



**T.C.
BURSA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**ÇOK KRİTERLİ KARAR VERME VE YAPAY ZEKA TEKNİKLERİ İLE BULUT
SERVİSİ SEÇİMİ**

YÜKSEK LİSANS TEZİ

Pınar Simay ERGÜN

Endüstri Mühendisliği Anabilim Dalı

Endüstri Mühendisliği Tezli Yüksek Lisans Programı

OCAK 2025

T.C.

BURSA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

ÇOK KRİTERLİ KARAR VERME VE YAPAY ZEKA TEKNİKLERİ İLE BULUT
SERVİSİ SEÇİMİ

YÜKSEK LİSANS TEZİ

Pınar Simay ERGÜN

(21435025024)

ORCID: 0000-0002-2391-4716

Endüstri Mühendisliği Anabilim Dalı
Endüstri Mühendisliği Tezli Yüksek Lisans Programı

Tez Danışmanı: Doç. Dr. Hasan ŞAHİN

ORCID: 0000-0002-8915-000X

OCAK 2025

BTÜ, Lisansüstü Eğitim Enstitüsü'nün 21435025024 numaralı Yüksek Lisans Öğrencisi Pınar Simay ERGÜN, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı "ÇOK KRİTERLİ KARAR VERME VE YAPAY ZEKA TEKNİKLERİ İLE BULUT SERVİSİ SEÇİMİ" başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Doç. Dr. Hasan ŞAHİN**
Bursa Teknik Üniversitesi

Jüri Üyeleri : **Doç. Dr. Hasan ŞAHİN**
Bursa Teknik Üniversitesi

Doç Dr. Yunus DEMİR
Bursa Teknik Üniversitesi

Doç Dr. Abdulkadir ATALAN
Çanakkale Onsekiz Mart Üniversitesi

Teslim Tarihi **: 9 Ocak 2025**
Savunma Tarihi **: 11 Şubat 2025**



20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, Bursa Teknik Üniversitesi’nin aboneliği olduğu intihal yazılım programı kullanılarak Lisansüstü Eğitim Enstitüsü’nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.

İNTİHAL BEYANI

Bu tezde görsel, işitsel ve yazılı biçimde sunulan tüm bilgi ve sonuçların akademik ve etik kurallara uyularak tarafımdan elde edildiğini, tez içinde yer alan ancak bu çalışmaya özgü olmayan tüm sonuç ve bilgileri tezde kaynak göstererek belgelediğimi, aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim.

Öğrencinin Adı Soyadı: Pınar Simay Ergün

İmzası:

ÖNSÖZ

Yüksek lisans eğitimim ve tez çalışması süresince ilgisini, bilgisini ve desteğini esirgemeyen

değerli danışman hocam Doç. Dr. Hasan Şahin'e,

Tez çalışmamda beni destekleyen ve zaman ayıran değerli hocam Doç. Dr. Abdülkadir Atalan'a

Eğitim sürecimde maddi-manevi yanımda olan, tüm başarılarımın en büyük mimarı anneme ve babama teşekkürlerimi sunarım.

Ocak 2025

Pınar Simay Ergün

(Endüstri Mühendisi)

İÇİNDEKİLER

Sayfa

ÖNSÖZ	vi
İÇİNDEKİLER	vii
KISALTMALAR	ix
SEMBOLLER	xi
ÇİZELGE LİSTESİ	xii
ŞEKİL LİSTESİ	xiii
ÖZET	xiv
SUMMARY	xv
1. GİRİŞ	1
1.1. Tezin Amacı ve Kapsamı	1
1.2. Problem Tanımı	1
1.3. Araştırmanın Önemi	1
1.4. Yöntem ve Araştırma Soruları	2
1.5. Tezin Yapısı	2
2. BULUT BİLİŞİM TEKNOLOJİSİ	3
2.1. Bulut Bilişim Kavramı ve Özellikleri	4
2.2. Bulut Servis Modelleri (IaaS, PaaS, SaaS).....	4
2.3. Bulut Bilişim Dağıtım Modelleri	5
2.4. Bulut Servis Sağlayıcıları ve Pazar	6
2.5. Bulut Bilişimde Karar Verme Problemleri.....	8
3. LİTERATÜR ARAŞTIRMASI	9
3.1 Çok Kriterli Karar Verme ÇKKV Yöntemleri	9
3.2 Yapay Zeka Teknikleri	17
3.3 Entegre Yöntemler ve Uygulamaları.....	20
3.4 Genel Değerlendirme	20
4. ÇOK KRİTERLİ KARAR VERME (ÇKKV) YÖNTEMLERİ	21
4.1. Çok Kriterli Karar Verme Kavramı.....	21
4.2. ÇKKV Yöntemleri ve Teknikleri	21
4.2.1. AHP.....	21
4.2.2. TOPSIS	23
4.2.3. Diğer ÇKKV yöntemleri	25
4.3. Bulut Servisi Seçiminde ÇKKV Uygulamaları.....	26
4.4 Duyarlılık Analizi	28

5. YAPAY ZEKA TEKNİKLERİ VE BULUT SERVİSİ SEÇİMİ.....	29
5.1. Yapay Zeka Kavramı.....	29
5.2. Bulut Servis Seçiminde Yapay Zeka Yöntemleri.....	29
5.2.1. Makine öğrenmesi.....	29
5.2.1.1 Denetimli öğrenme	30
5.2.1.2 Denetimsiz öğrenme	31
5.2.3. Yapay sinir ağları	32
5.2.4. Genetik algoritmalar.....	32
5.3 Doğruluk ve Hata Performansı Ölçümü.....	33
5.4. Regresyon Modeli Genel Performans Değerlendirmesi.....	33
5.5. ANOVA.....	34
5.6. Yapay Zeka Tekniklerinin ÇKKV ile Entegrasyonu	35
6. BULUT SERVİSİ SEÇİMİ İÇİN ÖNERİLEN YÖNTEM	36
6.1. Yöntemin Tanıtımı	36
6.2. Yöntemin Uygulama Adımları	36
6.3. Örnek Uygulama ve Sonuçları	37
7. UYGULAMA: BULUT SERVİSİ SEÇİM SÜRECİ	39
7.1. Verilerin Toplanması ve Hazırlanması.....	39
7.2. ÇKKV ve Yapay Zeka Yöntemlerinin Uygulanması.....	41
7.3. Uygulama ve Sonuçları	42
7.3.1. Uygulama	42
7.3.2. ÇKKV yöntemlerinin uygulanması.....	42
7.3.3. Yapay zeka destekli optimizasyon	45
7.3.3.1. Makine öğrenmesi.....	45
7.3.4 Duyarlılık analizi sonuçları	56
7.3.5. Karar ve uygulama	57
8. SONUÇLAR VE ÖNERİLER	59
8.1. Bulguların Değerlendirilmesi	59
8.1.1. ÇKKV yöntemlerinin katkısı	59
8.1.2 Yapay zeka yöntemlerinin rolü	59
8.1.3. Yöntemlerin performansı	60
8.2. Genel Değerlendirme.....	60
8.3. Yöntemin Avantajları ve Sınırlamaları	60
8.4. Gelecek Çalışmalar İçin Öneriler	61
KAYNAKÇA	63
ÖZGEÇMİŞ.....	69

KISALTMALAR

AAS	: Analitik Ağ Süreci
AHP	: Analitik Hiyerarşi Prosesi
ANP	: Analytic Network Process
ANP-COPRAS	: Analytic Network Process - Complex Proportional Assessment
ARAS	: Additive Ratio Assessment
AWS	: Amazon Web Services
BAHP	: Bulanık Analitik Hiyerarşi Süreci
BAHP-COPRAS	: Best Alternative for Hierarchical Process - Complex Proportional Assessment
BAHS	: Bulanık Analitik Hiyerarşi Süreci
CODAS	: Combinative Distance-based Assessment
COPRAS	: Complex Proportional Assessment
CRISP-DM	: Cross-Industry Standard Process for Data Mining
ÇKKV	: Çok Kriterli Karar Verme
DVM	: Destek Vektör Makineleri
DVR	: Destek Vektör Regresyonu
EDAS	: Evaluation based on Distance from Average Solution
ELECTRE	: Elimination and Choice Expressing Reality
GA	: Genetik algoritmalar
GCP	: Google Cloud Platform
IaaS	: Infrastructure as a Service
KA	: Karar Ağacı
KNN	: K-En yakın Komşu
LR	: Lojistik Regresyon

MABAC	: Multi-Attributive Border Approximation area Comparison
MACBETH	: Measuring Attractiveness by a Categorical Based Evaluation Technique
MAE	: Mean Absolute Error
MAPE	: Mean Absolute Percentage Error
MAUT	: Multi Attribute Utility Theory
ML	: Makine öğrenmesi
MOORA	: Multi-Objective Optimization on the Basis of Ratio Analysis
M-TOPSIS	: Modified Technique for Order of Preference by Similarity to Ideal Solution
ÖİO	: Öğrenci İşleri Otomasyonu
ÖYS	: Öğrenci Yönetim Sistemi
PaaS	: Platform as a Service
PROMETHEE	: Preference Ranking Organization Method for Enrichment Evaluations
RMSE	: Root Mean Square Error
RO	: Rastgele Orman
ROC	: Receiver Operating Characteristic
SaaS	: Software as a Service
STK	: Sivil Toplum Kuruluşları
SWARA	: Step-Wise Weight Assessment Ratio Analysis
TOPSIS	: Technique for Order Preference by Similarity to Ideal Solution
VIKOR	: VlseKriterijumska Optimizacija I Kompromisno Raspoređivanje
WEDBA	: Weight Evaluation Based on Distance from Average
YSA	: Yapay Sinir Ağları

SEMBOLLER

- S_{i+} : Uygun Ayırım
 S_{i-} : Negatif Uygun Ayırım
 C_i : Uygun Çözümüne Göreli Yakınlık



ÇİZELGE LİSTESİ

	<u>Sayfa</u>
Çizelge 4. 1 : Önem Değerlerine Göre Dilsel Değerler.....	22
Çizelge 7. 1 : Ölçütlerin Açıklamaları	40
Çizelge 7. 2 : Normalleştirilmiş Matris	43
Çizelge 7. 3 : Ağırlıklı Değerler ile Normalleştirilmiş Matris Çarpımı.....	43
Çizelge 7. 4 : Worst Best Değerlerinin Hesaplanması	44
Çizelge 7. 5 : Sağlayıcıların İdeal Çözüme Olan Uzaklığı.....	44
Çizelge 7. 6 : ÇKKV Yöntemi Sonuçları Genel Gösterimi.....	45
Çizelge 7. 7 : Model Özeti.....	46
Çizelge 7. 8 : ANOVA Sonuçları	47

ŞEKİL LİSTESİ

Sayfa

Şekil 7. 1: Bulut Hizmet Sağlayıcısının Değerlendirilmesi İçin Hiyerarşik Yapı	39
Şekil 7. 2: Knn Algoritması Confusion Matrix	50
Şekil 7. 3: Random Forest Algoritması Confusion Matrix.....	50
Şekil 7. 4: Neural Network Algoritması Confusion Matrix	51
Şekil 7. 5: Gradient Boosting Algoritması Confusion Matrix.....	51
Şekil 7. 6: Pareto Grafiği	52
Şekil 7. 7: Orange Uygulaması Kategorik Veri Kullanımı.....	53
Şekil 7. 8: Orange Uygulaması Nümerik Veri Kullanımı	53
Şekil 7. 9: Predictions Çıktısı	54
Şekil 7. 10: MSE, RMSE, MAE, MAPE ve R2 Değerleri	54
Şekil 7. 11: Duyarlılık Analizi Sıralama Sonucu	56

ÇOK KRİTERLİ KARAR VERME VE YAPAY ZEKA TEKNİKLERİ İLE BULUT SERVİSİ SEÇİMİ

ÖZET

Bu tez, bulut servisi seçim sürecinde Çok Kriterli Karar Verme (ÇKKV) yöntemleri ve yapay zeka tekniklerinin kullanımını incelemektedir. Günümüzde bulut bilişim, işletmelerin dijital dönüşümünde kritik bir rol oynamaktadır ve doğru bulut servisi sağlayıcısını seçmek, organizasyonların operasyonel verimliliği için önemlidir. Ancak, bulut servisi seçiminde çok sayıda kriter ve alternatif bulunması, karar verme sürecini karmaşık hale getirmektedir. Bu çalışma, en uygun bulut hizmet sağlayıcısının belirlenmesi amacıyla gerçekleştirilmiştir. Bilgi teknolojileri alanında çalışan 6 uzman ile yapılan beyin fırtınası ve literatür taraması sonucunda, bulut hizmet sağlayıcısı seçiminde önemli olan 8 temel ölçüt Maliyet, Kullanıcı Dostu Arayüz ve Yönetim Araçları, Veri Yedekleme ve Kurtarma, Güvenlik, Entegrasyon, Destek ve Müşteri Hizmetleri, Performans, Uyumluluk belirlenmiştir.

Tezde, bulut servisi seçim sürecinde ÇKKV yöntemlerinden AHP ve TOPSIS kullanılmıştır. AHP ile kriter ağırlıkları belirlenerek TOPSIS yöntemi ile en uygun bulut hizmet sağlayıcısı seçilmiştir. Bulut hizmet sağlayıcısı tahmininde makine öğrenmesi yöntemleri karşılaştırmalı olarak incelemiştir. Çalışmada, k-Nearest Neighbors, Random Forest, Neural Network ve Gradient Boosting algoritmaları tercih edilmiştir. Sonuçlara göre, MAE, MAPE ve RMSE kriterlerine göre en iyi tahmin yöntemi olarak kNN belirlenmiştir. Bu yaklaşım, karar vericilere, kriterler arasındaki dengeyi sağlamak ve büyük veri kümeleri üzerinde daha doğru analizler yapmak için kapsamlı bir çerçeve sunar. ÇKKV yöntemleri, kriterlerin önem derecelerini ve alternatiflerin sıralamasını belirlerken; yapay zeka teknikleri tahminleme yapar.

Araştırmanın uygulama kısmında, bulut servis sağlayıcılarının değerlendirilmesi için veri toplama, ÇKKV ve yapay zeka yöntemlerinin uygulanması adımları detaylı olarak ele alınmıştır. Elde edilen sonuçlar, önerilen yaklaşımın, bulut servisi seçiminde daha hızlı, doğru ve etkili sonuçlar sağladığını göstermektedir.

Sonuç olarak, bu tez bulut servisi seçimi gibi karmaşık karar verme süreçlerinde ÇKKV ve yapay zeka tekniklerinin nasıl kullanılacağına dair değerli bir yöntem sunmakta ve bu yaklaşımın avantajlarını, sınırlamalarını belirlemekte, ayrıca gelecekteki çalışmalar için önerilerde bulunmaktadır. Bu yaklaşım, işletmelerin bulut hizmetlerini daha etkin bir şekilde seçmelerine yardımcı olarak, daha verimli ve rekabetçi bir dijital ortam yaratmalarına katkı sağlamayı amaçlamaktadır.

Anahtar Kelimeler: Analitik hiyerarşi süreci (AHP), Bulut servisi seçimi, Çok kriterli karar verme (ÇKKV), Makine öğrenmesi, TOPSIS, Yapay zeka

MULTI-CRITERIA DECISION-MAKING AND CLOUD SERVICE SELECTION WITH ARTIFICIAL INTELLIGENCE TECHNIQUES

SUMMARY

This thesis investigates using multi-criteria decision-making (MCDM) methods and artificial intelligence techniques in the cloud service selection process. Today, cloud computing plays a critical role in the digital transformation of businesses, and selecting the right cloud service provider is vital for the operational efficiency of organizations. However, numerous criteria and alternatives in cloud service selection make the decision-making process complex. This study aims to identify the most suitable cloud service provider. Through brainstorming with six experts in information technology and a literature review, eight key criteria were identified as important in selecting a cloud service provider: Cost, User-Friendly Interface and Management Tools, Data Backup and Recovery, Security, Integration, Support and Customer Services, Performance, and Compliance.

This thesis employed the AHP (Analytic Hierarchy Process) and TOPSIS (Technique for Order of Preference by Similarity to Ideal Solution) methods from MCDM techniques in the cloud service selection process. AHP was used to determine the criteria weights, and TOPSIS was applied to select the most suitable cloud service provider. Machine learning methods for predicting cloud service providers were also compared. The k-Nearest Neighbors, Random Forest, Neural Network, and Gradient Boosting algorithms were selected for this comparison. According to the results, kNN was identified as the best prediction method based on the MAE, MAPE, and RMSE criteria. This approach provides a comprehensive framework for decision-makers to balance criteria and perform more accurate analyses on large datasets. While MCDM methods determine the importance of criteria and rank the alternatives, artificial intelligence techniques are used for prediction.

In the application section of the study, the steps for data collection, the application of MCDM, and artificial intelligence methods for evaluating cloud service providers were discussed in detail. The results show that the proposed approach provides faster, more accurate, and effective outcomes in cloud service selection.

In conclusion, this thesis offers a valuable methodology for utilizing MCDM and artificial intelligence techniques in complex decision-making processes such as cloud service selection. It highlights the advantages and limitations of this approach and provides recommendations for future research. The methodology aims to assist businesses in selecting cloud services more effectively, creating a more efficient and competitive digital environment.

Keywords: Analytic hierarchy process (AHP), Artificial intelligence, Cloud service selection, Machine learning, Multi-criteria decision making (MCDM), TOPSIS



1. GİRİŞ

1.1. Tezin Amacı ve Kapsamı

Bu tezin amacı, bulut bilişim teknolojileri kapsamında doğru servis sağlayıcısını seçmek için kullanılacak yöntemler geliştirmektir. Bulut servis sağlayıcıları arasında seçim yapmak, maliyet, güvenlik, performans, uyumluluk gibi pek çok farklı kriterin dikkate alınmasını gerektiren karmaşık bir süreçtir. Bu tezde, Çok Kriterli Karar Verme (ÇKKV) yöntemleri ile yapay zeka teknikleri entegre edilerek, kullanıcıların farklı kriterler doğrultusunda en uygun bulut servisini seçmelerine yardımcı olacak bir model önerilmektedir. Kapsam olarak, bulut bilişim servislerinin tanımı, ÇKKV yöntemleri, yapay zeka teknikleri ve bu iki metodolojinin entegrasyonu üzerinde durulmaktadır.

1.2. Problem Tanımı

Günümüzde pek çok işletme ve birey, çeşitli ihtiyaçlarını karşılamak amacıyla bulut servis sağlayıcılarını kullanmaktadır. Ancak her sağlayıcının sunduğu hizmetler, güvenlik önlemleri, fiyatlandırma politikaları ve performans düzeyleri farklıdır. Bu çeşitlilik, doğru servisi seçmeyi zorlaştırmaktadır. Bulut servisi seçimi, birden fazla kriterin aynı anda dikkate alınmasını gerektiren bir karar verme problemidir. Geleneksel yöntemler bu problemin çözümünde yetersiz kalabilir. Bu bağlamda, ÇKKV yöntemleri ile yapay zeka tekniklerinin birleşimi, daha etkin ve güvenilir sonuçlar elde etmeye imkan sunmaktadır. Bu tezde, bu problemin nasıl aşılabileceği araştırılmaktadır.

1.3. Araştırmanın Önemi

Bulut servis sağlayıcıları arasında doğru seçimi yapmak, bir işletmenin operasyonel verimliliği ve maliyet avantajı açısından büyük önem taşır. Yanlış bir seçim, yüksek maliyetler, performans düşüklüğü ve güvenlik açıkları gibi ciddi sorunlara yol açabilir. Bu nedenle, doğru ve sistematik bir karar verme süreci gereklidir. Araştırmanın önemi,

ÇKKV yöntemleri ve yapay zeka tekniklerinin bulut servis seçimi gibi karmaşık bir problemde nasıl kullanılabileceğini göstermek ve bu alanda literatüre katkı sağlamaktır. Bu çalışma, karar vericilerin daha bilinçli ve güvenilir seçimler yapmalarını sağlarken, aynı zamanda akademik ve pratik açıdan değerli bir yaklaşım sunmaktadır.

1.4. Yöntem ve Araştırma Soruları

Bu tezde kullanılan yöntem, ÇKKV ve yapay zeka tekniklerinin entegrasyonuna dayanmaktadır. Çalışma, çeşitli bulut servis sağlayıcılarının farklı kriterlere göre değerlendirilmesi sürecinde ÇKKV yöntemlerinden (AHP, TOPSIS) yararlanırken, yapay zeka teknikleri ile bu sürecin hızını ve doğruluğunu artırmayı hedeflemektedir. Araştırmada cevaplanması gereken temel sorular şunlardır:

- Bulut servis sağlayıcılarının seçiminde en önemli kriterler nelerdir?
- ÇKKV yöntemleri ve yapay zeka teknikleri bulut servis seçimi sürecine nasıl entegre edilebilir?
- Önerilen model, mevcut yöntemlerle karşılaştırıldığında ne kadar etkin ve güvenilirdir?

1.5. Tezin Yapısı

Tez, toplamda yedi bölümden oluşmaktadır. İlk bölümde giriş yapılmış, tezin amacı, kapsamı, problemi, önemi ve yöntemleri açıklanmıştır. İkinci bölümde bulut bilişim teknolojileri ve bulut servis sağlayıcıları incelenmiştir. Üçüncü bölümde ÇKKV yöntemleri detaylandırılmıştır. Dördüncü bölümde yapay zeka teknikleri ve bu tekniklerin ÇKKV ile entegrasyonu üzerinde durulmuştur. Beşinci bölümde önerilen model ve metodoloji tanıtılmış, altıncı bölümde ise örnek bir uygulama sunulmuştur. Son olarak, yedinci bölümde sonuçlar değerlendirilmiş ve gelecekte yapılabilecek çalışmalar hakkında önerilerde bulunulmuştur.

2. BULUT BİLİŞİM TEKNOLOJİSİ

Bulut bilişim gelişimi devam eden bir süreç olduğundan genel bir tanım yapmak güçtür. Bilişim sektörü içerisindeki uzmanlar bulut bilişim ile ilgili farklı tanımlamalar yapmaktadır. Bu tanımlar şu şekilde toparlanabilir: Bulut, çok sayıda bilgisayarın birleşimi ile oluşan veri merkezlerini içeren, kullanıcıların kaynaklara internet üzerinden erişimine olanak sağlayan bir bilgi işlem ağıdır.

