

Haziran, 2026

ENDÜSTRİ MÜHENDİSLİĞİ ALANINDA TEORİ VE UYGULAMALAR

EDİTÖR

DR. ÖĞR. ÜYESİ MEHMET CABİR AKKOYUNLU

DOI:10.5281/zenodo.21188377

Endüstri Mühendisliđi Alanında Teori ve Uygulamalar

Editör

Dr. Öğr. Üyesi Mehmet Cabir Akkoyunlu

İmtiyaz Sahibi
Platanus Publishing®

Editör
Dr. Öğr. Üyesi Mehmet Cabir Akkoyunlu
Kapak & Mizanpaj & Sosyal Medya
Platanus Yayın Grubu

Birinci Basım
Haziran, 2026

Yayımcı Sertifika No
45813

ISBN
978-625-8713-32-7

©copyright
Bu kitabın yayım hakkı Platanus Publishing'e aittir. Kaynak gösterilmeden alıntı yapılamaz, izin alınmadan hiçbir yolla çoğaltılamaz.

Adres: Natoyolu Cad. Fahri Korutürk Mah. 157/B, 06480, Mamak,
Ankara, Türkiye.


Telefon: +90 312 390 1 118
web: www.platanuspublishing.com
e-mail: platanuskita@gmail.com



Platanus Publishing®

İÇİNDEKİLER

BÖLÜM 1.....	5
Pestisitlerin Çok Boyutlu Özelliklerine Göre Kümeleme Analizi ile Sınıflandırılması: K-Prototypes, K-Modes ve Two-Step Algoritmalarının Karşılaştırmalı Uygulaması	
Senem Baybaş & Canefşan Alan & Ezgi Güler	
BÖLÜM 2.....	29
Stratejik Ham Maddelerin Dış Ticaret Trendleri Analizi	
Şahika Ercan & Elifcan Göçmen Polat	
BÖLÜM 3.....	51
Statistics-Driven Decision Modeling For Earthquake Damage Vulnerability in Disaster Management	
Ezgi Güler	
BÖLÜM 3.....	69
A Picture Fuzzy MEREC-AROMAN Model for Selecting the Maintenance Policy of Ship Main Engines	
Doğan Şengül & Mahmut Emin Sarıkaya	



Pestisitlerin Çok Boyutlu Özelliklerine Göre Kümeleme Analizi ile Sınıflandırılması: K-Prototypes, K-Modes ve Two-Step Algoritmalarının Karşılaştırmalı Uygulaması

Senem Baybaş¹ & Caneşan Alan² & Ezgi Güler³

1. Giriş

Tarım ilaçları, yaygın adıyla pestisitler, tarımsal ürünlere zarar veren hastalık ve zararlı etkenleri azaltmak ya da tamamen ortadan kaldırmak amacıyla kullanılan tek bir maddeden veya çeşitli maddelerin karışımından oluşan kimyasal ürünlerdir. Pestisitler; zararlı organizmaların etkisini önlemek, azaltmak, uzaklaştırmak ya da ortadan kaldırmak amacıyla kullanılan kimyasal maddeler veya madde karışımları olarak tanımlanmaktadır. Tarımsal pestisitler ise özellikle gıda üretimi, hasat, taşıma ve depolama süreçlerinde meydana gelebilecek kayıpları en aza indirmek, ürün verim ve kalitesini artırmak amacıyla yaygın biçimde kullanılmaktadır. Fiziksel yapı, etken madde, etki mekanizması, hedef organizma grubu, uygulama yöntemi ve toksisite düzeyi gibi çeşitli kriterlere göre sınıflandırılabilen pestisitler, özellikle hedef alınan zararlı grubuna göre farklı amaçlarla kullanılmaktadır. Bununla birlikte, pestisitler bilinçsiz veya hatalı kullanıldığında çevre ve insan sağlığı açısından ciddi riskler oluşturabilen tehlikeli maddeler arasında yer almaktadır. Doğru dozda ve kontrollü koşullarda uygulandıklarında ise tarımsal üretimde verimliliği artırarak önemli sosyoekonomik faydalar sağlayabilmektedirler (Arslan, 2020).

Son yıllarda tarımsal ürünlerin güvenilirliği ve insan sağlığı üzerindeki olası etkileri konusundaki tartışmalar artmış, tüketiciler güvenli gıdaya erişim

¹ Gazi Üniversitesi, Fen Fakültesi, İstatistik Bölümü
ORCID: 0009-0003-2249-7572

² Bilecik Şeyh Edebali Üniversitesi, Fen Fakültesi, İstatistik ve Bilgisayar Bilimleri Bölümü, ORCID: 0009-0006-6163-931X

³ Dr. Öğr. Üyesi, Bilecik Şeyh Edebali Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü, ORCID: 0000-0001-8789-8244

konusunda daha sorgulayıcı bir tutum benimsemiştir. Sebze ve meyvelerin besleyici değerleri ile fiziksel ve mikrobiyolojik kalite özellikleri önemini korumakla birlikte, bu ürünlerde bulunabilecek pestisit kalıntıları ve çevresel kaynaklı toksik metallerin düzeyi de önemli bir kalite ve güvenlik göstergesi haline gelmiştir. Bu nedenle birçok ülkede maksimum kalıntı limitleri belirlenmiş; söz konusu sınır değerleri aşan ürünlerin tüketime sunulması yasaklanarak sıkı denetim mekanizmaları uygulanmaya başlanmıştır. Bu yaklaşım hem halk sağlığının korunması hem de sürdürülebilir ve güvenilir tarımsal üretimin sağlanması açısından büyük önem taşımaktadır (Velioğlu vd., 2024)

