



Consensus among Multi-Criteria Decision-Making methods: Using methods as a voter

M. Fatih Hocaoglu*, Emre Tosun

Department of Industrial Engineering, Faculty of Engineering and Natural Sciences, Istanbul Medeniyet University, 34700, Istanbul, Türkiye

Highlights:

- Different normalization techniques are applied in more than one MCDM method and evaluated as voter preference.
- Preference rankings are carried out as an assignment problem for total tar and total preference rankings, thus ensuring integration across the land.
- The optimal decision selection is determined as the decision with the minimum distance from the decisions of MCDM methods.

Keywords:

- Distance from optimum decision,
- Entropy criteria normalization,
- Group Decision Making,
- Max-Min weight normalization,
- Multi-Criteria Decision Making,
- Multi-Criteria Nozzle Selection,

Article Info:

Research Article

Received: 13.08.2023

Accepted: 26.11.2023

DOI:

10.17341/gazimmfd.1342315

Correspondence:

Author: M. Fatih Hocaoglu
e-mail: mfatih.hocaoglu@medeniyet.edu.tr
phone: +90 553 652 3788

Graphical/Tabular Abstract

Normalization techniques are pivotal in converting datasets into meaningful vectors each carrying unique semantic significance. For example, maximum normalization prioritizes the dataset's highest value, while sum normalization scales values based on their contribution to the total. In our study, we view these semantic differences as reflective of personal preferences, incorporating all disparities into decision models. Decision rankings for selected Multi-Criteria Decision Making (MCDM) methods are established using various normalization techniques, generating diverse preference rankings and selection scales. Harmonizing these rankings, we employ max-min normalization, creating two optimization models to determine selection numbers and total selection weights for normalized rankings. While the selection count gives a matrix containing the number of times each of the alternatives has been placed in a rank, for example, the number of times Alternative-1 has been placed in the first place (Table A. # labeled column), the total choice weight gives a matrix containing the total weight of the alternatives in each rank (Table A W labeled column). The optimal order, minimizing the distance from MCDM methods' rankings, is chosen as the final ranking. Our approach reconciles different normalization techniques and MCDM methods to obtain a decision with minimal deviation from incorrect rankings, enhancing decision-making by providing an optimization model based on both discrete selection order and continuous total selection scale. This approach extends the method's application across multiple MCDMs.

Table A. Alternatives Total Weights at the ranks and number of selections for the Ranks

| | 1 | | 2 | | 3 | | 4 | |
|----|----------|----|----------|----|----------|----|----------|----|
| | w | # | w | # | w | # | w | # |
| A1 | ,764962 | 1 | 11,56043 | 22 | ,621927 | 2 | 0 | 0 |
| A2 | 0 | 0 | ,052032 | 1 | 1,699385 | 21 | -,16944 | 3 |
| A3 | 0 | 0 | 0,953394 | 2 | 3,568426 | 1 | 0,172807 | 22 |
| A4 | 23,37426 | 24 | 0 | 0 | ,154899 | 1 | 0 | 0 |

Purpose:

The study proposes a new method to assess decision orders in Multi-Criteria Decision-Making Methods (MCDM) using various normalization techniques as voters. These techniques are integrated with a group decision-making approach to reach a strong consensus.

Theory and Methods:

Various MCDM methods like AHP, VIKOR, TOPSIS, MOORA, and PROMETHEE are utilized, each normalized with five techniques. These rankings are then optimized for selection ranks and weights, resulting in two optimal group decisions. The final decision is made by selecting the solution closest to the rankings derived from MCDM methods. This approach is tested on a nozzle selection problem.

Results:

The study merges MCDM methods with group decision-making, resulting in a robust decision aligning with MCDM consensus. Additionally, it introduces a distance concept to identify decisions closely aligned with others, assessing MCDM methods' sensitivity to normalization techniques.

Conclusion:

The group decision shows strong agreement, with each normalization technique emphasizing unique dataset features, enriching the decision model's perspectives. It not only represents the optimal choice with increased consensus but also minimizes deviation from MCDM proposals. Additionally, the model highlights MCDM methods' sensitivity to different normalization techniques.



Çok Kriterli Karar Verme yöntemleri arasında fikir birliği: Yöntemlerin seçmen olarak kullanımı

M. Fatih Hocaoğlu*^{ID}, Emre Tosun^{ID}

İstanbul Medeniyet Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Endüstri Mühendisliği Bölümü, 34700, Üsküdar, İstanbul, Türkiye

Ö N E Ç I K A N L A R

- Farklı normalleştirme teknikleri uygulanmış ÇKKV yöntemleri sıralamaları seçmen tercihleri olarak değerlendirilmiştir
- Toplam ağırlık ve toplam tercih sıralamaları atama problemi olarak optimize edilerek karar entegrasyonu sağlanmıştır
- Optimal karar seçimi, ÇKKV yöntemlerinin kararlarına minimum mesafeye sahip karar olarak belirlenir

Makale Bilgileri

Araştırma Makalesi

Geliş: 13.08.2023

Kabul: 26.11.2023

DOI:

10.17341/gazimmfd.1342315

Anahtar Kelimeler:

Çok kriterli karar verme,
çok-kriterli nozul seçimi,
entropi kriter
normalleştirilmesi, grup karar
teknikleri, maks-min ağırlık
normalleştirilmesi, optimum
karardan uzaklık

ÖZ

Bu çalışma, Çok Kriterli Karar Verme Yöntemlerinin farklı normalleştirme teknikleriyle verdiği karar sıralamasını seçmen olarak değerlendiren ve bir grup karar verme yöntemiyle birleştiren yeni bir yaklaşım sunmaktadır. Önerilen çözümde, her bir Çok Kriterli Karar Verme (ÇKKV) Yöntemi, farklı normalleştirme teknikleri kullanarak kendi seçim sırasını hesaplar ve her sıra bir oy olarak kabul edilir. Sonraki adımda ise bu karar sıralamaları oylama ve sıralama oransal değerleri ağırlıklandırma olarak dikkate alınarak birleştirilir. Bu yöntemi geliştirmenin temel amacı, Çok Kriterli Karar Verme Yöntemleri (ÇKKVY) arasında fikir birliğini artırmaktır. Grup kararının belirlenmesinde biri oy sayısı optimizasyonuna dayalı diğeri ise kümülatif ağırlık optimizasyonuna dayalı olmak üzere iki optimizasyon modeli tanımlanmıştır. Nihai karar sıralamasını belirlemek için optimize edilmiş karar ile ÇKKVY tarafından üretilen kararlar arasında bir mesafe hesaplaması yapılmış ve en az mesafeye sahip sıra nihai karar olarak belirlenmiştir.

Consensus among Multi-Criteria Decision-Making methods: Using methods as a voter

H I G H L I G H T S

- Rankings of MCDM methods with different normalization techniques applied are evaluated as voter preferences
- Decision integration is achieved by optimizing the total weight and the total preference rankings as an assignment problem
- The optimal decision selection is determined as the decision with the minimum distance from the decisions of MCDM methods

Article Info

Research Article

Received: 13.08.2023

Accepted: 26.11.2023

DOI:

10.17341/gazimmfd.1342315

Keywords:

Distance from optimum
decision, entropy criteria
normalization, group
decision making, max-min
weight normalization, multi-
criteria decision making,
multi-criteria nozzle
selection

ABSTRACT

This study offers a new approach that evaluates the decision order made by Multi-Criteria Decision-Making Methods (MCDM) with different normalization techniques as voters and combines them with a group decision-making method. In the proposed solution, each Multi-Criteria Decision Making Method calculates its own election rank using different normalization techniques, and each rank is considered as one vote. In the next step, all these decision rankings are combined by considering the voting and ranking total weight values as weighting. The main purpose of developing this method is to increase consensus among MCDM. Two optimization models have been defined in determining the group decision, one based on number of votes optimization and the other based on cumulative weight optimization. To determine the final decision order, a distance calculation was made between the optimized decision and the decisions produced by ÇKKVY, and the order with the least distance was determined as the final decision.

*Sorumlu Yazar/Yazarlar / Corresponding Author/Authors : *mfatih.hocaoglu@medeniyet.edu.tr, emretosunn71@gmail.com /
Tel: +90 553 652 3788

1. Giriş (Introduction)

Normalleştirme (normalization), çok kriterli karar verme yöntemlerinde farklı büyüklüklere sahip seçim kriteri değerlerini birim vektöre dönüştürerek birbirleriyle kıyaslanabilir ve matematiksel işlemlere sokulabilir bir hale getirmek için önemli bir adımdır. Uygulanan normalleştirme tekniği, verilerin yapısına bağlıdır ve seçilen yöntem seçenekler arasında belirlenen sıralama sonuçları önemli ölçüde etkiler. Bunun sebebi her bir normalleştirme tekniğinin diziye ait farklı bir özelliği öne çıkarıyor olmasıdır. Aynı çok kriterli karar verme yöntemi kullanıldığında bile, farklı normalleştirme yöntemleri farklı sıralamalar verebilir. Analiz edilen verilerin özellikleri uygun normalleştirme tekniklerinin belirlenmesine yardımcı olurken, hangi tekniklerin uygun olduğu konusunda hâlâ bir belirsizlik vardır. Zira, Bölüm 3'te ele alınan normalleştirme tekniklerinin kullanımı uygun olan verilerin yapısını tanımlamaya dönük matematiksel bir ölçek bulunmamaktadır. ÇKKVY'nde, seçimler her seçeneğe normalize edilmiş ağırlıklar verilerek sıralanır ve en yüksek ağırlıklı puana sahip seçim ilk sırada yer alır. Bununla birlikte, en üst sıradaki seçeneğin seçimi kullanılan normalleştirme yöntemlerine ve değerlerin birbirlerine olan yakınlığına bağlı olarak değişiklik gösterebilir.

Bu çalışmada önerilen karar modeli, grup karar teknikleri için seçmen olarak ÇKKVY kararlarını kullanarak uzlaşma kararı almakla ilgilidir. ÇKKVY tarafından verilen kararlar, farklı normalleştirme teknikleriyle çoğullanır. Çünkü veri kümesi özelliğine bağlı olarak bir normalleştirme tekniğinin seçilmesine yönelik katı kurallar olmadığı için seçilen bir normalleştirme yönteminin en az seçilen kadar seçilme nedenselliği olan bir alternatif teknik hâlâ mevcuttur. Daha önce de ifade edildiği gibi, normalleştirme teknikleri veri dizisinin farklı özelliklerini öne çıkarır. Örnek olarak maksimum normalleştirme dizinin maksimum değerini öne çıkararak verileri ölçeklendirirken, toplam normalleştirme veri kümesinin değerlerini genel toplama orantılı katkılarına göre ölçeklendirir. Burada öne çıkarılan dizi özelliği bir tür kişisel tercih olarak düşünülerek normalleştirme teknikleriyle çoklanmış tercih sıraları bir grup karar problemine dönüştürülmüştür. Bölüm 3'te ele alındığı şekliyle, en dramatik farklılık, veri dizilerinden de görülebildiği gibi logaritmik normalleştirme ile diğer normalleştirme teknikleri arasında söz konusudur. Bu, bazı kuralların mevcut olmasına rağmen yine de gri alanlar olduğunu ve bu gri alanlar kararlar arasında farklılıklar yaratabildiğini göstermektedir. Önerilen yaklaşımda, bir ÇKKV yönteminin kullanıldığı her bir normalleştirme tekniği ile yaptığı sıralama bir oylama olarak kabul edilir ve tüm sıralamalar grup karar verme modelleri aracılığıyla birleştirilir. Birden fazla nihai karar elde edilmişse, seçim süreci farklı normalleştirme teknikleri ile ÇKKVY'nin sıralarına en az uzaklığa sahip karar seçilir ve böylece çoklu kararların tek bir karara indirgenmesi sağlanır. Önerilen yöntemin, farklı ÇKKVY'nin farklı normalleştirme teknikleriyle hazırladığı kararları birleştirme amacına ek olarak, normalleştirme tekniklerinin ÇKKVY üzerindeki etkileri de incelenmiş ve bazı gözlemler paylaşılmıştır.

Bu çalışmada, AHS (Analitik Hiyerarşi Süreci, İng. Analytic Hierarchy Process-AHS), MOORA (Multi-Objective Optimization by Ratio Analysis Method, Tr. Oran Analizine Dayalı Çok Amaçlı Optimizasyon), TOPSIS (Technique for Order Preference by Similarity to Ideal Solution, Tr. İdeal Çözüme Benzerliğe Göre Tercih Sıralaması Tekniği), PROMETHEE (Preference Ranking Organization METHod for Enrichment Evaluations, Tr. Zenginleştirme Değerlendirmeleri için Tercih Sıralaması Organizasyon Yöntemi) ve VIKOR (Sırpça: "VlseKriterijumska Optimizacija I Kompromisno Resenje, İng. Multi-Criteria Optimization and Compromise Solution, Tr. Çok Kriterli Optimizasyon ve Uzlaşık Çözüm) yöntemleri, belirlenen uygulama

üzerinde önerilen çözümü göstermek için seçilen yöntemlerdir. Seçilen problem, tipik bir ÇKKVY problemi olarak sıralanacak seçeneklere ve önceden tanımlanmış bir dizi kritere ve bunların ilgili ağırlıklarına sahiptir. Uygulanacak yöntemlerin seçiminde seçenekleri en yüksek puana gören sıralayan ve en az sapmaya göre sıralayan farklı yöntemlerin olmasına dikkat edilmiştir. Örneğimiz maça üretiminde kullanılan makinelerin, nozul seçenekleri arasından seçim yapma problemidir.

Makale şu şekilde düzenlenmiştir. Takip eden ikinci bölüm literatür araştırmasına ayrılmıştır. Üçüncü bölüm normalleştirme tekniklerini özetlemekte ve kullanım kavramlarını vermektedir. Dördüncü bölüm uygulanan ÇKKVY'nin hesaplama yöntemlerinin ve genel özelliklerinin açıklanmasına ayrılmıştır. Beşinci bölüm seçilen vaka çalışması ile ilgilidir ve ÇKKVY farklı normalleştirme teknikleriyle bir örneğe uygulanmaktadır. İlgili bölümde basitlik ve kısalığı muhafaza etmek için, sadece birkaç ÇKKVY uygulama detayı verilmiştir. Altıncı bölüm ÇKKVY 'den alınan sıralamaların birleştirilerek nihai karar sıralamalarının yapıldığı bölümdür. Yedinci bölümde her bir ÇKKVY sıralamasının nihai kararlara olan uzaklıklarının nasıl hesaplanacağı ve ÇKKVY'nin ortaya koyduğu karar sıralamalarının nasıl tek bir karar sıralamasına indirgeneceği ele alınmıştır. Sekizinci Sonuç ve Tartışmalar bölümünde tüm süreç ve ÇKKVY'nin normalleştirme tekniklerine duyarlılığı irdelenmiş, bazı öneriler sunulmuştur.

2. Literatür Taraması (Literature Survey)

Palczewski ve Salabun yaptıkları çalışmada farklı normalleştirme yöntemlerinin PROMETHEE II üzerindeki etkisini araştırmış ve bunu havalimanı yer seçimi örneği üzerinde göstermiştir. Çalışmada uzman bilgisine dayalı kriterlerin seçimiyle 10 alternatif ve yedi kriter analiz edilmiştir ve Maksimum-Minimum, Maksimum, Toplam, Vektör ve Logaritmik normalleştirme yöntemleri olmak üzere beş farklı normalleştirme yöntemi kullanılmıştır [1].

Satıcı farklı firmaların ürettiği yedi elektrikli süpürgeyi WASPAS yöntemiyle altı kriter üzerinden değerlendirmiştir [2]. Çalışma, farklı normalleştirme tekniklerinin ÇKKVY üzerindeki etkisini incelemeyi amaçlamıştır. WASPAS sonuçlarının normal dağılıma olan uygunluğu Shapiro-Wilk testi ile incelenmiştir. Ayrıca, normalleştirme teknikleri arasındaki ilişkiler, normal dağılım sonuçları için Pearson korelasyon testi kullanılarak incelenmiştir. Elde edilen sonuçlar incelendiğinde, doğrusal normalleştirme (Toplam) ve Vektör Normalleştirme tekniklerinin orijinal WASPAS yönteminin normalleştirme tekniğine alternatif olabileceği düşünülmüştür. Ancak, doğrusal normalleştirme (Max-Min) tekniğinin en kötü sonuçları verdiği ve WASPAS yöntemi için uygun olmadığı sonucuna varılmıştır. Bu sonuçlar, çalışma sırasında yapılan Pearson korelasyon testi ve Normal dağılım testinden elde edilen değerlere dayanmaktadır.