Bulut bilişim, işlem ve depolama kaynaklarının dağıtımını sağlayan, kullanıcıların internet aracılığıyla bilgilere erişmesini, paylaşmasını ve üzerinde ortak çalışmalar yapmalarını mümkün kılan bir teknolojidir. Bu teknoloji, bilgisayarlar için gerekli programların, kurulum yapmadan internet üzerinden erişilmesini sağlayarak kullanılabilmesini amaçlar. Bulut bilişim, bilgisayarların kapasitelerini artırarak, kullanıcıların çeşitli yazılım ve hizmetlere internet üzerinden ulaşmalarına imkân tanır. Ayrıca, bulut bilişim, bilgi teknolojileri hizmetlerinin internet tabanlı olarak sunulmasına yönelik yeni bir dağıtım ve destek modelidir.

Bu model, uzak cihazlar ve sunucu hizmetlerine internet üzerinden kolay erişim sağlama fikrinin bir sonucudur. Tipik bir bulut bilişim uygulaması, bir sunucuda bulunan veri ve yazılımlara, web servisleri ya da web tarayıcı benzeri yazılımlar aracılığıyla erişimi mümkün kılar. Web'in ikinci büyük dalgası olarak nitelendirilen bu teknoloji, iş dünyasında önemli bir rol oynayacak ve gelecekteki gelişmeleri etkileyecek bir kavramdır. Bulut bilişim, internet üzerinden sunulan bilgi teknolojileri hizmetlerinin kullanımını ve geliştirilmesini ifade eder.

Bulut bilişim, gerçek zamanlı ve internet tabanlı teknoloji servisleri ile kaynakları tanımlayan bir kavramdır. Bu model, depolama ve veri işleme yükünü istemci bilgisayarlarından alıp, uzak sunuculara yönlendiren bir yapıya sahiptir. Sunucularda barındırılan ve işleme tabi tutulan veriler, ihtiyaç duyulduğunda internet üzerinden istemci cihazlara iletilir. Verilere, dünyanın her yerinden ve internete bağlı herhangi bir cihaz aracılığıyla ulaşılabilir.

2.1. Bulut Bilişim Kavramı ve Özellikleri

Bulut bilişim, internet üzerinden sunulan ve kullanıcıların bilgi işlem kaynaklarına uzak bir lokasyondan erişim sağlayabildiği bir bilgi işlem modelidir. Bulut bilişim, fiziksel donanım ve yazılım kaynaklarının, kullanıcıların ihtiyaçlarına göre ölçeklendirilebilir bir biçimde sunulmasını mümkün kılar. Kısaca, kullanıcılar kendi donanımına sahip olmak yerine, uzaktan erişimle çeşitli hizmetleri ve altyapıları kiralarak kullanır. Bulut bilişimin temel özellikleri şunlardır:

- *Ölçeklenebilirlik:* Kullanıcılar ihtiyaçlarına göre hizmet kaynaklarını artırabilir veya azaltabilir.
- *Talep Üzerine Hizmet:* Kullanıcılar sadece ihtiyaç duydukları kadar kaynağı tüketir ve kullandıkları kadar ödeme yapar.
- *Ubiquity (Her Yerden Erişim):* İnternet bağlantısı olan her yerden bulut hizmetlerine erişim mümkündür.
- *Esneklik:* Bulut hizmetleri, çeşitli iş yüklerine göre dinamik olarak optimize edilebilir.
- *Paylaşımlı Kaynak Kullanımı:* Bulut altyapıları genellikle çok kullanıcı (multi-tenant) olup, kaynaklar birden fazla kullanıcı arasında paylaşılır.

2.2. Bulut Servis Modelleri (IaaS, PaaS, SaaS)

Bulut bilişim hizmetleri genel olarak üç temel modelde sunulmaktadır:

- *IaaS (Infrastructure as a Service):* Altyapı hizmetleri olarak bilinen IaaS, kullanıcıların sanal makineler, depolama ve ağ gibi fiziksel donanım kaynaklarına uzaktan erişim sağlamalarını mümkün kılar. Bu modelde kullanıcı, işletim sistemi, yazılım ve veri üzerinde tam kontrole sahip olurken, fiziksel altyapı sağlayıcı tarafından yönetilir. Örnek: Amazon Web Services (AWS), Microsoft Azure.
- *PaaS (Platform as a Service):* PaaS, uygulama geliştirme ve çalıştırma süreçlerini destekleyen bir platform sağlar. Kullanıcılar, altyapıyı yönetmek zorunda kalmadan yazılım geliştirme süreçlerine odaklanabilirler. Örnek: Google App Engine, Heroku.

- *SaaS (Software as a Service)*: SaaS, kullanıcıların internet üzerinden uygulamalara erişim sağlamalarına olanak tanır. Bu modelde yazılım ve altyapı sağlayıcı tarafından yönetilir ve kullanıcılar yalnızca uygulamanın ara yüzüne erişirler. Örnek: Google Workspace, Salesforce.

2.3. Bulut Bilişim Dağıtım Modelleri

Bulut hizmetleri, bulut bilişim dağıtım modelleri aracılığıyla kullanıcılara sunulmaktadır. Bu modeller, fiziksel ya da sanal kaynakların nasıl kontrol edileceğini ve paylaşılacağını tanımlar. Her dağıtım türünün kendine has özellikleri ve avantajları bulunmaktadır. Bir dağıtım modelinin seçilmesi, müşteri gereksinimlerinin ve beklentilerinin net bir şekilde belirlenmesini ve anlaşılmasını gerektirir.

Bulut dağıtım modelleri; genel bulut, özel bulut, topluluk bulutu ve hibrit bulut olmak üzere dört ana kategoride incelenir:

Genel bulut dağıtım modelinin temel prensibi, kaynakların ve hizmetlerin erişilebilir olması ve genel kullanıma sunulmasıdır. Bu model, geniş bir kullanıcı kitlesine erişim sağlayarak en az kısıtlamaya sahip olan dağıtım türüdür. Bilgi işlem kaynaklarının kontrolü, bulut hizmet sağlayıcısı ile kullanıcıların kendi tesislerinde gerçekleştirilebilir. Aksi belirtilmedikçe, bulut dağıtım terimi, sonraki bölümlerde genel bulut dağıtım modelini ifade eder.

Özel bulut, hizmetlerin yalnızca tek bir kuruluşun özel kullanımı için sağlandığı bir modeldir ve kaynaklar bu kuruluş tarafından kontrol edilir. Bu bulut modelinde, bulut hizmeti kullanıcıları birden fazla iş biriminden oluşabilir. Özel bulutun yönetimi, sahiplik ve operasyon sorumluluğu üçüncü bir tarafa devredilebilir, ayrıca fiziksel konum, hizmeti kullanacak kuruluşun kendi tesislerinde veya dışında olabilir. Özel bulutun avantajı, kullanımının yalnızca bir kuruluş veya yetkili kişiler tarafından kontrol edilmesi ve sınırların belirlenmiş olmasıdır.

Topluluk bulutu, belirli bir topluluğa ait kullanıcılar arasında paylaşılır ve yalnızca bu topluluk tarafından kullanılır. Bu tür bulut hizmetleri, benzer gereksinimlere ve ilişkilerle sahip olan kuruluşlar tarafından paylaşılır. Yönetim ve işletme, kuruluş içi ya da dışı olabilir. Topluluk bulutu, ortak endişelere sahip bir grup kullanıcı tarafından kullanılır, bu da onu genelden ayırır. Ayrıca, özel bulutlardan daha geniş bir

katılım oranına sahiptir. Paylaşılan endişeler, görevler, güvenlik gereksinimleri, politika ve uyumluluk gibi konuları içerebilir.

Hibrit bulut, genel, özel veya topluluk bulutlarının birleşiminden oluşan bir modeldir. Her bir bulut, kendi benzersiz varlık olarak kalır ancak birbirine bağlanarak birlikte çalışabilirlik, veri taşınabilirliği ve uygulama taşınabilirliği sağlanır. Hibrit bulutların sahipliği genellikle, bu bulut kurumlarının ilgili bölümlerini denetleyen kuruluşlar arasında paylaşılır. Örneğin, bir hibrit bulut, bir özel bulut ve bir genel bulut kombinasyonundan oluşabilir. Bu durumda, özel bulut kuruluşun kendi sahipliğinde olabilirken, genel bulut bulut hizmet sağlayıcısına ait olabilir. Hibrit bulut senaryoları, bulutlar arasında yük dengeleme veya ek hizmetler için genel bulut kaynaklarının kullanımını içerebilir.

Çoklu bulut, hibrit bulut dağıtım modelinin özel bir durumu veya bir uzantısı olarak değerlendirilebilir. Çoklu bulut, birden fazla genel bulut içerir ve aynı zamanda özel bulutları da kapsayabilir. Genel bulutların yaygınlaşması ile birlikte, çoklu bulut dağıtımlarının da artması beklenmektedir. Bu tür dağıtımlar, kullanıcıların coğrafi olarak farklı veri merkezlerine veya farklı bulut sağlayıcılarına dağılmasını destekler. Bazı coğrafi bölgelerde veri depolamayı sınırlayan düzenlemeler olabilir, bu nedenle uygulamaların, bir bulut sağlayıcısının kaybına karşı dayanıklı olması gerekir.

2.4. Bulut Servis Sağlayıcıları ve Pazar

Bulut bilişim pazarı hızla büyüyen ve küresel olarak genişleyen bir sektördür. Bu pazarda rekabet eden birçok büyük oyuncu bulunmaktadır. Başlıca bulut servis sağlayıcıları şunlardır:

- *Amazon Web Services (AWS)*: Dünya çapında en büyük bulut servis sağlayıcılarından biridir ve geniş bir hizmet yelpazesi sunmaktadır. AWS, esneklik, güvenilirlik ve yüksek performans ile tanınmaktadır.
- *Microsoft Azure*: Microsoft'un bulut bilişim platformu olan Azure, özellikle hibrit bulut çözümleri ile öne çıkmaktadır. Windows tabanlı uygulamalar ve hizmetlerle sıkı entegrasyon sağlar.

- *Google Cloud Platform (GCP):* Google Cloud, özellikle büyük veri ve yapay zeka hizmetleriyle bilinir. Gelişmiş analiz ve makine öğrenmesi araçları sunmaktadır.
- *Alibaba Cloud:* Asya-Pasifik bölgesinde büyük bir pazar payına sahip olan Alibaba Cloud, güçlü veri güvenliği ve depolama çözümleri sunar.
- *IBM Cloud:* Özellikle kurumsal düzeydeki kullanıcılar için karmaşık bulut çözümleri ve yapay zeka hizmetleri sunan IBM Cloud, güvenlik ve entegrasyon konusunda ön plana çıkar.
- *Oracle Cloud:* Oracle, özellikle veritabanı yönetim sistemleri ve kurumsal yazılımlar konusunda güçlüdür. Oracle Cloud, bu alanlarda gelişmiş hizmetler sunar.
- *Salesforce:* Özellikle CRM (müşteri ilişkileri yönetimi) yazılımı ile tanınan Salesforce, aynı zamanda bulut tabanlı platform hizmetleri de sunmaktadır.
- *DigitalOcean:* Genellikle geliştiriciler ve küçük işletmeler tarafından tercih edilen bulut hizmet sağlayıcısıdır. Basit ve hızlı çözüm sunduğu için popülerdir.
- *VMware Cloud:* VMware, sanallaştırma çözümleriyle tanınan bir firmadır. Bulut hizmetleri de sunarak özellikle işletmelere yönelik altyapı çözümleri sağlar.
- *Tencent Cloud:* VMware, sanallaştırma çözümleriyle tanınan bir firmadır. Bulut hizmetleri de sunarak özellikle işletmelere yönelik altyapı çözümleri sağlar.

Bu sağlayıcılar, büyük şirketlerden küçük işletmelere kadar geniş bir kullanıcı kitlesine hitap etmektedir. Her birinin sunduğu farklı hizmet ve özelliklerle sektördeki pek çok ihtiyaca cevap verir.

Bu büyük sağlayıcıların yanı sıra, daha küçük ve niş bulut servis sağlayıcıları da belirli sektörlere özel çözümler sunmaktadır. Pazarın hızlı büyümesi ve sürekli gelişen ihtiyaçlar, bulut sağlayıcıları arasındaki rekabeti artırmakta ve müşterilerin karar verme sürecini karmaşıklştırmaktadır.

2.5. Bulut Bilişimde Karar Verme Problemleri

Bulut servis sağlayıcıları arasında seçim yaparken, işletmeler ve bireyler birçok farklı kriteri dikkate almak zorundadır. Bu kriterler arasında maliyet, performans, güvenlik, veri yedekleme ve kurtarma, kullanım kolaylığı, teknik destek gibi unsurlar yer almaktadır. Ancak bu kriterlerin tamamını eş zamanlı olarak değerlendirmek oldukça zordur ve karar verme süreci karmaşıklaşır. Özellikle farklı sağlayıcıların sunduğu hizmetlerin teknik özellikleri ve fiyatlandırma modelleri arasındaki farklılıklar, bu seçimi daha da zorlaştırır.

Bulut servis sağlayıcıları arasında seçim yaparken karşılaşılan başlıca karar verme problemleri şunlardır:

- *Çok Kriterli Karar Verme:* Birden fazla faktörün (maliyet, güvenlik, performans vb.) aynı anda değerlendirilmesi gerektiğinden, bu süreç kompleks bir karar verme problemi haline gelir.
- *Veri Eksikliği ve Belirsizlik:* Servis sağlayıcıları arasındaki performans farkları, güvenlik önlemleri ve hizmet düzeyi taahhütleri her zaman net olmayabilir. Bu da belirsizlik yaratır ve karar verme sürecini olumsuz etkiler.
- *Farklı Kriterler Arasında Önem Dengesi:* Güvenlik gibi bazı kriterler belirli durumlarda daha kritik hale gelirken, maliyet ve performans gibi diğer kriterler farklı durumlarda öne çıkabilir. Bu kriterler arasında nasıl bir öncelik sırası kurulacağı belirsiz olabilir.

Bu problemler, bulut servisi seçimini karmaşık ve zaman alıcı bir süreç haline getirmekte, dolayısıyla ÇKKV yöntemleri ile yapay zeka tekniklerinin bu sürece dahil edilmesi ihtiyacı doğmaktadır.

3. LİTERATÜR ARAŞTIRMASI

Bu bölümde, bulut servisi seçiminde kullanılan ÇKKV ve yapay zeka tekniklerinin literatürdeki yeri ve uygulamaları incelenmiştir. ÇKKV ve yapay zeka tekniklerinin bulut hizmetleri seçim süreçlerindeki etkinliği ve uygulama alanları üzerine yapılmış çalışmalar derinlemesine ele alınmıştır.

3.1 Çok Kriterli Karar Verme Yöntemleri

Karar verme, mevcut alternatifler arasında amaçlara en uygun ve gerçekleştirilebilir olan bir ya da birkaç alternatifin seçilmesi sürecidir. Son yıllarda yapılan bilimsel araştırmalar, karmaşık ve belirsiz bir karar ortamında karar verme gerekliliğiyle karşılaşan bireylerin, bilgilerini ve deneyimlerini sistematik bir şekilde değerlendirerek en iyi sonuca nasıl ulaşılacağına dair yaklaşımlar geliştirmiştir. Bu bağlamda, karar vericilerin amaçlarını gerçekleştirebilmek için çeşitli alternatifler arasından seçtikleri ölçütlere göre analiz yaparak bir seçimde bulunmaları gerekmektedir.

ÇKKV karar bilimlerinin bir alt dalı olup, karar süreçlerinin belirlenen ölçütler doğrultusunda modellenmesi ve analiz edilmesini kapsar. Karar vericiler, sayılabilir ya da sayılamaz çok sayıda alternatiften oluşan bir küme içerisinde en az iki ölçüt dikkate alarak değerlendirme yaparlar. Bu sebeple ÇKKV yöntemleri, karar vericinin topladığı verileri analiz ederek, hedeflerine ulaşacak alternatifleri çeşitli ölçütlerle incelemesine ve en uygun seçeneği belirlemesine yardımcı olur.

ÇKKV yöntemleri, çok sayıda kriterin değerlendirilmesi gereken karar verme problemlerinde geniş bir uygulama alanına sahiptir. Saaty (1980) tarafından geliştirilen AHP, bu tür problemleri çözmek için yaygın olarak kullanılan bir tekniktir. AHP, karar vericilerin kriterler arasındaki önem derecelerini belirlemelerine ve alternatifleri sistematik bir şekilde değerlendirmelerine olanak tanır. Hwang ve Yoon

(1981) bu yöntemi çeşitli karar verme problemlerinde uygulamış ve AHP'nin karar destek sistemlerindeki etkinliğini vurgulamıştır.

TOPSIS yöntemi de ÇKKV süreçlerinde önemli bir rol oynamaktadır. Chen ve Chen (2019), TOPSIS yönteminin bulut servisi seçiminde nasıl uygulandığını ve bu yöntemin alternatiflerin ideal çözüme olan benzerliğine göre sıralama sağladığını belirtmiştir. Deng ve Zhang (2021), AHP ve fuzzy TOPSIS yöntemlerini entegre ederek bulut servislerinin değerlendirilmesinde daha hassas sonuçlar elde edilmesini sağlamışlardır.

Ek olarak, Tzeng ve Huang (2011), ÇKKV yöntemlerinin genel prensiplerini ve uygulama alanlarını kapsamlı bir şekilde ele almıştır. Mendoza ve Martins (2006) ise çevresel yönetim uygulamalarında ÇKKV yöntemlerinin kullanımını incelemiş ve bu yöntemlerin çeşitli disiplinlerde nasıl uygulandığını açıklamıştır.

Wang Chen ve diğ. (2016), çevresel konulara yönelik artan kamu farkındalığı ve hükümet düzenlemelerinin zorlukları nedeniyle, yeşil tedarik zinciri yönetiminin (SCM) şirketlerin çevresel sürdürülebilirlik hedeflerine ulaşmasında önemli bir konu haline geldiğini belirtmişlerdir. Tedarikçi seçimi, yeşil SCM oluşturmanın temel operasyonel görevlerinden biridir. En uygun tedarikçileri belirlemek için, karar verme sürecinde birçok ekonomik ve çevresel kriterin dikkate alınması gerekmektedir. Birçok araştırma, tedarikçi seçiminde maliyet, kalite ve teslim süresi gibi ekonomik kriterleri kullanmışken, sadece bazı çalışmalar çevresel faktörleri göz önünde bulundurmıştır. Bu çalışma, hem ekonomik hem de çevresel kriterleri içeren kapsamlı bir bulanık ÇKKV yaklaşımı önermektedir. Önerilen yaklaşımdaki belirsiz ortamda, kriterlerin ağırlıklarını belirlemek için bulanık AHP kullanılmaktadır. Ayrıca, potansiyel tedarikçilerin değerlendirilmesi ve sıralanması için ideal çözüme benzerlikle performans sıralaması yapan bir bulanık teknik olan TOPSIS yöntemi uygulanmaktadır. Son olarak, önerilen yöntemin geçerliliği ve etkinliği, Luminans Geliştirme Filmi (LEF) endüstrisinde yapılan bir vaka çalışması ile gösterilmektedir.

Chowdhury ve Paul (2020), malzeme seçimi süreçlerinde ÇKKV yöntemlerinin uygulamaları üzerine metodik bir inceleme sunmaktadır. Malzeme seçimi için uygulanabilecek farklı ÇKKV yöntemlerinin anlaşılabilmesi adına, bazı ÇKKV araçları kısaca açıklanmıştır.

Stanujkić ve diğ. (2013), makalelerinde belirli ÇKKV yöntemlerinin Sırbistan bankalarını sıralama örneği üzerinden incelenmesini ele almışlardır. Bu çalışmanın amacı, bankaların sıralanmasında hangi yöntemin en uygun olduğunu belirlemek değildir. Bunun yerine amaç, farklı ÇKKV yöntemlerinin kullanımı ile bazen farklı alternatif sıralamaları ortaya çıkarabileceğini vurgulamaktır. Ayrıca makale, farklı yöntemlerle elde edilen sıralama sonuçlarının rastlantısal bir olay olmadığını, gerçekliği yansıttığını ve bu farklı sonuçların bazı nedenlere dayandığını belirtmeyi amaçlamaktadır.

Bhole ve Deshmukh (2018), tüm ÇKKV yöntemlerine dair bilgi sunarak, literatürde bu yöntemlerin farklı alanlarda nasıl uygulandığını açıklamaktadır. Çalışmanın amacı, ÇKKV yöntemlerini ve uygulamalarını tanıtmak ve çeşitli problemlere yönelik ÇKKV'nin doğasını anlamaktır. ÇKKV'nin farklı alanlardaki uygulaması, yeni araştırma alanları için bir bakış açısı kazandırır. İnceleme, farklı araştırmacılar tarafından ele alınan problemleri ve AHP, TOPSIS, MAUT gibi yöntemlerle çözüm bulma süreçlerini keşfetmeye yardımcı olur. AHP, TOPSIS ve MAUT, en yaygın kullanılan yöntemler arasında yer almakla birlikte, hibrit veya entegre yöntemler de konum, iflas, finans, atık su ve köprü inşaatı gibi çeşitli problemler için etkili çözümler sunmaktadır.

Dhurkari (2022), mevcut ÇKKV yöntemlerinde karşılaşılan pratik zorlukları eleştirel bir bakış açısıyla incelemiştir. Ayrıca, herhangi bir ÇKKV yönteminin yeteneklerini değerlendirmede kıyaslama karar durumunun önemli bir rol oynadığını vurgulamaktadırlar. Çoğu ÇKKV yöntemi, iki ana adımdan oluşmaktadır. İlk adımda, karar verici, problemin çeşitli kriterleri ve alternatifleri üzerinde tercihlerinin ne olduğunu belirler. İkinci adımda ise, bu tercihler bir araya getirilir. Birleştirilen sonuç, sıralama hesaplamalarında ve nihai seçimde kullanılır. Ancak, ÇKKV yönteminin önerileri, eğer karar vericinin gerçek tercihlerini yansıtmıyorsa ya da bu tercihler karar vericinin beklentilerine uygun şekilde birleştirilmiyorsa, yöntem başarısız sayılır. Bu çalışma, karar verme ile ilgili en son teorileri tartışırken, çok kriterli karar analizinin açıklayıcı yönlerini iyileştirmek adına üç önemli eğilim sunmaktadır.

Toloie-Eshlaghy ve Homayonfar (2011), çalışmalarında ÇKKV'nin temel teorileri, metodolojileri ve uygulamaları konusundaki en son gelişmeleri önde gelen uzmanların yaptığı en son durum incelemeleriyle birleştirmeyi amaçlamaktadır.