Pestisitler ve bunların bozunma sonucunda ortaya çıkan yan ürünleri, içerdikleri aktif bileşenler nedeniyle çevre ve canlı sağlığı açısından önemli ölçüde toksik özellik gösterebilmektedir. Bazı parçalanma ürünlerinin, başlangıçtaki pestisitten daha dayanıklı ve daha yüksek toksisiteye sahip olduğu bildirilmektedir. Bu maddeler yalnızca hedef zararlıları değil, aynı zamanda doğal düşmanları ve ekosistem açısından yararlı organizmaları da olumsuz etkileyerek ekolojik dengenin bozulmasına ve yeni zararlı salgınlarının ortaya çıkmasına yol açabilmektedir. Çevrede yayılım göstermeleri ve canlı dokularında birikebilmeleri nedeniyle pestisitler ciddi çevresel kirleticiler arasında değerlendirilmektedir. Belirli düzeylerin üzerindeki maruziyetin ise insanlarda kanser, üreme bozuklukları, doğumsal anomaliler, DNA hasarı ve oksidatif stres gibi önemli sağlık problemleriyle ilişkili olduğu ifade edilmektedir. Ayrıca yoğun ve bilinçsiz kullanım, hedef organizmalarda direnç gelişimine neden olarak mücadele etkinliğini azaltmakta ve uygulamaların başarısını düşürmektedir (Salvagni vd., 2011; Sabarwal vd., 2018; Porter vd., 2018; De Souza vd., 2020). Pestisitlerin bazı çeşitleri çevresel koşullarda uzun süre bozulmadan kalabilmektedir. Bu durum, tarımsal alanlarda zararlıların etkili biçimde kontrol altına alınması açısından avantaj sağlasa da çevresel riskleri artırmaktadır. Uygulanan pestisitlerin önemli bir bölümünün hedef bölge dışına taşındığı bilinmektedir. Özellikle yağışlar ve tarımsal sulama faaliyetleri, bu kimyasalların yüzey ve yeraltı su sistemlerine ulaşmasına neden olmaktadır. Su ortamlarına taşınan pestisitler, omurgasız canlılar ile balıkların bünyesinde birikebilmekte; ardından besin zinciri aracılığıyla kuşlara, memelilere ve insanlara kadar ulaşabilmektedir (Wang vd., 2019; Hanedar vd., 2023).

Pestisitler, hem tarımsal verimlilik açısından önemli faydalar sağlamakta hem de yanlış veya bilinçsiz kullanımlarda insan sağlığı ve çevre üzerinde ciddi riskler oluşturabilmektedir. Ayrıca, ürünlerdeki pestisit kalıntıları ve toksik metallerin düzeyi, kalite ve güvenlik açısından kritik göstergeler haline gelmiştir. Bu çok boyutlu ve karmaşık veri yapısı, tek tek ürünleri veya etken maddeleri

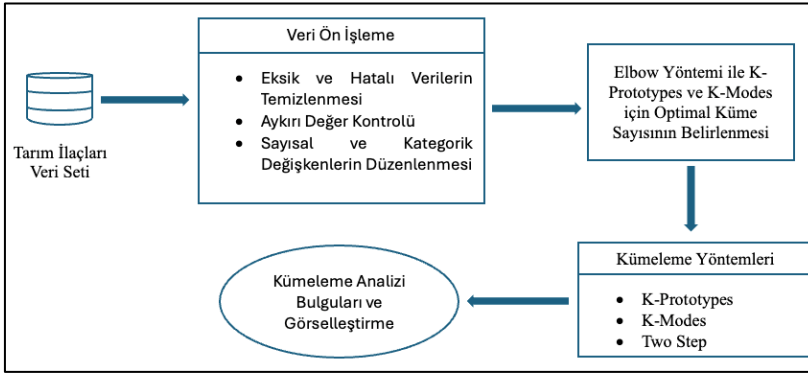
değerlendirmeyi zorlaştırmaktadır. Bu nedenle istatistik biliminin temel konularından biri olan kümeleme analizi, benzer etken maddelere sahip pestisitlerin, hedef zararlılara yönelik ürünlerin ve risk profilleri bakımından birbirine yakın ürünlerin gruplandırılmasını sağlayarak, tarımsal üretimde verimlilik ve güvenliğin artırılmasına, denetim ve karar destek süreçlerinin daha etkin planlanmasına imkân vermektedir. Literatürde de pestisit kullanımını kümeleme analizi ile değerlendiren pek çok çalışma bulunmaktadır. Robu ve diğ. (2023) çalışmalarında, Avrupa Birliği ülkelerinde pestisit kullanımını etkileyen sosyoekonomik faktörler incelemiş ve ülkeleri kümeleme analizi ile benzer özelliklerine göre sınıflandırmışlardır. Çalışmada kişi başına düşen gelir, nüfus ve satış fiyatlarının pestisit kullanımını artırdığı; organik tarım alanları ve sübvansiyonların ise azaltıcı etki gösterdiği belirlenmiştir. Ayrıca kümeleme analizi sonucunda Avrupa Birliği ülkelerinin ekonomik ve demografik özelliklerine göre üç farklı bölgesel grup oluşturduğu ifade edilmiştir. Mei (2024) çalışmasında, pestisitlerin farklı balık türleri üzerindeki toksik etkilerinin belirlenmesi amacıyla in silico modelleme yaklaşımını kullanmıştır. Çalışmada negatif olmayan matris faktörizasyonu (NMF) ve kümeleme yöntemleri aracılığıyla balık türlerinin toksisite profilleri ile filogenetik ilişkileri ve pestisitlerin yapısal özellikleri arasındaki bağlantılar ortaya konmuştur. Ayrıca geliştirilen modelin, farklı balık türleri için yüksek doğrulukla eksik toksisite verilerini tahmin edebildiği belirtilmiştir. Faraj vd. (2024) çalışmalarında, Suudi Arabistan'ın Al-Kharj bölgesindeki tarım topraklarında pestisit kalıntılarını incelemişler ve kalıntı düzeylerine göre örnekleme alanlarını kümeleme analizi yöntemleri ile sınıflandırmışlardır. Çalışmada hiyerarşik kümeleme analizi ve dendrogramlar kullanılarak benzer pestisit profiline sahip bölgeler belirlenmiş, bazı pestisitlerin toprak ve yeraltı su kaynakları açısından önemli çevresel riskler oluşturduğu ortaya konmuştur. Ayrıca sürdürülebilir toprak ve su yönetimi için pestisit kullanımına yönelik politika düzenlemelerinin gerekliliği vurgulanmıştır. Faria ve Raposo (2025) çalışmalarında, Brezilya'da 2011–2019 yılları arasında bildirilen pestisit zehirlenme vakalarını kümeleme analizi yöntemiyle incelenmiştir. Çalışmada, demografik özellikler, maruz kalma türleri ve bölgesel farklılıklara göre üç farklı zehirlenme kümesi belirlenmiş; özellikle intihar girişimleri, çocukluk çağı kazaları ve mesleki maruziyetlerin öne çıktığı ifade edilmiştir. Elde edilen bulguların, pestisit kaynaklı sağlık risklerinin azaltılması amacıyla bölgesel halk sağlığı politikaları ve daha sıkı pestisit düzenlemeleri geliştirilmesine katkı sağlayabileceği belirtilmiştir. (Li vd., 2025) çalışmalarında, pestisit kalıntılarının tespiti amacıyla nanozim tabanlı kolorimetrik sensör dizisi ile derin öğrenme yaklaşımı bir arada kullanmışlardır. Çalışmada, amino asitler ve bakır iyonlarından sentezlenen nanozimler aracılığıyla yedi farklı pestisit kalıntısının yüksek hassasiyetle kümelenmesi ve tespiti gerçekleştirilmiş,