Vafaei, Rita Ribeiro, Luis ve Matos araştırmalarında çok kriterli karar verme için en uygun normalleştirme tekniğini belirlemeyi amaçlamışlardır [3]. Seçim süreci bağlamında altı normalleştirme tekniğini incelemişlerdir. Kullanılan normalleştirme yöntemleri Maximum, Maximum-Minimum, Toplam, Vektör, Logaritmik ve bulanık normalleştirme teknikleridir. Çalışmada yedi alternatif analiz edilmiş ve değerlendirme için sıralama tutarlılık indeksi (RCI-Random Consistency Index) hesaplaması, Pearson korelasyonu ve Spearman korelasyonu istatistikleri kullanılmıştır. Sonuçlar, toplam normalleştirme SAW (basit ağırlıklandırma – Simple Additive Weighting) yöntemi için en iyi sonucu verdiğini, ardından Vektör ve Maksimum normalleştirme geldiğini göstermiştir. Yapı alanında Katmanlı Üretim (KÜ) kullanımını ve özelliklerini üzerinden ölçütler

ortaya koyma, belirlenen ölçütlere göre sektör uzman tercihlerinin bulanık DEMATEL yöntemi (The Decision Making Trial and Evaluation Laboratory) ile analiz edilmesi öneren çok ölçütlü karar verme modeli (ÇÖKVM), Çirpi ve Sev tarafından önerilmiştir [4].

ÇKKV'de klima seçimi problemi Ertuğrul ve Özçil tarafından TOPSIS ve VIKOR yöntemleri kullanılarak yapılan çalışmada incelenmiş ve sonuçlar karşılaştırılmıştır [5]. Uygulama klima seçimi için fiyat ve teknik özelliklere göre tercih önerileri sunmaya odaklanmıştır. Çalışmada TOPSIS yönteminin VIKOR'a kıyasla daha doğru bir karar verdiğini öne sürmüştür. Ayrıca VIKOR yöntemindeki sıralamanın Q'ye (maksimum grup faydası) göre yapıldığı vurgulanmıştır.

Aktepe ve Ersöz tarafından yapılan çalışmada AHS, VIKOR ve MOORA yöntemlerinin depo yeri seçimi problemine uygulanmasına odaklanılmıştır [6]. Yazarlar problemi ele almak için üç farklı yöntemi sentezlediklerini kriter ağırlıklandırma için AHS ve alternatif sıralama için VIKOR ve MOORA kullanıldıklarını belirtmişlerdir. Çalışmada on bir alternatif şehir ve altı kriter incelenmiştir. Uygulanan seçim yöntemleriyle depo kurulumu için üç alternatif şehir belirlenmiştir.

Demir ve Mert çalışmalarında, Çok Amaçlı Genetik Algoritma (ÇAGA)'nın performansını arttırmak amacıyla yeni bir seçim stratejisi olarak, çok kriterli karar verme yöntemlerinden biri olan MultiMoora metoduna dayalı MultiMoora Rank Selection (MMRS) geliştirilmiştir. Geliştirilen metodun performansı çok amaçlı akış tipi çizelgeleme problemlerinde test edilmiştir. MultiMoora Rank Selection ile elde edilen sonuçlar, genetik algoritmada yaygın olarak kullanılan Rulet Tekerleği Seçimi, Lineer Rank Seçimi ve Turnuva Seçimi metodlarının aynı problem üzerindeki sonuçları ile karşılaştırılarak değerlendirilmiştir. Elde edilen sonuçlar, önerilen MultiMoora Rank Selection metodunun karşılaştırılan diğer metotlara üstünlük sağladığını göstermişlerdir [7].

Temiz ve Çalı, ÇKKVY'nden AHS ve PROMETHEE'yi kullanarak iş makinesi seçimi problemini çözmüşlerdir [8]. Çalışma dokuz kriter ve dört alternatif içeriyordu ve her iki yöntem de aynı sonucu vermiştir.

Cihan ve ark., bir devlet hastanesi için ekokardiyografi cihazı seçimi problemini incelemişlerdir [9]. Değerlendirme, literatür taraması ve uzman girdisi yoluyla belirlenen yedi kriteri içeriyordu. Maliyet, güvenlik, hasta sonuçları, kullanıcı eğitimi, kullanım kolaylığı, satış sonrası servis, teknik özellikler gibi kriterler dikkate alınmıştır. Yazarlar çalışmalarında kriter ağırlıklarını AHS yöntemiyle belirlediklerini, en iyi alternatifi sıralamak için ise TOPSIS yönteminden yararlandıklarını belirtmişlerdir.

Yılız ve Yazıcıoğlu çalışmalarında ÇKKVY'ni kullanarak küresel bir tedarikçi seçimi gerçekleştirmişlerdir [10]. Çalışmada beş kriter (fiyat, teslimat, kalite, teknoloji ve esneklik) ve dört alternatif şirket belirlenmiştir. TOPSIS yöntemiyle belirlenen kriter ağırlıklarına göre tedarikçi seçimi yapılmıştır.

Bedir ve Eren bir personel seçim problemini AHS ve PROMETHEE yöntemlerini kullanarak çözmüşlerdir [11]. Adayların ilk ön seçimi beklentilere göre yapılmış ve belirlenen kriterler AHS kullanılarak ağırlıklandırılmıştır. Kalan havuzdan en uygun aday belirlemek için PROMETHEE yöntemi kullanılmıştır.

Ayağ ve Özdemir, takım tezgahı alternatiflerini değerlendirmek için bulanık AHS ve TOPSIS yöntemlerini kullanmışlardır [12]. Verimlilik, esneklik, makine boyutları, uyarlanabilirlik, hassasiyet, güvenilirlik, güvenlik ve çevre, bakım ve servis gibi kriterler dikkate alınmıştır. Çalışmada yazarlar, göreceli ağırlıkları belirlemek için,

AHS'nin daha genel formu olan Analitik Ağ Süreci (AAS) (Analytic Network Process-ANP) [13] bulanık AAS yöntemi, kriterler kümesine göre sıralama yapmak için ise değiştirilmiş TOPSIS yöntemi kullanıldıklarını raporlamışlardır.

Özcan, İnan ve Korkusuz, ÇKKVY'ni kullanarak metro şoförü seçimine odaklanmışlardır [14]. Adaylar, Gri İlişkisel Analiz (GRA) [15] ve TOPSIS yöntemleri kullanılarak sıralanmış ve her iki yaklaşımda da aynı sıralama elde edilmiştir.

Li, Wang, Fan, Li ve Chen takım tezgahı seçim problemi için bulanık DEMATEL ve VIKOR yöntemlerini kullanmışlardır [16]. Kriterler DEMATEL yöntemi kullanılarak ağırlıklandırılmış ve alternatifler VIKOR yöntemi kullanılarak sıralanmıştır. Maksimum delme hızı, kullanım etkinliği, maksimum delme torku, arıza oranı, yapıştırma doğruluğu ve maliyet gibi kriterler dikkate alınmıştır.

Garg, Agarwal ve Choubey, ÇKKVY tam olarak bilinmeyen, belirsizlik, bulanıklık içeren nitelik ağırlıkları altında araştırmayı amaçlamışlardır [17]. Karar vericilerin tercihlerini toplamak için bir entropi işlevi uygulamışlardır. Yaklaşım bir ev seçimi örneği aracılığıyla gösterilmiştir.

Özarlan ve Karakaya tarafından Çok kriterli sınıflandırma problemleri için karar vericiye az sayıda soru soran etkileşimli olasılıksal bir yaklaşım geliştirilmiştir. Yöntemde iterasyonlar boyunca karar vericiden belirli alternatiflerin kategori bilgisi alınmaktadır. Önerilen yöntemde alternatiflerin atanma belirsizliklerini ölçmek için göreceli entropiden yararlanılmakta ve atama belirsizliği en yüksek alternatif karar vericiye sorulmaktadır. Alternatiflerin atanma belirsizlikleri belirli bir seviyenin altına düştüğünde atanma olasılıkları belirli bir seviyeden yüksek olan alternatifler olasılıksal olarak kategorilere atanmaktadır. Uygulamada amaç karar vericiden yeterli atama bilgisi olmadan olasılıksal atama yapılmaması hatalı sınıflandırmaları en aza indirmektir. Yaklaşım Dünya Enerji Konseyi tarafından ülkelerin enerji performanslarını değerlendirmek üzere yıllık olarak yayınlanan enerji tüketimi endeksi verisi üzerinde test edilmiştir [18].

He, Xu ve Chen çalışmalarında, öznel bilgileri nesnelleştirmek, nitelik değerlerinden ve karar vericilerin yargılarından bilgileri toplamak için bir yaklaşım önermişlerdir. Kullanıcıların öznel tercihleri tanımlayabilecekleri bir fayda fonksiyonu tanımlamışlardır. Öznel değer matrisi daha sonra öznel yargıları içeren bir öznel nitelikler değer matrisine dönüştürülmüş, nitelikler üzerindeki hem öznel hem de nesnel ağırlıkları belirlemek için entropi ağırlıklandırma tekniği kullanılmıştır. Son olarak, tüm karar vericilerin öznel ağırlıklarını, ek bilgi gerektirmeden yargılarıyla uyumlu tek bir ağırlık vektöründe birleştirmek için minimum çapraz entropi ilkesi uygulanmıştır [19].

Büyük veri çalışmalarının hızla yükselmesiyle normalleştirme teknikleri bu alanda tekrar gündeme gelmiştir. Heterojen sensörlerden ve diğer veri kaynaklarından büyük verilerin toplandığı Siber Fiziksel Sistemlerin ortaya çıkışıyla birlikte, uygun bir normalleştirme tekniğinin bulunması, veri füzyonunu (entegrasyonunu) sağlamak için de bir zorluk haline gelmiştir. Bu nedenle, veri birleştirme ve kriterlerin toplanması, ortak bir puan elde etmek için kriterlerden veya sensörlerden alınan değerlerin birleştirilmesine yönelik benzer süreçlerdir. Vafaei ve arkadaşları çalışmalarında AHS çok kriterli yöntem özelinde karar problemlerinde en uygun normalleştirme tekniklerinin hangileri olduğunu değerlendirmeye yönelik metrikleri tartışmıştır [3].

Literatürde, bu çalışmada da dikkat çekilen, normalleştirme teknikleri arasındaki gri bölgelerin varlığı ve belirli bir tip problem için seçilecek normalleştirme tekniğinin belirlenemiyor olması, bir

araştırma konusu olmuştur. Jahan ve Edwards çalışmalarında bu soru üzerine yoğunlaşmış ve normalleştirme tekniklerinin zayıflıkları üzerinde çalışmalarını yürütmüşlerdir [20]. Çalışmalarında normalleştirme teknikleri arasındaki küçük farklılıklar olduğu fakat kritik karar süreçlerinde bu farklılıkların önem kazandığını vurgulamışlardır.

Çelen [21] çalışmasında Doğrusal normalleştirme, Maksimum-Minimum Normalleştirme, Maksimum Normalleştirme ve Vektör Normalleştirme tekniklerinin bir ÇKKV problemi üzerindeki etkilerinin ölçülmesi TOPSIS ve Bulanık AHS ile incelemiştir.

Pavlicic üç popüler normalleştirme tekniğinin üç farklı ÇKKVY (SAW, TOPSIS ve ELECTRE) üzerindeki etkilerini incelemiştir. Pavlicic kullanılan normalizasyon prosedürünün nihai tercihleri etkilediği sonucuna varmıştır. Bu çalışma aynı zamanda ÇKKVY'nin tutarlı seçimin belirli koşullarını ihlal ettiğine ve bu ihlalin kullanılan normalizasyon prosedürlerine atfedilebileceğine de göstermiştir [22].

Mhlanga ve Lall çalışmalarında Web servislerinin seçiminde AHP-VIKOR hibrit yönteminde normalleştirme etkilerini araştırmışlardır. Araştırmada ele alınan Web hizmetleri hizmet kalitesi (Quality of Service-QoS) ölçümüne dönük kriterler belirlenmiştir. Bunlar hizmetlerin yanıt süresi, üretim hızı, gecikme süresi, kullanılabilirlik ve güvenilirlik olmak üzere beş farklı Hizmet Kalitesi gereksinimine göre değerlendirilmiştir. Kullanılan beş normalleştirme tekniği doğrusal toplam, doğrusal maksimum, doğrusal maksimum-minimum, geliştirilmiş doğruluk ve vektör normalleştirme. VIKOR yöntemine farklı normalleştirme teknikleri uygulandığında farklı sıralama listelerinin üretildiği ve normalleştirme'nin nihai sıralama listesine etkisi olduğu görülmüştür [23].

Bonferroni ortalaması fikrinden esinlenerek, Xu ve Chen tarafından yapılan çalışmada aralık değerli sezgisel bulanık bilgilerin toplanması için aralık değerli sezgisel bulanık Bonferroni ortalaması adı verilen bir toplama tekniği geliştirilmiştir. Giriş argümanlarının farklı öneme sahip olduğu durumlar için, daha sonra, aralık değerli sezgisel bulanık ortamlar altında ÇKKV için bir prosedür tanımlanmış ve buna dayanarak, ağırlıklı aralık değerli sezgisel bulanık Bonferroni ortalaması tanımlanmıştır [24].

Otay çalışmasında üçgen sezgisel bulanık kümeler kullanılarak tanımlanmış bir bütünleşik AHY-TOPSIS metodolojisi, aralık değerli üçgen sezgisel bulanık sayıların kullanılabilmesi bir metodolojiye dönüştürmüştür. Uygulama alanı olarak, İstanbul'da faaliyet gösteren bir hastaneler grubunun yeni açacağı hastane için ameliyat robotu değerlendirme ve seçim problemi incelenmiştir. Elde edilen sonuçlar, farklı bulanık küme uzantı tabanlı veri kümelerinin birbirlerine dönüştürülerek aynı metodolojide başarıyla kullanılabilmesini göstermiştir. Bu çalışmada ayrıca karşılaştırma ve duyarlılık analizleri yapılmış ve önerilen modelin sonuçlarının oldukça gürbüz ve tutarlı olduğu gözlemlenmiştir [25].

Bu çalışmanın, normalleştirme teknikleri üzerinde yürütülen ve sıklıkla belirli ÇKKV Yöntemi ve/veya Yöntemleri üzerindeki etkileri ve zayıflıklarını araştıran çalışmalardan, önemli farklılığı farklı ÇKKV Yöntemlerine uygulanmış birden fazla normalleştirme tekniği ile elde edilen sıralama ve ağırlıklandırılmaları birer uzman seçimi olarak değerlendirerek bir grup kararı olarak tümleştirecek bir yöntem geliştirmektir.

3. Normalleştirme Teknikleri (Normalization Techniques)

Bu bölümde, çeşitli ÇKKVY'nde kullanılan ve çalışmamıza konu olan, bazı normalleştirme tekniklerinin bir özeti verilmektedir. Her bir

normalleştirme tekniğinin hangi matematiksel özelliklere sahip seriler için uygun olduğu belirtilmiştir.

3.1. Maksimum-Minimum Normalleştirme (Max-Min Normalization)

Bu yaklaşım, analiz edilen veri kümesindeki en yüksek ve en düşük değerlere dayanır. Palczewski'ye göre kâr odaklı kriterler Eş. 1'e ve maliyet odaklı kriterler Eş. 2'ye göre hesaplanır [1].

$$r_{ij} = \frac{x_{ij} - \min_j(x_{ij})}{\max_j(x_{ij}) - \min_j(x_{ij})} \quad (1)$$

$$r_{ij} = \frac{\max_j(x_{ij}) - x_{ij}}{\max_j(x_{ij}) - \min_j(x_{ij})} \quad (2)$$

Min-Maks normalleştirme veya özellik ölçeklendirme olarak da bilinen Minimum-Maksimum normalleştirme tekniği, bir veri kümesinin değerlerini belirli bir aralığa, tipik olarak 0 ile 1 arasında ölçeklendirmek istendiğinde uygulanır.