Sotoudeh-Anvari (2022), çalışmasında COVID-19'un çok boyutlu doğası ve sağlık ile sosyo-ekonomik sistemlerin karmaşıklığı nedeniyle ÇKKV yöntemlerinin pandemiyle ilgili sorunları modellemede popülerleştiğini vurgulamaktadır. Veri toplama, PRISMA protokolüne göre yapılmıştır. Sonuçlar, AHP'nin (%37.5) en popüler yöntem olduğunu, ardından TOPSIS ve VIKOR'ın geldiğini göstermektedir. İnceleme, ÇKKV yöntemlerinin COVID-19 araştırmalarında önemli bir alan olduğunu ortaya koymaktadır. Çalışmaların %69'u, belirsizlikleri aşmak için bulanık ÇKKV yöntemlerini kullanmıştır, ancak bu yöntemlerin teorik temelleri genellikle eksiktir. Bulanık ÇKKV yöntemlerinin avantajları ve keskin yöntemlerle karşılaştırıldığında sağladığı net faydalar konusunda genel bir uzlaşma bulunmamaktadır. COVID-19 ile ilgili çalışmalar, teorik temelleri anlamayı ve bulanık yöntemlerin potansiyel dezavantajlarından kaçınmayı önermektedir. Bu makale, bulanık ÇKKV yöntemlerinin matematiksel eleştirisini sunarak literatüre katkı sağlamaktadır.

Günümüzde karar problemleri fazla karışık hale gelmiştir. Günümüz rekabet koşullarında karmaşık karar problemlerinin nicel karar analizi yöntemleriyle çözülmesi gerekmektedir. Bu nedenle son zamanlarda ÇKKV yöntemleri yaygın bir şekilde kullanılmaktadır. Arslan ve diğ. (2018), eğitim kurumundaki yöneticilerin karşılaştıkları karar problemlerinde ÇKKV yöntemlerinin kullanılabilirliğini göstermeyi hedeflemiştir. Literatürde eğitim kurumlarındaki karar problemlerinin ÇKKV yöntemleri ile çözümlenebildiği görülmektedir. Çalışmada, ödül alacak öğrencilerin tespiti probleminde MACBETH (Measuring Attractiveness by a Categorical Based Evaluation Technique) yöntemi kullanılmıştır. Analiz için gereken veriler eğitim kurumu yetkililerinden alınmıştır. Yetkililer eş zamanlı karar verici olarak da kabul edilmiştir. Oluşan çözüm modelindeki kriter ve alternatifler belirlenmiştir. Çalışmada MACBETH yöntemi kullanılarak uygun bir seçimin yapılması hedeflenmiştir.

Yapay Zeka uygulamaları, son yıllarda hızla önem kazanmaktadır. Sağlık alanında da bu teknolojinin kullanımı artmaktadır. Ancak, yapay zeka uygulamalarında karşılaşılan zorluklar ve problemlerin tespiti, bunların önceliklendirilmesi oldukça kritik bir rol oynamaktadır. Basmacı (2022), bu süreci yönetmek için yaygın olarak kullanılan ÇKKV yöntemlerinden AHS yöntemini tercih etmiştir. Amaç, sağlık

alanındaki yapay zeka uygulamalarında hangi zorluklara odaklanması gerektiğine dair bilgi sunmaktır.

Tedarik zinciri yönetiminde, doğru tedarikçi seçimi ve değerlendirilmesi önemli bir problem teşkil etmektedir. Supçiller ve Deligöz (2018), bir tekstil firması için en uygun tedarikçinin belirlenmesini hedeflemiştir. Alanında uzman kişilerle yapılan görüşmeler sonrası kriterler belirlenmiş ve kriter ağırlıkları AHP yöntemi ile hesaplanmıştır. Karar verme sürecinde TOPSIS, VIKOR, Basit Toplamlı Ağırlıklandırma, Gri İlişkisel Analiz, MOORA, ELECTRE II ve M-TOPSIS gibi çok kriterli yöntemler uygulanmıştır. Elde edilen sıralamalar, Borda sayım ve Copeland yöntemleriyle karşılaştırılarak en uygun tedarikçi seçilmiştir.

Yavuz ve Birdoğan (2019), otomotiv sektöründe faaliyet gösteren bir firma için çalışma yapmış ve firmanın sahip olduğu patentlerin değerine göre sıralanmasını amaçlamışlardır. İlk olarak, patent değerini etkileyen kriterler belirlenmiş ve entropi yöntemiyle kriterlerin ağırlıkları hesaplanmıştır. Ardından, TOPSIS ve VIKOR yöntemleri kullanılarak alternatifler sıralanmıştır. Sonuçlar karşılaştırılmış ve iki yöntem arasındaki ilişkiyi belirlemek için Spearman korelasyon analizi yapılmıştır. Analiz sonucunda, sıralamalar arasında pozitif yönde ve yüksek derecede bir ilişki olduğu bulunmuştur.

Konuşkan ve diğ. (2014), ÇKKV problemlerinde en fazla faydayı sağlayan kriterin seçilmesini amaçlamıştır. MAUT (Multi Attribute Utility Theory) yöntemi incelenmiş ve entropi yöntemiyle kriter ağırlıkları belirlenmiştir. Ardından, telefon seçimi için MAUT ve entropi yöntemleri birleştirilerek kullanılmıştır. Seçim süreci, yedi kişiden niteliksel özellikler hakkında görüş alınarak yapılmış, böylece daha objektif bir seçim hedeflenmiştir.

Günümüzde teknolojik gelişmelerin hızla artması, işletmeleri Tedarik Zinciri Yönetimi'ne yönlendirmiştir. Bir firmada tedarikçi seçimi önemli bir karar olmakla birlikte, tedarikçi performansının da değerlendirilmesi gerekmektedir. Tedarikçilerin performansı, işletmenin başarısını doğrudan etkiler ve tedarikçilerin firmanın ihtiyaçlarına uygun olması beklenir. Tedarikçi seçim problemi, birçok farklı kritere bağlıdır ve çözüm için ÇKKV yöntemleri kullanılmalıdır. Yüzügüllü (2011), problemin karmaşıklığı nedeniyle, nicel ve nitel verilerle çalışan AHP yöntemini tercih

etmiştir. Çalışmanın amacı, tedarikçi seçiminde karar verilmesini sağlamak ve kullanılan ölçütlerin sonuca olan etkisini belirlemektir.

Kökümer (2018), işletmelerin dijital dönüşüm yeterliliklerini ölçmek amacıyla bir sistem tasarlamıştır. Beyaz eşya sektöründe faaliyet gösteren 7 firma üzerinde, 4 ana ve 23 alt kriter içeren bir anket uygulanarak puanlama yapılmıştır. ÇKKV yöntemleri olan MACBETH ve TOPSIS kullanılarak, bu firmaların dijital dönüşüm yetenekleri değerlendirilmiştir.

Özbek (2014), Sivil Toplum Kuruluşları (STK) için doğru yöneticilerin seçilmesinin büyük önem taşıdığını vurgulamıştır. En uygun adayın seçilmesi, kuruluş için kritik bir karar verme problemi olarak ele alınmaktadır. Bu çalışmada, Bulanık Analitik Hiyerarşi Süreci (BAHS) yöntemi kullanılarak bir yönetici seçim modeli geliştirilmiştir. BAHS, belirsiz verilerle çalışabilen, nitel ve nicel kriterleri dikkate alan bir yöntemdir. Model, 7 aday ve 12 kriter doğrultusunda değerlendirme yapmış ve STK için en uygun adayı belirlemiştir. Çalışma, yönetici seçim sürecine rehberlik etmekte ve STK'ların ihtiyaçlarına en uygun adayı seçmelerine yardımcı olmaktadır.

Yüksel ve Börklü (2021), Pahl ve Beitz'in sistematik tasarım yaklaşımı, bulanık mantık yöntemiyle entegre ederek tasarım değerlendirmesi yapmıştır. Yöntem, bir tekerlekli sandalye tasarımı üzerinde uygulanmıştır. Ayrıca, kullanılan bulanık mantık yöntemi ile geleneksel kavramsal tasarım yönteminin sonuçları karşılaştırılmıştır. Bulanık mantığın kullanımı, basit ve anlaşılır olmasının yanı sıra hızlı, hassas ve kapsamlı değerlendirmeler yapma avantajı sağlamaktadır.

Özbek ve Engür (2019), Öğrenci İşleri Otomasyonu (ÖİÖ)'nun, kullanıcıların performansını önemli düzeyde etkileyen önemli bir yazılım sistemi olduğunu belirtilmiştir. Kullanıcıların verimliliğini arttırmak için ÖİÖ'lerin verimli çalışması gerekir. Bu çalışmadaki amaç, farklı üniversitelerin ÖİÖ'lerinin performansını ölçerek en uygun olanı seçmektir. Bu sürede, birçok kriter dikkate alınmıştır. ÇKKV problemi olarak kabul edilmiştir. Beş üniversitenin kullandığı ÖİÖ'ler ele alınmıştır. ARAS, SWARA, ve EDAS gibi ÇKKV yöntemleri çözülmüştür. SWARA, ölçme kriterlerini ağırlıklandırmakta kullanılmıştır. ARAS ve EDAS yöntemleri ise ÖİÖ'lerin performansını belirlerken kullanılmıştır. Çalışmanın sonucunda ise, en önemli kriter

veri tabanı güvenliği olarak belirlenmiştir. ÖİO'lerin sıralaması, her bir yöntem sonucunda aynı çıktıyı vermiştir.

Madenoglu (2019), verilerin yetersiz olduğu bir durumda yeşil tedarikçi seçimi yapmıştır. Bu çözümde, bulanık TOPSIS, bulanık Gri İlişkisel Analiz, bulanık VIKOR ve bulanık Aras yöntemleri kullanılarak yeşil tedarikçiler sıralanmıştır. Değerlendirme kriterlerinin ağırlıkları, bulanık SWARA yöntemiyle belirlenmiş ve bilgi kaybını önlemek amacıyla kriter ağırlıkları için bulanık sayılar kullanılmıştır. Çalışma, mobilya üretimi yapan bir firmaya uygulanmıştır. Sonuçlar, dört bulanık yöntemin benzer sonuçlar verdiğini göstermektedir. Kullanılan yöntemlerin özellikleri değerlendirilmiş ve Gri İlişkisel Analiz yönteminin daha uygun olduğuna karar verilmiştir.

Uslu. ve diğ. (2019), bulut bilişim konusunu araştırmış ve Ankara bölgesindeki bir yazılım şirketini incelemiştir. Şirketin verilerini işleyip saklayabilmesi için en uygun bulut hizmetinin seçilmesi gerektiği belirtilmiştir. Çalışmada, 7 farklı bulut bilişim sağlayıcısı uzmanlar tarafından belirlenmiş ve seçimde etkili olan 5 kriter seçilmiştir. Bu sağlayıcıların seçiminde, TOPSIS ve PROMETHEE gibi ÇKKV yöntemleri kullanılmıştır.

Keskin ve diğ. (2020), bulut bilişimde güvenliğin sağlanması konusunu ele almıştır. Bir firma için bulut bilişim güvenlik gereksinimleri belirlenmiş ve bu gereksinimlere uygun en iyi alternatifin seçilmesi hedeflenmiştir. Çözümde, AHP, TOPSIS ve AAS yöntemleri kullanılarak en uygun alternatif belirlenmiştir.

Uslu. ve diğ (2019), bulut hizmet sağlayıcısı seçiminde etkili olan kriterleri belirlemiştir. Uzman görüşlerine dayanarak, 5 ana kriter ve 17 alt kriter tespit edilmiştir. Bu kriterler, 9 yetkili tarafından değerlendirilmiştir. Kriterler arasındaki ilişkiler göz önünde bulundurularak, ÇKKV yöntemlerinden AAS kullanılmıştır. Bu yöntem, firmalara bulut hizmet sağlayıcısı seçiminde rehberlik etmektedir.

Özcan ve Emiroğlu (2020), firmaların belirli kriterlere uygun seçim yapmalarına yardımcı olmak amacıyla BAHS tabanlı bir model geliştirmiştir. Bu modelde, bulut tabanlı Öğrenci Yönetim Sistemi (ÖYS) seçiminde etkili olabilecek kriterler incelenmiş ve hiyerarşik bir yapı oluşturulmuştur. Çalışma sonucunda, kriterler ve altı

alternatif çevrimiçi eğitim uzmanları tarafından değerlendirilmiştir. Bulanık ikili karşılaştırmalar yapılarak, belirlenen kriterlere göre en uygun bulut tabanlı ÖYS olarak Talent LMS seçilmiştir.

Çakır ve Karabıyık (2017), çeşitli bulut depolama hizmet sağlayıcıları arasından en uygun olanın seçilmesini hedeflemiştir. Seçim sürecinde, bulut depolama hizmet sağlayıcısı seçiminde etkili olan kriterler belirlenmiş ve bu kriterlerin önem düzeyleri, SWARA yöntemi ile tespit edilmiştir. Belirlenen kriterlere göre, COPRAS yöntemi kullanılarak en uygun hizmet sağlayıcısı seçilmiştir. Yapılan analizler sonucunda, Güvenlik kriterinin en yüksek öneme sahip olduğu, Müşteri Hizmetleri kriterinin ise en düşük öneme sahip olduğu bulunmuştur. En uygun bulut depolama hizmet sağlayıcısı olarak ise Google Drive belirlenmiştir.

Arman ve Kundakcı (2023), bulut hizmet sağlayıcısı seçiminde kriter ağırlıklarını FUCOM yöntemiyle belirlemiştir. Ardından, WEDBA yöntemi kullanılarak en uygun bulut hizmet sağlayıcısı seçilmiştir. Elde edilen sonuçlar incelendiğinde, bulut hizmet sağlayıcısı seçiminde en önemli kriterin "Güvenlik" olduğu tespit edilmiştir. İşletmelere sunulan bulut hizmet sağlayıcıları arasında ise en uygun seçenek olarak Google Drive belirlenmiştir.

Uslu ve diğ. (2021), bir yazılım şirketi için bulut hizmeti seçimi yapmıştır. Etkili kriterler, uzman görüşleri doğrultusunda belirlenmiş ve önem sırasına göre sıralanmıştır. Çalışmada, 5 ana kriter ve 17 alt kriter belirlenmiş ve bu kriterlerin ağırlıkları BAHP yöntemiyle değerlendirilmiştir. Elde edilen kriter ağırlıkları, ANP yöntemiyle karşılaştırılmıştır. Uygulamada, BAHP-COPRAS ve ANP-COPRAS yöntemleri kullanılarak alternatifler sıralanmıştır. Çalışma sonucunda, alternatif sıralamaların etki düzeyleri detaylı bir şekilde yorumlanmıştır.

Artsın ve Günal (2021), yükseköğretim ve uzaktan eğitim kurumlarının Öğrenci Yönetim Sistemi (ÖYS) seçim kriterlerini belirlemiştir. Bu amaçla, yükseköğretim kurumlarında görevli uzman profesyonellerle görüşmeler yapılmış ve AHP yöntemi kullanılarak kriterler oluşturulmuştur. Verilerin toplanmasında uzmanlar, belirli kriterleri saptamış ve sonrasında bu kriterler, farklı bir uzman grubu tarafından yeniden değerlendirilmiştir. Sonuçta, 6 ana kriter ve 42 alt kriter belirlenmiş ve kriterlerin

ağırlıkları hesaplanmıştır. Çalışmanın sonucuna göre, ana kriterlerden Ölçme ve değerlendirme boyutunun en yüksek öneme sahip olduğu tespit edilmiştir.

Yıldırım ve Önay (2013), bulut teknolojisi üzerine yapılan bir rapordan yola çıkılarak beş firmanın sağladığı hizmetleri incelemiştir. Raporda değerlendirilen kriterlere dayanarak bir sıralama yapılmış ve kriterlerin ağırlıkları AHP yöntemiyle belirlenmiştir. Ardından, alternatiflerin sıralanması için MOORA yöntemi kullanılmıştır.

Baki (2022), ROC ve CODAS tekniklerine dayalı entegre bir karar modeli geliştirmiştir. İlk aşamada, kriterler ROC yöntemi ile değerlendirilmiş, ikinci aşamada ise hizmet sağlayıcıları CODAS tekniği ile sıralanmıştır. Önerilen model, bulut hizmeti sağlayıcısı seçmek isteyen bir yazılım firması tarafından test edilmiştir. Araştırmanın sonucunda, firmaların ihtiyaçlarını karşılayacak uygun bulut hizmeti sağlayıcısının seçilmesi ve bu seçimle firmalara katkı sağlanması amaçlanmıştır.

3.2 Yapay Zeka Teknikleri

Yapay zeka teknikleri, bulut servisi seçim süreçlerinde önemli katkılar sunmaktadır. Makine öğrenmesi, bulut servislerinin performans tahminlerini ve analizlerini yapabilen güçlü bir araçtır. Jain ve Jain (2018), yapay zeka ve karar destek sistemlerinin bulut bilişimdeki uygulamalarını ve bu tekniklerin nasıl kullanılabileceğini detaylandırmıştır. Ayrıca, Zhang ve Wang (2019) makine öğrenmesi ve AHP yöntemlerinin entegre edilmesinin bulut servisleri seçiminde nasıl etkin olduğunu vurgulamıştır.

Genetik algoritmalar, optimizasyon problemlerini çözmeye etkili bir teknik olarak öne çıkmaktadır. Rao ve Kumar (2019), genetik algoritmaların mühendislik optimizasyonlarındaki uygulamalarını incelemiş ve bulut servisleri seçiminde bu tekniklerin nasıl kullanılabileceğini açıklamıştır. Kumar ve Kumar (2020) ayrıca, bulut bilişimde evrimsel algoritmaların kullanımını kapsamlı bir şekilde ele almış ve bu tekniklerin bulut servislerinin değerlendirilmesindeki rolünü tartışmıştır.

Shou ve Liu (2018), genetik algoritmalar ve ÇKKV yöntemlerinin bulut servisi seçiminde nasıl entegre edilebileceğini incelemiş ve bu tekniklerin birleşiminin daha isabetli sonuçlar sağladığını belirtmiştir.

Nar (2022), çalışmada Yenikapı M1 – Kirazlı M1 metro hattı için hat ve istasyon bazında talep tahminleri yapmıştır. İstasyon bazında yapay sinir ağı ve makine öğrenmesi algoritmaları kullanılarak hata değerleri karşılaştırılmakta, hat bazında ise regresyon analizi ve basit ortalama yöntemleriyle tahmin yapılmaktadır. İstasyon bazında en başarılı sonuçlar karar ağacı algoritması ile, hat bazında ise basit ortalama ile elde edilmiştir. İkinci çalışmada, raylı ulaşımda sefer sıklığı belirlemede kritik başarı faktörlerinin önceliklendirilmesi ele alınmıştır. SWARA, TOPSİS ve AHP yöntemleri ile ana kriterler ve karar alternatifleri belirlenmiş, AHP ile ikili karşılaştırmalar matrisleri oluşturulmuştur. AHP ve TOPSİS modelleri sonucunda, çalışma kuralları alternatifi birincil öncelik olarak belirlenirken, güvenilirlik kriteri ise ana kriterler arasında birinci sırada yer almıştır.

Özen ve diğ. (2021), çalışmada Amerika Birleşik Devletleri'ndeki doğrulanmış vaka sayılarına dayanarak gelecekteki vaka tahminlerini, farklı makine öğrenmesi modelleriyle yapmıştır. Python ve R programlama dilleri kullanılarak yapılan tahminlerde, Prophet, Polinom Regresyon, ARIMA, Doğrusal Regresyon ve Random Forest modelleri uygulanmıştır. Test verisi ile yapılan tahminlerin performansı, MAPE, RMSE ve MAE gibi hata metrikleri ile değerlendirilmiştir. Sonuç olarak, MAPE hata metriği temel alınarak en iyi tahminleri Polinom Regresyon modeli vermiştir.

Erdal ve Yapraklı (2016), çalışmada Erzurum ilinde 38 yıldır faaliyet gösteren inşaat malzemeleri toptancısı bir firmanın müşterilerinin vadeli borçlarını ödeme/ödememe riskleri firma başarısızlığı kapsamında ele almış ve firma başarısızlığının tahmininde uygun bir makine öğrenmesi yöntemi araştırmıştır. Probleme etki eden değişkenler Temel Bileşenler Analizi (TBA) ile ortaya konulmuştur. Son yıllarda makine öğrenmesinde oldukça gelişmekte olan Yapay Sinir Ağları (YSA) ve Destek Vektör Makineleri (DVM)'nin TBA yöntemiyle beraber kullanımıyla oluşturulan hibrit modellerin bu tahminde uygulanabilirliği incelenmiş ve tahmin performansları yalnız YSA ve DVM'ler ile karşılaştırılmıştır. TBA ile bütünleşik olarak kullanılan hibrit modellerin tahmin başarısının yalnız YSA ve DVM'lere oranla daha tatmin edici sonuçlar verdiği görülmüştür. Özellikle TBA-DVM modelinin firma başarısızlığı tahminlemede alternatif bir yöntem olarak etkin bir şekilde kullanılabileceği sonucuna varılmıştır.

Dođan ve B y kk r (2022), alıřmada finansal zaman serisi tahmininde makine  đrenmesi y ntemlerinin karřılařtırmalı olarak incelemiřtir. alıřmada, geliřmiř ve geliřmekte olan borsa endeksleri ile İstanbul borsasındaki y ksek hacimli iki hisse senedinin son 5 yıllık kapanıř verileri kullanılmıřtır. Endeks tahmininde sıklıca kullanılan ve bařarılı bulunan Destek Vekt r Regresyonu (DVR) ile zaman serisi tahmininde nadiren kullanılan topluluk y ntemleri olan Random Forest (RF) ve eXtreme Gradient Boosting (XGBoost) tercih edilmiřtir. Sonulara g re, MAE, MAPE ve RMSE kriterlerine g re en iyi tahmin y ntemi olarak DVR belirlenmiřtir.

Yaman (2021), alıřmada m řterilerin davranıřları ve  zneliklerinden m řteri ser veninin belirlenmesi ve m řteri tiplerine g re gelecekteki davranıřların tahmin edilmesi amacıyla bir makine  đrenmesi modeli geliřtirmiřtir. M řteri davranıř analizi, gemiř davranıřlara dayanarak gelecekteki olası hareketlerin  ng r lmesi aısından firmalar iin  nemli olup, m řteri memnuniyeti ve finansal kazanç iin kritik rol oynar. alıřmada sentetik bir veri k mesi kullanılmıř ve CRISP-DM metodolojisi ile ilerlenmiřtir. Veri  n iřleme adımlarının ardından, eřitli bađlantılı modellerle tahminler yapılmıř ve sistemde yeni katılacak bir m řterinin gelecekteki aktiviteleri hakkında tahminler yapılmıřtır. Modelin bařarıları deđerlendirilmiř, en k t  modelin bařarı oranı %75, en iyi modelin bařarı oranı ise %100 olarak belirlenmiřtir.