YOLOv8 algoritması sayesinde oldukça yüksek doğruluk oranlarına ulaşılmıştır. Elde edilen sonuçların, karmaşık ortamlarda hızlı ve güvenilir pestisit kalıntısı tespitine önemli katkılar sağlayabileceği ifade edilmiştir.

Literatürde yer alan çalışmalar incelendiğinde, pestisitlere yönelik kümeleme analizlerinin çoğunlukla belirli bir problem alanına odaklandığı görülmektedir. Mevcut çalışmalar genellikle pestisit kalıntılarının çevresel etkileri, toksisite düzeyleri, bölgesel kullanım farklılıkları veya sağlık etkileri üzerine yoğunlaşmış; kullanılan veri yapıları çoğunlukla yalnızca sayısal ya da yalnızca kategorik değişkenlerle sınırlandırılmıştır. Ayrıca tarım ilaçlarının aktif madde, hedef organizma, formülasyon tipi, kullanım amacı ve toksisite sınıfı gibi çok boyutlu özelliklerini birlikte değerlendiren bütüncül kümeleme çalışmalarının sınırlı olduğu dikkat çekmektedir. Özellikle resmi kurum verileri kullanılarak hem sayısal hem de kategorik değişkenlerin aynı model yapısı içerisinde analiz edildiği karşılaştırmalı kümeleme uygulamalarına literatürde yeterince rastlanmamaktadır. Bu çalışma, söz konusu literatür boşluğunu doldurmayı amaçlamaktadır. Çalışmada, T.C. Tarım ve Orman Bakanlığı Bitki Koruma Ürünleri Daire Başkanlığı tarafından sağlanan gerçek tarım ilacı verileri kullanılarak pestisitler çok boyutlu özelliklerine göre analiz edilmiştir. Ayrıca farklı veri tiplerine uygun olarak K-Modes, K-Prototypes ve Two-Step kümeleme algoritmalarının birlikte uygulanması sayesinde hem yöntemsel hem de uygulama açısından kapsamlı bir değerlendirme sunulmuştur. Böylece tarım ilaçlarının benzer özelliklerine göre sınıflandırılması, karar destek süreçlerinin geliştirilmesi, risk gruplarının belirlenmesi ve sürdürülebilir pestisit yönetimine katkı sağlayabilecek bütüncül bir yaklaşım ortaya konulmuştur. Elde edilen bulguların hem sayısal hem de kategorik veriler dikkate alınarak oluşturulan kümeler ile güvenilir ve anlamlı sonuçlara ulaşılması beklenmektedir. Bu bağlamda, tarım ilaçları arasında belirgin farklılıklar ortaya koymak ve bu sayede ilaçların tarımsal üretimde zararlı ve hastalık etmenlerine karşı kullanımının etkisinin maksimize edilmesi gibi faydalar sağlamak amaçlanmaktadır.

2. Materyal ve Metod

Bu çalışmada; tarım ilaçları verileri, kümeleme analizi algoritmaları ile değerlendirilmektedir. Çalışmanın genel iş akışı, Şekil 1'de şematik olarak sunulmuştur.