Bu normalleştirme yöntemi, standart bir aralık içinde olmalarını sağlarken değerler arasındaki göreceli ilişkileri ve oranları korumanın önemli olduğu durumlarda yararlıdır. Her veri noktasından minimum değeri çıkararak ve ardından bunu aralığa (maksimum ve minimum değerler arasındaki fark) bölerek, değerler istenen aralığa sığacak şekilde dönüştürülür. Verilerin mutlak değerleri, göreceli konumları veya oranları kadar önemli olmadığında özellikle yararlıdır. Bu normalleştirme tekniği, tüm değerlerin belirtilen aralık içinde orantılı olarak ölçeklenmesini sağladığından, farklı değişkenler veya veri noktaları arasında adil karşılaştırmalara izin verir.

3.2. Maksimum Normalleştirme (Maximum Normalization)

Bu yöntem, dikkate alınan dizideki yalnızca en büyük değeri kullanır. Formüller, sırasıyla kâr tipi Eş. 3 ve maliyet tipi kriterleri Eş. 4 için aşağıdaki şekildedir [3]:

$$r_{ij} = \frac{x_{ij}}{\max_j(x_{ij})} \quad (3)$$

$$r_{ij} = 1 - \frac{x_{ij}}{\max_j(x_{ij})} \quad (4)$$

Maksimum normalleştirme tekniği tipik olarak, bir veri kümesinin değerlerini maksimum değerden göreceli mesafelerine göre ölçeklendirmek istendiğinde uygulanır.

Bu normalleştirme tekniği, veri kümesindeki maksimum değeri belirlemeye ve diğer tüm değerleri maksimum değerle göreceli karşılaştırmaya odaklanıldığında kullanışlıdır. Her bir değeri maksimum değere bölerek, tüm değerler Minimum/Maksimum ile bir (1) arasında ölçeklenir ve maksimum değer bir (1) olur. Bu, her bir değer maksimum değerle nasıl karşılaştırıldığının net bir şekilde anlaşılmasını sağlar.

Maksimum normalleştirme, maksimum değer özel ilgi veya önem taşıdığı durumlarda yaygın olarak kullanılır. Veri analizi, karar verme ve optimizasyon problemleri gibi çeşitli alanlarda sıklıkla kullanılmaktadır. Bu teknik, her bir değer göreceli büyüklüğünü vurgulamaya yardımcı olur ve maksimum değere yakınlıklarına göre karşılaştırmaları kolaylaştırır.

3.3. Toplam Normalleştirme (Sum Normalization)

Bu teknik, dikkate alınan kümedeki tüm değerlerin toplamını kullanır. Formüller sırasıyla kâr türü Eş. 5 ve maliyet türü ölçütleri Eş. 6 için aşağıdaki şekildedir [20].

$$r_{ij} = \frac{x_{ij}}{\sum_{i=1}^m (x_{ij})} \quad (5)$$

$$r_{ij} = \frac{1}{\sum_{i=1}^m (x_{ij})} \quad (6)$$

Toplam normalleştirme tekniği, tipik olarak amaç, bir veri kümesinin değerlerini genel toplama orantılı katkılarına göre ölçeklendirmek olduğunda uygulanır. Bu teknik, değerler bir bütünün parçalarını temsil ettiğinde veya değerlerin toplamı anlamlı olduğunda kullanışlıdır. Örneğin, ÇKKV'de, birden çok kritere dayalı alternatifleri değerlendirirken, her bir kriterin değerlerinin genel karara katkılarına göre orantılı olarak ölçeklenmesini sağlamak için toplam normalleştirme tekniği uygulanabilir. Bu, alternatifler arasında adil ve dengeli bir karşılaştırmaya izin verir. Toplam normalleştirme, genel olarak, bir toplam toplama ilişkin olarak değerlerin nispi katkısı veya oranı önemli olduğunda uygulanır. Ancak bu yöntem sıfır-bir arasına ölçeklemez.

3.4. Kareli Toplam (Vektör) Normalleştirme (Vector Normalization)

Bu yöntem, tüm elemanların karelerinin toplamının karekökünü kullanır. Toplam normalleştirmeye benzer görünse de sonuçları oldukça farklıdır. Toplam normalleştirme gibi, vektör normalleştirme de, sıfır bir arasına ölçeklemez. Formüller sırasıyla kâr türü Eş. 7 ve maliyet türü Eş. 8 için aşağıdaki gibidir [3].

$$r_{ij} = \frac{x_{ij}}{\sqrt{\sum_{i=1}^m (x_{ij}^2)}} \quad (7)$$

$$r_{ij} = 1 - \frac{x_{ij}}{\sqrt{\sum_{i=1}^m (x_{ij}^2)}} \quad (8)$$

Kareli toplam normalleştirme tekniği, genellikle verilerin geniş bir değer aralığına sahip olduğu ve verilerin genel modelini korurken aşırı değerlerin etkisini azaltma isteğinin olduğu durumlarda uygulanır. Bu teknik, çarpık (skewed) bir dağılıma sahip değişkenlerle uğraşırken veya genel toplamı orantısız bir şekilde etkileyen aykırı değerler olduğunda özellikle yararlıdır. Toplamın karekökünü alarak normalleştirme işlemi, değerler arasındaki göreceli ilişkileri korurken büyük değerlerin etkisini azaltır.

Toplamın karekökü normalleştirme, istatistik, makine öğrenimi ve veri analizi gibi alanlarda yaygın olarak kullanılır. Verilerin daha dengeli bir temsiline oluşturmaya yardımcı olur ve çeşitli analitik yöntemlerin ve algoritmaların etkinliğini artırabilir.

3.5. Logaritmik Normalleştirme (Logarithmic Normalization)

Bu normalleştirme yöntemi, doğal logaritmayı kullanır. Ele alınan kümenin değerlerinin pozitif olduğu varsayılır. Formüller sırasıyla kâr türü Eş. 9 ve maliyet türü Eş. 10 için aşağıdaki şekildedir [3].

$$r_{ij} = \frac{\ln(x_{ij})}{\ln(\prod_{i=1}^m (x_{ij}))} \quad (9)$$

$$r_{ij} = \frac{1 - \frac{\ln(x_{ij})}{\ln(\prod_{i=1}^m (x_{ij}))}}{m-1} \quad (10)$$

Logaritmik normalleştirme teknikleri tipik olarak, geniş bir değer aralığını kapsayan ve önemli ölçüde değişkenlik gösteren verilerle uğraşırken uygulanır. Bu normalleştirme yöntemi, değerlerin logaritmasını alarak verileri daha yönetilebilir bir ölçeğe doğru sıkıştırmaya yardımcı olur. Veriler çarpık bir dağılıma sahip olduğunda veya aşırı uç değerler olduğunda özellikle yararlıdır. Logaritmik normalleştirme uygulanarak, değer aralığı azaltılabilir, bu da verileri karşılaştırmayı ve analiz etmeyi kolaylaştırır.

4. Geliştirilen Yöntem ve Kullanılan ÇKKVY (Developed Method and Used MCDM)

Bu bölümde çalışmada seçilmiş olan ÇKKVY AHS, TOPSIS, VIKOR, MOORA ve PROMETHEE, uygulama akışları kısaca ele alınacaktır. Uygulanan tüm yöntemlerde karar kriter ve alternatiflere göre bir ağaç yapısında tanımlanır. Şekil 1'de A_i i. Alternatifi, K_i i. Kriteri ve AK_i i. Alt kriteri göstermek üzere karar sürecine ilişkin karar hiyerarşisi görülmektedir.

4.1. AHS (AHP)


Saaty tarafından 1980 yılında ortaya konulmuş bir ÇKKV yöntemidir. AHS ikili karşılaştırmalara yönelik bir öz değer yaklaşımıdır [26]. Aynı zamanda hem niceliksel hem de niteliksel performansların ölçümü için sayısal ölçeği kalibre etmeye yönelik bir metodoloji sağlar. Ölçek, karşılaştırmaların tüm yelpazesini kapsayan "en az değerli" için 1/9'dan, "eşit" için 1'e ve "kesinlikle daha önemli" için 9'a kadar değişir.

4.2. Uygulama Aşamaları (Application Phases)

AHS çözüm yaklaşımı hem alternatiflerin hem de kriterlerin ikili karşılaştırılması temeline dayanır. AHS kriterler için alt kriterleri hiyerarşik olarak ele alır. Problemin tanımlanması aşamasında kriterler bir ağaç yapısı olarak tanımlanırken, kriter alt kriterleri alt ağaç yapısı formunda hiyerarşik olarak düzenlenir. Tanımlama sonrası aşağıdaki aşamalar gerçekleştirilir;

1. Kriterler ve alternatifler ikili olarak karşılaştırılır ve birbirlerine olan tercihleri 1-9 arasında puanlandırma veya mümkünse nominal değerleriyle derecelendirilir ve Eş. 11'da görülen karar matrisi oluşturulur.

a. İki kriteri, C_j ve C_k 'yi ele alalım. Karar vericiden, hedefe ilişkin olarak C_j 'nin C_k üzerindeki göreceli önemi açısından çift hakkında dereceli karşılaştırmalı bir yargıda bulunması istenir. Karşılaştırmalı yargı, anlamsal bir ölçekte (eşit derecede önemli/orta derecede daha önemli/güçlü derecede önemli vb.) ele alınır ve sayısal bir tamsayı değeri olan a_{jk} 'ye dönüştürülür. C_k 'nin C_j üzerindeki göreceli önemi karşılıklı olarak tanımlanır, yani $a_{kj}=1/a_{jk}$. Daha sonra tüm j ve k için a_{jk} kullanılarak karşılıklı ikili karşılaştırma matrisi A oluşturulur. Burada $a_{jj}=1$ olduğuna dikkat



Şekil 1. Karar Hiyerarşisi (Decision Hierarchy)

ediniz. Burada nominal değerler kullanılabilir. Örnek olarak, fiyat bilgisi, güç bilgisi gibi bilinen ve kıyaslanabilir sayısal değerler doğrudan kullanılabilir.

Elde edilen $n \times n$ matris aşağıda görüldüğü şekildedir.

$$A = \begin{bmatrix} 1 & a_{12} & \dots & a_{1n} \\ 1/a_{12} & 1 & \dots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ 1/a_{1n} & 1/a_{2n} & \dots & 1 \end{bmatrix} \quad (11)$$

A matrisinde,

- $a_{ij} = \alpha$ ise $a_{ji} = 1/\alpha$, $\alpha \neq 0$
- C_i ve C_j eşit derecede öneme sahipse ($a_{ij} = a_{ji} = 1$), olur,
- C_i ve C_j $i=j$ ise ($a_{ij} = a_{ji} = 1$), olur.

Tanımlama sonrasında her bir kritere göre alternatiflerin ikili karşılaştırıldığı ve kriterlerin ikili karşılaştırıldığı, m alternatif sayısını göstermek üzere, $m+1$ adet matris vardır.

2. İkili karşılaştırmalar matrislerinin aşağıdaki üç aşama ile sentezlenmeleri gerçekleştirilir [27].

- İkili karşılaştırmalar matrisinin her sütunundaki değerler toplanır,
- İkili karşılaştırmalar matrisindeki her eleman, kendi sütun toplamına bölünür. Elde edilen matris normalize edilmiş matris olarak adlandırılır,
- Normalize edilen ikili karşılaştırmalar matrisinin her bir satırındaki elemanların ortalaması hesaplanır. Elde edilen bu ortalamalar öncelik sıralamasına yönelik tahmin değerleridir. Bu değerlerden oluşan öncelikler aşağıdaki şekilde w sütun vektörü olarak ifade edilir,

$$w = [w_1 \quad \dots \quad w_n]^T, \quad i=1, \dots, n$$

3. Kriter ikili kıyaslama ve ağırlık ikili kıyaslama matrisleri tutarlılık oranları hesaplanır,

- Tutarlılık Oranı (Consistency Ratio = CR)'nin $0,10$ 'dan küçük olması durumunda, ikili karşılaştırmalar matrisinin geçerli olduğu sonucuna varılır. Tutarlılık oranı aşağıdaki adımlar ve formüller ile hesaplanır [28],
- İkili karşılaştırmalar matrisi A ile w matrisi çarpılır ve ağırlıklandırılmış toplamlar matrisi olan Aw elde edilir,
- Elde edilen Aw matrisi, w matrisine bölünerek $\frac{Aw}{w}$ matrisi bulunur,
- $\frac{Aw}{w}$ matrisindeki değerlerin aritmetik ortalaması hesaplanarak maksimum λ_{max} bulunur.
- Hesaplanan λ_{max} değeri aşağıdaki formüle konduğunda Eş. 12 Tutarlılık İndeksi (Consistency Index = CI) elde edilir,

$$CI = \frac{\lambda_{max} - n}{n - 1} \quad (12)$$

v. Tutarlılık Oranı ise (CR) aşağıdaki formül ile hesaplanır Eş. 13,

$$CR = \frac{CI}{RI} \quad (13)$$

Rassal İndeks (RI = Randomly Index), n sayısına bağlı olarak rassal olarak türetilmiş ikili karşılaştırmalar matrislerinin ortalama değerleridir. RI değeri Eş.14'de görülen formül kullanılarak hesaplanır.

$$RI = \frac{1.86(n-2)}{n} \quad (14)$$

4.3. Topsis (Topsis)

TOPSIS ilk olarak 1981'de Ching-Lai Hwang ve Yoon tarafından geliştirilen [29], 1987'de Yoon tarafından yeni geliştirmelerle bugünkü formuna ulaştırılan çok kriterli bir karar analizi yöntemidir [30].

4.4. Uygulama Aşamaları (Application Phases)

TOPSIS yöntemi aşağıdaki adımları içermektedir [31].

1. Karar matrisi Eş. 15'de görüldüğü gibi oluşturulur,

$$\begin{bmatrix} x_{11} & \dots & x_{1n} \\ x_{i1} & \dots & x_{in} \\ x_{m1} & \dots & x_{mn} \end{bmatrix}, \quad i=1, \dots, m \text{ ve } j=1, \dots, n \quad (15)$$

Burada, m : alternatif sayısını, n : her bir alternatifi tanımlayan kriter sayısını x_{ij} : alternatif i 'nin j kriteri bazında performans değerini temsil etmektedir.

2. Karar matrisi Eş. 16 kullanılarak normalize edilir.

$$x_{ij}^* = \frac{x_{ij}}{\sqrt{\sum_{i=1}^m x_{ij}^2}}, \quad i=1, \dots, m \text{ ve } j=1, \dots, n \quad (16)$$

Burada, x_{ij}^* alternatif i 'nin j kriteri bazında performans değerinin normalize edilmiş değerini temsil etmektedir.

3. Ağırlıklı normalize edilmiş karar matrisi Eş. 17 kullanılarak belirlenir:

$$v_{ij} = w_{ij} * x_{ij}^*, \quad i=1, \dots, m \text{ ve } j=1, \dots, n \quad (17)$$

4. Her bir kritere ait pozitif (yüksek değer en iyi) ve negatif (düşük değer en iyi) ideal değerler bulunur. Eş. 18 ve Eş. 19, sırasıyla pozitif ve negatif idealden sapma hesaplamalarını ifade eder.

$$\text{Pozitif idealden sapmalar} = \{v_1^+, v_2^+, \dots, v_n^+\}, \quad v_j^+ = \text{Max}_i(v_{ij}) \quad (18)$$

$$\text{Negatif idealden sapmalar} = \{v_1^-, v_2^-, \dots, v_n^-\}, \quad v_j^- = \text{Min}_i(v_{ij}) \quad (19)$$

5. Her alternatifin pozitif ve negatif ideal çözümlerden geometrik uzaklıkları, sırasıyla, Eş. 20 ve Eş. 21 kullanılarak hesaplanır.

$$S_i^+ = \sqrt{\sum_{j=1}^n (v_{ij} - v_j^+)^2}, \quad i=1, \dots, m \quad (20)$$

$$S_i^- = \sqrt{\sum_{j=1}^n (v_{ij} - v_j^-)^2}, \quad i=1, \dots, m \quad (21)$$

6. İdeal çözümden göreceli uzaklık (C_i) Eş. 22 kullanılarak hesaplanır.

$$C_i = \frac{S_i^-}{S_i^+ + S_i^-}, \quad i = 1, \dots, m; \quad 0 < C_i < 1 \quad (22)$$

Alternatiflerin seçim sıralaması en yüksek göreceli uzaklık değeri C_i 'ye göre yapılır.