Y ce ve Kabak (2021), alıřmada bir  retim tesisine ait detay  retim alanlarında 4 farklı prosese ait toplam 8 iř merkezine  retim s resi tahminleme iin makine  đrenmesi algoritmalarından yapay sinir ađı, destek vekt r regresyonu ve gradyan artırma algoritmaları uygulanmıř ve her iř merkezi iin en iyi sonucu veren algoritma belirlemiřtir. Elde edilen sonulara g re, yapay sinir ađları ortalamada %56,02 bařarı g sterirken destek vekt r regresyonu %84,08, gradyan artırma makinesi ise %85,31 oranında bařarı g stermiřtir.

Sevli (2021), alıřmada 3D yazıcılara ait ayar parametreleri ve  retilecek  r n n niteliklerini ifade eden 12  znelikten oluřan bir veri seti kullanarak, basım iin uygun malzemenin tahmin edilmesine y nelik makine  đrenmesi sınıflandırmaları yapmıřtır. Destek Vekt r Makinesi (DVM), K-En yakın Komřu (KNN), Karar Ađacı (KA), Rastgele Orman (RO) ve Lojistik Regresyon (LR) gibi beř farklı y ntemle ve 5 kat apraz dođrulama ile yapılan sınıflandırma iřlemlerinde en y ksek dođruluk %100 ile LR algoritmasıyla elde edilmiřtir.

3.3 Entegre Yöntemler ve Uygulamaları

ÇKKV ve yapay zeka tekniklerinin entegrasyonu, bulut servisi seçim süreçlerinde önemli avantajlar sunmaktadır. Xu ve Chen (2020), makine öğrenmesi ve ÇKKV yöntemlerinin birleşiminin bulut servisi seçiminde nasıl uygulandığını ve bu entegrasyonun karar verme süreçlerine sağladığı katkıları incelemiştir. Zhou ve Yang (2018), AHP ve fuzzy logic yöntemlerinin bulut servisi seçiminde nasıl entegre edilebileceğini açıklamış ve bu yöntemlerin birleşiminin karar süreçlerine olan etkilerini tartışmıştır.

Adeli ve Wu (2020), bulut servislerinin seçiminde yapay zeka ve karar destek sistemlerinin rolünü ele almış ve bu tekniklerin seçim süreçlerini nasıl iyileştirdiğini açıklamıştır. Lee ve Lee (2019), AHP-TOPSIS modelinin bulut servisi seçiminde nasıl uygulandığını ve bu yaklaşımın sağladığı avantajları detaylandırmıştır.

Öztürk ve Aydın (2020), bulut servisi seçiminde çok kriterli yöntemlerin ve yapay zeka tekniklerinin birlikte kullanılmasının avantajlarını ve uygulama sonuçlarını ele almıştır.

3.4 Genel Değerlendirme

Literatürdeki çalışmalar, ÇKKV yöntemleri ve yapay zeka tekniklerinin bulut servisi seçim süreçlerinde etkili bir şekilde kullanılabileceğini göstermektedir. ÇKKV yöntemleri, alternatiflerin çeşitli kriterlere göre sistematik bir şekilde değerlendirilmesini sağlarken, yapay zeka teknikleri performans tahminlerini ve optimizasyon süreçlerini hızlandırarak daha doğru sonuçlar elde edilmesine katkı sağlamaktadır. Entegre yaklaşımlar, bu iki tekniğin güçlü yönlerini birleştirerek daha etkili ve optimize edilmiş karar verme süreçleri sunmaktadır.

4. ÇOK KRİTERLİ KARAR VERME (ÇKKV) YÖNTEMLERİ

4.1. Çok Kriterli Karar Verme Kavramı

ÇKKV, karar vericinin birden fazla kriteri değerlendirerek en iyi sonucu elde etmeye çalıştığı bir karar verme sürecidir. Bu süreçte, karar verici genellikle birbirleriyle çelişen birçok kriteri aynı anda dikkate alır. ÇKKV'nin amacı, karmaşık ve çok yönlü karar problemlerinde, çeşitli seçenekler arasından en uygun olanını seçmektir. Özellikle bulut servisi seçiminde, maliyet, güvenlik, performans, uyumluluk gibi birçok faktörün dikkate alınması gereklidir ve bu süreçte ÇKKV yöntemleri büyük fayda sağlar.

4.2. ÇKKV Yöntemleri ve Teknikleri

ÇKKV, farklı karar problemlerine göre uyarlanabilen çeşitli yöntemler sunar. Bu yöntemlerin her biri farklı yaklaşım ve algoritmalara dayansa da ortak hedef, karar vericinin seçenekleri karşılaştırarak en iyi sonucu elde etmesine yardımcı olmaktır. ÇKKV yöntemlerinin bazıları şunlardır:

4.2.1. AHP

AHP, 1968'de Myers ve Alpert tarafından başlatılmış, 1977'de ise Thomas Lorie Saaty tarafından geliştirilmiştir. AHP, çok ölçütlü programlamada alternatiflerin ve projelerin önceliklerinin belirlenmesinde kullanılan bir karar verme yöntemidir. Bu süreç, problemin daha kolay analiz edilebilmesi için bir ölçütler hiyerarşisi oluşturularak başlar. Ardından, karar vericiler, her bir ölçüt için ikili karşılaştırmalar yaparak alternatifleri değerlendirir.

AHP, karar problemlerini hiyerarşik bir yapı ile modelleyen ve seçeneklerin her bir kriter altındaki önem derecelerine göre karşılaştırılmasına olanak tanıyan bir yöntemdir. AHP'de süreç, öncelikle kararın ana hedefinin, kriterlerin ve alt kriterlerin hiyerarşik olarak yapılandırılmasıyla başlar. Ardından, kriterler ikili karşılaştırmalar

yoluyla değerlendirilir ve bu karşılaştırmalar sonucunda kriterlerin ağırlıkları belirlenir. Son olarak, bu ağırlıklar kullanılarak her seçeneğin genel puanı hesaplanır.

1. Adım: Problem tanımlandıktan sonra, karar için gerekli ölçütler belirlenir ve bu ölçütlerin öncelikleri sıralanır.

2. Adım: Hiyerarşik yapı, ana hedefin en üstte yer aldığı bir düzenle oluşturulur. Ana hedefin altında temel ve alt ölçütler bulunur, en alt seviyede ise alternatifler yer alır. Hiyerarşinin aşama sayısı, problemin karmaşıklığına göre değişir. Hiyerarşi oluşturulurken, aynı düzeydeki seçeneklerin birbirinden bağımsız olduğu kabul edilir.

3. Adım: İkili karşılaştırmalar matrisi, 1 ile 9 arasında değer alan bir önem derecesi ölçeğiyle oluşturulur. İlk olarak temel ölçütler, varsa alt ölçütler ve ardından tüm ölçütler dikkate alınarak karar seçenekleri karşılaştırılır. Bu matrisler kare şeklindedir ve köşegen elemanları 1 olur. Önem dereceleri, Çizelge 4.1'deki dilsel değerlerle belirtilir.

Çizelge 4. 1 : Önem Değerlerine Göre Dilsel Değerler

Önem Değerleri	Dilsel Değerler
1	Eşit Önemde
3	Biraz Daha Önemli (Az Üstünlük)
5	Oldukça Önemli (Fazla Üstünlük)
7	Çok Önemli (Çok Üstünlük)
9	Son Derece Önemli (Kesin Üstünlük)
2,4,6 ve 8	Ara Değerler (Uzlaşma Değerleri)

4. Adım: Matristeki her eleman, ilgili sütun toplamına bölünerek normalize edilir. Bu işlem sonucunda, normalize edilmiş matrisin her sütun toplamı 1 olur.

5. Adım: Öncelik vektörü, normalize edilmiş matrisin her satır toplamının matris boyutuna bölünerek hesaplanır. Bu işlemin ortalaması alınarak her ölçüt için önem ağırlıkları bulunur. Elde edilen ağırlıklar, öncelik vektörünü oluşturur.

6. Adım: Tutarlılık oranı, ikili karşılaştırmalar yapıldıktan ve öncelikler belirlendikten sonra hesaplanır. Bir A matrisinin tutarlılığını değerlendirmek için "Tutarlılık İndeksi Katsayısı" (CI) gibi yöntemler kullanılır. Ayrıca, tutarlılığı ölçmek için "Rasgele İndeks" (RI) değeri de gereklidir. CI ve RI değerleri belirlendikten sonra, "Tutarlılık Oranı" hesaplanır.

7. Adım: Ölçütler için ikili karşılaştırma matrisi oluşturulup, karar seçeneklerinin öncelik vektörü hesaplanır. Bu öncelik vektörü, aynı zamanda ölçütler için ağırlık vektörü olarak da tanımlanabilir.

8. Adım: Karar seçenekleri sıralanırken, ölçütler için elde edilen öncelik vektörleri birleştirilerek tüm öncelikler matrisi oluşturulur. Bu matris, karar seçeneklerinin öncelik vektörü ile çarpılıp toplanarak sonuç vektörü elde edilir. Sonuç vektöründe en yüksek ağırlığa sahip karar seçeneği, problemin çözümü için tercih edilmesi gereken seçenek olarak belirlenir.

- *Avantajları:* Basit ve anlaşılır bir yöntemdir. Karar vericinin sezgisel değerlendirmelerini kullanabilmesine olanak tanır.
- *Dezavantajları:* Karşılaştırma matrisleri büyük olduğunda hesaplama karmaşık hale gelebilir ve subjektif değerlendirmeler sonucu etkileyebilir.

4.2.2. TOPSIS

TOPSIS, seçenekleri ideal ve anti-ideal çözümlere olan uzaklıklarına göre sıralayan bir ÇKKV yöntemidir. Bu yönteme göre en iyi seçenek, ideal çözüme en yakın ve anti-ideal çözüme en uzak olan seçenektir. İlk adımda, kriterler normalize edilir ve ağırlıklandırılır. Daha sonra, her bir seçeneğin ideal ve anti-ideal çözümle olan uzaklıkları hesaplanır.

1. Adım: Standart karar matrisi, A matrisinin elemanlarından yararlanarak ve belirli bir formül kullanılarak hesaplanır.

$$r_{ij} = \frac{a_{ij}}{\sqrt{\sum_{i=1}^m a_{ij}^2}} \quad (1.1)$$

2. Adım: Öncelikle, değerlendirme faktörlerine ilişkin ağırlık değerleri (W_i) belirlenir. Ardından, R matrisinin her sütunundaki elemanlar, ilgili ağırlık değeriyle çarpılarak V matrisi oluşturulur.

3. Adım: TOPSIS yöntemi, her bir değerlendirme faktörünün sabit artan veya azalan bir eğilime sahip olduğunu varsayar. Uygun çözüm setinin oluşturulabilmesi için, V matrisindeki ağırlıklandırılmış değerlendirme faktörlerinin (yani sütun değerlerinin) en büyükleri seçilir. Uygun çözüm setinin bulunması, aşağıdaki formül ile gösterilmektedir:

$$A^+ = \left\{ \left(\max_i V_{ij} \mid j \in J \right), \left(\min_i V_{ij} \mid j \in J' \right) \right\} \quad (1.2)$$

Negatif uygun çözüm seti, V matrisindeki ağırlıklandırılmış değerlendirme faktörlerinin (sütun değerlerinin) en küçükleri seçilerek oluşturulur. Negatif uygun çözüm setinin belirlenmesi, aşağıdaki formülde gösterilmektedir:

$$A^- = \left\{ \left(\min_i V_{ij} \mid j \in J \right), \left(\max_i V_{ij} \mid j \in J' \right) \right\} \quad (1.3)$$

Her iki formülde de, fayda en büyüklenirken kayıp ise en küçüklenmektedir. Bu yaklaşımda:

Uygun çözüm seti, alternatiflerin en yüksek fayda (veya en büyük) değerlerine sahip olduğu, yani değerlendirme faktörlerinin en yüksek olduğu durumu ifade eder.

Negatif uygun çözüm seti ise alternatiflerin kaybının (veya en küçük) değerlerine sahip olduğu, yani değerlendirme faktörlerinin en düşük olduğu durumu ifade eder.

Her iki çözüm seti de, m elemandan oluşan değerlendirme faktörü sayısını içermektedir. Bu faktörler, karar verme sürecinde kullanılan ölçütlerin sayısını temsil eder. Bu faktörlerin ağırlıkları, karar vericinin önceliklerine göre belirlenir ve her iki çözüm seti bu faktörlere dayalı olarak hesaplanır.

4. Adım: TOPSIS yönteminde, her bir karar noktasına ait değerlendirme faktör değerlerinin, uygun ve negatif uygun çözüm setlerinden sapmalarını bulmak için Öklid Uzaklık Yaklaşımı kullanılmaktadır. Elde edilen sapma değerleri, Uygun Ayırım (S_i^+

) ve Negatif Uygun Ayırım (S_{i-}) Ölçüsü olarak adlandırılmaktadır. Uygun Ayırım (S_{i+}) Ölçüsünün hesaplanma formülü ile Negatif Uygun Ayırım (S_{i-}) Ölçüsünün hesaplanması aşağıdaki formüllerle gösterilmektedir.

$$S_{i+} = \sqrt{\sum_{j=i}^n (V_{ij} - V_{j+})^2} \quad (1.4)$$

$$S_{i-} = \sqrt{\sum_{j=i}^n (V_{ij} - V_{j-})^2} \quad (1.5)$$

Burada hesaplanacak S_{i+} ve S_{i-} sayısı karar noktası sayısı kadar olacaktır.

5. Adım: Her bir karar noktasının uygun çözüme görelî yakınlığının (C_i) hesaplanmasında, uygun ve negatif uygun ayırım ölçülerinden faydalanılmaktadır. Burada, negatif uygun ayırım ölçüsünün toplam ayırım ölçüsü içindeki payı dikkate alınır. Uygun çözümün yakınlık değerinin hesaplanması aşağıdaki formülde gösterilmektedir.

$$C_i = \frac{S_{i-}}{(S_{i-} + S_{i+})} \quad (1.6)$$

Burada C_i değeri $0 \leq C_i \leq 1$ aralığında değer alır ve $C_i = 1$ ilgili karar noktasının uygun çözüme, $C_i = 0$ ilgili karar noktasının negatif uygun çözüme mutlak yakınlığını göstermektedir.

- *Avantajları:* Basit ve etkili bir yöntemdir, az sayıda hesaplama gerektirir. Çok sayıda kriterle çalışabilir.
- *Dezavantajları:* Kriterler arasında doğrusal bağıntılar varsayar, bu da her durumda gerçekçi olmayabilir.

4.2.3. Diğer ÇKKV yöntemleri

- *PROMETHEE (Preference Ranking Organization Method for Enrichment Evaluations):* Bu yöntem, seçenekleri belirli bir tercih fonksiyonu kullanarak

sıralar. Seçenekler birbirleriyle karşılaştırılır ve her bir kriter için tercih oranları hesaplanır.

- *ELECTRE (Elimination and Choice Expressing Reality)*: Özellikle çok sayıda seçeneğin ve kriterin bulunduğu durumlarda kullanılan bu yöntem, seçenekler arasında karşılaştırma yaparak hangi seçeneğin daha uygun olduğunu belirler. Kriter ağırlıkları göz önüne alınarak seçimler daraltılır.
- *MABAC (Multi-Attributive Border Approximation area Comparison)*: Bu yöntem, her bir kriter için sınır değerler belirleyerek seçenekleri değerlendiren bir tekniktir. Sınır bölgesine en yakın olan seçenek, en iyi olarak belirlenir.

4.3. Bulut Servisi Seçiminde ÇKKV Uygulamaları

Bulut servisi seçimi, çok sayıda faktörün dikkate alınması gereken bir karar problemidir. Maliyet, güvenlik, performans, veri yedekleme ve kurtarma gibi kriterlerin her biri bulut hizmetlerinin değerlendirilmesinde önemli rol oynar. ÇKKV yöntemleri, bu kriterler arasındaki önceliklerin belirlenmesine ve farklı sağlayıcılar arasındaki seçeneklerin karşılaştırılmasına olanak tanır.

Bulut servis sağlayıcılarının seçiminde ÇKKV yöntemlerinin uygulanması, şu adımları içerir:

1. *Kriterlerin Belirlenmesi*: Karar verici, bulut servisi seçerken hangi kriterlerin önemli olduğuna karar verir (örneğin maliyet, performans, güvenlik).
2. *Kriter Ağırlıklarının Belirlenmesi*: Her bir kriterin diğerlerine göre ne kadar önemli olduğu belirlenir. Bu adımda AHP gibi yöntemlerle ikili karşılaştırmalar kullanılabilir.
3. *Seçeneklerin Değerlendirilmesi*: Belirlenen kriterler doğrultusunda bulut sağlayıcıları değerlendirilir ve puanlanır.
4. *Sonuçların Analizi*: TOPSIS veya VIKOR gibi yöntemler kullanılarak, sağlayıcılar sıralanır ve en iyi seçenek belirlenir.

ÇKKV yöntemlerinin bulut servisi seçiminde uygulanması, karar vericilere karmaşık seçim süreçlerinde sistematik ve objektif bir yaklaşım sunarak, doğru ve verimli kararlar almalarını sağlar.

Bulut bilişim, bilişim dünyasında önemli bir paradigma değişikliği yaratmıştır ve birçok çalışma bu konuda derinlemesine incelemeler sunmaktadır. Yıldız (2009) bulut bilişimin şirketler üzerindeki etkilerini ve denetim süreçlerini ele almıştır. Rayport ve Heyward (2009) bulut bilişimin gelecekteki potansiyelini vurgulamışlardır. Knorr ve Gruman (2008) ise bulut bilişimin gerçek anlamını ve bu teknolojinin iş dünyasında ne anlama geldiğini açıklamıştır. Kocagüneli ve diğ. (2009), bulut bilişimde yazılım ölçümleme, hata analizi ve tahmin araçlarını tartışmıştır.

ÇKKV yöntemleri, bulut hizmet sağlayıcıları gibi karmaşık seçim süreçlerinde kritik bir rol oynamaktadır. Chen ve Hwang (1992), bulanık ÇKKV yöntemlerinin temellerini atmıştır. Stanujkić ve diğ. (2013) bazı öne çıkan ÇKKV yöntemlerini analiz ederek Sırp bankalarının sıralanmasına yönelik bir uygulama yapmışlardır. Bhole ve Deshmukh (2018), ÇKKV yöntemlerinin genel uygulamaları üzerine kapsamlı bir çalışma sunmuştur.

Saaty (1986), Analitik Hiyerarşi Süreci (AHS) metodunun aksiyomatik temellerini açıklamış ve bu yöntemin karar verme süreçlerinde nasıl kullanıldığını detaylandırmıştır. Taş ve diğ. (2018), AHS ve TOPSIS yöntemlerinin entegrasyonunu kullanarak poliklinik değerlendirmeleri üzerine bir çalışma yapmıştır. Asoğlu ve Eren (2018) ise benzer yöntemlerle bir işletmenin kargo şirketi seçimini incelemiştir. Cheng ve diğ. (2002), AHS yönteminin hatalı kullanımında ortaya çıkan problemleri ele almışlardır.

Yurdakul ve İç (2005), üretim şirketleri için performans ölçüm modelleri geliştirmiş ve AHS ile TOPSIS yöntemlerini birleştirerek bu modelleri değerlendirmişlerdir. Bu çalışmalar, bulut hizmet sağlayıcı seçimi gibi karmaşık karar süreçlerinde ÇKKV yöntemlerinin önemini ve etkinliğini ortaya koymaktadır.

Bu literatür çalışmaları, hem bulut bilişimin hem de ÇKKV yöntemlerinin kuramsal temellerini oluşturmakta ve pratik uygulamalarına yönelik çeşitli yöntemler sunmaktadır.

4.4 Duyarlılık Analizi

ÇKKV yöntemlerinde duyarlılık analizi yapılmasının nedeni, kararın alınmasında kullanılan kriterlerin ve parametrelerin deęişkenliğine karşı çözümün ne kadar duyarlı olduğunu anlamaktır. Bu analiz, karar verilen alternatifin seçiminde hangi kriterlerin daha etkili olduğunu ve hangi faktörlerin küçük deęişimlere daha hassas olduğunu gösterir. Duyarlılık analizi ile Őu sorulara cevap ararız:

1. Kriterlerin Deęişkenliğine Tepki: Kriterlerdeki küçük deęişikliklerin karar sonucunu ne kadar etkileyebileceğini görerek, kararın daha sağlam ve dayanıklı olup olmadığını anlayabiliriz.
2. Risk ve Belirsizlik Yönetimi: Kriterlerin deęerlendirilmesindeki belirsizlikleri anlamak, kararın risklerini azaltmak için önemlidir. Hangi kriterlerdeki belirsizliğin en fazla etki yarattığı tespit edilebilir.
3. Kriter Ağırlıklarının Deęişimi: Eđer kriterlerin ağırlıkları deęişirse, bu deęişikliklerin karar üzerindeki etkisi incelenebilir. Bu, kararın doğruluğu ve güvenilirliğini artırmaya yardımcı olur.

Sonuç olarak, duyarlılık analizi, daha sağlam, güvenilir ve esnek kararlar alınabilmesi için yapılır. Ayrıca karar süreçlerinde daha bilinçli ve Őeffaf bir yaklaşım sağlar.

Duyarlılık Analizi, kriterlerin ağırlıklarında deęişiklikler yaparak, sonuçların nasıl deęiştiğini incelemeyi amaçlar. Bu sayede hangi kriterlerin karar üzerinde daha fazla etkisi olduğunu görebiliriz.

5. YAPAY ZEKA TEKNİKLERİ VE BULUT SERVİSİ SEÇİMİ

5.1. Yapay Zeka Kavramı

Yapay Zeka, bilgisayarların insan benzeri zekâyâ sahip olmasını ve karmaşık problemleri çözme yeteneğini geliştiren bir bilim dalıdır. Yapay zeka, insan düşünme biçimlerini modelleyerek, makinelerin öğrenme, mantık yürütme, karar verme ve kendilerini geliştirme gibi işlevleri yerine getirmesine olanak sağlar. Yapay zeka, çok sayıda veri ile çalışarak ve öğrenme algoritmalarını kullanarak karar verme süreçlerinde etkin çözümler sunar. Bulut servisi seçimi gibi karmaşık problemlerde, yapay zeka teknikleri, veri analizini hızlandırma, optimal çözümler üretme ve hataları minimize etme açısından büyük avantajlar sunar.