Şekil 1. Tarım İlaçlarının Gruplandırılmasında Farklı Kümeleme Yöntemlerinin Uygulanması İş Akış Diyagramı

Şekil 1'e göre çalışma süreci, tarım ilaçları verilerinin elde edilmesi ile başlamaktadır. İlk aşamada tarım ilacı verileri elde edilmiştir. Ardından veri ön işleme adımı gerçekleştirilmiş; eksik veya tutarsız veriler kontrol edilerek veri seti kümeleme analizine uygun hale getirilmiştir. Bu aşamada özellikle sayısal ve kategorik değişkenlerin analiz sürecine uygun biçimde düzenlenmesine dikkat edilmiştir. Bir sonraki aşamada, K-Prototypes ve K-Modes algoritmaları için optimum küme sayısının belirlenmesi amacıyla Elbow yöntemi uygulanmıştır. Elbow yöntemi sayesinde farklı küme sayıları için oluşan hata değerleri değerlendirilmiş ve veri yapısını en iyi temsil eden küme sayısı belirlenmiştir. Böylece kümeleme performansının artırılması ve daha anlamlı kümelerin elde edilmesi amaçlanmıştır. Optimum küme sayısının belirlenmesinin ardından kümeleme yöntemleri uygulanmıştır. Çalışmada hem sayısal hem kategorik değişkenleri birlikte değerlendirebilen K-Prototypes algoritması, yalnızca kategorik verilerin analizine uygun olan K-Modes algoritması ve küme sayısını otomatik belirleyebilme özelliğine sahip olan Two-Step kümeleme yöntemi kullanılmıştır. Böylece farklı veri yapılarına uygun yöntemlerin karşılaştırmalı olarak değerlendirilmesi sağlanmıştır. Son aşamada ise kümeleme analizi sonuçları değerlendirilmiş ve görselleştirme teknikleri ile desteklenmiştir. Elde edilen kümeler aracılığıyla benzer özelliklere sahip tarım ilaçları aynı gruplar altında toplanmış; pestisitlerin kullanım özellikleri, hedef organizmaları ve risk profilleri açısından anlamlı sınıflandırmalar ortaya konulmuştur. Bu süreç sayesinde sürdürülebilir pestisit yönetimi ve karar destek mekanizmalarına katkı sağlayabilecek bulgular elde edilmesi hedeflenmiştir.

2.1. Veri Seti

Çalışma kapsamında kullanılan veri seti, T.C. Tarım ve Orman Bakanlığı'nın Bitki Koruma Ürünleri Veritabanı'ndan (<https://bku.tarimorman.gov.tr/>) elde edilmiştir. Bu platform, Türkiye'de tarımsal kullanım amacıyla ruhsatlandırılmış tüm bitki koruma ürünleri, pestisitler ve ilgili kimyasal maddelere ilişkin

kapsamlı bilgiler içermektedir. Veri setinde bitki koruma ürünlerinin özelliklerini tanımlayan beş değişken yer almaktadır. İlk değişken olan BKÜ/Ruhsatları, Tarım ve Orman Bakanlığı tarafından ruhsatlandırılmış bitki koruma ürünlerinin ticari adlarını ifade etmektedir. Etken madde değişkeni, ürünün biyolojik veya kimyasal etkisini sağlayan aktif bileşeni göstermektedir. Ürün değişkeni, bitki koruma ürününün kullanıldığı tarımsal ürünü veya bitki türünü ifade ederken, hedef zararlı değişkeni ürünün mücadele amacıyla kullanıldığı zararlı organizma, hastalık veya yabancı ot bilgisini içermektedir. Raf ömrü değişkeni ise ürünün uygun depolama koşullarında etkinliğini koruyabildiği süreyi göstermektedir. Bu değişkenler kullanılarak bitki koruma ürünleri arasındaki benzerliklerin belirlenmesi ve ürünlerin özelliklerine göre gruplandırılması amaçlanmıştır. Veri seti toplam 213 gözlemden oluşmakta olup her bir gözlem, ruhsatlandırılmış bir bitki koruma ürününü temsil etmektedir. Analiz öncesinde veri seti ön işleme tabi tutulmuştur. Bu kapsamda eksik değerler ve aykırı gözlemler kontrol edilmiş, veri tutarlılığı incelenmiş ve analiz sürecinde kullanılacak uygun bir veri yapısı oluşturulmuştur. Elde edilen veri seti daha sonra kümeleme analizlerinde kullanılmak üzere hazırlanmıştır.

2.2. Kullanılan Yöntemler

Bu çalışmada analizler R programlama dili (R, 2025) ve IBM SPSS Statistics 31.0 (IBM, 2025) ortamlarında gerçekleştirilmiştir. R ortamında K-Prototypes ve K-Modes kümeleme yöntemleri sırasıyla karma veri yapıları için `clustMixType` (Szepannek, 2026) ve kategorik veriler için `klaR` (Roever et al., 2026) paketleri kullanılarak uygulanmıştır. Two-Step kümeleme analizi ise SPSS paket programında sırasıyla `Analyze`, `Classify` ve `TwoStep Cluster` menü yolu izlenerek gerçekleştirilmiştir. Analizde değişkenler ilgili pencereye tanımlanmış ve küme sayısı otomatik belirleme seçeneği kullanılarak Bayesian Information Criterion (BIC) kriteri doğrultusunda optimal küme yapısı elde edilmiştir.