4.5. Vikor (Vikor)

VIKOR Opricovic tarafından geliştirilmiş ve ilk olarak 1980 yılında yayınlanmış birçok kriterli karar verme yöntemidir [32]. Yöntem çelişkili ve karşılaştırılmayan (farklı birimler) kriterlere sahip karar problemlerini çözmek için, çatışma çözümü için uzlaşmanın kabul

edilebilir olduğu, karar vericinin, belirlenen tüm kriterlere göre, ideale en yakın çözümü istediği ve alternatiflerin buna göre değerlendirildiği varsayılarak geliştirilmiştir. VIKOR alternatifleri sıralayarak ideale en yakın olan uzlaşma adı verilen çözümü belirler.

4.6. Uygulama Aşamaları (Application Phases)

VIKOR uygulama adımları TOPSIS uygulama adımlarından ilk ikisi ile örtüşür. Bir karar matrisi belirlenmiştir ve seçilen herhangi bir normalleştirme yöntemi ile normalleştirme yapılarak normalleştirilmiş karar matrisi elde edilmiştir. TOPSIS Adım 4'de yapıldığı gibi VIKOR pozitif ve negatif idealleri aynı şekilde belirler ve aşağıdaki adımlar takip edilir.

1. İdeal değerler kullanılarak karar matrisi normalleştirilir. Bunun için Eş. 23 kullanılır:

$$f_{ij} = \frac{|d_j^+ - d_{ij}|}{|d_j^+ - d_j^-|} \quad (23)$$

Buradan $F = [f_{ij}]_{m \times n}$ matrisi elde edilir.

2. Normalleştirilmiş F matrisinin tüm değerleri, her bir kriterin önem değeri ile çarpılarak ağırlıklandırılır. $W = [w_j]_{1 \times n}$ önem vektörünü göstermek üzere Eş. 24 kullanılarak ağırlıklandırılmış karar matrisi hesaplanır;

$$r_{ij} = f_{ij} w_j \quad (24)$$

Her bir alternatif için fayda ve pişmanlık değerleri hesaplanır. Bunun için i . Alternatif grup fayda vektörü $S = [s_i]_{m \times 1}$ ve minimum bireysel pişmanlık vektörü $R = [r_i]_{m \times 1}$ aşağıda verilen Eş. 25 ve Eş. 26 kullanılarak hesaplanır.

$$s_i = \sum_{j=1}^n r_{ij} \quad (25)$$

$$r_i = \max_j(r_{ij}) \quad (26)$$

3. Uzlaşmacı çözüm değerlerinin hesaplanması yürütülür. Yaklaşım maksimum grup faydası ile minimum bireysel pişmanlık arasında bir denge kurmaktır. Bunun için grup faydası ve bireysel pişmanlık, $[0,1]$ kapalı aralığında değer alan, sırasıyla, v ve $1-v$ değerleriyle çarpılır. V değeri sıklıkla 0.5 değeri alır ve bu maksimum fayda ile pişmanlık arasında eşit bir düşünüşmeyi temsil eder. Hesaplama Eş. 27 kullanılarak gerçekleştirilir.

$$q_i = v \frac{s_i - \min_i(s_i)}{\max_i(s_i) - \min_i(s_i)} + (1-v) \frac{r_i - \min_i(r_i)}{\max_i(r_i) - \min_i(r_i)} \quad (27)$$

4. Uzlaşmacı çözüm değerleri küçükten büyüğe doğru sıralanarak en iyi alternatif sırası elde edilir. q_i değerleri arasında $1/(m-1)$ değerinden büyük bir fark varsa veya tüm S, R, Q vektörü sıralamalarında en iyi alternatif aynı alternatifse, en küçük q_i değerine sahip olan bu alternatif en iyi alternatif olarak belirlenir.

4.7. Moora (Moora)

TOPSIS ve VIKOR yöntemlerine benzer şekilde geliştirilmiştir. Bu yöntemlerden farklı olarak MOORA ideal olmayan çözüm ile ilgilenmemektedir. Çözümler yalnızca referans noktası baz alınarak gerçekleştirilir. Her bir alternatifin referans noktasıyla olan ilişkisi, TOPSIS yöntemindeki gibi, Öklidyen mesafe olarak değil, her bir kriter için fark alınarak belirlenmektedir [33].

4.8. Uygulama Aşamaları (Application Phases)

Uygulama TOPSIS'de olduğu şekilde karar matrisi normalleştirilmesini Eş. 16'de verilen kareler toplamının kareköküne göre gerçekleştirir. Ardından kriter ağırlıklarıyla çarpılarak Eş. 24'de

görülen rij matrisi elde edilir. MOORA'nın bu noktadan sonra farklılaşan adımları aşağıdaki gibidir [33]:

1. Karar matrisinden bir adet referans noktası (r), Eş. 28 kullanılarak, elde edilir. Formül pozitif çözümler için verilmiştir. Negatif durumlar için formül minimizasyon olarak kullanılarak referans noktası belirlenir.

$$r = \{r_j | \forall j \text{ için } \max_i(r_{ij})\} \quad (28)$$

2. Her bir alternatif için, ilgili kritere ait maksimum değerden fark hesaplanır ve her bir alternatif için farklar toplanır (Eş. 29).

$$\text{Maksimum Sapma} = \sum_{j=1}^n (d_j - d_{ij}) \quad (29)$$

3. Minimum toplam sapmadan, maksimum sapmaya doğru alternatifler sıralanır. En düşük sapmalı alternatif ilk seçimdir.

4.9. Promethee (Promethee)

Bu yöntem ilk olarak 1982 yılında Brans [34] tarafından ortaya atılmış ve 1985 yılında Vincke ve Brans tarafından daha da genişletilmiştir [35].

4.10. Uygulama Aşamaları (Application Phases)

Diğer yöntemlerde de olduğu gibi karar matrisinin normalleştirilmesi gerçekleştirilir. Elde edilen normalleştirilmiş matris kullanılarak;

1. Alternatiflerin ikili eşleşmesi yapılır. A_i i alternatifini ve A_k k alternatifini göstermek üzere, $f_{ik} = A_i - A_k$ ikilileri tanımlanır. $i=1, \dots, m$ ve $k=1, \dots, m$ $i \neq k$ ve her A_i her A_k ile ilişkilendirilecektir.
2. Normalleştirilmiş matris değerleri (d_{ik}) kullanılarak eşleme normalleştirilmiş değerler arasındaki farklar alınarak, eşlenmiş alternatifler x kriterler matrisi oluşturulur (F) (Eş. 30),

$$\begin{matrix} A_1 & A_2 & & & & \\ A_{\dots} & A_{\dots} & & & & \\ A_m & A_{m-1} & & & & \end{matrix} \begin{bmatrix} d_{11} - d_{21} & \dots & d_{1n} - d_{2n} \\ \dots & \dots & \dots \\ d_{m1} - d_{(m-1)1} & \dots & d_{mn} - d_{(m-1)n} \end{bmatrix} F = f_{ik} = A_i - A_k = d_{ij} - d_{kj}, j \text{ kriteri göstermek üzere } j=1, \dots, n \text{ ve } i \neq k \quad (30)$$

3. Elde edilen matriste sıfırdan küçük olan ($f_{ik} < 0$) değerler sıfır ile değiştirilir.

4. F matrisi her bir satırı toplanır (Eş. 31). Satır toplamları kullanılarak seçeneklerin satır ve sütunda yer aldığı Tablo 1 hazırlanır. Tablo ikili eşleşme kesişim hücreleri olan hücrede toplam değerleri tutar ve satır ve sütun toplamları hesaplanır.

$$\begin{matrix} A_1 & A_2 & & & & \\ A_{\dots} & A_{\dots} & & & & \\ A_m & A_{m-1} & & & & \end{matrix} \begin{bmatrix} d_{11} - d_{21} & \dots & d_{1n} - d_{2n} \\ \dots & \dots & \dots \\ d_{m1} - d_{(m-1)1} & \dots & d_{mn} - d_{(m-1)n} \end{bmatrix} \begin{matrix} S_{12} \\ S_{\dots} \\ S_{m(m-1)} \end{matrix} \quad (31)$$

Tablo 1. PROMETHEE (PROMETHEE)

| | A1 | A... | Am | |
|-----|-----|-------|---------|-------|
| A1 | 0 | S... | S1m | St1 |
| ... | .. | 0 | | St... |
| Am | Sm1 | Sm... | Sm(m-1) | Stm |
| | t1 | t... | tm | |

5. Tablo 1 satır ve sütun toplamları Tablo 2 N^+ ve N^- kolonlarını, sırasıyla oluşturur. N^+ ve N^- arasındaki fark ile elde edilen vektörün büyükten küçüğe doğru sıralanması alternatif sıralamasını belirler.

Tablo 2. PROMETHEE Karar Tablosu (PROMETHEE Decision Table)

| | N+ | N- | Fark |
|------|-------|------|------------|
| A1 | St1 | t1 | St1-t1 |
| A... | St... | t... | St...-t... |
| Am | Stm | tm | Stm-tm |

4.11. Yöntemlerin Ortak Özellikleri (Common Properties of The Methods)

Burada ele alınan yöntemler varsayılan olarak bir normalleştirme yöntemi sunarlar. AHS toplam normalleştirmeyi ve TOPSIS kareler toplamının kareköküne göre normalleştirmeyi varsayılan normalleştirme tekniği olarak sunar. Çalışmanın alt bölümlerinde ayrıntılı bir şekilde ele alınacağı gibi, normalleştirme tekniği incelenen karar matrisindeki değerlerin niteliğine bağlıdır. AHS’de varsayılan veya sıklıkla yürütülen uygulama 1-9 arasında derecelendirme yapılarak karar matrisinin hazırlanmasıdır. Uygulamadan elde edilen değerler arasında marjinal farklılıklar olamayacağı için toplam normalleştirme tekniği uygulanabilir bir seçimdir. Fakat nominal değerlerin kullanıldığı bir karar matrisinde veri setine bağlı olarak uygulanacak teknik değişiklik gösterebilir. Örnek olarak uç değerler içeren bir karar matrisi için logaritmik normalleştirme kullanımı tercih edilebilir.

Tutarlılık indeksi her ne kadar AHS uygulama adımlarında sıklıkla yer alsada tutarlılık karar vericinin karar matrisini oluşturması aşamasında, uyguladığı ÇKKV yönteminden bağımsız olarak yürüteceği bir adımdır. Tutarlılık kontrolü bir döngüsellik oluşturup oluşturmadığının araştırılması ile ilgilidir ve AHS’nin de kullandığı ve ona ait olmayan bir kontrol tekniğidir. Tutarlılık indeksi hesaplayarak yürütülen tutarlılık kontrolü tüm karar matrisi oluşturma aşamasında tüm ÇKKV’de uygulanabilir. Döngüsellğe bir örnek olarak şöyle bir durumu düşünelim. Dolma kalem, tükenmez kalem ve kurşun kalem arasında bir tercih ifadesi şu şekilde tanımlanmış olsun; “Dolma kalem tükenmez kaleme 3 kez, dolma kalem kurşun kaleme 5, tükenmez kalem kurşun kaleme 2 ve kurşun kalem dolma kaleme 4 kez tercih edilmiştir”. Tanımlamada bir döngüsel durum söz konusu olduğu için tutarlı bir değerlendirme değildir. Bu durum karar matrisi tanımlama ile ilgilidir ve tüm ÇKKV için geçerlidir.

4.12. Geliştirilen Yöntem (Developed Method)

ÇKKV’nin karar vektörlerinin farklı normalleştirme teknikleriyle çoklanarak grup karar teknikleriyle birleştirilmesinde uygulanan yöntem şu şekildedir. Problemin girdisi satırları seçenek ve sütunları kriter olan bir karar matrisidir. İşlem için sıralı olarak AHS, TOPSIS, VIKOR, MOORA ve PROMETHEE yöntemlerine uygulanır. Uygulanacak yöntem seçilir ve girdi matrisi Toplam, Vektör, Maks-Min, Maks ve Logaritma normalleştirme teknikleri kullanılarak normalleştirilir. Normalleştirilen karar matrisi seçilen ÇKKV Yöntemine göre çözülerek seçim sıra vektörü belirlenir. Seçim sıra matrisi uygulanan yöntemle göre en yüksek ağırlıktan en düşük ağırlığa sıralama verilecek şekilde düzenlenir. Bu işlem yürütülürken, en az sapmaya sahip (MOORA) seçenek en yüksek tartıya sahip olacak şekilde düzenlenirken, sıralamayı en büyükten en küçüğe ağırlık şeklinde veren AHS vektörü bir sonraki aşamaya doğrudan alınır. Elde edilen sıralamalar Maks-Min normalleştirme ile normalize edilerek nihai ağırlık belirlenir (Tablo 16-Tablo 20). Bu işlem tercih sıralamasını değiştirmez fakat 0-1 arasında normalize ederek, elde edilen tüm seçim vektörlerine ait ağırlıkları toplanabilir kılar. Tüm seçim vektörleri 0-1 arasında dağıldığı için ağırlıklar büyüklük (magnitüde) olarak da toplanabilir, mukayese edilebilir bir benzerliğe sahip olur. Yürütülen işlem sonunda elimizde her bir ÇKKV’ne ait normalleştirme tekniği sayısı kadar Seçim Vektörü (SV) vardır. Seçim vektörü seçenek, seçeneğin seçim ağırlığı ve seçim sırasını içerir.

Bir sonraki adım her bir seçeneğin her bir sıra için seçilme sayısını ve seçim ağırlığı toplamını belirlemektir. Elde edilen iki matrisler maksimizasyon amaçlı birer atama problemi olarak çözülür. Elde edilen iki sıralama ile ÇKKV’nin normalleştirme teknikleriyle sahip oldukları çözüm sıralamaları arasındaki mesafe hesaplanır. ÇKKV sıralamalarıyla en düşük sapmayı veren optimum çözüm sıralaması üzerinde en fazla uzlaşma olduğu düşüncesiyle nihai karar (optimum çözüm) olarak seçilir. Uygulanan yöntemle ilişkin sözde kod Şekil 2’de verilmiştir.

5. Örnek Uygulama: Nozul Seçimi Problemi (The Case Study: Nozzle Selection Problem)

Bu örnek uygulamada, bir otomotiv firmasında motor bloğu üretimi için motorlarda kullanılan nozulların seçimine yönelik bir karar modeli geliştirilmiştir. Bu problem için seçilen çok kriterli yöntemler, farklı normalleştirme teknikleri kullanılarak ardışık olarak uygulanmıştır. Sonuç olarak, her yöntem ve normalleştirme tekniği kombinasyonu için belirli bir seçim sırası elde edilmiştir.

Tablo 3’de nozul alternatifleri (A1, A2, A3 ve A4) değerlendirme kriterleri ile birlikte sunulmaktadır. Nozulların değerlendirilmesi;

- Getiri (R); Nozullar yardımıyla maça üretiminden kazanılan aylık para miktarı (Birim: ₺),
- Ömür (L); Cihazın kullanım ömrü (birim: Saat),
- Garanti (W); Verilen garanti süresi (birim: Saat),
- Güç (P); Nozulun maça sandığına üfleyebildiği kum miktarı, (Litre/dakika),
- Bakım Aralığı (M); Bakımlar arası önerilen süre (birim: Gün)

kriterlerine göre yapılır. Alternatiflere ait kriter sayısal değerleri Tablo 3’de görülmektedir. Tablo 4’de her bir normalleştirme tekniğine göre normalize edilmiş değerler görülmektedir. Tablodaki değerler tüm ÇKKV’de kullanılacak değerlerdir.