5.2. Bulut Servis Seçiminde Yapay Zeka Yöntemleri

Yapay zeka teknikleri, bulut servisi seçiminde ÇKKV sürecine çeşitli katkılar sağlayabilir. Bu teknikler, büyük miktarda veriyi işleyip analiz ederek bulut servis sağlayıcıları arasında en iyi seçimi yapmayı hızlandırır. Bulut servis seçiminde en sık kullanılan yapay zeka yöntemleri şunlardır:

5.2.1. Makine öğrenmesi

Makine öğrenmesi, bilgisayarların deneyimlerden öğrenmesini sağlayan bir yapay zeka alt alanıdır. Bulut servis seçimi sürecinde makine öğrenmesi, geçmiş verilere dayanarak gelecekteki seçimleri tahmin edebilir ve daha iyi kararlar alınmasını sağlayabilir. Makine öğrenmesi algoritmaları, çeşitli kriterleri analiz ederek bulut sağlayıcılarının performansını ve müşteri memnuniyetini değerlendirebilir. Özellikle denetimli öğrenme ve denetimsiz öğrenme algoritmaları, kullanıcı ihtiyaçlarına göre en uygun bulut hizmetlerini önerebilir.

5.2.1.1 Denetimli öğrenme

Makine öğrenmesi modeli, daha önce etiketlenmiş verilerle eğitilir ve bu öğrenilen bilgileri yeni veriler üzerinde uygulayarak kararlar alır.

Bu algoritmalar, etiketli veri kullanarak model eğitir. Etiketli veri, her girişin doğru çıktısının bilindiği veridir.

- *Doğrusal Regresyon:* Sürekli bir değeri tahmin etmek için kullanılır. Doğrusal regresyon, makine öğreniminde tahmine dayalı analiz için yaygın olarak kullanılan bir regresyon modelidir. Bu modelde her gözlem, bir bağımlı ve bir bağımsız değişkene bağlıdır. Bağımlı (y) ve bağımsız (x) değişkenler arasındaki doğrusal ilişki, doğrusal regresyon ile belirlenir. Denklem 5.1 y'nin x ile nasıl ilişkili olduğunu gösterir.

$$y = \beta_0 + \beta_1 x + \varepsilon \quad (5.1)$$

ε , doğrusal regresyon modelindeki hata terimini ifade eder ve x ile y arasındaki değişkenliği açıklamak için kullanılır. β_0 , doğrunun y eksenini kestiği noktayı (kesişim) temsil ederken, β_1 ise doğrunun eğimini (yani x değişkenindeki bir birimlik değişikliğe karşılık gelen y değişikliği) temsil eder.

- *Lojistik Regresyon:* İkili sınıflandırma problemlerinde kullanılır (örneğin, evet/hayır). Lojistik regresyon analizi, veri setindeki gözlemleri gruplara atamak için kullanılan bir yöntemdir. Bu analizde, sınıf sayısı bilindiğinde mevcut verilerle bir sınıflandırma modeli oluşturulur ve bu model sayesinde yeni gözlemler sınıflara atanabilir.
- *Karar Ağaçları:* Verileri sınıflandırmak ve regresyon problemlerini çözmek için ağaç yapısında kararlar alır. Bu algoritmada, bir ağaç yapısı oluşturulur ve ağacın yapraklarında sınıf etiketleri bulunur. Yaprğa giden yollar ve başlangıçtan çıkan dallar ise özellikler üzerindeki işlemleri temsil eder.
- *Rastgele Orman:* Karar ağaçlarının bir ensemble (bir arada çalışan) modelidir. Daha iyi genelleme sağlar. Bu algoritma, birden fazla karar ağacı oluşturarak sınıflandırma doğruluğunu artırır. Rastlantısal olarak seçilen karar ağaçları bir araya gelerek bir karar ormanı oluşturur. Birçok veri seti için, Destek Vektör

Makinelerinden daha doğru sonuçlar elde edilir. Özellikle çok sayıda değişken, sınıf etiketi içeren kategorik değişkenler, kayıp veriler veya dengesiz dağılımlar gösteren veri setlerinde iyi performans sergiler.

- *Destek Vektör Makineleri:* Verileri, iki sınıfa ayıracak en uygun düzlemle ayırmaya çalışır. Bu algoritma, yüksek boyutlu değişken uzayında doğrusal olmayan karar sınırlarını tanımlayarak ikinci dereceden optimizasyon problemini çözer. SVM, doğrusal olarak ayrılmayan veri setlerinde, sınıfları bölen çizgiyi destek vektörleri kullanarak belirler. Doğrusal olmayan ayrılabilir veriler için kernel fonksiyonları, verileri doğrusal bir düzlemde ayırmak için kullanılır. Uygun kernel fonksiyonu ve genişliğinin seçilmesi, performansı artırmak için önemlidir.
- *K-En Yakın Komşu:* Sınıflandırma veya regresyon yaparken, yakın komşulara bakarak karar verir. K-Nearest Neighbors (k-NN) algoritması, sınıflandırılmak istenen yeni bireyin, daha önceki bireylerdeki k en yakın komşusuna bakarak sınıflandırma yapar (Cover ve Hart, 1967). Sınıflandırma sırasında, test örnekleri eğitim örnekleriyle karşılaştırılır ve komşuluk mesafesi olarak öklidyen mesafe kullanılır. Tahminler, komşu örneklerin oy çoğunluğuna dayalıdır.
- *Naive Bayes:* Bayes teoremi temelinde çalışan, genellikle metin sınıflandırması için kullanılan bir algoritmadır. Naive Bayes, diğer algoritmalarla karşılaştırıldığında temel bir sınıflandırıcı olarak önerilen, yaygın olarak bilinen bir istatistiksel öğrenme yöntemidir. Bu algoritma, belirli bir sınıf için girdilerin bağımsız olduğunu varsayar ve sınıf koşulu olasılıklarını tarafsız bir şekilde tahmin eder.
- *Yapay Sinir Ağları:* İnsan beynine benzer yapılarla öğrenen, karmaşık ilişkileri modelleyebilen algoritmalar. Yapay Sinir Ağları (YSA), insan beyninin çalışma şeklini taklit ederek veriden öğrenme, genelleme yapma ve birçok değişkenle çalışma gibi önemli özelliklere sahiptir. YSA'nın temel bileşenleri ise yapay sinir hücreleri veya işlem elemanlarıdır.

5.2.1.2 Denetimsiz öğrenme

Etiketlenmemiş verilerle çalışan bu model, veri kümesindeki gizli örüntüleri ve grupları keşfederek öneriler sunar

Denetimsiz Öğrenme Algoritmaları

Bu algoritmalar, etiketlenmemiş veriler üzerinde çalışır ve verilerin iç yapısını keşfetmeye çalışır.

- *K-Ortalama*: Verileri k sayıda kümeye ayırmak için kullanılan bir kümeleme algoritmasıdır.
- *Hiyerarşik Kümeleme*: Veriyi bir hiyerarşi şeklinde kümeler.
- *Ana Bileşenler Analizi*: Verinin boyutunu azaltarak en önemli bileşenleri bulur.
- *t-SNE*: Veriyi daha düşük boyutlarda görselleştirmek için kullanılan bir tekniktir.
- *Kendi Kendine Organize Olmuş Haritalar*: Verileri, benzerliklerine göre düzenler.

5.2.3. Yapay sinir ağları

Yapay sinir ağları (YSA), insan beynindeki nöronların işleyişine benzer bir yapı ile çalışarak karmaşık problemlerin çözümüne olanak tanır. YSA, özellikle çok sayıda kriterin olduğu bulut servisi seçiminde etkili bir yöntemdir. Bu teknik, büyük veri kümelerini işleyip öğrenerek, kriterler arasındaki ilişkileri anlamaya ve en uygun seçimi yapmaya yardımcı olabilir. Yapay sinir ağları, bulut servislerinin performansını tahmin etmek ve bu tahminlere dayanarak seçim yapmak için kullanılır.

- *Avantajları*: Yüksek doğruluk oranına sahiptir ve karmaşık veri kümeleri üzerinde etkili sonuçlar verir.
- *Dezavantajları*: Eğitim süreci uzun sürebilir ve modelin doğru çalışması için büyük miktarda veriye ihtiyaç duyulur.

5.2.4. Genetik algoritmalar

Genetik algoritmalar (GA), doğal seçim sürecinden esinlenerek geliştirilen bir optimizasyon tekniğidir. GA, belirli bir hedef doğrultusunda en iyi çözümü bulmak için bir dizi potansiyel çözümü (gen) rastgele oluşturur ve bu çözümleri, çaprazlama ve mutasyon gibi işlemlerle geliştirir. Bulut servisi seçiminde genetik algoritmalar, çok sayıda kriterin bulunduğu karmaşık ortamlarda en uygun bulut sağlayıcısını

belirlemek için kullanılabilir. Genetik algoritmalar, seçim sürecinde her kriterin optimal dengesini bulmak için iteratif bir yöntem sunar.

- *Avantajları:* Çok büyük arama alanlarında hızlı çözüm bulma kapasitesine sahiptir ve global optimum çözüme ulaşmayı hedefler.
- *Dezavantajları:* Doğru çözümü bulmak için yeterli sayıda iterasyona ihtiyaç duyabilir ve başlangıçta rastgele çözümler üretmesi nedeniyle bazı yanlış sonuçlar elde edilebilir.

5.3 Doğruluk ve Hata Performansı Ölçümü

1. *MSE (Mean Squared Error - Ortalama Kare Hata):* Tahmin edilen değerler ile gerçek değerler arasındaki farkların karelerinin ortalamasıdır. MSE ne kadar küçükse, modelin tahminleri o kadar doğrudur.
2. *RMSE (Root Mean Squared Error - Kare Kök Ortalama Hata):* MSE'nin kareköküdür. Yine, daha düşük değerler daha iyi modeli gösterir. RMSE, hataları orijinal birimle aynı ölçekte gösterdiği için MSE'ye göre daha anlaşılabilir.
3. *MAE (Mean Absolute Error - Ortalama Mutlak Hata):* Tahmin edilen değerler ile gerçek değerler arasındaki mutlak farkların ortalamasıdır. Bu metrik de ne kadar küçükse modelin doğruluğu o kadar iyidir.
4. *MAPE (Mean Absolute Percentage Error - Ortalama Mutlak Yüzde Hata):* Tahmin hatalarının yüzdesel ortalamasıdır. MAPE değerinin küçük olması, modelin daha doğru tahminler yaptığını göstermektedir.
5. *R² (R-squared - R-kare):* Modelin ne kadar iyi açıklayıcı olduğunu gösteren bir istatistiktir. Değer 0 ile 1 arasında olup, 1'e yaklaşması modelin veriyi ne kadar iyi açıkladığını göstermektedir. Yüksek bir R² değeri, modelin doğru tahminlerde bulunduğunu göstermektedir.

5.4 Regresyon Modeli Genel Performans Değerlendirmesi

1. *S (Standart Hata - Standard Error):* Modelin tahmin hatalarının ortalamasını göstermektedir. Bu değer, modelin doğruluğunu anlamamıza yardımcı olmaktadır. Daha düşük bir değer, modelin daha doğru tahminler yaptığını işaret etmektedir.

2. *R-sq (R-kare)*: Bu metrik, modelin hedef deęişkenin varyansını ne kadar iyi açıkladığını göstermektedir. Yüksek bir R-kare deęeri, modelin hedef deęişkeni iyi açıkladığını belirtmektedir.
3. *R-sq(adj) (Düzeltilmiş R-kare)*: R-sq, modeldeki tüm bağımsız deęişkenleri dikkate alır ve modelin karmaşıklığından etkilenebilir. Düzeltilmiş R-kare, bağımsız deęişken sayısındaki deęişlikleri dikkate alarak R-sq'yi düzeltir, böylece modelin doğruluğunu daha güvenilir bir şekilde deęerlendirir.
4. *R-sq(pred) (Tahmin R-kare)*: Modelin gelecekteki veriler üzerindeki tahmin gücünü ölçmektedir. Genellikle modelin tahmin yeteneğini anlamak için kullanılmaktadır.

5.5. ANOVA

ANOVA, bağımsız deęişkenlerin hedef deęişken üzerindeki etkisinin anlamlı olup olmadığını test etmek için kullanılmaktadır. Bu tabloda, modelin genel başarısı, her bir bağımsız deęişkenin katkısı ve modelin hataları incelenecektir.

Kolonlar:

1. *Source (Kaynak)*: Varyansın kaynağını belirtir. Burada iki ana kaynak var: Regression (regresyon modelinin deęişkenleri) ve Error (modelin tahmin ettięi deęerlerle gerçek deęerler arasındaki hata).
2. *DF (Degree of Freedom - Serbestlik Derecesi)*: Bu, varyansın hesaplanması için kullanılan serbestlik derecesini ifade etmektedir. Her bağımsız deęişken için 1 serbestlik derecesi, hata için ise 21 serbestlik derecesi bulunmaktadır.
3. *Adj SS (Düzeltilmiş Kareler Toplamı)*: Her bir kaynağın modelin açıklanan varyansına katkısını göstermektedir. Yüksek bir Adj SS, deęişkenin hedef deęişken üzerindeki etkisinin güçlü olduğunu göstermektedir.
4. *Adj MS (Düzeltilmiş Kareler Ortalaması)*: Adj SS'nin serbestlik derecesine bölünmesiyle elde edilmektedir. Bu, her deęişkenin etkisinin büyüklüğünü standartlaştırır.
5. *F-Value*: Her bir kaynağın varyansın toplam varyansa katkısını test etmek için kullanılan F istatistiğidir. Yüksek bir F-deęeri, bağımsız deęişkenin hedef

değişken üzerindeki etkisinin istatistiksel olarak anlamlı olduğunu göstermektedir.

6. *P-Value*: İlgili değişkenin istatistiksel olarak anlamlı olup olmadığını test etmektedir. Genellikle 0,05'ten küçük p-değerleri, o değişkenin anlamlı olduğunu göstermektedir.

5.6. Yapay Zeka Tekniklerinin ÇKKV ile Entegrasyonu

Yapay zeka teknikleri ve ÇKKV yöntemlerinin entegrasyonu, bulut servisi seçimi gibi karmaşık problemlerin daha verimli bir şekilde çözülmesine olanak sağlar. ÇKKV yöntemleri, kriterlerin önem sırasını belirleme ve seçenekleri sıralama açısından güçlüdür; ancak büyük veri kümeleri ile çalışırken zaman alıcı olabilir. Bu noktada, yapay zeka teknikleri, ÇKKV süreçlerini hızlandırmak, büyük veri kümelerini işlemek ve daha doğru sonuçlar elde etmek için devreye girer.

- *Makine Öğrenmesi ile Entegrasyon*: Makine öğrenmesi algoritmaları, geçmiş seçim verilerini analiz ederek ÇKKV yöntemlerinin ağırlıklandırma ve sıralama aşamalarına katkı sağlar. Örneğin, TOPSIS veya AHP yöntemleri kullanılarak yapılan seçimlerde, makine öğrenmesi ile kriterler arasındaki ilişkiler optimize edilebilir.
- *Yapay Sinir Ağları ile Entegrasyon*: YSA, ÇKKV yöntemlerinin belirli aşamalarında öğrenme süreçlerini devreye sokarak kriterler arasındaki kompleks ilişkileri analiz edebilir. AHP gibi yöntemlerde kullanılan kriter ağırlıkları, yapay sinir ağları tarafından optimize edilerek daha isabetli sonuçlar elde edilebilir.
- *Genetik Algoritmalar ile Entegrasyon*: ÇKKV yöntemleriyle birlikte genetik algoritmalar kullanılarak, en iyi bulut servisi sağlayıcısını seçmek için iteratif bir süreç oluşturulabilir. Genetik algoritmalar, çok sayıda alternatif çözümü değerlendirerek optimal çözüm yoluna ulaşılmasını hızlandırabilir.

Bu entegrasyonlar, bulut servisi seçim sürecinde karar vericilere daha hızlı, doğru ve verimli sonuçlar sunarak, karmaşık seçim süreçlerini basitleştirir.

6. BULUT SERVİSİ SEÇİMİ İÇİN ÖNERİLEN YÖNTEM

6.1. Yöntemin Tanıtımı

Bu tez kapsamında, bulut servisi seçimi sürecinde etkili bir çözüm sağlayan entegre bir yöntem önerilmektedir. Önerilen yöntem, ÇKKV teknikleri ve yapay zeka yöntemlerinin birleşimi üzerine kuruludur. Bu yöntem, karar vericiye kriterler arasındaki dengeyi sağlamak ve büyük veri kümeleri üzerinde daha hızlı analiz yapmak için bir çerçeve sunar. ÇKKV yöntemleri ile karar problemlerinin yapısal olarak modellenmesi ve alternatiflerin sıralanması sağlanırken, yapay zeka ile tahminleme yapılmıştır.

Önerilen yöntemin ana aşamaları şunlardır:

- *ÇKKV Teknikleri:* AHP ile kriter ağırlıklarının belirlenmesi, TOPSIS ile alternatiflerin sıralanması.
- *Yapay Zeka Teknikleri:* Makine öğrenmesi ile bulut hizmet sağlayıcısı seçiminde tahminleme yapılması.

Bu entegrasyon, bulut sağlayıcılar arasında en iyi seçeneği belirlemek için sistematik bir yaklaşım sunar ve mevcut yöntemlerin zayıf yönlerini giderir.

6.2. Yöntemin Uygulama Adımları

Önerilen yöntem, aşağıdaki adımlar doğrultusunda uygulanır:

1. *Kriterlerin Belirlenmesi:* İlk adımda, bulut servisi seçiminde dikkate alınacak kriterler Maliyet, Kullanıcı Dostu Arayüz ve Yönetim Araçları, Veri Yedekleme ve Kurtarma, Güvenlik, Entegrasyon, Destek ve Müşteri Hizmetleri, Performans, Uyumluluk olarak belirlenir. Bu kriterler, karar vericiye özgü olabilir ve kararın gerekliliklerine göre seçilir.

2. *Kriter Ağırlıklarının Belirlenmesi (AHP Kullanımı):* AHP yöntemi kullanılarak kriterler arasındaki önem dereceleri belirlenir. Bu adımda, ikili karşılaştırmalar yapılır ve her bir kriterin diğerlerine göre göreceli ağırlıkları hesaplanır.
3. *Alternatiflerin Değerlendirilmesi (TOPSIS Kullanımı):* Ağırlıklandırılmış kriterler kullanılarak bulut servis sağlayıcıları TOPSIS yöntemi ile değerlendirilir. Her bir sağlayıcı, kriterlere göre ideal ve anti-ideal çözümlere olan uzaklıkları temelinde sıralanır.
4. *Yapay Zeka Destekli Optimizasyon (Makine Öğrenmesi):* Makine öğrenmesi algoritmaları, geçmiş verilerden faydalanarak tahminleme yapar.
5. *Sonuçların Analizi ve Karar:* Son adımda, ÇKKV ve yapay zeka tekniklerinden elde edilen sonuçlar analiz edilir ve karar vericiye sunulur. Bu aşamada en yüksek performansı gösteren bulut servisi seçilir.

6.3. Örnek Uygulama ve Sonuçları

Önerilen yöntemin uygulanabilirliğini göstermek için bir örnek bulut servisi seçimi süreci ele alınmıştır. Örnek olarak, bir şirketin bulut hizmeti sağlayıcısı seçme ihtiyacı göz önünde bulundurulmuştur. Şirketin ihtiyaçlarına göre belirlenen kriterler şunlardır: Maliyet, Kullanıcı Dostu Arayüz ve Yönetim Araçları, Veri Yedekleme ve Kurtarma, Güvenlik, Entegrasyon, Destek ve Müşteri Hizmetleri, Performans, Uyumluluk

Kriterlerin Belirlenmesi: Şirketin ihtiyaçlarına göre belirlenen sekiz ana kriter (Maliyet, Kullanıcı Dostu Arayüz ve Yönetim Araçları, Veri Yedekleme ve Kurtarma, Güvenlik, Entegrasyon, Destek ve Müşteri Hizmetleri, Performans, Uyumluluk) tanımlanmıştır.

1. *AHP ile Kriter Ağırlıklarının Belirlenmesi:* AHP yöntemi kullanılarak her kriter için ağırlıklar belirlenmiştir. Maliyet ve güvenlik en yüksek ağırlığı alırken, destek ve müşteri hizmetleri ve veri yedekleme ve kurtarma daha düşük ağırlıklar almıştır.
2. *TOPSIS ile Alternatiflerin Değerlendirilmesi:* Pazarın önde gelen beş bulut servis sağlayıcısı (AWS, Microsoft Azure, Salesforce, Alibaba, Digitalocean)

kriterlere göre TOPSIS yöntemiyle sıralanmıştır. AWS ve Microsoft Azure ideal çözüme en yakın sağlayıcılar olarak tespit edilmiştir.

3. *Yapay Zeka Destekli Optimizasyon:* Makine öğrenmesi, geçmiş veri analizleri ve müşteri geri bildirimlerine dayanarak tahminleme yapmıştır.
4. *Sonuçların Analizi ve Karar:* Yapılan analizler sonucunda, Azure'un şirkete en uygun bulut sağlayıcı olduğu belirlenmiştir. Önerilen yöntem, karar vericiye sistematik bir yol haritası sunarak karmaşık seçim süreçlerini daha kolay yönetmelerini sağlamıştır. Bulut servisi seçiminde ÇKKV teknikleri ile yapay zeka yöntemlerinin kullanımı, karar vericilerin en uygun seçimi hızlı ve doğru bir şekilde yapmasına yardımcı olmuştur.

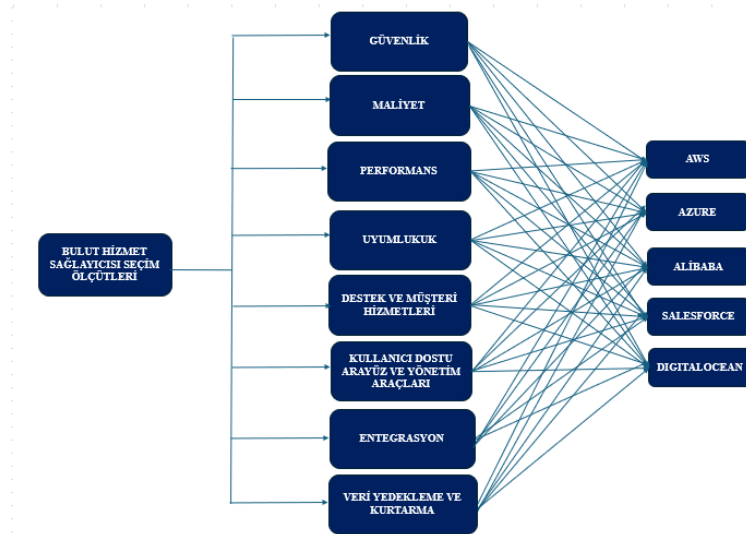


7. UYGULAMA: BULUT SERVİSİ SEÇİM SÜRECİ

7.1. Verilerin Toplanması ve Hazırlanması

Bulut servisi seçim sürecinde kullanılacak verilerin doğru şekilde toplanması ve hazırlanması, başarılı bir karar verme sürecinin temelini oluşturur. Bu aşamada, öncelikle bulut hizmeti sağlayıcıları hakkında performans, maliyet, güvenlik ve veri yedekleme ve kurtarma gibi çeşitli kriterler doğrultusunda veri toplanır. Verilerin toplanması sürecinde dikkat edilmesi gereken unsurlar şunlardır:

- *Veri Kaynakları:* Bulut servis sağlayıcılarının web siteleri, bağımsız değerlendirme platformları, kullanıcı geri bildirimleri ve sektörel raporlar gibi kaynaklardan veri toplanır.
- *Kriterlerin Tanımlanması:* Önceden belirlenen kriterler (maliyet, güvenlik, performans, Veri yedekleme ve kurtarma, müşteri desteği vb.) doğrultusunda her bir bulut sağlayıcısı için veri setleri oluşturulur. Bu kriterler, karar vericinin önceliklerine göre farklı ağırlıklarda değerlendirilecektir. Şekil 7.1’de Bulut Hizmet Sağlayıcısının Değerlendirilmesi İçin Hiyerarşik Yapı gösterilmiştir.