2.2.1. Elbow Yöntemi

Kümeleme analizlerinde optimum küme sayısının belirlenmesinde yaygın olarak kullanılan yöntemlerden biri Elbow yöntemidir. Bu yaklaşımda, her bir gözlemin ait olduğu küme merkezine olan uzaklığının kareleri toplamı dikkate alınarak hata kareler toplamı hesaplanmaktadır. Farklı küme sayıları için elde edilen bu değerler incelendiğinde, hata kareler toplamındaki azalmanın belirgin biçimde yavaşladığı nokta “dirsek noktası” olarak ifade edilmekte ve uygun küme sayısı bu noktaya göre belirlenmektedir. Başka bir ifadeyle yöntem, yeni bir küme eklenmesinin model performansına anlamlı düzeyde katkı sağlamadığı noktayı tespit etmeye dayanmaktadır (Bholowalia ve Kumar, 2014; Özari ve Can, 2023). Görsel değerlendirmeye dayalı bir yöntem olan Elbow yaklaşımının temel uygulama aşamaları şu şekilde özetlenebilir (Syakur vd., 2018):

1. İlk olarak küme sayısı $k = 1$ olacak şekilde analiz başlatılır.
2. Belirlenen küme sayısı için hata kareler toplamı hesaplanır.
3. Daha sonra k değeri aşamalı olarak artırılarak her bir küme sayısı için hata kareler toplamı yeniden elde edilir.
4. Son aşamada, hata kareler toplamındaki düşüş hızının belirgin şekilde azaldığı nokta belirlenir ve bu nokta optimum küme sayısı olarak kabul edilir.

2.2.2. K-Prototypes Kümeleme Yöntemi

Huang (1998) tarafından geliştirilen K-Prototypes kümeleme yöntemi, K-Means ve K-Modes algoritmalarının birlikte kullanılmasına dayanmaktadır. Gerçek yaşam veri setlerinde sayısal ve kategorik değişkenlerin bir arada bulunması nedeniyle, K-Prototypes algoritması karma veri tiplerinin analizinde önemli avantajlar sağlamaktadır. Yöntem, bölümlendirme temelli kümeleme yaklaşımı ile çalışmakta ve veri noktaları ile küme merkezleri arasındaki uzaklığı hem sayısal hem de kategorik değişkenleri dikkate alarak hesaplamaktadır.

K-Prototypes algoritmasının temel amacı, veri setini belirli sayıda kümeye ayırırken toplam farklılık değerini en aza indirmektir. Bu süreçte kullanılan maliyet fonksiyonu, sayısal değişkenler için Öklid uzaklığını, kategorik değişkenler için ise eşleşme/eşleşmeme durumuna dayalı uzaklık ölçüsünü birlikte değerlendirmektedir. Ayrıca kategorik değişkenlerin etkisini dengelemek amacıyla ağırlık parametresinden yararlanılmaktadır (Ji vd., 2013).

K-Prototypes algoritmasının çalışma süreci aşağıdaki adımlardan oluşmaktadır:

1. İlk aşamada veri setinden rastgele k adet gözlem seçilerek başlangıç küme merkezleri oluşturulur.
2. Daha sonra her bir veri noktası, uzaklık ölçüsüne göre kendisine en yakın küme merkezine atanır ve küme merkezleri güncellenir.
3. Tüm gözlemler kümelere atandıktan sonra veri noktalarının mevcut kümeler ile benzerlikleri yeniden hesaplanır. Eğer bir gözlemin başka bir kümeye daha yakın olduğu belirlenirse ilgili gözlem yeni kümeye aktarılır ve küme merkezleri tekrar güncellenir.
4. Veri noktalarının küme üyeliklerinde herhangi bir değişiklik kalmayınca kadar işlem tekrarlanır ve algoritma sonlandırılır.

Kümeleme analizlerinde kullanılan yöntemler, seçilen parametrelere ve veri yapısına bağlı olarak farklı sonuçlar üretebilmektedir. Aynı algoritma kullanılsa bile başlangıç merkezleri veya veri sıralaması kümelerin yapısını

etkileyebilmektedir. Bu nedenle elde edilen kümelerin doğruluğunu ve anlamlılığını değerlendirebilmek için uygun performans ölçütlerinin kullanılması büyük önem taşımaktadır. Ayrıca analiz sürecinde en önemli problemlerden biri uygun küme sayısının belirlenmesidir. Bu amaçla literatürde optimum küme sayısını belirlemeye yönelik çok sayıda indeks ve değerlendirme yaklaşımı geliştirilmiştir (Akay vd., 2021)

2.2.3. K-Modes Kümeleme Yöntemi

K-Modes algoritması, Huang tarafından kategorik veri yapılarının kümelenebilmesi amacıyla geliştirilen ve K-Means algoritmasının genişletilmiş bir versiyonu olarak kabul edilen bölme kümeleme yöntemlerinden biridir. K-Means algoritması, uzaklık hesaplamalarında ortalama değerleri esas aldığı için yalnızca sayısal veriler üzerinde etkili sonuçlar üretmekte, kategorik değişkenlerin analizinde ise yetersiz kalmaktadır. K-Modes algoritması bu sınırlılığı ortadan kaldırmak amacıyla geliştirilmiş olup, kategorik verilerin kümelenebilmesine uygun yeni benzerlik ölçütleri ve küme merkezi tanımlamaları kullanmaktadır. Bu yöntemde kümeler arasındaki farklılıkların belirlenmesinde basit eşleşme katsayısı ya da Hamming uzaklığı esas alınmaktadır. Buna göre iki veri nesnesi arasındaki benzerlik değeri, ilgili kategorik değişkenlerdeki eşleşmeyen özelliklerin toplamı üzerinden hesaplanmaktadır. Eşleşmeyen özellik sayısının azalması, gözlemler arasındaki benzerliğin arttığını göstermektedir. Dolayısıyla algoritma, benzer kategorik özelliklere sahip gözlemleri aynı kümeler altında toplamayı amaçlamaktadır (Khan, 2007).