5.1. ÇKKV Yöntemlerinin Uygulanması (Application of MCDMMs)

Bu bölümde MOORA ve TOPSIS yöntemleri için uygulama detayları verilirken, AHS, VIKOR ve PROMETHEE için sonuç seçim sıralamaları doğrudan verilecektir. Uygulamanın kritik adımlardan biri, her bir yöntem ve normalleştirme tekniği için gerçekleştirilen kriter ağırlıklarının hesaplanmasıdır. Bu örnekte Entropi tabanlı ağırlık hesaplama yöntemi seçilmiştir. Alternatif olarak, özvektör hesaplama yöntemi de seçilebilir.

Tablo 3. Nozul Alternatifleri ve Seçim Kriterleri (Nozzle Alternatives and Selection Criteria)

| | R | L | W | P | M |
|------|--------|--------|--------|----|----|
| A1 | 125000 | 800000 | 230000 | 12 | 45 |
| A2 | 115000 | 750000 | 200000 | 8 | 55 |
| A3 | 150000 | 840000 | 215000 | 10 | 40 |
| A4 | 155000 | 780000 | 265000 | 15 | 50 |
| Maks | 155000 | 840000 | 265000 | 15 | 55 |
| Min | 115000 | 750000 | 200000 | 8 | 40 |

5.1.1. Ağırlık Vektörü hesaplama (Weight vector calculation)

Normalleştirme tekniklerini uygulamadan önce ilk adım kriter ağırlıklarının hesaplanmasıdır. Kriter ağırlık vektörü entropi yöntemi kullanılarak hesaplanabilir ve burada bu yöntemi tercih edeceğiz. ÇKKV bağlamında entropi, bir veri kümesindeki belirsizliği veya düzensizliği ölçmek için kullanılan matematiksel bir kavramı ifade eder. ÇKKV yöntemlerinde entropi, kriter ağırlıkları veya karar

```

CKKVY=[AHS, TOPSIS, VIKOR, MOORA, PROMETHEE]
Normallestirme = [Toplam, Vektor, Maks-Min, Maks, Logaritma]
M → Seçenek x Kriter Matrisi
Secenekler = [] % Seçenekler vektörü
Kriter = [] % kriterler vektörü
Sec_ij[Secenek, Ağırlık, Sıra]: i CKKVY j normalleştirme yöntemi, seçenek, tartı ve sıra
for i in CKKVY:
    for j in Normallestirme:
        Nj=j(M) % M matrisi Normalleştir
        Sec_ij=i(Nj) % Seçim vektörünü belirle
        Sec_ij=Maks_Min(Sec_ij) % Kullanılan yöntemle göre seçim vektörünü
        % Maks-Min tekniği ile normalleştir.
% Tartı ve sıra seçim matrisleri, Satırlar seçenek ve sütunlar sıra
WMatris=[] % Tartı sıfır matrisi
SMatris=[] % Seçim sayısı sıfır matrisi
for k in Secenekler:
    for i in CKKVY:
        for j in Normallestirme:
            Sec_ij[k,W,S]
            WMatris[k,S] +=W
            SMatris[k,S] +=1
WMatris'ini ve SMatris'ini atama problemi olarak çöz ve Final-1 ve Final-2 çözümlerini elde et,
% Final-1 ve Final-2 çözümleri bir seçim sırasıdır. Elde edilen optimum çözüm
f[k]=0 tüm k=1,...m % Final çözüm f k seçeneği mesafesi
% f[k,_,S] Final çözüm f k seçeneği S sırasında
% Sec_ij[k,W,S] i CKKV Yöntemi j normalleştirme yöntemi k seçeneği w ağırlığı ve S sırası
for f in [Final-1,Final-2]:
    for i in CKKVY:
        for j in Normallestirme:
            for k in Secenekler:
                f[k] += abs(f[k,_,S]-Sec_ij[k,W,S])

```

Şekil 2. Geliştirilen Çözüme ait Sözde-kod (Pseudo-code of the Developed Solution)

matrisi içindeki bilgi içeriğinin veya çeşitliliğinin bir ölçüsü olarak kullanılır.

Entropi tabanlı yöntemler, ÇKKVY kriter ağırlıklarını hesaplamak veya karar verme sürecinde her bir kriterin önemini değerlendirmek için yaygın olarak kullanılır. Bu yöntemler, kriterlerin entropisini değerlendirerek, her bir kriterin genel karara yönelik göreceli önemini veya katkısını yakalamayı amaçlar. Entropi temelli yaklaşım, kriter ağırlıklarının daha objektif ve sistematik olarak belirlenmesine yardımcı olmakta ve böylece çok kriterli senaryolarda karar verme sürecini kolaylaştırmaktadır. Hesaplama aşağıdaki şekilde yürütülür [17, 36].

C_{ij} : Normalleştirilmiş değerleri (Tablo 4), m: Seçenek sayısı ve n: kriter sayısı olmak üzere her bir matris elemanı L_{ij} aşağıdaki gibi hesaplanır;

$$L_{ij} = C_{ij} \times \ln(C_{ij}) \quad (32)$$

$$k = 1/\ln(m) \quad (33)$$

$$e_j = -k \times \sum_{j=1}^m L_{ij} \quad (34)$$

$$d_j = 1 - e_j \quad (35)$$

$$w_j = \frac{d_j}{\sum_{j=1}^n d_j} \quad (36)$$

Eş. 32 ağırlıkların 0-1 aralığında olduğu için L_{ij} her zaman negatif sonuç verir. Formül uç değerlerdeki ağırlıkları diğer ağırlıklara doğru sıkıştırır. Entropi sistem kararsızlığını gösterir ve yüksek entropi, yüksek değişkenlik ve kararsızlık anlamına gelir. Eş. 33 seçenek sayısı ile orantılayan bir çarpan hesaplar. Eş. 34 ağırlıklara ait entropi

hesabını verirken, Eş. 35 her bir değerlendirme kriteri için farklılaşma derecesini verir. Nihai ağırlıklandırma Eş. 36'de görüldüğü şekilde toplam normalleştirilmesi olarak hesaplanmaktadır. Elde edilen w_j değerinin yüksek olması, kriterlere ait alternatif skorlar arasındaki uzaklığın veya farklılaşmanın fazla olduğunu ifade etmektedir [31].

Tablo 5 ağırlık vektörünün entropi yöntemi kullanılarak nasıl hesaplandığını göstermek için bir Maks-Min normalleştirme örneğinin kullanımı göstermektedir. Yukarıda verilen formüllere göre ağırlık hesaplamaları Tablo 5'te görülmektedir. w_i her bir kriter ağırlığını göstermektedir. Tablo 4'de her bir normalleştirme için Entropi yöntemi ile hesaplanan ağırlık vektörleri yer almaktadır.

Ağırlık vektörünü hesapladıktan sonra, ÇKKVY kullanarak seçeneklerin sıralamasını hesaplamaya geçebiliriz. MOORA yöntemi ilk olarak probleme uygulanır ve burada kriter değerleri her bir normalleştirme tekniğine göre normalleştirilir. Yöntem daha sonra Tablo 6'deki her bir normalleştirilmiş seçenek-kriter matrisine uygulanır. Bu işlem sonucunda alternatif bir sıra elde edilir. MOORA yönteminin tüm normalleştirme teknikleri için aynı sıralamayı vermesi dikkat çekicidir. Şimdi sanki beş kişilik bir grubun oylamasından oyların tamamında aynı sırayı almış bir sıralamamız mevcuttur.

TOPSIS yöntemi probleme aynı şekilde uygulanır. Tablo 7, vektör normalleştirilmesi için hesaplamaları göstermektedir. Pozitif idealerden ve Negatif idealden sapmalar Tablo 8'da verilmiş ve sonuç sıralaması aynı tabloda görülmektedir. Tablo 9 ve Tablo 10, Maksimum Normalleştirme için aynı işlemi göstermektedir. Max-min normalleştirme Tablo 9'da ve elde edilen sıra ile ilgili sapmalar Tablo 11'de görülmektedir. TOPSIS için toplam normalleştirme Tablo 12'de ve sonuç sıra ile sapmalar Tablo 13'da görülmektedir. Son normalleştirme tekniği, logaritmik normalleştirme tekniği örneğe uygulanır (Tablo 14). Logaritmik normalleştirme TOPSIS için pozitif

ve negatif sapmalar Bölüm 6 Grup Karar Yapımı: Oylama Tablo 21 grup kararlarını vermektedir. Bu noktada iki hareket tarzımız vardır. Bunlardan ilki her seçenek için sıralama sıklığını belirlemeyi içerirken, ikincisi, her seçeneğin kümülatif ağırlığı hesaplamaktır. Her iki yöntem de problemi bir atama optimizasyon problemine dönüştüren matrislerle sonuçlanır. Tablo 22, seçim sıralamaları için kümülatif oyları göstermektedir. Örnek olarak, A4 24 kez birinci seçenek olarak seçilmişken, A3 ikinci seçenek olarak iki kez seçilmiştir. Tablodaki geri kalan değerlerin anlamları aynı şekilde yorumlanır.

Bu örnekte VIKOR, AHS, PROMETHEE için aynı işlem uygulanmaktadır. Bu örnekte kullanılan her bir ÇKKVY'nin her biri için beş sıra elde edilir ve her sıra bir oylama olarak değerlendirilir. Bu aşamada karar problemi bir karar vericiden çok kriter altında grup karar verme [37] senaryosuna dönüşerek toplamda 25 sıra elde edilir. Takip eden bölüm bu kararların bir grup kararı olarak birleştirilmesiyle ilgilidir.

$$(a) - (125000 - 115000/155000 - 115000) = ,250$$

5.1.2. Grup karar yapımı: Oylama (Group decision making: Voting)

ÇKKVY'nin normalleştirme tekniklerine göre verdikleri karar sıralaması toplu olarak Tablo 21'de görülmektedir. Burada önceki bölümde bahsedilen oylama sayımı ve tartı hesaplamalarını iki ayrı çözüm olarak geliştireceğiz, Tablo 22 seçim sıralamaları için kümülatif oyları göstermektedir. Örnek olarak A1 22 kez ikinci seçenek olarak seçilirken, A3 ikinci seçenek olarak iki kez seçilmiştir. Tablodaki geri kalan değerlerin anlamları aynı şekilde yorumlanır.

İkinci optimizasyon modelimiz olan toplam tartıların maksimizasyonu için seçim vektörlerinin normalleştirilmesi gerekir. AHS, TOPSIS, VIKOR, MOORA ve PROMETHEE için her bir

Tablo 4. Normalize Edilmiş Değerler (Normalized Values)

| Vektör | Normalleştirme | | | | | Maks Normalleştirme | | | | | Logaritmik Normalleştirme | | | | | |
|----------|------------------|------|------|------|------|-----------------------|------|------|------|------|---------------------------|------|------|------|------|--|
| | R | L | W | P | M | R | L | W | P | M | R | L | W | P | M | |
| A1 | ,455 | ,504 | ,503 | ,520 | ,470 | ,806 | ,952 | ,868 | ,800 | ,818 | ,248 | ,250 | ,250 | ,260 | ,247 | |
| A2 | ,419 | ,473 | ,437 | ,347 | ,575 | ,742 | ,893 | ,755 | ,533 | 1,00 | ,247 | ,249 | ,247 | ,217 | ,260 | |
| A3 | ,546 | ,530 | ,470 | ,433 | ,418 | ,968 | 1,00 | ,811 | ,667 | ,727 | ,252 | ,251 | ,249 | ,240 | ,239 | |
| A4 | ,565 | ,492 | ,579 | ,650 | ,523 | 1,00 | ,929 | 1,00 | 1,00 | ,909 | ,253 | ,250 | ,253 | ,283 | ,254 | |
| w_i | ,161 | 0,18 | ,116 | ,556 | ,148 | ,212 | ,259 | ,195 | ,133 | ,200 | ,201 | ,202 | ,201 | ,196 | ,200 | |
| Maks-Min | Normalleştirme | | | | | Toplam Normalleştirme | | | | | | | | | | |
| | R | L | W | P | M | R | L | W | P | M | | | | | | |
| A1 | ,25 ^a | ,56 | ,46 | ,57 | ,33 | A1 | ,229 | ,252 | ,253 | ,267 | ,237 | | | | | |
| A2 | ,00 | ,00 | ,00 | ,00 | 1 | A2 | ,211 | ,237 | ,220 | ,178 | ,289 | | | | | |
| A3 | ,88 | 1 | ,23 | ,29 | ,00 | A3 | ,275 | ,265 | ,236 | ,222 | ,211 | | | | | |
| A4 | 1 | ,33 | 1 | 1 | ,67 | A4 | ,284 | ,246 | ,291 | ,333 | ,263 | | | | | |
| w_i | ,245 | ,184 | ,184 | ,188 | ,199 | w_i | ,161 | 0,18 | ,117 | ,557 | ,147 | | | | | |

Tablo 5. Maks Normalleştirme için Ağırlık Vektörü Hesaplama (Weight Vector Calculation for Max Normalization)

| | R | L | W | P | M | |
|-------------|---|--------|--------|--------|--------|---------------------------------|
| A1 | -,1735 ^a | -,0465 | -,1229 | -,1785 | -,1642 | |
| A2 | -,2215 | -,1012 | -,2124 | -,3353 | ,0000 | |
| A3 | -,0317 | ,0000 | -,1696 | -,2703 | -,2316 | |
| A4 | ,0000 | -,0688 | ,0000 | ,0000 | -,0866 | |
| Σ | -,4267 | -,2165 | -,5050 | -,7841 | -,4824 | |
| e_j | ,3078 ^b | ,1561 | ,3643 | ,5656 | ,3480 | |
| d_j | ,6922 ^c | ,8439 | ,6357 | ,4344 | ,6520 | $\Sigma=3,2582$ |
| w_j | ,212 ^d | ,259 | ,195 | ,133 | ,200 | |
| (a): | $,806 \times \ln(,806) = -,17068$, (b): $-k(-,4267) = ,3078$; | | | | | (c): $1-(,3078) = ,6922$, (d): |
| (k=1/Ln(4)) | | | | | | ,6922/3,2582=,212 |

Tablo 6. MOORA için Normalleştirmeler (Normalizations for MOORA)

| Vektör Normalleştirilmesi | | | | | | | | | |
|---------------------------|------------|---|------------------|------------------|-----|-----|-----|------|---|
| | $\sum y_i$ | S | R | L | W | P | M | Maks | S |
| A1 | ,50 | 2 | ,10 ^a | ,03 ^b | ,08 | ,13 | ,10 | ,13 | 2 |
| A2 | ,42 | 3 | ,15 | ,06 | ,14 | ,30 | ,00 | ,30 | 4 |
| A3 | ,49 | 4 | ,02 | ,00 | ,11 | ,22 | ,16 | ,22 | 3 |
| A4 | ,57 | 1 | ,00 | ,04 | ,00 | ,00 | ,05 | ,05 | 1 |
| Maks Normalleştirme | | | | | | | | | |
| | $\sum y_i$ | S | R | L | W | P | M | Maks | S |
| A1 | ,84 | 2 | ,19 ^c | ,05 | ,13 | ,20 | ,18 | ,20 | 2 |
| A2 | ,77 | 4 | ,26 | ,11 | ,25 | ,47 | ,00 | ,47 | 4 |
| A3 | ,82 | 3 | ,03 | ,00 | ,19 | ,33 | ,27 | ,33 | 3 |
| A4 | ,97 | 1 | ,00 | ,07 | ,00 | ,00 | ,09 | ,09 | 1 |
| Maks-Min Normalleştirme | | | | | | | | | |
| | $\sum y_i$ | S | R | L | W | P | M | Maks | S |
| A1 | ,44 | 3 | ,75 | ,44 | ,54 | ,43 | ,67 | ,75 | 2 |
| A2 | ,20 | 4 | 1 | 1 | 1 | 1 | ,00 | 1 | 4 |
| A3 | ,47 | 2 | ,13 | ,00 | ,77 | ,71 | 1 | 1 | 3 |
| A4 | ,80 | 1 | ,00 | ,67 | ,00 | ,00 | ,33 | ,67 | 1 |
| Toplam Normalleştirme | | | | | | | | | |
| | $\sum y_i$ | S | R | L | W | P | M | Maks | S |
| A1 | ,25 | 2 | ,06 | ,01 | ,04 | ,07 | ,05 | ,07 | 2 |
| A2 | ,23 | 4 | ,07 | ,03 | ,07 | ,16 | ,00 | ,16 | 4 |
| A3 | ,24 | 3 | ,01 | ,00 | ,05 | ,11 | ,08 | ,11 | 3 |
| A4 | ,28 | 1 | ,00 | ,02 | ,00 | ,00 | ,03 | ,03 | 1 |
| Logaritmik Normalleştirme | | | | | | | | | |
| | \sum | S | R | L | W | P | M | Maks | S |
| A1 | ,25 | 2 | ,00 | ,00 | ,00 | ,02 | ,01 | ,02 | 2 |
| A2 | ,24 | 4 | ,01 | ,00 | ,01 | ,07 | ,00 | ,07 | 4 |
| A3 | ,25 | 3 | ,00 | ,00 | ,00 | ,04 | ,02 | ,04 | 3 |
| A4 | ,26 | 1 | ,00 | ,00 | ,00 | ,00 | ,01 | ,01 | 1 |