Şekil 7. 1 : Bulut Hizmet Sağlayıcısının Değerlendirilmesi İçin Hiyerarşik Yapı

Aşağıda Çizelge 7.1 'de ölçütlerin açıklamaları yer almaktadır.

Çizelge 7. 1: Ölçütlerin Açıklamaları

Ölçütler	Açıklamalar
Maliyet	Farklı bulut sağlayıcıları farklı fiyatlandırma modelleri sunar (kullandıkça öde, sabit fiyatlı paketler vs.). Hangi hizmetlerin kullanılacağına bağlı olarak, toplam maliyet önemli bir faktördür.
Güvenlik	Sağlayıcının sağladığı şifreleme, erişim kontrolü, kimlik doğrulama ve güvenlik duvarı gibi özellikleri kapsar. Ayrıca, sağlayıcının güvenlik sertifikaları ve uyumluluk standartlarına (ISO 27001, SOC 2 gibi) sahip olması önemlidir.
Uyumluluk	Verilere ve kaynaklara dünyanın herhangi bir yerinden hızlı ve güvenli bir şekilde erişimin sağlanmasıdır.
Destek ve Müşteri Hizmetleri	7/24 teknik destek hizmetleri, hızlı geri dönüşler ve çözüm odaklı yaklaşımları kapsar.
Performans	Hız, işlemci gücü, depolama ve ağ bant genişliği gibi performans kriterlerini kapsar.
Entegrasyon	Bulut platformunun, mevcut altyapı ve yazılım çözümleri ile entegrasyon kolaylığı sunması gerekir. API desteği ve üçüncü parti yazılımlarla uyumluluğu kapsar.
Kullanıcı Dostu Arayüz ve Yönetim Araçları	Kullanıcıların kolayca kaynakları yönetebileceği, erişimi ve yapılandırmayı basitleştiren bir yönetim panelini kapsar.

Çizelge 7. 1 (devam): Ölçütlerin Açıklamaları

Ölçütler	Açıklamalar
Veri Yedekleme ve Kurtarma	Sağlayıcıların veri yedekleme ve olabilecek felaketslere karşı sağlanan kurtarma çözümleridir.

- *Veri Hazırlama:* Toplanan veriler, eksik veya hatalı kayıtlar bakımından incelenir ve düzenlenir. Gerekirse normalize edilerek ÇKKV yöntemlerinin uygulanmasına hazır hale getirilir.

Bu aşamada sağlıklı verilerin elde edilmesi, daha sonraki analizlerde doğru sonuçlar almak için kritik öneme sahiptir.

7.2. ÇKKV ve Yapay Zeka Yöntemlerinin Uygulanması

Verilerin toplanması ve hazırlanmasının ardından, bulut servisi seçim sürecinde ÇKKV yöntemleri ve yapay zeka teknikleri uygulanır. Aşağıdaki adımlarla ilerlenir:

1. *AHP ile Kriter Ağırlıklarının Belirlenmesi:* AHP yöntemi kullanılarak belirlenen kriterler arasındaki önem dereceleri hesaplanır. Bu süreçte, her bir kriterin diğerlerine göre ne kadar önemli olduğu ikili karşılaştırmalar yoluyla elde edilir. Sonuç olarak her bir kriter için ağırlıklandırma yapılır ve bu ağırlıklar daha sonraki aşamalarda kullanılacak olan TOPSIS yöntemi için temel teşkil eder.
2. *TOPSIS ile Alternatiflerin Değerlendirilmesi:* AHP ile elde edilen kriter ağırlıkları, bulut servisi sağlayıcılarını sıralamak için TOPSIS yöntemine uygulanır. TOPSIS yöntemi, her bir bulut servisi sağlayıcısını ideal ve anti-ideal çözümlere göre sıralayarak en uygun sağlayıcıyı belirler. Bu aşamada her bulut servisi sağlayıcısının performansı, çeşitli kriterler ışığında değerlendirilir.
3. *Yapay Zeka Destekli Optimizasyon:*

Makine Öğrenmesi: Makine öğrenmesi teknikleri, alternatifler arasındaki ilişkileri ve kriterler üzerindeki etkileri analiz ederek tahmin süreci sağlar.

Makine öğrenmesi algoritmaları, geçmiş veriler ve örneklemelerle eğitim olarak seçim süreçlerini optimize eder.

7.3. Uygulama ve Sonuçları

7.3.1. Uygulama

Bir teknoloji şirketi, beş bulut servis sağlayıcısının (AWS, Microsoft Azure, Salesforce, Alibaba, Digitalocean) çeşitli kriterlere göre değerlendirilmesini istemektedir. Kriterler: Maliyet, Kullanıcı Dostu Arayüz ve Yönetim Araçları, Veri Yedekleme ve Kurtarma, Güvenlik, Entegrasyon, Destek ve Müşteri Hizmetleri, Performans, Uyumluluk'tir.

7.3.2. ÇKKV yöntemlerinin uygulanması

1. *AHP ile Kriter Ağırlıklarının Belirlenmesi:* AHP yöntemi kullanılarak kriterlerin önem dereceleri belirlenmiştir:
 - MALİYET: 0.22
 - GÜVENLİK: 0.20
 - KULLANICI DOSTU ARAYÜZ VE YÖNETİM ARAÇLARI: 0,11
 - PERFORMANS: 0.10
 - UYUMLULUK: 0.10
 - ENTEGRASYON: 0.09
 - DESTEK VE MÜŞTERİ HİZMETLER: 0.09
 - VERİ YEDEKLEME VE KURTARMA: 0.08
2. *TOPSIS ile Alternatiflerin Değerlendirilmesi:* TOPSIS yöntemi kullanılarak normalize edilmiş değerler hesaplanmıştır. İdeal ve anti-ideal çözümlerler bulunarak çizelgelerde ilgili hesaplamalara ayrıntılı olarak yer verilmiştir. Her sağlayıcının ideal çözüme olan uzaklığı hesaplanmıştır. Çizelge 7.2'de normalleştirilmiş matris yer almaktadır. Çizelge 7.3'te ağırlıklı değerler ile normalleştirilmiş matris çarpımı gösterilmiştir. Yöntem adımları aşağıda detaylı olarak yer almaktadır. Devamında worst best değerleri hesaplanacak olup sonuca gidilecektir.

Çizelge 7. 2: Normalleştirilmiş Matris

	Güvenlik	Maliyet	Performans	Uyumluluk	Destek ve Müşteri Hizmetleri	Kullanıcı Dostu Arayüz ve Yönetim Araçları	Entegrasyon	Veri Yedekleme ve Kurtarma
AWS	0.656	0.65	0.544	0.544	0.492	0.629	0.478	0.545
AZURE	0.525	0.52	0.544	0.544	0.492	0.504	0.598	0.545
ALİBABA	0.393	0.39	0.408	0.408	0.492	0.378	0.478	0.436
SALESFORCE	0.262	0.26	0.272	0.408	0.369	0.252	0.239	0.327
DIGITAL OCEAN	0.262	0.26	0.408	0.272	0.369	0.378	0.359	0.327

Çizelge 7. 3: Ağırlıklı Değerler ile Normalleştirilmiş Matris Çarpımı

	Güvenlik	Maliyet	Performans	Uyumluluk	Destek ve Müşteri Hizmetleri	Kullanıcı Dostu Arayüz ve Yönetim Araçları	Entegrasyon	Veri Yedekleme ve Kurtarma
AWS	0.132	0.15	0.057	0.052	0.044	0.070	0.043	0.045
AZURE	0.106	0.12	0.057	0.052	0.044	0.057	0.054	0.045
ALİBABA	0.079	0.08	0.043	0.039	0.044	0.042	0.043	0.036

Çizelge 7. 3 (devam): Ağırlıklı Değerler ile Normalleştirilmiş Matris Çarpımı

	Güvenlik	Maliyet	Performans	Uyumluluk	Destek ve Müşteri Hizmetleri	Kullanıcı Dostu Arayüz ve Yönetim Araçları	Entegrasyon	Veri Yedekleme ve Kurtarma
SALESFORCE	0.053	0.06	0.028	0.039	0.033	0.028	0.021	0.027
DIGITAL OCEAN	0.05	0.06	0.04	0.026	0.033	0.043	0.032	0.027

Çizelge 7.4’te worst best değerleri hesaplanmıştır. Çizelge 7.5’te sağlayıcıların ideal çözüme olan uzaklığı gösterilmiştir. Çizelge 7.6’da ÇKKV yöntemi sonuçlarının genel gösterimi yer almaktadır.

Çizelge 7. 4: Worst Best Değerlerinin Hesaplanması

Worst Best	Güvenlik	Maliyet	Performans	Uyumluluk	Destek ve Müşteri Hizmetleri	Kullanıcı Dostu Arayüz ve Yönetim Araçları	Entegrasyon	Veri Yedekleme ve Kurtarma
V+	0.132	0.059	0.057	0.052	0.044	0.071	0.054	0.045
V-	0.053	0.148	0.028	0.026	0.033	0.028	0.021	0.027

Çizelge 7. 5: Sağlayıcıların İdeal Çözüme Olan Uzaklığı

Bulut Hizmetleri	Si+	Si+	P SCORE
AWS	0.089277577	0.102275475	0.533927671

Çizelge 7.5 (devam): Sağlayıcıların İdeal Çözümüne Olan Uzaklığı

Bulut Hizmetleri	Si+	Si+	P SCORE
AZURE	0.066238222	0.086190799	0.565448749
ALİBABA	0.70898419	0.073637449	0.50947526
SALESFORCE	0.102644497	0.089567583	0.465983111
DIGITALOCEAN	0.094083145	0.091506174	0.493057328

Çizelge 7. 6: ÇKKV Yöntemi Sonuçları Genel Gösterimi

Bulut Hizmetleri	AHS&TOPSIS
AZURE	1
AWS	2
ALİBABA	3
DIGITALOCEAN	4
SALESFORCE	5

7.3.3. Yapay zeka destekli optimizasyon

7.3.3.1. Makine öğrenmesi

Uygulamada Orange ve Minitab uygulamaları kullanılarak tahminleme yapılmıştır.

İlk olarak değişkenler, girdiler ve çıktılar belirlenmiştir. Problemimizde değişkenler, girdiler ve çıktılar aşağıda belirtilmiştir. Değişkenler, kriterlere verilen puanlardır, girdi, kriterlerdir ve çıktı bulut servisleridir. Makine öğrenmesinde 2 aşama bulunmaktadır. Bunlar eğitim ve test aşamalarıdır. Örneğin 100 veri olan bir problemde 80 veriyi algoritmanın öğrenmesi istenilirken kalan 20 veride test etmesi istenebilir. Bu sayede ne kadar doğru çalıştığına bakılmış olur. Orange programında veriler 70/30 olarak bölünmüştür. 30 veriden 21 tanesi üzerinde çalışılarak 9 tanesi üzerinde test edilecektir.

Çalışmanın ilk aşamasında sonuçlar Minitab programı ile değerlendirilmiştir.

Çizelge 7.7’de regresyon modelinin genel performansını değerlendiren model özeti sonuçları yer almaktadır.

Çizelge 7. 7: Model Özeti

S	R-sq	R-sq(adj)	R-sq(pred)
0,74386	80,63%	73,26%	58,12%

Her bir metriği açıklanarak tablo yorumlanmıştır.

Metrikler:

- *S (Standart Hata - Standard Error):* Burada $S = 0,743861$ değeri, modelin tahminlerinin ortalama hatasının $0,7438$ olduğunu göstermektedir. Bu değer, modelin doğruluğunu anlamamıza yardımcı olmaktadır. Daha düşük bir değer, modelin daha doğru tahminler yaptığına işaret etmektedir.
- *R-sq (R-kare):* Buradaki $R-sq = 80,63\%$, modelin hedef değişkenin varyansının **%80,63**'ünü açıkladığını göstermektedir. Bu, modelin oldukça iyi bir açıklayıcılığa sahip olduğunu ve verinin büyük bir kısmını doğru bir şekilde modellediğini ifade etmektedir.
- *R-sq(adj) (Düzeltilmiş R-kare):* Buradaki $R-sq(adj) = 73,26\%$, modelin doğruluğunun düzeltilmiş haliyle $\%73,26$ olduğunu göstermektedir. Bu, modelin karmaşıklığını dikkate alarak yine oldukça yüksek bir açıklayıcı güce sahip olduğunu göstermektedir.
- *R-sq(pred) (Tahmin R-kare):* $R-sq(pred) = 58,12\%$, modelin yeni (görülmemiş) verilerdeki doğruluğunu ifade etmektedir. Bu değer, modelin tahmin gücünün $\%58,12$ olduğunu göstermektedir. Yani, model eğitim verisinde oldukça iyi bir açıklayıcı güce sahipken, test (veya yeni) veriler üzerinde biraz daha düşük bir doğruluk sağlamaktadır. Bu durum, modelin aşırı uyum yapmadığını ancak bazı iyileştirmelere ihtiyaç duyabileceğini göstermektedir.

Genel Yorum:

- *Modelin Genel Başarısı:* Model %80,63 oranında bir R-kare değeriyle çok iyi bir açıklama gücüne sahiptir. Düzeltilmiş R-kare de %73,26 ile oldukça iyi, bu da modelin gereksiz değişkenlerden kaçındığını ve karmaşıklığı dikkate aldığına da iyi performans gösterdiğini göstermektedir.
- *Tahmin Gücü:* Model, eğitim verisi üzerinde yüksek doğruluk göstermektedir (R-sq yüksek), ancak yeni verilerdeki (R-sq(pred)) doğruluğu biraz daha düşüktür. Bu, modelin genel geçerliliği hakkında bilgi verir ve modelin aşırı uyum yapmadığını, ancak daha iyi tahminler için iyileştirilebileceğini göstermektedir.

Modelin genel başarısı ve tahmin gücü yukarıda açıklanmıştır. Modelin genel başarısı çok iyi bir açıklama gücüne sahipken, tahmin gücü eğitim verisi üzerinde yüksek doğruluk göstermektedir.

Model iyi bir performans göstermektedir, ancak test verileri üzerinde daha yüksek doğruluk sağlamak için bazı iyileştirmeler yapılabilir.

Çalışmanın ilerisinde Varyans Analizi (ANOVA) sonuçları incelenmiştir. Çizelge 7.8'de ANOVA sonuçlarına yer verilmiştir.

Çizelge 7. 8: ANOVA Sonuçları

Source	DF	Adj SS	Adj MS	F-Value	P-Value
REGRESSION	8	48,3801	6,04751	10,93	0,000
GÜVENLİK	1	0,3395	0,33950	0,61	0,442
MALİYET	1	8,5830	8,58304	15,51	0,001
PERFORMANS	1	2,1904	2,19041	3,96	0,060
UYUMLULUK	1	3,7694	3,76942	6,81	0,016

Çizelge 7. 7: ANOVA Sonuçları devamı

Source	DF	Adj SS	Adj MS	F-Value	P-Value
DESTEK VE MÜŞTERİ HİZMETLERİ	1	0,7457	0,74569	1,35	0,259
KULLANIC DOSTU ARAYÜZ VE YÖNETİM ARAÇLARI	1	0,0143	0,01435	0,03	0,874
ENTEGASYON	1	1,8869	1,88693	3,41	0,079
VERİ YEDEKLEME VE KURTARMA	1	0,5580	0,55801	1,01	0,327
Error	21	11,6199	0,55333		
Lack-of-Fit	20	11,6199	0,58100		
Pure Error	1	0,0000	0,00000		
Total	29	60,0000			

Bu çizelge, regresyon modelinin ANOVA sonuçlarını içermektedir. ANOVA, bağımsız değişkenlerin hedef değişken üzerindeki etkisinin anlamlı olup olmadığını test etmek için kullanılmaktadır. Bu tabloda, modelin genel başarısı, her bir bağımsız değişkenin katkısı ve modelin hataları incelenecektir.

Değişkenlerin Yorumları:

1. **REGRESYON:** Toplam 8 bağımsız değişken vardır. Adj SS 48,3801, Adj MS 6,04751, F-Value 10,93, P-Value değeri 0'dır. Modelin genel regresyonu, hedef değişkeni çok iyi açıklamaktadır. P-değeri 0,000 olduğu için, modelin genel olarak istatistiksel olarak anlamlı olduğu ve bağımsız değişkenlerin hedef değişkeni önemli ölçüde açıkladığı söylenebilmektedir.

2. *GÜVENLİK*: Adj SS 0,3395, Adj MS 0,3395, F-Value 0,61, P-Value değeri 0,442'dir. Güvenlik değişkeni, hedef değişken üzerinde anlamlı bir etkiye sahip değildir çünkü p-değeri 0,05'ten büyüktür. Bu, güvenlik değişkeninin modelin performansını önemli ölçüde etkilemediğini gösterir.
3. *MALİYET*: Adj SS 8,583, Adj MS 8,583, F-Value 15,51, P-Value değeri 0,001'dir. Maliyet değişkeni, hedef değişken üzerinde anlamlı bir etkiye sahiptir. P-değeri 0,001 olduğu için maliyetin etkisi güçlüdür.
4. *PERFORMANS*: Adj SS 2,1904, Adj MS 2,19041, F-Value 3,96, P-Value değeri 0,006'dır. Performans değişkeni, hedef değişken üzerinde anlamlı bir etkiye sahip olabilir. P-değeri 0,05'e yakın, bu nedenle bu değişkenin etkisi sınırlı anlamlılık göstermektedir.
5. *UYUMLULUK*: Adj SS 3,7694, Adj MS 3,76942, F-Value 6,81, P-Value değeri 0,016'dır. Uyumluluk değişkeni, hedef değişken üzerinde istatistiksel olarak anlamlı bir etkiye sahiptir. P-değeri 0,016 olduğu için, uyumluluk değişkeni modelin performansını anlamlı ölçüde etkilemektedir.
6. *DESTEK VE MÜŞTERİ HİZMETLERİ*: Adj SS 0,7457, Adj MS 0,74569, F-Value 1,35, P-Value değeri 0,259'dur. Destek ve müşteri hizmetleri değişkeni, hedef değişken üzerinde anlamlı bir etkiye sahip değildir çünkü p-değeri 0,05'ten büyüktür.
7. *KULLANICI DOSTU ARAYÜZ VE YÖNETİM ARAÇLARI*: Adj SS 0,0143, Adj MS 0,01435, F-Value 0,03, P-Value değeri 0,874'tür. Kullanıcı dostu arayüz ve yönetim araçları değişkeni de hedef değişken üzerinde anlamlı bir etkiye sahip değildir.
8. *ENTEGRASYON*: Adj SS 1,8869, Adj MS 1,88693, F-Value 3,41, P-Value değeri 0,079'dur. Entegrasyon değişkeninin etkisi, p-değeri 0,05'e yakın olduğu için sınırlı anlamlılık göstermektedir.

9. *VERİ YEDEKLEME VE KURTARMA*: Adj SS 0,5580, Adj MS 0,55801, F-Value 1,01, P-Value değeri 0,327'dir. Veri yedekleme ve kurtarma değişkeni de hedef değişken üzerinde anlamlı bir etkiye sahip değildir.

10. *Error (Hata)*: Adj SS 11.6199, Adj MS 0,55333, Lack-of-Fit 11,6199, Pure Error değeri 0'dır. Modelin tam olarak veriyle uyumsuz olan kısmını gösterir. Buradaki değerlerin büyük kısmı hata olarak kalmaktadır.

Çalışmanın sonraki aşamasında Confusion Matrix her bir algoritma için incelendiğinde aşağıdaki çıktılara ulaşılmaktadır. Şekil 7.2'de Knn algoritması confusion matrix, Şekil 7.3'te Random Forest Algoritması Confusion Matrix, Şekil 7.4'te Neural Network Algoritması Confusion Matrix, Şekil 7.5'te Gradient Boosting Algoritması Confusion Matrix sonuçları yer almaktadır.

		Predicted					Σ
		ALİBABA	AWS	AZURE	DIGITALOCEAN	SALESFORCE	
Actual	ALİBABA	1	0	0	0	0	1
	AWS	0	2	0	0	0	2
	AZURE	0	0	2	0	0	2
	DIGITALOCEAN	0	0	0	2	1	3
	SALESFORCE	0	0	0	1	0	1
Σ		1	2	2	3	1	9

Şekil 7. 2: Knn Algoritması Confusion Matrix

		Predicted					Σ
		ALİBABA	AWS	AZURE	DIGITALOCEAN	SALESFORCE	
Actual	ALİBABA	1	0	0	0	0	1
	AWS	0	2	0	0	0	2
	AZURE	0	0	2	0	0	2
	DIGITALOCEAN	2	0	1	0	0	3
	SALESFORCE	0	0	0	0	1	1
Σ		3	2	3	0	1	9

Şekil 7. 3: Random Forest Algoritması Confusion Matrix

		Predicted					Σ
		ALİBABA	AWS	AZURE	DIGITALOCEAN	SALESFORCE	
Actual	ALİBABA	1	0	0	0	0	1
	AWS	0	2	0	0	0	2
	AZURE	0	1	1	0	0	2
	DIGITALOCEAN	1	0	0	1	1	3
	SALESFORCE	0	0	0	0	1	1
Σ		2	3	1	1	2	9

Şekil 7. 4: Neural Network Algoritması Confusion Matrix

		Predicted					Σ
		ALİBABA	AWS	AZURE	DIGITALOCEAN	SALESFORCE	
Actual	ALİBABA	1	0	0	0	0	1
	AWS	0	2	0	0	0	2
	AZURE	0	0	2	0	0	2
	DIGITALOCEAN	2	0	0	1	0	3
	SALESFORCE	0	0	0	0	1	1
Σ		3	2	2	1	1	9

Şekil 7. 5: Gradient Boosting Algoritması Confusion Matrix

Confusion Matrix, sınıflandırma modellerinin performansını değerlendirmek için kullanılan önemli bir araçtır. Modelin tahmin ettiği sınıflarla gerçek sınıflar arasındaki ilişkiyi gösteren bir tablo şeklindedir. Karışıklık matrisi, modelin doğru ve yanlış tahminlerini daha ayrıntılı bir şekilde anlamaya yardımcı olmaktadır.