K-Means algoritmasında küme merkezleri ortalama değerler ile temsil edilirken, K-Modes algoritmasında kategorik değişkenler için en sık tekrar eden değerler, yani mod değerleri kullanılmaktadır. Böylece kategorik veri yapısına daha uygun küme merkezleri elde edilmektedir. Algoritmanın temel amacı, kümeler içerisindeki toplam benzerlik değerini minimize ederek veri setini en uygun biçimde gruplandırmaktır.

K-Modes algoritmasının çalışma süreci genel olarak şu adımlardan oluşmaktadır:

1. İlk aşamada kullanıcı tarafından belirlenen k adet başlangıç küme modu seçilmektedir.
2. Her bir veri nesnesi, benzerlik ölçüsüne göre kendisine en yakın kümeye atanmakta ve gerekli durumlarda kümeler arasında geçişler gerçekleştirilmektedir.
3. Veri noktalarının kümelere atanmasının ardından her küme için mod değerleri yeniden hesaplanarak küme merkezleri güncellenmektedir.

4. Küme üyeliklerinde deęişim kalmayınca kadar atama ve güncelleme işlemleri tekrar edilmektedir.

K-Modes algoritmasının önemli avantajlarından biri, yalnızca küme sayısının kullanıcı tarafından belirlenmesini gerektirmesi ve büyük veri setlerinde düşük hesaplama maliyeti ile çalışabilmesidir. Algoritmanın zaman karmaşıklığı; veri setindeki gözlem sayısı, küme sayısı ve iterasyon sayısına baęlı olarak ifade edilmektedir. Bu nedenle özellikle kategorik veri aęırlıklı büyük veri setlerinin analizinde etkin ve pratik bir yöntem olarak deęerlendirilmektedir (Kaman, 2017).

2.2.4. Two-Step Kümeleme Yöntemi


Two-Step (iki aşamalı) kümeleme analizi hem sürekli hem de kategorik deęişkenlerin aynı anda analiz edilmesine olanak saęlayan ve özellikle büyük ölçekli veri setlerinde etkili sonuçlar üreten bir kümeleme yöntemidir. Bu yöntemin, farklı veri tiplerini birlikte deęerlendirebilmesi nedeniyle karma veri yapılarında başarılı performans gösterdiği belirtilmektedir (Kayri, 2007). Two-Step Cluster algoritması, yüksek boyutlu veri setlerinin analizine uygun ölçeklenebilir bir yapı sunmakta ve büyük veri kümeleri üzerinde etkin biçimde çalışabilmektedir (Rundle Thiele vd., 2015). İki aşamalı kümeleme yöntemi temel olarak “ön kümeleme” ve “esas kümeleme” olmak üzere iki ana süreçten oluşmaktadır (Okazaki, 2007). İlk aşamada veri setindeki gözlemler küçük alt gruplara ayrılmakta ve bu alt kümeler daha sonraki analizlerde tek bir gözlem gibi deęerlendirilmektedir. Bu süreçte gözlemlerin mevcut kümelere dahil edilmesi veya yeni bir küme oluşturulması işlemi, belirlenen uzaklık ölçütüne göre gerçekleştirilmektedir. İkinci aşamada ise ilk aşamada elde edilen alt kümeler, benzerlik düzeylerine göre yeniden birleştirilerek nihai kümeler oluşturulmaktadır.

Two-Step Cluster yönteminin önemli avantajlarından biri, optimum küme sayısını otomatik olarak belirleyebilmesidir. Bu amaçla algoritma, hiyerarşik kümeleme yaklaşımından yararlanmakta ve kümeleri aşamalı biçimde birleştirerek en uygun küme yapısını oluşturmaktadır. Böylece benzer özellikler taşıyan bireyler veya gözlemler aynı küme altında toplanmakta, veri setindeki doğal grup yapılarının ortaya çıkarılması saęlanmaktadır. Yöntemde kümeler arası benzerliklerin belirlenmesinde çoęunlukla log-olabilirlik uzaklık ölçüsü kullanılmaktadır. Bu uzaklık ölçütü, sürekli ve kategorik deęişkenlerin birlikte bulunduğu veri setlerinde etkili sonuçlar üretmesi nedeniyle tercih edilmektedir. Log-olabilirlik yaklaşımında sürekli deęişkenlerin normal dağılıma, kategorik deęişkenlerin ise multinomial dağılıma sahip olduğu varsayılmaktadır. Ayrıca veri setinin kaç kümeye ayrılacağına önceden bilinmediği durumlarda, uygun küme sayısının belirlenebilmesi için Bayes Bilgi Kriteri (BIC) kullanılmaktadır.


Böylece veri yapısını en iyi temsil eden küme sayısı otomatik olarak elde edilmektedir. SPSS yazılımında Two-Step Cluster yöntemi uygulanırken, sürekli ve kategorik değişkenlerin aynı analiz içerisinde değerlendirilebilmesine olanak sağlayan log-olabilirlik uzaklığı temel alınmaktadır. Bu özellik sayesinde yöntem, karma veri yapılarının bulunduğu uygulamalarda esnek, hızlı ve güvenilir sonuçlar sunan önemli bir kümeleme tekniği olarak değerlendirilmektedir (Deniz, 2023).

3. Bulgular

Bu çalışmada, ilk olarak K-Prototypes ve K-Modes kümeleme yöntemlerinden önce optimal küme sayısını belirlemek amacıyla Elbow yöntemi uygulanmıştır. Şekil 2 ve Şekil 3, Elbow yöntemine ait grafikleri göstermektedir.