S: Sıra, (a) - |,46 - ,56 (Maksimum değer)| = ,10, (b) - |,50 - ,53| = ,03, (c) - |,81 - 1| = ,19

Tablo 7. TOPSIS - Vektör Normalleştirilmesi (TOPSIS Vector Normalization)

| | R | L | W | P | M |
|-------|------------------|------|------|------|------|
| A1 | ,09 ^a | ,10 | ,10 | ,10 | ,09 |
| A2 | ,08 | ,10 | ,09 | ,07 | ,11 |
| A3 | ,11 | ,11 | ,09 | ,09 | ,08 |
| A4 | ,11 | ,10 | ,12 | ,13 | ,10 |
| w_i | ,200 | ,201 | ,200 | ,198 | ,200 |
| P^i | ,11 | ,11 | ,12 | ,13 | ,11 |
| N^i | ,08 | ,10 | ,09 | ,07 | ,08 |

P^i, N^i =Positif İdeal ve Negatif ideal, (a) - $(w_1)_{20} \times ,46 = ,092$

normalleştirme tekniği karar vektörü Maks-Min normalleştirme tekniği kullanılarak tekrar normalize edilir. Daha önce belirtildiği gibi, Maks-Min normalleştirme tekniği kullanılmasının sebebi tüm yöntemlerin farklı normalleştirme teknikleri ile yaptığı sıralama vektörlerini sıfır (0)- bir (1) aralığına yayılmasıdır. Bu tüm sıralama vektörlerini toplanabilir vektörler haline getirecektir. Elde edilen normalize seçim vektörleri kullanılarak Tablo 23 hazırlanır. Tabloda her bir ÇKKVY için normalleştirme tekniklerinden elde edilen kümülatif ağırlık toplamları sunulmaktadır. Tablo değerleri her bir seçeneğin ilgili ÇKKVY'nde uygulanan normalleştirme yöntemlerinden aldığı tartıların toplam değerleri olarak belirlenir. Örnek olarak AHS A1 1. Sıra ortalama tartı 0,764962 ve 2. Sıra tartısı 1,550254 olarak belirlenmiştir. Bu değerler her bir normalleştirme tekniğinden aynı sıra için aldığı seçim vektörü tartıları toplamı alınarak bulunmuştur. AHS için yapılan Maks-Min seçim vektörü normalleştirilmesi Tablo 16'de görülmektedir. TOPSIS Vektör normalleştirilmesi için hazırlanan Tablo 17'de $S^i/(S^*+S^i)$ kolonu

sıralamayı belirleyen kolondur ve Maks-Min normalleştirme tekniği ile tartılar belirlenmiştir. Tablo vektör normalleştirilmesi için örnek olarak sunulmuştur ve aynı işlem tüm normalleştirmeler için yürütülmüştür.

VIKOR yönteminde seçim minimum sapmaya göre yapıldığı için, Tablo 18'da görüldüğü gibi $(1 - |Q|)$ değerleri maksimum değerden çıkarılmış ve elde edilen değerler, Maks-Min normalleştirilmesi ile normalleştirilip tartılar elde edilmiştir. Aynı işlem MOORA için de yürütülmüştür (Tablo 19). PROMETHEE için yürütülen işlem Tablo 20'da görülmektedir. Burada farkların minimumundan sapma değerlerinin Maks-Min normalleştirmeye göre normalleştirilmesi yapılarak ağırlıklar belirlenmiştir.

Bu işlemlerden sonra AHS, TOPSIS, VIKOR, MOORA ve PROMETHEE sıralama tartıları toplanabilir, normalleştirilmiş değerlerlerdir ve Tablo 24'de görülen toplam sıralama

Tablo 8. TOPSIS-Vektör Normalleştirilmesi için İdeallerden Sapmalar (Deviations from Ideals for TOPSIS-Vector Normalization)

| Pozitif İdeallerden Sapmalar | | | | | | | |
|------------------------------|--------------------|--------------------|-------|--|-------|----------|-----------------|
| | R | L | W | P | M | Σ | $\sqrt{\Sigma}$ |
| A1 | ,0005 ^a | ,0000 ^b | ,0002 | ,0007 | ,0004 | ,0 | ,08 |
| A2 | ,0008 | ,0001 | ,0008 | ,0036 | ,0000 | ,01 | ,17 |
| A3 | ,0000 | ,0000 | ,0005 | ,0018 | ,0010 | ,02 | ,12 |
| A4 | ,0000 | ,0001 | ,0000 | ,0000 | ,0001 | 0 | ,01 |
| Negatif İdeallerden Sapmalar | | | | | | | |
| | R | L | W | P | M | Σ | $\sqrt{\Sigma}$ |
| A1 | ,0001 | ,0000 | ,0002 | ,0012 | ,0001 | ,0016 | ,0394 |
| A2 | ,0000 | ,0000 | ,0000 | ,0000 | ,0010 | ,0010 | ,0314 |
| A3 | ,0007 | ,0001 | ,0000 | ,0003 | ,0000 | ,0011 | ,0334 |
| A4 | ,0008 | ,0000 | ,0008 | ,0036 | ,0004 | ,0057 | ,0756 |
| | (S^*+S') | $S'/(S^*+S')$ | S | | | | |
| A1 | ,08 | ,48 | 2 | $(a): (.11 - (P^i))^2 = (.11 - .09)^2 = .0005$ | | | |
| A2 | ,10 | ,30 | 4 | $(b): (.11 - .1)^2 = .000$ | | | |
| A3 | ,09 | ,37 | 3 | | | | |
| A4 | ,09 | ,85 | 1 | | | | |

Tablo 9. TOPSIS-Maks ve Maks-Min Normalleştirmeleri (TOPSIS-Max and Max-Min Normalizations)

| | Maks Normalleştirme | | | | | Maks-Min Normalleştirme | | | | |
|-----------------------------------|---------------------|------|------|------|------|-------------------------|------|------|------|------|
| | R | L | W | P | M | R | L | W | P | M |
| A1 | ,16a | ,16 | ,18 | ,19 | ,16 | ,05 | ,11 | ,10 | ,12 | ,07 |
| A2 | ,14 | ,15 | ,15 | ,12 | ,20 | ,00 | ,00 | ,00 | ,00 | ,20 |
| A3 | ,19 | ,17 | ,16 | ,15 | ,15 | ,16 | ,21 | ,05 | ,06 | ,00 |
| A4 | ,19 | ,16 | ,20 | ,23 | ,18 | ,18 | ,07 | ,21 | ,21 | ,13 |
| wj | ,194 | ,172 | ,203 | ,232 | ,200 | ,183 | ,206 | ,206 | ,205 | ,200 |
| P^i | ,19 | ,17 | ,20 | ,23 | ,20 | ,18 | ,21 | ,21 | ,21 | ,20 |
| N^i | ,14 | ,15 | ,15 | ,12 | ,15 | ,00 | ,00 | ,00 | ,00 | ,00 |
| $(a): .81 \times .194(w_1) = .16$ | | | | | | | | | | |

Tablo 10. TOPSIS: Maks Normalleştirmeden Sapmalar (TOPSIS: Deviations from Max Normalization)

| Pozitif İdeallerden Sapmalar | | | | | | | |
|------------------------------|------------|---------------|-------|-------|-------|----------|-----------------|
| | R | L | W | P | M | Σ | $\sqrt{\Sigma}$ |
| A1 | ,0014 | ,0001 | ,0007 | ,0022 | ,0013 | ,0057 | ,0753 |
| A2 | ,0025 | ,0003 | ,0025 | ,0117 | ,0000 | ,0170 | ,1306 |
| A3 | ,0000 | ,0000 | ,0015 | ,0060 | ,0030 | ,0105 | ,1023 |
| A4 | ,0000 | ,0002 | ,0000 | ,0000 | ,0003 | ,0005 | ,0219 |
| Negatif İdeallerden Sapmalar | | | | | | | |
| | R | L | W | P | M | Σ | $\sqrt{\Sigma}$ |
| A1 | ,0002 | ,0001 | ,0005 | ,0038 | ,0003 | ,0049 | ,0703 |
| A2 | ,0000 | ,0000 | ,0000 | ,0000 | ,0030 | ,0030 | ,0545 |
| A3 | ,0019 | ,0003 | ,0001 | ,0010 | ,0000 | ,0033 | ,0579 |
| A4 | ,0025 | ,0000 | ,0025 | ,0117 | ,0013 | ,0181 | ,1344 |
| | (S^*+S') | $S'/(S^*+S')$ | | | S | | |
| A1 | ,15 | | | | ,48 | 2 | |
| A2 | ,19 | | | | ,29 | 4 | |
| A3 | ,16 | | | | ,36 | 3 | |
| A4 | ,16 | | | | ,86 | 1 | |

ağırlıklandırmasını oluşturabiliriz. Örnek olarak Tablo 23'ü kullanarak A1 seçeneğine 2. Sıra toplam ağırlığı AHS, TOPSIS, VIKOR, MOORA ve PROMETHEE sırasıyla, toplam =,313028 + ,193339 + ,271897 + ,270478 + ,248888=1,29763 olarak bulunur. Diğer tablo değerleri aynı şekilde hesaplanır.

Tablo 22 ve Tablo 24 kullanılarak, her senaryo için optimizasyon modelleri formüle edilebilir. Her ne kadar sonuç tablodan net bir şekilde görülüyor olsa da büyük hacimli problemlerde sonuç bu denli net görülemez. Bu sebeple doğrusal atama optimizasyonu modeli kurulması her zaman fayda sağlayacaktır.

5.2. Oy Sayısına Göre Optimum Grup Kararı Modeli (Optimum Group Decision Model Based on Number of Votes)

Aşağıda sunulan model Tablo 22'de görülen toplam oylamayı optimize ederek en ideal sıralamayı belirler. Eş. 37 Tercih toplamını maksimize eden amaç denklemdir. Eş. 38 bir sıraya yalnız ve yalnız bir atama yapılabileceğini ve Eş. 39 ise bir tercihin mutlaka bir sıraya atanacağını ifade eden kısıtlardır.

$$\text{Maks } Z = \sum_{i=1}^4 \sum_{j=A1}^{A4} V_{ij} X_{ij} \quad (37)$$

Tablo 11. TOPSIS: Maks-Min Normalleştirme-İdeallerden Sapmalar (TOPSIS: Max-Min Normalization-Deviations from Ideals)

| Pozitif İdealden Sapmalar | | | | | | | |
|---------------------------|------------|---------------|-----|-----|-----|----------|-----------------|
| | R | L | W | P | M | Σ | $\sqrt{\Sigma}$ |
| A1 | ,02 | ,01 | ,01 | ,01 | ,02 | ,06 | ,25 |
| A2 | ,03 | ,04 | ,04 | ,04 | ,00 | ,16 | ,40 |
| A3 | ,00 | ,00 | ,03 | ,02 | ,04 | ,09 | ,29 |
| A4 | ,00 | ,02 | ,00 | ,00 | ,00 | ,02 | ,15 |
| Negatif İdealden Sapmalar | | | | | | | |
| | R | L | W | P | M | Σ | $\sqrt{\Sigma}$ |
| A1 | ,00 | ,01 | ,01 | ,01 | ,00 | ,04 | ,21 |
| A2 | ,00 | ,00 | ,00 | ,00 | ,00 | ,04 | ,20 |
| A3 | ,03 | ,04 | ,00 | ,00 | ,00 | ,07 | ,27 |
| A4 | ,03 | ,00 | ,04 | ,04 | ,02 | ,14 | ,37 |
| | (S^*+S') | $S'/(S^*+S')$ | S | | | | |
| A1 | ,46 | ,45 | 3 | | | | |
| A2 | ,60 | ,33 | 4 | | | | |
| A3 | ,57 | ,48 | 2 | | | | |
| A4 | ,53 | ,71 | 1 | | | | |

Tablo 12. TOPSIS: Toplam Normalleştirme(TOPSIS: Total Normalization)

| | R | L | W | P | M |
|-------|------|------|------|------|------|
| A1 | ,05 | ,05 | ,05 | ,05 | ,05 |
| A2 | ,04 | ,05 | ,04 | ,04 | ,06 |
| A3 | ,06 | ,05 | ,05 | ,04 | ,04 |
| A4 | ,06 | ,05 | ,06 | ,07 | ,05 |
| w_j | ,200 | ,201 | ,200 | ,199 | ,200 |
| P_j | ,06 | ,05 | ,06 | ,07 | ,06 |
| N_j | ,04 | ,05 | ,04 | ,04 | ,04 |

Tablo 13. TOPSIS: Toplam Normalleştirme için Sapmalar (TOPSIS: Deviations for Total Normalization)

| Pozitif İdealden Sapmalar | | | | | | | |
|---------------------------|------------|---------------|-------|-------|-------|----------|-----------------|
| | R | L | W | P | M | Σ | $\sqrt{\Sigma}$ |
| A1 | ,0001 | ,0000 | ,0001 | ,0002 | ,0001 | ,0005 | ,0218 |
| A2 | ,0002 | ,0000 | ,0002 | ,0010 | ,0000 | ,0014 | ,0376 |
| A3 | ,0000 | ,0000 | ,0001 | ,0005 | ,0002 | ,0009 | ,0294 |
| A4 | ,0000 | ,0000 | ,0000 | ,0000 | ,0000 | ,0000 | ,0065 |
| Negatif İdealden Sapmalar | | | | | | | |
| | R | L | W | P | M | Σ | $\sqrt{\Sigma}$ |
| A1 | ,0000 | ,0000 | ,0000 | ,0003 | ,0000 | ,0004 | ,0202 |
| A2 | ,0000 | ,0000 | ,0000 | ,0000 | ,0002 | ,0002 | ,0158 |
| A3 | ,0002 | ,0000 | ,0000 | ,0001 | ,0000 | ,0003 | ,0169 |
| A4 | ,0002 | ,0000 | ,0002 | ,0010 | ,0001 | ,0015 | ,0386 |
| | (S^*+S') | $S'/(S^*+S')$ | R | | | | |
| A1 | ,04 | ,48 | 2 | | | | |
| A2 | ,05 | ,30 | 4 | | | | |
| A3 | ,05 | ,37 | 3 | | | | |
| A4 | ,05 | ,86 | 1 | | | | |

Tablo 14. TOPSIS: Logaritmik Normalleştirme(TOPSIS: Logarithmic Normalization)

| | R | L | W | P | M |
|-------|-----|-----|-----|-----|-----|
| w_j | ,20 | ,20 | ,20 | ,20 | ,20 |
| A1 | ,05 | ,05 | ,05 | ,05 | ,05 |
| A2 | ,05 | ,05 | ,05 | ,04 | ,05 |
| A3 | ,05 | ,05 | ,05 | ,05 | ,05 |
| A4 | ,05 | ,05 | ,05 | ,06 | ,05 |
| P^j | ,05 | ,05 | ,05 | ,06 | ,05 |
| N^j | ,05 | ,05 | ,05 | ,04 | ,05 |