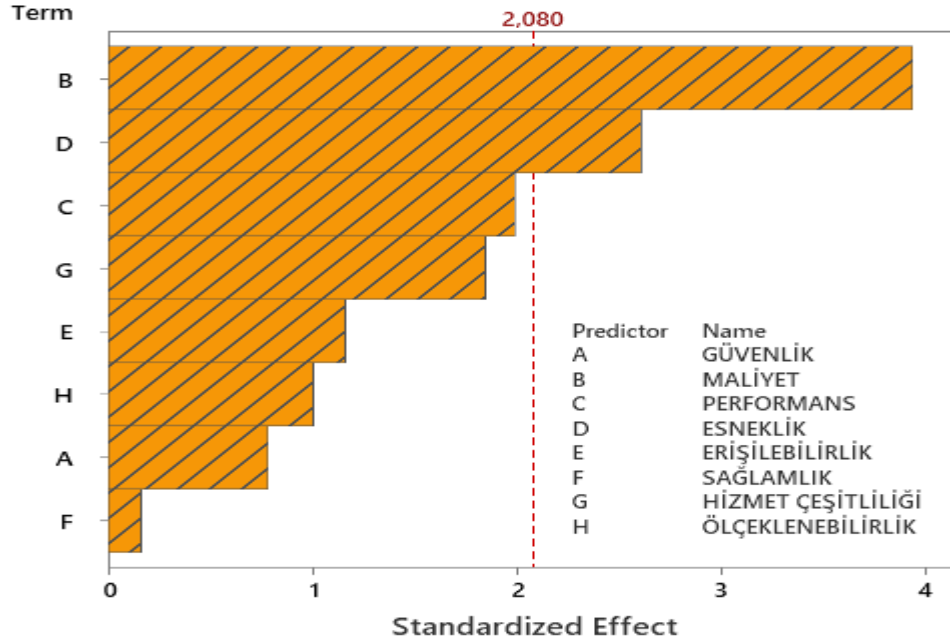
Genel Yorum:

- *Anlamlı Değişkenler:* Maliyet, uyumluluk ve performans değişkenlerinin hedef değişken üzerinde istatistiksel olarak anlamlı bir etkisi vardır.
- *Anlamsız Değişkenler:* Güvenlik, destek ve müşteri hizmetleri, kullanıcı dostu arayüz ve yönetim araçları ve veri yedekleme ve kurtarma gibi değişkenler modeldeki hata ile açıklanabilecek etkiler taşır ve bunların etkisi anlamlı değildir.
- *Modelin Genel Başarısı:* Regresyon modelinin genel anlamda iyi bir performans gösterdiği söylenebilmektedir. Ancak, bazı değişkenler (güvenlik,

destek ve müşteri hizmetleri, kullanıcı dostu arayüz ve yönetim araçları, veri yedekleme ve kurtarma) hedef değişken üzerinde anlamlı bir etkiye sahip değildir.

Modelin doğruluğunu ve güvenilirliğini artırmak için, anlamlı etkisi olmayan değişkenlerin dışlanması veya modellenmesi gerekebilir.

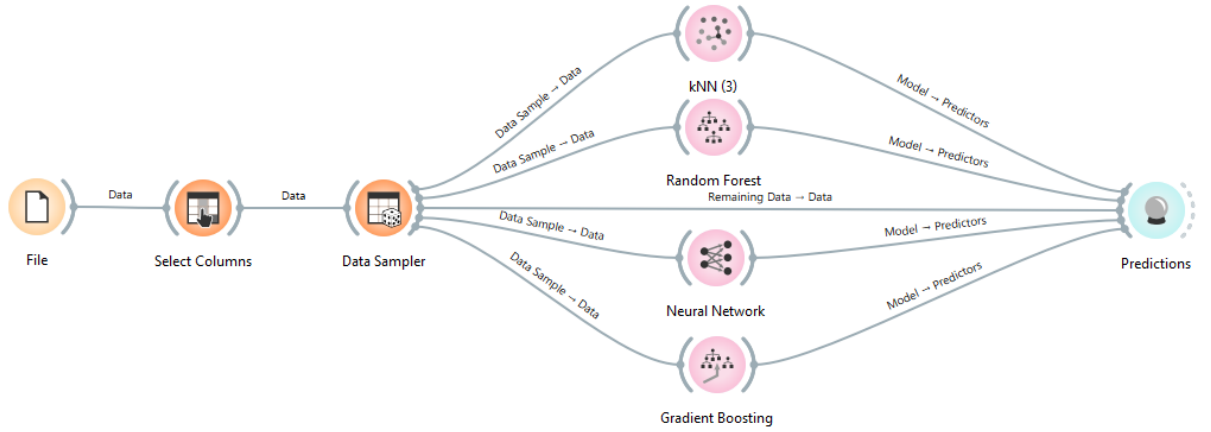
Şekil 7.6'da pareto grafiğine yer verilmiştir.



Şekil 7. 6: Pareto Grafiği

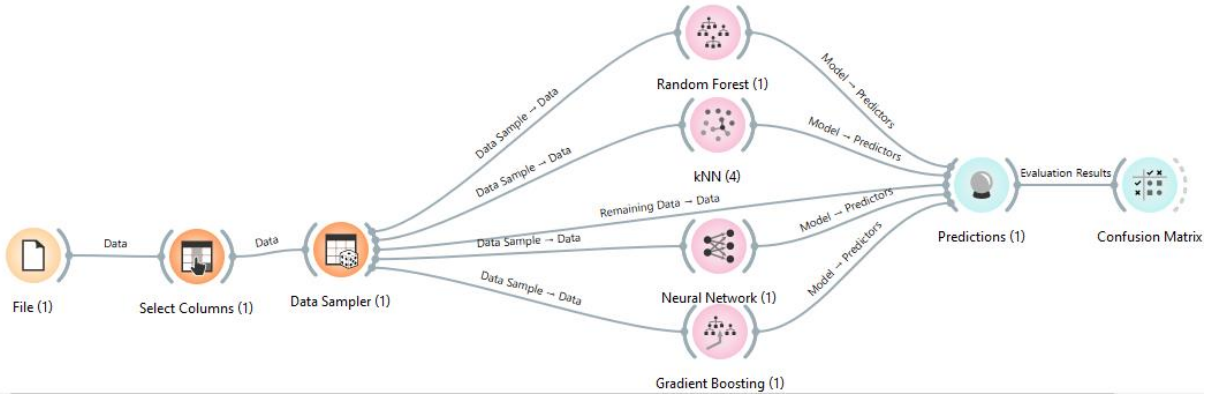
Çalışmanın diğer aşamasında Orange programı kullanılmıştır. Orange programında seçilen algoritmalar; kNN, Random Forest, Neural Network ve Gradient Boosting'tir. Aşağıda seçilen algoritmalar şekil üzerinde gösterilmiştir.

İlk şekilde kategorik veriler ile çalışılmıştır. Şekil 7.7'de kategorik veriler ile çalışılmıştır.



Şekil 7. 7: Orange Uygulaması Kategorik Veri Kullanımı

Şekil 7.8’de Minitab programında hesaplama yapılabilmesi için nümerik veriler ile çalışılmıştır.



Şekil 7. 8: Orange Uygulaması Nümerik Veri Kullanımı

Çalışmanın devamında Predictions kısmı incelenmiş ve alt şekilde yer alan verilere ulaşılmıştır.

Şekil 7.9’da predictions çıktısına yer verilmektedir. İncelendiğinde ilk satırda KNN, Random Forest, Neural Network ve Gradient Boosting algoritmaları 2 tahminlemiş. Bulut Numeric 2 çıkmış ve algoritmalar doğru çalışmıştır.

İkinci satırda KNN, Random Forest ve Gradient Boosting 4 tahminlerken Neural Network 5 tahminlemiştir. Bulut Numeric 4 çıkmış ve Neural Network algoritması yanlış çalışmıştır.

Bu mantıkla diğer algoritmalar yorumlandığında Neural Network algoritmasının doğru çalışmadığı sonucuna varılmıştır.

	kNN (3)	Random Forest	Neural Network	Gradient Boosting	BULUTNUMERIC	GÜVENLİK	MALİYET	PERFORMANS	ESNEKLİK	ERİŞİLEBİLİRLİK	SAĞLAMLIK	HİZMET ÇEŞİTLİLİĞİ	ÖLÇEKLENEBİLİRLİK
1	2	2	2	2	2	4	4	4	5	4	4	5	4
2	4	4	4	5	4	3	3	3	2	4	3	2	4
3	4	4	4	4	5	2	2	2	4	3	3	3	2
4	1	1	2	1	1	5	5	5	5	5	5	4	4
5	4	4	5	4	3	2	2	2	3	3	3	2	3
6	1	1	1	1	1	4	5	5	5	4	5	4	5
7	4	3	2	3	5	3	2	4	4	4	4	4	5
8	4	5	5	5	5	2	2	3	3	3	3	2	3
9	2	2	1	2	2	3	4	4	5	4	4	4	5

Şekil 7. 9: Predictions Çıktısı

Çalışmanın devamında MSE, RMSE, MAE, MAPE ve R2 değerleri hesaplanmıştır.

Şekil 7.10'da MSE, RMSE, MAE, MAPE ve R2 değerleri gösterilmiştir.

Model	MSE	RMSE	MAE	MAPE	R2
kNN (3)	0.493	0.702	0.600	0.224	0.806
Random Forest	0.783	0.885	0.621	0.201	0.692
Neural Network	2.396	1.548	1.179	0.463	0.058
Gradient Boosting	0.704	0.839	0.477	0.113	0.723

Şekil 7. 10: MSE, RMSE, MAE, MAPE ve R2 Değerleri

Tablodaki metrikler, farklı makine öğrenmesi modellerinin doğruluk ve hata performansını ölçmek için kullanılmıştır. Bu metriklerin her biri, modelin tahminlerinin gerçek verilere ne kadar yakın olduğunu değerlendirmek için kullanılmaktadır.

Aşağıda her bir modelin performansını yorumlanmıştır.

Modellerin Yorumları:

1. *KNN (K-Nearest Neighbors)*: MSE 0,493 diğer modellere göre düşük bir değerdir, modelin tahminleri genelde doğrudur. RMSE 0,702 ortalama hata değeri, kabul edilebilir seviyededir. MAE 0,6 oldukça düşük bir hata değeridir. MAPE 0,224 yüzde hata oranı düşük, modelin tahminleri çoğunlukla doğrudur. R² 0,806 yüksek bir R², modelin veriyi iyi açıkladığını göstermektedir.
2. *Random Forest*: MSE 0,783 KNN'den daha yüksektir, bu modelin tahminleri biraz daha hatalıdır. RMSE 0,885 ortalama hata değeri daha yüksektir, tahminlerde daha fazla sapma vardır. MAE 0,621 KNN'den biraz daha

yüksektir. MAPE 0,201 yüzde hata oranı oldukça düşüktür, iyi bir modeldir. R^2 0,692 KNN'den daha düşüktür, modelin doğruluğu biraz daha düşüktür.

3. *Neural Network*: MSE 2,396 çok yüksektir, bu modelde büyük hatalar vardır. RMSE 1,548 yüksek bir hata değeridir, modelin tahminleri oldukça sapmıştır. MAE 1,1179 çok yüksek bir mutlak hatadır, modelin performansı düşüktür. MAPE 0,463 yüzde hata oranı çok yüksektir, modelin tahminleri genelde hatalıdır. R^2 0,058 çok düşüktür, model veriyi neredeyse hiç açıklayamamaktadır.
4. *Gradient Boosting*: MSE 0,704 diğer modellere göre daha düşüktür, tahminler genel olarak iyidir. RMSE 0,839 ortalama hata değeridir, kabul edilebilir seviyededir. MAE 0,477 düşük bir hata değeridir. MAPE 0,113 çok düşük bir yüzde hata oranıdır, oldukça doğru tahminlemiştir. R^2 0,723 yüksek bir değerdir fakat KNN ve Random Forest'tan biraz daha düşüktür.

Genel Yorum:

- *En iyi model*: KNN, yüksek bir R^2 değeri ve düşük hata metrikleri ile en iyi performansı göstermektedir. Bu model, veriyi en iyi açıklayan modeldir.
- *En kötü model*: Neural Network, yüksek MSE, RMSE ve MAE değerleri ile en kötü performansı göstermektedir. Bu model, veri üzerinde iyi bir tahmin yapmamaktadır ve hata oranları çok yüksektir.
- *Arada kalan modeller*: Random Forest ve Gradient Boosting, genel olarak iyi performans sergilemektedir. Ancak, KNN'ye kıyasla daha düşük doğruluk ve daha fazla hata barındırmaktadır. Gradient Boosting, MAPE açısından oldukça iyi sonuçlar verirken, Random Forest daha iyi bir R^2 sunmaktadır.

KNN modeli veriyi en iyi şekilde tahmin ederken, Neural Network bu görevde oldukça zayıf kalmıştır.

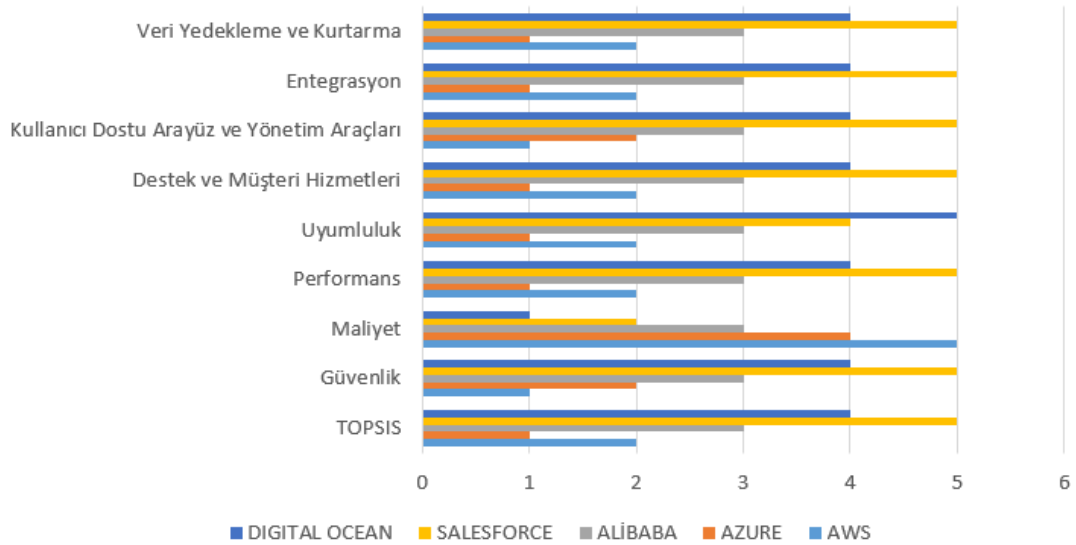
Sonuçları Yorumlama:

- ÇKKV aşamasında AWS ve Azure, model tarafından en yüksek olasılıklarla iyi alternatifler olarak sınıflandırılır. Alibaba, Salesforce ve Digitalocean ise düşük olasılıklarla kötü alternatifler olarak sınıflandırılacaktır.

- Yapay zeka aşamasında KNN modeli veriyi en iyi şekilde tahmin ederken, Neural Network bu görevde oldukça zayıf kalmıştır
- Güvenlik, destek ve müşteri hizmetleri, kullanıcı dostu arayüz ve yönetim araçları ve veri yedekleme ve kurtarma gibi değişkenler modeldeki hata ile açıklanabilecek etkiler taşır ve bunların etkisi anlamlı değildir. Regresyon modelinin genel anlamda iyi bir performans gösterdiği söylenebilmektedir. Modelin doğruluğunu ve güvenilirliğini artırmak için, anlamlı etkisi olmayan değişkenlerin dışlanması veya modellenmesi gerekebilir.

7.3.4 Duyarlılık analizi sonuçları

Her bir kritere sırası ile 0,5 değeri verilmiş olup, toplamı olacak şekilde ağırlıklar diğer değişkenlere dağıtılmıştır. Şekil 7.11’de alternatiflerin sıralamalarına yer verilmiştir.



Şekil 7. 11: Duyarlılık Analizi Sıralama Sonucu

Alibaba kriter ağırlıklarındaki değişime en az duyarlı alternatiftir.

Maliyet kriteri daha etkilidir ve kriter ağırlıklarındaki küçük değişimlere daha hassastır.

Destek ve Müşteri Hizmetleri, Entegrasyon, Veri Yedekleme ve Kurtarma kriterleri daha az etkilidir ve kriter ağırlıklarındaki küçük değişimlere hassas değildir.

7.3.5. Karar ve uygulama

Sonuçlara dayanarak Azure, Maliyet, Kullanıcı Dostu Arayüz ve Yönetim Araçları, Veri Yedekleme ve Kurtarma, Güvenlik, Entegrasyon, Destek ve Müşteri Hizmetleri, Performans, Uyumluluk kriterlerinde en uygun bulut servisi sağlayıcısı olarak seçilmiştir. Bu karar, şirketin ihtiyaçlarına en iyi şekilde yanıt verecek ve uzun vadede en yüksek verimliliği sağlayacaktır.

Son aşamada, ÇKKV yöntemleri ve yapay zeka tekniklerinden elde edilen sonuçlar özetlenir. Bu süreçte aşağıdaki adımlar takip edilir:

- *ÇKKV Sonuçları:* AHP ve TOPSIS yöntemleri ile elde edilen bulut servisi sıralamaları incelenir. Her bir bulut servisi sağlayıcısının kriterlere göre ne kadar başarılı olduğu ve hangi kriterlerde öne çıktığı analiz edilir.
- *Yapay Zeka Sonuçları:* Yapay zeka aşamasında KNN modeli veriyi en iyi şekilde tahmin ederken, Neural Network bu görevde oldukça zayıf kalmıştır. Güvenlik, destek ve müşteri hizmetleri, kullanıcı dostu arayüz ve yönetim araçları ve veri yedekleme ve kurtarma gibi değişkenler modeldeki hata ile açıklanabilecek etkiler taşır ve bunların etkisi anlamlı değildir. Regresyon modelinin genel anlamda iyi bir performans gösterdiği söylenebilmektedir. Modelin doğruluğunu ve güvenilirliğini artırmak için, anlamlı etkisi olmayan değişkenlerin dışlanması veya modellenmesi gerekebilir.
- *Sonuçların Uyumunun Değerlendirilmesi:* Yapay zeka teknikleri ile ÇKKV sonuçlarının birbirine uyumlu olup olmadığı değerlendirilir. Bu değerlendirme, farklı yöntemlerin birleşik kullanımıyla daha isabetli bir seçim süreci sağlayıp sağlamadığını ortaya koyar.

Karşılaştırma Analizi: Önerilen entegre yaklaşım, karar vericilere daha hızlı ve doğru sonuçlar sağlayarak bulut servisi seçimi sürecini etkin hale getirir. ÇKKV ve yapay zeka yöntemlerinin kullanımın, karar sürecinde daha güvenilir ve optimize edilmiş çözümler sunar.

Sonuçlara dayanarak yapılan değerlendirmeler ve karşılaştırmalar, Azure'un Maliyet, Kullanıcı Dostu Arayüz ve Yönetim Araçları, Veri Yedekleme ve Kurtarma, Güvenlik, Entegrasyon, Destek ve Müşteri Hizmetleri, Performans, Uyumluluk kriterlerinde en

uygun bulut servisi sağlayıcısı olarak seçildiğini göstermektedir. Bu seçim, şirketin ihtiyaçlarına en iyi şekilde yanıt verecek ve uzun vadede en yüksek verimliliği sağlayacaktır.

Önerilen Entegre Yaklaşım

- ÇKKV ve yapay zeka yöntemlerinin kullanımı, karar vericilere daha kapsamlı ve doğruluğu yüksek sonuçlar sunar.
- ÇKKV yöntemlerinin detaylı kriter analizleri ile yapay zeka tekniklerinin tahmin doğrulukları birleştirilerek daha isabetli seçim sonuçları elde edilebilir.
- Bu entegre yaklaşım, bulut servisi seçimi sürecini hem daha hızlı hem de daha güvenilir hale getirir, böylece karar verme süreçlerinde optimizasyon ve verimlilik sağlanır.

8. SONUÇLAR VE ÖNERİLER

8.1. Bulguların Değerlendirilmesi

Bu tezde, ÇKKV yöntemleri ve yapay zeka teknikleri kullanılarak bulut servisi seçim sürecinin nasıl optimize edilebileceği araştırılmıştır. Tez kapsamında yapılan uygulama ve elde edilen bulgular aşağıda değerlendirilmiştir:

8.1.1. ÇKKV yöntemlerinin katkısı

- *AHP ve TOPSIS Uygulamaları:* ÇKKV yöntemleri, bulut servis sağlayıcılarının çeşitli kriterlere göre sistematik bir şekilde değerlendirilmesini sağlamıştır. Özellikle AHP ve TOPSIS yöntemleri, kriterlerin önem sırasını belirlemede ve karar verme sürecinde önemli bir rol oynamıştır.
- *Kriterlerin Doğru Belirlenmesi:* Kriterlerin önem sırasının doğru belirlenmesi, karar vericilerin daha isabetli sonuçlar elde etmesini sağlamıştır. Bu yöntemlerin sağladığı yapısal analiz, karar verme sürecini sistematik hale getirmiştir.

8.1.2 Yapay zeka yöntemlerinin rolü

- *Makine Öğrenmesi:* Yapay zeka tekniklerinin kullanılması, bulut servisi seçim sürecinde tahminleme yapılmasına olanak tanımıştır. Geçmiş verilerin analizinde ve gelecekteki performans tahminlerinde yüksek doğruluk sağlamıştır. Optimizasyon problemlerinin çözümünde etkili olmuştur.
- *Veri Analizi ve Performans Tahmini:* Yapay zeka teknikleri, büyük veri setlerinin analiz edilmesinde ve gelecekteki performans tahminlerinin yapılmasında önemli katkılar sunmuştur. Bu teknikler, karar verme sürecine daha dinamik ve veri odaklı bir yaklaşım kazandırmıştır.

8.1.3. Yöntemlerin performansı

- *ÇKKV ve Yapay Zeka:* ÇKKV ve yapay zeka tekniklerinin kullanımı, her iki yaklaşımın güçlü yönlerini birleştirerek daha etkili bir karar verme süreci sunmuştur. Hem yapısal analiz hem de veri odaklı tahminleri bir araya getirerek daha kapsamlı ve güvenilir sonuçlar elde edilmesini sağlamıştır.
- *Optimize ve Hızlı Çözümler:* Bu yaklaşım, karmaşık problemler için daha optimize ve hızlı çözümler sunmuştur. Bulut servisi seçiminde her iki yaklaşım, daha verimli ve etkili kararlar alınmasına olanak sağlamıştır.