Şekil 2. K-Prototypes Kümeleme Yöntemi için Optimal Küme Sayısının Belirlenmesinde Elbow Yöntemi



Şekil 3. K-Modes Kümeleme Yöntemi için Optimal Küme Sayısının Belirlenmesinde Elbow Yöntemi

Optimal küme sayısının belirlenmesi amacıyla Şekil 2 ve Şekil 3'te gösterildiği gibi küme sayısı 1 ile 5 arasında değiştirilerek her bir k değeri için küme içi farklılık hesaplanmıştır. Elbow grafikleri ggplot2 paketi (Wickham, 2016) kullanılarak oluşturulmuş, küme sayısına karşılık gelen toplam küme içi fark değerleri görselleştirilmiştir. Optimal küme sayısı, eğrinin kırılma noktasına göre belirlenmiş ve $k = 3$ olarak seçilmiştir. Bu doğrultuda veri seti her iki yöntem için de üç kümeye ayrılmıştır.

Kümeler, veri setinin yapısına uygun olarak iki farklı yöntem kullanılarak oluşturulmuştur. K-Prototypes algoritması, sayısal ve kategorik değişkenleri birlikte ele alarak raf ömrü gibi sayısal değişkenler ile etken madde ve hedef zararlı gibi kategorik değişkenleri aynı model içinde değerlendirmiştir. K-Modes algoritması ise yalnızca kategorik değişkenler üzerinden çalışarak veri noktaları arasındaki benzerliği kategori eşleşmeleri üzerinden tanımlamıştır.


Bu iki yöntemle, benzer sayısal ve kategorik özellikler gösteren pestisitler aynı kümeler altında toplanmıştır. K-Prototypes ve K-Modes algoritmaları ile elde edilen bu kümeler; pestisitlerin etken madde, hedef zararlı ve raf ömrü gibi temel özellikleri bakımından birbirinden belirgin şekilde ayrıştığını göstermektedir. K-Prototypes yönteminde sayısal bir değişken olan raf

ömrü analize dahil edilirken, K-Modes algoritması sadece kategorik veriler üzerinden ilerlemiştir. Genel olarak K-Prototypes ve K-Modes algoritmaları ile elde edilen bu kümeler; pestisitlerin etken madde, hedef zararlı ve raf ömrü gibi temel özellikleri bakımından birbirinden belirgin şekilde ayrıştığını göstermektedir.

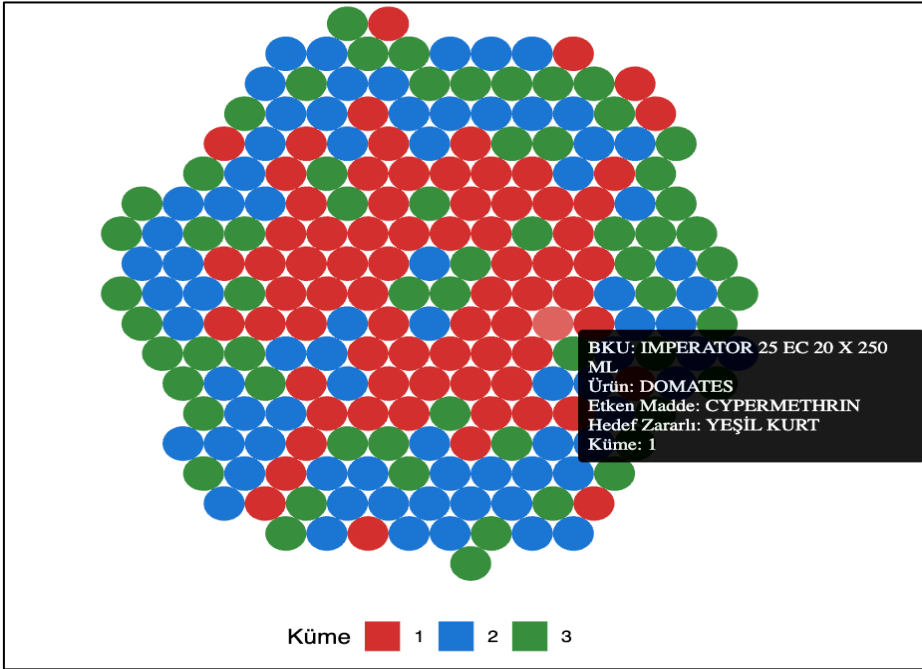
Küme-1, standart uygulamalı ve yaygın kullanılan pestisitleri temsil etmektedir. Bu gruptaki ürünler tablet, sıvı veya granül formunda olup genellikle oda sıcaklığında saklanmaktadır. Kullanım alanları domates, hıyar, biber, patlıcan, kabak ve turunçgil gibi ürünlerdir. Örnek ürünler arasında AGRIMEC EC, ALVERDE ve PREV-AM bulunmaktadır. Küme-2, profesyonel kullanım ve kontrollü koşullarda uygulanan pestisitleri kapsamaktadır. Ürünler genellikle ampul veya sıvı konsantr formundadır ve ışık ile sıcaklıktan korunması gerekmektedir. Bu küme, seralar veya özel uygulama ortamları gibi kontrollü alanlarda kullanılan ürünleri temsil etmektedir. Örnek ürün olarak ARABUS SC240, NEEMARIN ve PREVICUR ENERGY bulunmaktadır. Küme-3 ise, uzun raf ömürlü ve yüksek paketleme miktarına sahip, standart saklama koşullarına uygun pestisitleri içermektedir. Ürünler tablet, sıvı veya granül formunda olup domates, hıyar, biber, patlıcan, kabak, kavun ve turunçgil gibi çeşitli kültürlerde kullanılabilir. Bu kümedeki örnek ürünler arasında ADMIRAL 10 EC, BREAKER240SC ve MOVENTO SC100 yer almaktadır.

