academy of Marketing Science*, 48(3), 543–564.
<https://doi.org/10.1007/s11747-019-00657-7>
- Öztemel, E. (2003). *Yapay sinir ağıları*. PapatyaYayincilik.
- Stathopoulos, G. (2011). *Application of Recognition Input Squinting and Error-Correcting Output Coding to Convolutional Neural Networks* [Yüksek Lisans Tezi]. Concordia University.
- van de Laar, B. (2007). *Call Center Mathematics* [Lisans Bitirme Tezi]. Eindhoven University of Technology.
- van den Berg, H. L. (2005). *Verkeersafwikkeling op het digitale wegennet*. University of Twente.
- Wang, H. ve Raj, B. (2015). A survey: Time travel in deep learning space: An introduction to deep learning models and how deep learning models evolved from the initial ideas. arXiv preprint. <https://doi.org/10.48550/arXiv.1510.04781>
- Yegnanarayana, B. (2009). *Artificial neural networks*. PHI Learning Pvt. Ltd..
- Yilmaz, F. M. (2023). *Employing Deep Learning Approaches for Financial Time Series Analysis* [Yüksek Lisans Tezi]. Dokuz Eylül University.
- Yin, W., Kann, K., Yu, M. ve Schütze, H. (2017). Comparative study of CNN and RNN for natural language processing. arXiv preprint. <https://doi.org/10.48550/arXiv.1702.01923>

Yin, Y. (2018). *Random neural networks for deep learning* [Doktora Tezi]. Imperial College London.