Tablo 15. TOPSIS: Logaritmik Normalleştirme- Sapmalar (TOPSIS: Logarithmic Normalization - Deviations)

| Pozitif İdealden Sapmalar | | | | | | | |
|---------------------------|---------|------------|-------|-------|-------|-------|-----------------|
| | R | L | W | P | M | Σ | $\sqrt{\Sigma}$ |
| A1 | ,0000 | ,0000 | ,0000 | ,0000 | ,0000 | ,0000 | ,0054 |
| A2 | ,0000 | ,0000 | ,0000 | ,0002 | ,0000 | ,0002 | ,0130 |
| A3 | ,0000 | ,0000 | ,0000 | ,0001 | ,0000 | ,0001 | ,0093 |
| A4 | ,0000 | ,0000 | ,0000 | ,0000 | ,0000 | ,0000 | ,0013 |
| Negatif İdealden Sapmalar | | | | | | | |
| A1 | ,0000 | ,0000 | ,0000 | ,0001 | ,0000 | ,0001 | ,0085 |
| A2 | ,0000 | ,0000 | ,0000 | ,0000 | ,0000 | ,0000 | ,0041 |
| A3 | ,0000 | ,0000 | ,0000 | ,0000 | ,0000 | ,0000 | ,0047 |
| A4 | ,0000 | ,0000 | ,0000 | ,0002 | ,0000 | ,0002 | ,0133 |
| | (S*+S') | S'/(S*+S') | S | | | | |
| A1 | ,01 | ,61 | 2 | | | | |
| A2 | ,02 | ,24 | 4 | | | | |
| A3 | ,01 | ,34 | 3 | | | | |
| A4 | ,01 | ,91 | 1 | | | | |

Tablo 16. Vektör normalleştirme için AHS Seçim Tartlandırması (AHP Selection Weighing for vector normalization)

| Seçim Vektörü | | |
|----------------|----|--------------------|
| qi | Si | (qi-Max)/(Max-Min) |
| ,393261549 | 2 | ,3857568 |
| ,365462631 | 3 | ,298008646 |
| ,271052466 | 4 | 0 |
| ,587855909 | 1 | 1 |
| Max=,587855909 | | |
| Min=,271052466 | | |

Tablo 17. Vektör normalleştirme için TOPSIS Seçim Tartlandırması (TOPSIS Selection Weighing for vector normalization)

| Seçim Vektörü | | | |
|---------------|------------|----|-------------------------|
| (S*+S') | S'/(S*+S') | Si | Maks-Min Normalleştirme |
| ,09 | ,40 | 2 | ,207144398 |
| ,12 | ,46 | 4 | ,313556513 |
| ,10 | ,30 | 3 | 0 |
| ,09 | ,80 | 1 | 1 |
| | Max = ,80 | | |
| | Min = ,30 | | |

$$\sum_{i=1}^4 X_{ij} = 1, \forall j = \{A1, A2, A3, A4\} \quad (38)$$

$$\sum_{j=A1}^{A4} X_{ij} = 1, \forall i = \{1,2,3,4\} \quad (39)$$

X_{ij} : Seçenek j sıra i. Sıraya atanmışsa bir değilse sıfır değeri alır, $i=\{1,2,3,4\}$, $j=\{A1, A2, A3, A4\}$,
 V_{ij} : Seçenek j sıra i. Sıra için verilen toplam oy,

Eş. 38'in örneğimiz için yazılmış formu Eş. 40'da görülmektedir. Benzer şekilde Eş. 41-Eş. 44, sırasıyla, 1. 2., 3. ve 4. sıraya A1, A2, A3 ve A4 seçeneklerinden birinin atanacağını ifade eder.

$$\text{Maks } Z = x_{1,A1} + 24x_{1,A4} + 22x_{2,A1} + x_{2,A2} + 2x_{2,A3} + 2x_{3,A1} + 21x_{3,A2} + x_{3,A3} + x_{3,A4} + 3x_{4,A2} + 22x_{4,A3} \quad (40)$$

$$x_{1,A1} + x_{1,A2} + x_{1,A3} + x_{1,A4} = 1 \quad (41)$$

$$x_{2,A1} + x_{2,A2} + x_{2,A3} + x_{2,A4} = 1 \quad (42)$$

$$x_{3,A1} + x_{3,A2} + x_{3,A3} + x_{3,A4} = 1 \quad (43)$$

$$x_{4,A1} + x_{4,A2} + x_{4,A3} + x_{4,A4} = 1 \quad (44)$$

Eş. 39'in örneğimiz için yazılmış formu Eş. 45-Eş. 48'de görülmektedir. Eşitlikler sırasıyla, A1, A2, A3 ve A4'ün bir sıraya atanacağını ifade eder. Eş. 49 değişkenlerin sıfır ya da bir değeri alabileceğini gösterir.

$$x_{1,A1} + x_{2,A1} + x_{3,A1} + x_{4,A1} = 1 \quad (45)$$

$$x_{1,A2} + x_{2,A2} + x_{3,A2} + x_{4,A2} = 1 \quad (46)$$

$$x_{1,A3} + x_{2,A3} + x_{3,A3} + x_{4,A3} = 1 \quad (47)$$

$$x_{1,A4} + x_{2,A4} + x_{3,A4} + x_{4,A4} = 1 \quad (48)$$

$$\forall X_{ij} \in \{0,1\} \quad (49)$$

Modelin çözümünden $x_{1,A4}=x_{2,A1}=x_{3,A2}=x_{4,A3}=1$ sonucu elde edilir. Bu sonuç bize optimum sıralamayı A4-A1-A2-A3 olarak verir.

5.3. Grup Ağırlık Optimum Kararı Modeli (Group Weight Optimum Decision Model)

Bölüm 6.1'de sunulan amaç fonksiyonu, seçimlerin sıralamasını maksimize etmektedir. Benzer şekilde, seçenekleri sıralamalara toplam ağırlığı maksimize edecek şekilde atamak için alternatif bir hedef fonksiyonu formüle edilebilir. Amaç fonksiyonu, Tablo 24 kullanılarak, aşağıda şekilde yazılır;

W_{ij} j. Seçeneğin i. Sırada altığı toplam tartıyı göstermek üzere doğrusal atama modeli Eş. 50'de ve problem için yazılmış formu Eş. 5'de görüldüğü şekildedir,

$$\text{Maks } Z = \sum_{i=1}^4 \sum_{j=A1}^{A4} w_{ij} X_{ij} \quad (50)$$

$$\text{Maks } Z = ,764962x_{1,A1} + 11,56043x_{2,A1} + ,621927x_{3,A1} + ,052032x_{2,A2} + 1,699385x_{3,A2} - ,16944x_{4,A2} + ,953394x_{2,A3} + 3,568426x_{3,A3} + ,172807x_{4,A3} + 23,37426x_{1,A4} + ,154899x_{3,A4} \quad (51)$$

Tablo 18. Vektör normalleştirme için VIKOR Seçim Tartlandırması (VIKOR Selection Weighing for vector normalization)

| | Seçim Vektörü | | | 1- IQI | Si | Max-(1- IQI) | Maks-Min Normalleştirme |
|----------|---------------|-----|-------|-------------------|----|--------------|-------------------------|
| | S | R | Q | | | | |
| A1 | ,57 | ,15 | -,58 | ,42 | 2 | 1-,42=,58 | ,57596 |
| A2 | ,80 | ,20 | ,00 | 1,0 | 4 | 1-1=,00 | 0 |
| A3 | ,52 | ,20 | -,24 | ,76 | 3 | 1-,76=,24 | ,240381 |
| A4 | ,20 | ,13 | -1,00 | ,00 | 1 | 1-0=1,00 | 1 |
| Max=1,00 | | | | Max=1,00, Min=,00 | | | |

Tablo 19. Vektör normalleştirme için MOORA Seçim Tartlandırması (MOORA Selection Weighing for vector normalization)

| Seçim Vektörü | | | |
|------------------|------------------|---------|-------------------------|
| Maks Sapma (Msi) | Si | Max-Msi | Maks-Min Normalleştirme |
| ,13 | 2 | ,17 | ,690461 |
| ,30 | 4 | ,00 | 0 |
| ,22 | 3 | ,09 | ,34523 |
| ,05 | 1 | ,25 | 1 |
| Max=,30 | Max=,25, Min=,00 | | |

Tablo 20. Vektör normalleştirme için PROMETHEE Seçim Tartlandırması (PROMETHEE Selection Weighing for vector normalization)

| Seçim Vektörü | | | | | |
|---------------|---------|-----------------------|----|------------------------------|-------------------------|
| N+ | N- | Fark | Si | Max-Fark | Maks-Min Normalleştirme |
| ,121245 | ,132703 | -,01146 | 3 | -,16254-(-,01146)=,151077351 | ,318471466 |
| ,106865 | ,244718 | -,13785 | 2 | -,16254-(-,13785)=,024683014 | ,05203186 |
| ,087151 | ,249686 | -,16254 | 4 | -,16254-(-,16254)=0 | 0 |
| ,331871 | ,020024 | ,311847 | 1 | -,16254-(,311847)=,474382691 | 1 |
| Min=,16254 | | Max=,474382691, Min=0 | | | |

Tablo 21. Grup Kararları (Group Decisions)

| | AHS | TOPSIS | VIKOR | MOORA | PROMETHEE |
|------------|-------------|-------------|-------------|-------------|-------------|
| Vektör | A4-A1-A2-A3 | A4-A1-A2-A3 | A4-A1-A2-A3 | A4-A1-A2-A3 | A4-A2-A1-A3 |
| Toplam | A4-A1-A2-A3 | A4-A1-A2-A3 | A4-A1-A2-A3 | A4-A1-A2-A3 | A4-A1-A2-A3 |
| Maks | A4-A1-A2-A3 | A4-A1-A2-A3 | A4-A1-A2-A3 | A4-A1-A2-A3 | A4-A1-A2-A3 |
| Maks-Min | A4-A1-A2-A3 | A4-A3-A1-A2 | A4-A1-A2-A3 | A4-A1-A2-A3 | A4-A1-A3-A2 |
| Logaritmik | A1-A3-A4-A2 | A4-A1-A2-A3 | A4-A1-A2-A3 | A4-A1-A2-A3 | A4-A1-A2-A3 |

Tablo 22. Sıra Seçimi Kümülatif Oylar (Rank Selection Cumulative Votes)

| | A1 | A2 | A3 | A4 |
|---|----|----|----|----|
| 1 | 1 | 0 | 0 | 24 |
| 2 | 22 | 1 | 2 | 0 |
| 3 | 2 | 21 | 1 | 1 |
| 4 | 0 | 3 | 22 | 0 |

Kısıtlamalar, önceki optimizasyon modelindekiyle aynı kalır. Çözümler, ortaya çıkan sıralamayı A4, A1, A3, A2 (Final-1) olarak verir. Değişken değerleri, X1,A4=X2,A1=X3,A3=X4,A2=1 olarak bulunur.

6. Optimum Sıralamalara Olan Mesafeler (Distances to Optimum Rankings)

Son olarak, her normalleştirme tekniğinin ve her bir ÇKKVY'nin nihai karara olan uzaklığını analiz edelim. Mesafe hesabı, mesafesi ölçülecek olan sıralamada seçeneklerin konumlandığı sıra ile final sıralamada konumlandığı sıra arasındaki farkın mutlak değerleri toplamı olarak belirlenir. Örneğin, logaritmik normalleştirme tekniği ile AHS sıralamasının (A1-A3-A4-A2) nihai karardan (A4-A1-A2-A3) (kümülatif ağırlıklara göre-Final-1) uzaklığı $|2-1|+|3-4|+|4-2|+|1-3|=6$. Benzer şekilde, Final-2 nihai kararına olan mesafe (A4-A1-A2-A3) $|2-1|+|4-4|+|3-2|+|1-3|=4$ olarak belirlenir. Böylece, bir ÇKKV metodun optimum final çözümlerden olan uzaklığını ve her bir normalleştirme tekniğinin optimum final çözümlere olan uzaklığını hesaplayabiliriz. Bu bize fikir birliğine varılmış karara en yakın

ÇKKV metodunu ve en az sapmalı normalleştirme tekniğini tespit etmemizi sağlar.

Tablo 23. ÇKKV Yöntemi Bazında Kümülatif Tartılar (Cumulative Weighings Based on MCDM Method)

| | 1 | 2 | 3 | 4 |
|-----------|----|---------|----------|----------|
| AHS | A1 | ,764962 | 1,550254 | 0 |
| | A2 | 0 | 0 | 1,221289 |
| | A3 | 0 | ,56314 | 0 |
| | A4 | 3,37426 | 0 | ,154899 |
| TOPSIS | A1 | 0 | 1,423057 | ,303455 |
| | A2 | 0 | 0 | 0 |
| | A3 | 0 | ,390255 | ,385247 |
| | A4 | 5 | 0 | 0 |
| VIKOR | A1 | 0 | 3,042404 | 0 |
| | A2 | 0 | 0 | 0 |
| | A3 | 0 | 0 | 1,357928 |
| | A4 | 5 | 0 | 0 |
| MOORA | A1 | 0 | 3,550004 | 0 |
| | A2 | 0 | 0 | 0 |
| | A3 | 0 | 0 | 1,435848 |
| | A4 | 5 | 0 | 0 |
| PROMETHEE | A1 | 0 | 1,994708 | ,318471 |
| | A2 | 0 | ,052032 | ,478096 |
| | A3 | 0 | 0 | ,389402 |
| | A4 | 5 | 0 | 0 |

Sıra: A4-A1-A3-A2 (Final-2)

Tablo 24. Kümülatif Toplamlar (Cumulative Totals)

| | 1 | 2 | 3 | 4 |
|----|----------|----------|----------|----------|
| A1 | ,764962 | 11,56043 | ,621927 | 0 |
| A2 | 0 | ,052032 | 1,699385 | -,16944 |
| A3 | 0 | 0,953394 | 3,568426 | 0,172807 |
| A4 | 23,37426 | 0 | ,154899 | 0 |

Tablo 25’de görüldüğü gibi, AHS Final bir çözümünden sadece Logaritmik normalleştirme tekniğinde sapmıştır ve sapma miktarı altıdır (6). Diğer normalleştirme tekniklerinde sapmadığı için toplam sapma altıdır. TOPSIS ve PROMETHEE’nin toplam sapma miktarı dörttür ve MOORA ve VIKOR’da yöntemlerde sapma sıfırdır. Aynı işlemi Final-2 çözümüne olan mesafe için yürütecek olursak, A4-A1-A2-A3 sıralaması sapması 2, A1-A3-A4-A2 sıralaması sapması 4 olarak hesaplanır ve aynı işlem tüm sıralamalar için tekrarlanır. Hesaplama TOPSIS, VIKOR, MOORA ve PROMETHEE için sırasıyla 12, 10, 12, 12, ve 14 olarak elde edilir. Her bir ÇKKV yöntemi için elde edilen Final-1 ve Final-2’den toplam sapmaları Tablo 25’de görülmektedir. Mesafe hesapları ÇKKV yöntemi bazında yapıldığı gibi, normalleştirme tekniği bazında da yürütülür. Sonuçlar Tablo 25 ikinci bölümünde görülmektedir.

AHS’nin her iki nihai karardan toplam uzaklığı yüksektir. Bunun sebebi Logaritmik normalleştirme tekniğindeki yüksek sapmadır. Buradan Final-1 çözümü tüm yöntemlerin en yakın olduğu çözümdür ve MOORA ve VIKOR bunu sıfır sapma ile sağlamıştır. Normalleştirme tekniklerinin sapmalarını hesapladığımızda ise; Vektör normalleştirme Final-1’den 2 ve Final-2’den 12 birim sapmaktadır. Tüm sapma değerleri Tablo 25’de görülmektedir. Hem ÇKKV yöntemi hem de normalleştirme teknikleri örtüştürüldüğünde ideal çözümü VIKOR maksimum normalleştirme tekniği ile Final-1 çözümünde vermektedir.