8.2. Genel Değerlendirme

- *Başarılar:* ÇKKV ve yapay zeka tekniklerinin kullanımı, bulut servisi seçim sürecinde önemli iyileştirmeler ve optimizasyonlar sağlamıştır. Her iki yöntem de, daha doğru ve hızlı kararlar alınmasına yardımcı olmuştur.
- *Geliştirme Alanları:* Her iki yaklaşım ile elde edilen sonuçlar, daha fazla veri seti ve farklı senaryolar ile test edilerek daha da geliştirilebilir. Ayrıca, farklı yapay zeka tekniklerinin de entegrasyona dahil edilmesi, karar verme sürecinin daha da iyileştirilmesine olanak tanıyabilir.

Sonuç olarak, tezde kullanılan yöntemlerin kullanımı, bulut servisi seçim sürecinde hem ÇKKV yöntemlerinin sistematik analiz yeteneğini hem de yapay zeka tekniklerinin veri odaklı tahmin yeteneklerini bir araya getirerek etkili bir karar verme süreci sunmuştur.

8.3. Yöntemin Avantajları ve Sınırlamaları

Bu tez kapsamında önerilen yöntemin avantajları ve sınırlamaları şu şekilde değerlendirilebilir:

Avantajları:

- *Doğruluk ve Güvenilirlik:* ÇKKV ve yapay zeka tekniklerinin kullanılması, kriterler arasındaki ilişkileri daha iyi analiz ederek daha doğru sonuçlar elde edilmesini sağlar.

- *Esneklik:* Önerilen yöntem, farklı sektörler ve ihtiyaçlar için uyarlanabilir niteliktedir. Kullanıcıların farklı kriterler doğrultusunda kendi önceliklerine göre özelleştirilebilen bir yapıya sahiptir.
- *Veri İşleme Hızı:* Yapay zeka tekniklerinin kullanılması, özellikle büyük veri kümeleri üzerinde çalışırken veri işleme sürecini hızlandırır ve sonuçların daha kısa sürede elde edilmesine olanak tanır.

Sınırlamaları:

- *Veri Kalitesine Bağımlılık:* Kullanılan yapay zeka tekniklerinin başarısı, toplanan verinin doğruluğuna ve kalitesine bağlıdır. Eksik veya hatalı veriler, sonuçları olumsuz yönde etkileyebilir.
- *Teknik Uzmanlık Gereksinimi:* Yapay zeka tekniklerinin uygulanması, belirli bir teknik bilgi ve uzmanlık gerektirir. Bu nedenle, bu tür yöntemlerin kullanımı her kurum veya karar verici için uygun olmayabilir.
- *Hesaplama Maliyetleri:* Özellikle genetik algoritmalar ve yapay sinir ağları gibi karmaşık algoritmaların çalıştırılması, yüksek hesaplama gücü gerektirebilir. Bu durum, küçük ölçekli işletmeler veya sınırlı kaynaklara sahip organizasyonlar için bir engel oluşturabilir.

8.4. Gelecek Çalışmalar İçin Öneriler

Bu tezde elde edilen bulgular, bulut servisi seçiminde ÇKKV ve yapay zeka tekniklerinin önemli bir potansiyele sahip olduğunu göstermektedir. Ancak, gelecekte yapılacak çalışmalar bu yöntemin daha da geliştirilmesine katkı sağlayabilir. Gelecek çalışmalar için öneriler şu şekilde sıralanabilir:

- *Farklı ÇKKV ve Yapay Zeka Yöntemlerinin İncelenmesi:* Bu tezde AHP, TOPSIS gibi ÇKKV yöntemleri ve makşne öğrenmesi gibi yapay zeka teknikleri kullanılmıştır. Gelecek çalışmalarda, PROMETHEE, ELECTRE gibi diğer ÇKKV yöntemleri ve derin öğrenme, bulanık mantık gibi farklı yapay zeka teknikleri de entegre edilerek daha geniş bir perspektif sunulabilir.
- *Dinamik Kriterler Üzerine Çalışmalar:* Bulut servis sağlayıcılarının performansı zaman içinde değişebilir. Bu nedenle, dinamik kriterler üzerinde

alıřan ve gerek zamanlı verileri kullanarak karar surecini gncelleyebilen yntemler geliřtirilmesi, seim surecini daha etkin hale getirebilir.

- *Hibrit Yntemlerin Geliřtirilmesi:* KKV ve yapay zeka yntemlerinin kullanımını daha ileriye tařıyan hibrit yntemlerin geliřtirilmesi, karmařık karar problemlerinin özmnde daha etkin bir yaklařım saėlayabilir. zellikle, veri madenciliėi ve optimizasyon teknikleriyle entegre edilmiř yapılar zerine alıřmalar yapılabilir.
- *Farklı Sektrlere Uygulamalar:* Bu alıřmada bulut servisi seimi ele alınmıřtır; ancak nerilen yntem, farklı sektrler ve karar problemleri iin de uygulanabilir. Gelecek alıřmalarda saėlık, finans, retim gibi farklı sektrlerdeki karar problemlerine ynelik uygulamalar geliřtirilebilir.

Bu neriler doėrultusunda yapılacak arařtırmalar, KKV ve yapay zeka yntemlerinin karar verme srelerine katkısını daha da artırabilir ve daha geniř bir uygulama alanı sunabilir.

KAYNAKÇA

- Abrahart, R. J., See, L.** (1998). Neural Network vs. ARMA Modelling: Constructing Benchmark Case Studies of River Flow Prediction. In J. Blenc, (Ed.), *GeoComputation '98. Proceedings of the Third International Conference on GeoComputation*, (pp.145-154). United Kingdom : University of Bristol, September 17-19.
- Adeli, H., Wu, J.** (2020). A Survey on Cloud Service Selection Techniques. *Computers*, 9(3), 60.
- Arman, K., Kundakçı, N.** (2023). Yeni Bütünleşik Fucom – Wedba Yaklaşımı ile Bir İşletme İçin Bulut Hizmet Sağlayıcısı Seçimi, *Pamukkale Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, (56), 281-295.
- Arslan, H. M., Âdem, K. Ö. S. E., Durak, İ.** (2018). Çok Kriterli Karar Verme Yöntemleri ile Eğitim Kurumları Karar Problemlerinin Çözümü. *Ejovoc (Electronic Journal of Vocational Colleges)*, 8(2), 27-34.
- Artsın, M., Günal, K.** (2021). Öğrenme Yönetim Sistemi Seçiminde Kullanılacak Kriterlerin Belirlenmesine Yönelik Çok Ölçütlü Karar Verme Yöntemi Önerisi. *Açık Öğretim Uygulamaları ve Araştırmaları Dergisi*, 7 (2), 87-108.
- Asoğlu, İ., Eren, T.** (2018). AHP, TOPSIS, PROMETHEE Yöntemleri ile Bir İşletme İçin Kargo Şirketi Seçimi. *Yalova Sosyal Bilimler Dergisi*, 8(16), 102-122.
- Aydın, C.** (2018). Makine Öğrenmesi Algoritmaları Kullanılarak İtfaiye İstasyonu İhtiyacının Sınıflandırılması. *Avrupa Bilim ve Teknoloji Dergisi*, (14), 169-175.
- Baki, R.** (2022). Application of ROC and CODAS Techniques for Cloud Service Provider Selection. *Gaziantep University Journal of Social Sciences*. 21 (1), 217-230.
- Basmacı, G.** (2022). Prioritizing Challenges in a Applications in Healthcare: Multi-Criteria Decision Making Approach. Sağlık Sektöründe Yapay Zekâ Uygulamalarında Karşılaşılan Zorlukların Önceliklendirilmesi: Çok Kriterli Karar Verme Yaklaşımı.
- Başer, B. Ö., Yangın, M., Sarıdaş, E. S.** (2021). Makine Öğrenmesi Teknikleriyle Diyabet Hastalığının Sınıflandırılması. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 25(1), 112-120.

- Bhole, G. P., Deshmukh, T.** (2018). Multi-Criteria Decision Making (MCDM) Methods and Its Applications. *International Journal for Research in Applied Science & Engineering Technology (IJRASET)*, 6(5), 899-915.
- Chen, C., Chen, Y.** (2019). Data-Driven Decision Making in Cloud Computing: A Comprehensive Review. *Journal of Cloud Computing: Advances, Systems and Applications*, 8(1), 1-20.
- Chen, S. J., Hwang, C. L.** (1992). Fuzzy Multiple Attribute Decision Making Methods. In *Fuzzy Multiple Attribute Decision Making: Methods and Berlin, Heidelberg: Springer*, pp. 289-486.
- Cheng, E. W., Li, H., Ho, D. C.** (2002). Analytic Hierarchy Process (AHP): A Defective Tool When Used Improperly. *Measuring Business Excellence*, 6(4), 33-37.
- Chowdhury, P., Paul, S. K.** (2020). Applications of MCDM Methods in Research on Corporate Sustainability: A Systematic Literature Review. *Management of Environmental Quality: An International Journal*, 31(2), 385-405.
- Çakır, E. Kutlu Karabiyik, B.** (2017). Bütünleşik SWARA – COPRAS Yöntemi Kullanarak Bulut Depolama Hizmet Sağlayıcılarının Değerlendirilmesi. *Bilişim Teknolojileri Dergisi*, 10 (4) , 417-434
- Deng, Y., Zhang, J** (2021). A Hybrid Model İntegrating AHP and Fuzzy; TOPSIS for Cloud service Select. *Applied Soft Computing*, 105, 107132
- Dhurkari, R. K.** (2022). MCDM Methods: Practical Difficulties and Future Directions for İmprovement. *RAIRO-Operations Research*, 56(4), 2221-2233.
- Doğan, S., Büyükkör, Y.** (2022). Makine Öğrenmesi ile Finansal Zaman Serisi Tahminleme. *Ankara Hacı Bayram Veli Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 24(3), 1205-1230.
- Erdal, H., Yapraklı, T. Ş.** (2016). Firma Başarısızlığı Tahminlemesi: Makine Öğrenmesine Dayalı Bir Uygulama. *Bilişim Teknolojileri Dergisi*, 9(1), 21.
- Eren, T., Özcan, E.** (2021). Bulut Hizmet Sağlayıcı Kriterlerinin Bulanık Ortamda Değerlendirilmesi ve COPRAS Yöntemi ile Bulut Hizmet Sağlayıcılarının Sıralanması. *Uluslararası Yönetim Bilişim Sistemleri ve Bilgisayar Bilimleri Dergisi*, 5 (2), 166-184
- Hwang, C. L., Yoon, K.** (1981). Multiple Attribute Decision Making: Methods and Applications. *Springer*.
- Jain, R., Jain, A.** (2018). Artificial İntelligence and Decision Support Systems for Cloud Computing. *Springer*.
- Kaynar, O., Taştan, S.** (2009). Zaman Serisi Analizinde MLP Yapay Sinir Ağları ve Arıma Modelinin Karşılaştırılması. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, (33), 161-172.

- Knorr, E., Gruman, G.** (2008). What Cloud Computing Really Means. *InfoWorld*, 7(20-20), 1-17.
- Kocagüneli, E., Tosun, A., Çağlayan, B., Bener, A., Aytaç, T., Turhan, B.** (2009). Bulutlarda Akıllı Bir Yazılım Ölçümleme, Hata Analiz ve Tahmin Aracı: Prest. Ulusal Yazılım Mühendisliği Sempozyumu-UYMS'09, 311-314
- Konuşkan, Ö. Mühendisliği, A. E., Uygun, Ö.** (2014). Çok Nitelikli Karar Verme (Maut) Yöntemi ve Bir Uygulaması. Ömer Halisdemir Üniversitesi: Niğde, Turkey.
- Köküner, Z.** (2018) Çok Kriterli Karar Verme Yöntemleri ile Beyaz Eşya Sektöründe Endüstri 4.0 Dijital Dönüşüm Yetkinlik Analizi. MS Thesis. Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü.
- Kumar, R., Kumar, A.** (2020). Evolutionary Algorithms in Cloud Computing: A Survey. *Future Generation Computer Systems*, 107, 368-385.
- Lee, J., Lee, H.** (2019). An İmproved AHP-TOPSIS Approach for Cloud Service Selection. *Computers & Industrial Engineering*, 137, 106015.
- Madenoğlu, F. S.** (2019). Green Supplier Selection in Fuzzy Multi-Criteria Decision Making Environment. *Business & Management Studies: An International Journal*, 7(4), 1850–1869.
- Mendoza, G. A., Martins, H.** (2006). Multi-Criteria Decision Analysis in Environmental Management. *Springer*.
- N. Keskin, A. N. Kiran, F. K. Eğdemir, T. Eren,** (2020) “Bulut Bilişim Güvenlik Gereksinimlerine Göre Çok-Ölçütlü Karar Verme Yöntemleri ile Hizmet Sağlayıcı Seçimi”, *Uluslararası Bilgi Güvenliği Mühendisliği Dergisi*, 6(1), 1, 45-60, Jun.
- N. Yüksel, H. R. Börklü,** (2021) “Yapay Zekâ Destekli Kavramsal Tasarım: Tekerlekli Sandalye Tasarım Seçenekleri Değerlendirmede Bulanık Mantık Kullanımı”, *Gazi Mühendislik Bilimleri Dergisi*, 7(3), 309-319.
- Nar, M.** (2022). Yenikapı M1–Kirazlı M1 Hattı için İstasyon ve Hat Bazlı Yolcu Talep Tahmini ve Raylı Ulaşım Sistemlerinde Sefer Sıklığı Belirlemede Kritik Başarı Faktörlerinin Çok Kriterli Karar Verme Yöntemleri ile Önceliklendirilmesi= Station and Line-Based Passenger Demand Forecasting for Yenikapı M1-Kirazlı M1 line and Prioritization of Critical Success Factors in Headway Determination in Railway Systems with Multi-Criteria Decision-Making Methods.
- Özbek, A.** (2014) “Yöneticilerin Çok Kriterli Karar Verme Yöntemi ile Belirlenmesi”. *Journal of Management and Economics Research*, 12, 209-225
- Özbek, A., Engür, M.** (2019). Çok Kriterli Karar Verme Yöntemleriyle Öğrenci İşleri Otomasyon Seçimi. *Afyon Kocatepe Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 21 (1), 1-18.

- Özcan, H., Emiroğlu, B. G.** (2020). Bulut Tabanlı Öğrenme Yönetim Sistemi Seçiminde Bulanık Çok Kriterli Karar Analizi Yaklaşımı. *Bilişim Teknolojileri Dergisi*, 13 (1), 97-111.
- Özen, N. S., Saraç, S., Koyuncu, M.** (2021). COVID-19 Vakalarının Makine Öğrenmesi Algoritmaları ile Tahmini: Amerika Birleşik Devletleri örneği. *Avrupa Bilim ve Teknoloji Dergisi*, (22), 134-139.
- Öztürk, M., Aydın, I.** (2020). Decision Making for Cloud Service Selection Using Multi-Criteria Methods. *Soft Computing*, 24(4), 3027-3038.
- Rao, R. V., Kumar, M.** (2019). Genetic Algorithms and Engineering Optimization. *Wiley*.
- Rayport, J. F., Heyward, A.** (2009). Envisioning the Cloud: The Next Computing Paradigm. *Int. J. Database Manage. Syst. (IJDMs)*, 1(1).
- Saaty, T. L.** (1980). The Analytic Hierarchy Process: Planning, Priority Setting, Resource Allocation. McGraw-Hill.
- Saaty, T. L.** (1986). Axiomatic Foundation of The Analytic Hierarchy Process. *Management Science*, 32(7), 841-855.
- Sevli, O.** (2021). 3 Boyutlu Baskıda Kullanılacak Malzemenin Makine Öğrenmesi Teknikleri ile Tahminlenmesi. *International Journal of 3D Printing Technologies and Digital Industry*, 5(3), 596-605.
- Shou, Y., Liu, J.** (2018). Cloud Service Selection Using Multi-Criteria Decision Analysis and Genetic Algorithms. *Future Generation Computer Systems*, 80, 646-655.
- Sotoudeh-Anvari, A.** (2022). The Applications of MCDM Methods in COVID-19 Pandemic: A state of the art review. *Applied Soft Computing*, 126, 109238.
- Stanujkić, D., Djordjevic, B., Djordjevic, M.** (2013). Comparative Analysis of Some Prominent MCDM Methods: A Case of Ranking Serbian Banks. *Serbian Journal of Management*, 8(2), 213-241.
- Supçiller, A. A., Deligöz, K.** (2018). Tedarikçi Seçimi Probleminin Çok Kriterli Karar Verme Yöntemleriyle Uzlaşık Çözümü. *Uluslararası İktisadi ve İdari İncelemeler Dergisi*, 18. EYI Special Issue, 355-368.
- Taş, C., Bedir, N., Eren, T., Alağaç, H. M., Çetin, S.** (2018). AHP-TOPSIS Yöntemleri Entegrasyonu ile Poliklinik Değerlendirilmesi: Ankara'da Bir Uygulama. *Sağlık Yönetimi Dergisi*, 2(1), 1-17.
- Toloié-Eshlaghy, A., Homayonfar, M.** (2011). MCDM Methodologies and Applications: a Cloud Literature Review From 1999 to 2009. *Research Journal of International Studies*, 21, 86-137.
- Tzeng, G. H., Huang, J. J.** (2011). Multiple Attribute Decision Making: Methods and Applications. *CRC Press*.

- Uslu, B., Eren, T., Gür, Ş.** (2019). Bulut Hizmet Sağlayıcı Seçiminde Etkili Olan Kriterlerin Çok Kriterli Karar Verme Yöntemleri ile Değerlendirilmesi. *Yönetim Bilişim Sistemleri Dergisi*, 5 (1), 16-30.
- Uslu, B., Gür, Ş., Eren, T., Özcan, E. C.** (2019). Çok Kriterli Karar Verme Yöntemleri ile Bulut Hizmet Sağlayıcı Sıralaması. *Pamukkale İşletme ve Bilişim Yönetimi Dergisi*, 6 (1), 20-34.
- Vural, S., Naghizade, K., Erkollar, A.** (2017). Bulut Bilişimin Dijital İşletme Üzerindeki Etkisi. *EUREFE*, 17, 1-9.
- Wang Chen, H. M., Chou, S. Y., Luu, Q. D., Yu, T. H. K.** (2016). A Fuzzy MCDM Approach for Green Supplier Selection From The Economic and Environmental Aspects. *Mathematical Problems in Engineering*,
- Xu, W., Chen, L.** (2020). A Novel Approach for Cloud Service Selection Using Machine Learning and Multi-Criteria Decision Analysis. *Journal of Cloud Computing: Advances, Systems and Applications*, 9(1), 1-14.
- Yaman, Y.** (2021). Müşteri Yolculuğu Analitiğini Makine Öğrenmesi Modeliyle Tahminleme.
- Yavuz, N., Birdoğan, B.** (2019). Patent Değerlerinin Çok Kriterli Karar Verme Yöntemleri ile Sıralanması: Otomotiv Sektöründe Bir Uygulama. *Karadeniz Teknik Üniversitesi Sosyal Bilimler Enstitüsü Sosyal Bilimler Dergisi*, 9(17), 27-52.
- Yıldırım, B. Önay, O.** (2013). Bulut Teknolojisi Firmalarının Bulanık AHP – MOORA Yöntemi Kullanılarak Sıralanması. *İstanbul Üniversitesi İşletme Fakültesi İşletme İktisadi Enstitüsü Yönetim Dergisi*, 24 (75), 59-81.
- Yıldız, Ö. R.** (2009). Bilişim Dünyasının Yeni Modeli: Bulut Bilişim Cloud Computing ve Denetim. *Sayıştay Dergisi*, (74), 5-23.
- Yurdakul, M., İç, Y. T.** (2005). Development of a Performance Measurement Model for Manufacturing Companies Using The AHP and TOPSIS Approaches. *International Journal of Production Research*, 43(21), 4609-4641.
- Yüce, T., Kabak, M.** (2021). Makine Öğrenmesi Algoritmaları ile Detay Üretim Alanları İçin İş Merkezi Kırılımında Üretim Süresi Tahminleme. *Erciyes Üniversitesi Fen Bilimleri Enstitüsü Fen Bilimleri Dergisi*, 37(1), 47-60.
- Yüzüğüllü, E.** (2011). Tedarikçi Seçiminde Çok Kriterli Karar Verme ve Uygulaması Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü.
- Zhang, Y., Wang, Z.** (2019). An Integrated Approach for Cloud Service Selection Using AHP and Machine Learning. *Applied Soft Computing*, 81, 105510.

Zhou, H., Yang, L. (2018). A Hybrid Decision-Making Approach for Cloud Service Selection Using AHP and Fuzzy Logic. *Journal of Cloud Computing: Advances, Systems and Applications*, 7(1), 1-12.



ÖZGEÇMİŞ

Ad-Soyad : Pınar Simay ERGÜN

ÖĞRENİM DURUMU:

- **Lisans** : 2021, Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği
- **Yüksek Lisans** : Devam ediyor, Bursa Teknik Üniversitesi, Mühendislik ve Doğa Bilimleri Anabilim Dalı, Endüstri Mühendisliği

MESLEKİ DENEYİM VE ÖDÜLLER:

- Beyçelik Gestamp A.Ş., Satınalma Uzmanı, 2021-2023
- Toksan Otomotiv A.Ş., Satınalma Uzmanı, 2023-Devam ediyor

TEZDEN TÜRETİLEN ESERLER, SUNUMLAR VE PATENTLER:

- **Ergün, P. S., ve Şahin, H.** (2024). Bulut servisi sağlayıcı seçiminde çok kriterli karar verme yaklaşımları: AHS ve TOPSIS uygulaması. *Proceedings of the 4th Global Conference on Engineering Research*, Bandırma, Türkiye, Ekim 14-18, 2024.

DİĞER ESERLER, SUNUMLAR VE PATENTLER:

- **Deliktaş, D., Ergün, P. S., & Akpınar, M.** (2021). Multi-criteria evaluation of cloud service providers with the integrated fuzzy group decision-making approaches. *Proceedings of the 4th European International Conference on Industrial Engineering and Operations Management*, Roma, İtalya, Ağustos 2-5, 2021.
- **Akpınar, M., ve Ergün, P. S.** (2021). Çok kriterli karar verme metotları ile uygun bulut hizmet sağlayıcısının seçilmesi: Bulut bilişime geçişin SAP-ERP altyapı maliyetleri üzerine etkisi. *TÜBİTAK 2209-A Proje Önerisi*.