Tablo 25. Normalleştirme Teknikleri Optimum Karar Mesafeleri (Normalization Techniques Optimum Decision Distances)

| | Final-1 | Final-2 | | Final-1 | Final-2 |
|-----------|---------|---------|-----------|---------|---------|
| AHS | 6 | 12 | Vektör | 2 | 12 |
| TOPSIS | 4 | 10 | Toplam | 2 | 12 |
| VIKOR | 0 | 12 | Maks | 0 | 10 |
| MOORA | 0 | 12 | Maks-Min | 4 | 11 |
| PROMETHEE | 4 | 14 | Logaritma | 6 | 12 |
| Σ | 14 | 60 | | 14 | 67 |

Tablodan Final-1’in tüm ÇKKVY ile en uyumlu çözüm olduğu, diğer bir ifadeyle çözümün ÇKKVY ile en yüksek fikir birliğine sahip olduğu görülmektedir.

7. Sonuçlar ve Tartışmalar (Results and Discussions)

Bu çalışmada, ÇKKVY’nin farklı normalleştirme teknikleriyle seçim sıralamalarını çoklamak ve çoklanmış seçim vektörlerini grup karar teknikleriyle birleştirerek en yüksek katılımın sağlandığı seçim vektörünü diğer bir ifadeyle seçimler sıralamasını belirlemektir. Yaklaşımın arkasındaki ana fikir, normalleştirme tekniklerinin ve ÇKKVY’lerinin normalleştirme tekniklerine olan duyarlılıklarının kararlar üzerindeki etkisini en aza indirmek ve nihai karar üzerinde güçlü bir fikir birliği oluşturmaktır.

Veri kümemizde, AHS dışında çoğu ÇKKVY için normalleştirme yöntemleri arasında gözlemlenen önemli bir fark olmadığı görülmüştür. Kümülatif ağırlık maksimizasyonuna dayalı nihai karardan olan mesafeler incelendiğinde, AHS’nin örnekte kullanılan diğer yöntemlere kıyasla logaritmik normalleştirme yöntemine daha

duyarlı olduğu görülmüştür. Bu nedenle, bir veri seti için, logaritmik normalleştirme tekniği, veri seti özelliklerinin etkisini vurgulayarak AHS aracılığıyla daha anlamlı sonuçlar sağladığı için uygun olabileceği görülmektedir. Öte yandan, VIKOR ve MOORA, özellikle yakın kümelenmiş değerler içeren bir veri kümesiyle uğraşırken, normalleştirme tekniklerinin seçiminden daha az etkilenmiş görülmektedir.

Burada önerilen yöntem, çeşitli normalleştirme tekniklerinden elde edilen cevapları birleştirerek karar anlaşmasını geliştirmeyi amaçlamaktadır. Bu, her bir tekniğe hesaplanmış ağırlıklar atanarak, çok sayıda seçeneğe sahip daha büyük vakalarda geniş çapta yayılmış kararları etkili bir şekilde bir araya getirerek elde edilir. Ancak iki farklı grup karar verme optimizasyon yönteminin varlığından dolayı iki farklı optimal karar sırası elde etmek mümkündür. Bunu tek bir uygulanabilir karara indirgemek, ÇKKVY’nin sıralamalarına minimum mesafeli karar seçilerek belirlenir, böylece genel belirsizlik azaltılır.

Kümülatif tartırlarla kurulan optimizasyon modeli, değerlerin sürekli olması sebebiyle, komşu sıralamalarda bir geçişkenlik doğurmuştur (Final-2). Oysa, sıralama problemleri doğası gereği tam sayılıdır ve bir seçenek bir sırada ya bulunur ya da bulunmaz. Bir sıraya atanmanın oy olarak kabul edilerek sayılıp optimize edildiği birinci çözümde (Final-1) bu kesiklileştirmenin nihai karara daha etkin bir şekilde yansıdığı görülmektedir. Bu ÇKKVY’ne ait sonuçların Final-1 ile olan uzaklığının en az olması ile kendini göstermektedir.

Elde edilen optimum karar ile Tablo 25’de en uygun kararın Final-1 sıralaması, problemimiz için en uygun ÇKKV yönteminin VIKOR ve en uygun normalleştirme tekniğinin Maksimum normalleştirme tekniği olduğunu söyleyebiliriz. Bu sonuca dayanarak VIKOR ve maksimum normalleştirme tekniği en uygun ikilidir genellemesini yapamayız, fakat problem bazında böyle bir seçim yapabiliriz. Yöntem farklı teknikler ile yapılan aramada, kriterlerin sayısal değerlerinin matematiksel özelliklerine göre, en güvenilir çözümü veren ÇKKV yöntemi ve normalleştirme tekniğini bulmamıza yardımcı olur. Bu noktada ÇKKV yöntemi ve normalleştirme tekniğini seçim motivasyonunu ters yönde kontrol edebiliriz. Örneğimiz için en iyi çözüm maksimum normalleştirmeden geldiğine göre kriterlerimizin maksimum değere göreceli normalize etmek daha anlamlıdır. Bu aynı şekilde, logaritmik normalleştirme tercihini gerektiren, aşırı uç değerlerin dizide mevcut olması gibi, özelliklerin kriter değerleri kümemizde mevcut olmadığını da gösterir. Benzer, şekilde vektör normalleştirme dikkate aldığı çarpık bir değer setinin olmadığını da gösteren bir sonuçtur.

Literatürde pek çok çalışmada normalleştirme teknikleri ile ÇKKVY ile normalleştirme teknikleri iç içe, tümlü bir yapıda ele alınmıştır [9, 6]. Oysa, AHS, Bulanık AHS ve benzer şekilde diğer hiçbir ÇKKV yöntemi bir tartı belirleme yöntemi değildir. AHS ile yürütülen ağırlıklandırma, esasen AHS’nin de kullandığı özvektör belirlemesidir. Tartı belirleme ve normalleştirme bu yöntemlerin girdisi ve ön adımıdır. Bu çalışmada, ÇKKVY ile normalleştirme teknikleri arasındaki kesin ayrıma dikkat çekilmektedir. Normalleştirme tekniği farklı değer skalasına sahip kriterin alternatifler için oluşturduğu veri dizilerini, birbirleriyle kıyaslanabilir, matematiksel olarak işleme tabi tutularak anlamlı bir normatif değer üretilebilir bir forma getirir. Uygulanacak normalleştirme yöntemini, Bölüm 3’te ele alındığı gibi, belirleyen unsur veri dizisinin karakteristiği ve ilgili kriterin ne ifade ettiği, ÇKKV yönteminin kendisi değildir. Eğer ilgili kriterde marjinal uç değerler varsa, kriter maksimum değeri öne çıkarıyorsa, veri setinde sıralı olmayan düşük ve yüksek dalgalanmalı değerler varsa gibi pek çok özellik seçilecek normalleştirme tekniği hakkında ipucu verir. Fakat uç değer, dalgalanma, maksimum değere verilen önem sayısal

olarak belirlemez. Örnek olarak bir dizide uç değer olarak hangi değeri diğer değerlerden ne ölçüde uzaklaştığında uç değer olarak niteleyebileceğimizin bir sayısal ölçüsü yoktur. Benzer şekilde, seride dalgalanma değeri olarak kullanabileceğimiz, tanımlı, bilinen bir sabit değer veya hesaplanabilir bir standart değer mevcut değildir. Aynı düşünüş normalleştirme tekniklerinden birini seçerek sağladığı faydayı tercih ederken diğerlerinin sağladığı avantajdan vaz geçmenin nedenselliğini izahı için de geçerlidir. Tüm bu tanımlamalar kaniya ve verinin temsil ettiği alana bağlıdır ve hâlâ bir ipucu olmanın ötesine geçememektedir. Bu açıdan çalışmada verilen optimum kararın işaret ettiği veri seti özelliği önemli bir değerlendirme olarak dikkate alınabilir. Çalışmanın bir sonraki adımında, ortaya konan yöntemin işletim performansı ve tutarlılığı hem kriter hem de seçenekler olarak farklı büyüklüklerde hazırlanmış problemlerle test edilecektir. Çalışma kullanıcıların farklı ÇKKVY'ni ve normalleştirme tekniklerini bir yazılım uzantısı (plugin) olarak ekleyebildiği ve ÇKKVY ile normalleştirme tekniklerini eşleyerek probleme, bu çalışmada tanımlanan süreci uygulayıp optimum karar elde edebileceği bir yazılım çerçevesi (framework) geliştirilebilir.

Kaynaklar (References)

1. Palczewski K., Sałabun W., Influence of Various Normalization Methods in PROMETHEE II: An Empirical Study on The Selection of The Airport Location, *Procedia Computer Science*, 159, 2051-2060, 2019.
2. Satıcı S., Farklı Normalizasyon Tekniklerinin Çok Kriterli Karar Verme Yöntemlerine Etkisi: Waspas Örneği, *İşletme Ekonomi ve Yönetim Araştırmaları Dergisi*, 4 (2), 350-361, 2021.
3. Vafaei N., Ribeiro R.A., Camarinha-Matos, L.M., Normalization Techniques for Multi-Criteria Decision Making: Analytical Hierarchy Process Case Study, In *Doctoral Conference on Computing, Electrical and Industrial Systems, DoCEIS 2020: Technological Innovation for Life Improvement*, 43-52, 2020.
4. Çirpi M.E., Sev A., Multi-Criteria Decision Making Model for The Applicability of Additive Manufacturing Technologies In Buildings, *Journal of Gazi University Faculty of Engineering and Architecture*, 37 (4), 1971-1984, 2022.
5. Ertuğrul İ., Özçil A., Çok Kriterli Karar Vermede TOPSIS ve VIKOR Yöntemleriyle Klima Seçimi, *Çankırı Karatekin Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 4 (1), 267-282, 2014.
6. Aktepe A., Ersöz S., Application of Ahp-Vikor and Moora Methods in Storage Location Selection Problem, *Industrial Engineering*, 25, (1), 2-15, 2014.
7. Demir A., Gelen M.B., A New Selection Strategy Proposal for Multi-Objective Genetic Algorithm: Multi-Moora Rank Selection, *Journal of Gazi University Faculty of Engineering and Architecture*, 37 (4), 2119-2132, 2022.
8. Temiz I., Çaltış G., Selection of Construction Equipment by using Multi-Criteria Decision Making Methods, *Procedia Engineering*, 196, 286-293, 2017.
9. Cihan Ş., Ayan E., Eren T., Topal T., Yıldırım E. K., Choosing an Echocardiography Device with Multi-Criteria Decision Making Methods, *Journal of Health Sciences and Professions*, 4 (1), 41-49, 2017.
10. Yılmaz T., Yazıcıoğlu O., Global Supplier Selection with Multi-Criteria Decision-Making Methods: An Application in Automotive Supply Industry, *Journal of Eurasian Social and Economic Research*, 6 (5), 296-307, 2019.
11. Bedir N., Eren T., Personnel Selection Problem with Integration of AHP-PROMETHEE Methods: An Application in Retail Industry, *Journal of Social Sciences Research*, 4 (4), 46-58, 2015.
12. Ayağ Z., Özdemir R. G., Evaluating Machine Tool Alternatives Through Modified Topsis and Alpha-Cut Based Fuzzy ANP, *International Journal of Production Economics*, 140 (2), 630-636, 2012.
13. Saaty T. L., *Decision Making with Dependence and Feedback: The Analytic Network Process*. Pittsburgh, Pennsylvania: RWS Publications., Cornell University, 1996.
14. Özcan İ., İnan U. H., Korkusuz A. Y., Çok Kriterli Karar Verme Yöntemleri ile Metro Şoför Seçimi, *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 15 (3), 1185-1202, 2020.
15. Vatasever K., Akgül Y., Performance Evaluation of Websites Using Entropy and Grey Relational Analysis Methods: The Case of Airline Companies, *Decision Science Letters*, 7 (1), 19-30, 2018.
16. Li H., Wang W., Fan L., Li Q., Chen X., A Novel Hybrid MCDM Model for Machine Tool Selection using Fuzzy DEMATEL, Entropy Weighting and Later Defuzzification VIKOR, *Journal of Applied Soft Computing*, 91, 106207, 2020.
17. Garg H., Agarwal N., Tripathi A., Entropy based Multi-Criteria Decision Making Method Under Fuzzy Environment and Unknown Attribute Weights, *Global Journal of Technology and Optimization*, 6 (3), 2-4, 2015.
18. Özarslan A., Karakaya G., A New Interactive Method for Multi-Criteria Classification Problems: An Application in The Energy Sector, *Journal of Gazi University Faculty of Engineering and Architecture*, 36 (4), 2239-2254, 2021.
19. He D., Xu J., Chen X., Information-Theoretic-Entropy Based Weight Aggregation Method in Multiple-Attribute Group Decision-Making, *Entropy*, 18 (6), 2-13, 2016.
20. Jahan A., Edwards K. L., A State-Of-The-Art Survey on The Influence of Normalization Techniques in Ranking: Improving the Materials Selection Process in Engineering Design, *Materials and Design*, 65, 335-342, 2015.
21. Çelen A., Comparative Analysis of Normalization Procedures in TOPSIS Method: With an Application to Turkish Deposit Banking Market, *Informatica*, 25 (2), 185-208, 2014.
22. Pavlicic D., Normalization Affects the Results of MADM Methods, *Yugoslav Journal of Operations Research*, 11 (2), 251-265, 2001.
23. Mhlanga S. T., Lall M., Influence of Normalization Techniques on Multi-criteria Decision-Making Methods, *J. Phys.: Conf. Ser.*, 2224 (1), 1-12, 2022.
24. Xu Z., Chen Q., A Multi-Criteria Decision Making Procedure Based On Interval-Valued Intuitionistic Fuzzy Bonferroni Means, *Journal of Systems Science and Systems Engineering*, 20 (2), 217-228, 2011.
25. Otay İ., Intuitive Fuzzy Multi-Temporal and Multi-Criteria Decision-Making Methodology: An Application in The Healthcare Sector, *Journal of Gazi University Faculty of Engineering and Architecture*, 37 (2), 1047-1062, 2022.
26. Saaty T. L., *The Analytic Hierarchy Process*. New York, 1980.
27. Özveri O., Güçlü P., Değer Akış Haritalamada Analitik Hiyerarşi Süreci (AHP) Uygulanması, *Uluslararası Alanya İşletme Fakültesi Dergisi*, 7 (1), 1-12, 2015.
28. Saaty T.L., How to Make a Decision: The Analytic Hierarchy Process, *European Journal of Operational Research*, 48, 9-26, 1990.
29. Hwang L., Yoon K., *Multiple Attribute Decision Making: Methods and Applications*. New York: Springer-Verlag, 1981.
30. Yoon K., A Reconciliation Among Discrete Compromise Situations, *Journal of the Operational Research Society*, 38 (3), 277-286, 1987.
31. Şahin M., Çok Kriterli Karar Verme Yöntemleri. Nobel, 2022.
32. Regulwar D. G., Anand P., Multiobjective Optimization in River Basin Development, *Water Resources Research*, 16 (1), 14-20, 1980.
33. Çelikbilek Y., Çok Kriterli Karar verme Yöntemleri. Nobel, 2018.
34. Brans J. P., *L'ingénierie de la décision; Elaboration d'instruments d'aide à la décision. La méthode PROMETHEE in L'aide à la décision: Nature, Instruments et Perspectives d'Avenir*. Quebec: Presses de l'Université Laval, 1982.
35. Brans J. P., Vincke P., A Preference Ranking Organisation Method: The PROMETHEE Method for MCDM, *Management Science*, 31 (6), 647-656, 1985.
36. Chen C., A Novel Multi-Criteria Decision-Making Model for Building Material Supplier Selection Based on Entropy-AHP Weighted TOPSIS, *Entropy*, 22 (259), 1-23, 2020.
37. Hwang C.-L., Lin M.-J., *Group Decision Making under Multiple Criteria*. Springer, 1987.