Şekil 4 ve Şekil 5, K-Prototypes ve K-Modes algoritmaları kullanılarak elde edilen pestisitlerin balon grafik formatında kümelenmesini göstermektedir. Dairelerin çakışmadan yerleşimi packcircles paketi (Bedward ve Eppstein, 2024) ile sağlanmış, görselleştirme ggplot2 (Wickham, 2016) ile gerçekleştirilmiştir. Grafiğin interaktif hale getirilmesinde ggiraph paketi (Gohel ve Skintzos, 2026) kullanılmıştır.

Bu grafiklerde her bir balon bir pestisit ürününü temsil etmektedir ve balonun rengi, pestisit ürününün ait olduğu kümeyi göstermektedir. Üç farklı renk, üç farklı kümeyi ifade etmektedir. Bu etkileşimli grafikte, herhangi bir balonun üzerine gelindiğinde ilgili pestisit ürünü, kullanıldığı ürün grubu, etken maddesi, hedef zararlısı ve atandığı küme görüntülenmektedir. Bu grafik, pestisitlerin üç farklı kümede net bir şekilde ayrıldığını ve kümeleme algoritmasının veri setinde anlamlı gruplamaları başarıyla belirlediğini göstermektedir.

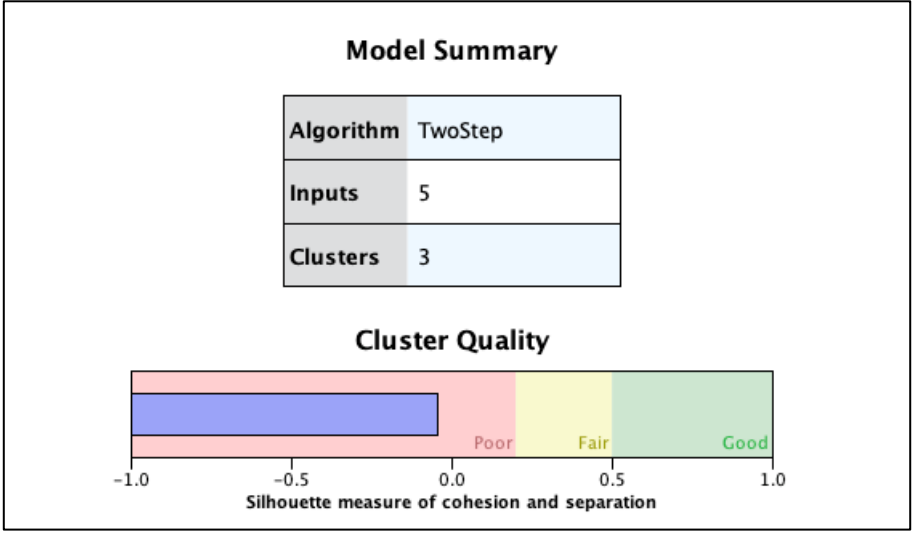


Şekil 4. K-Prototypes Kümeleme Sonucuna Dayalı Pestisit Ürünlerinin Baloncuk Haritası



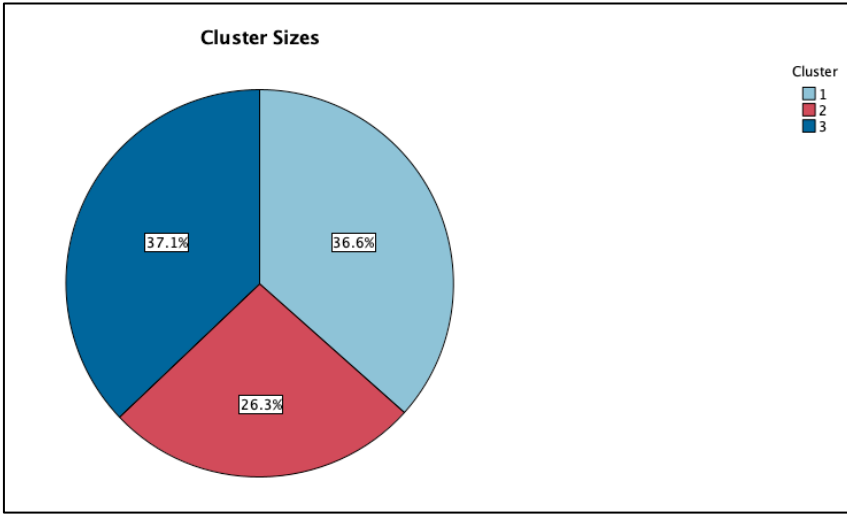
Şekil 5. K-Modes Kümeleme Sonucuna Dayalı Pestisit Ürünlerinin Baloncuk Haritası

K-Prototypes ve K-Modes algoritmaları ile elde edilen sonuçlar, veri setinin üç kümeye ayrılan tutarlı bir yapı sergilediğini göstermiştir. Çalışmanın devamında, bu bulguları karşılaştırmalı olarak değerlendirmek ve veri setinin küme yapısını farklı bir yaklaşım ile analiz etmek amacıyla, küme sayısını veri yapısından otomatik olarak belirleyebilen ve hem kategorik hem de sayısal değişkenleri log-olabilirlik temelli yaklaşım ile birlikte ele alan Two-Step kümeleme yöntemi uygulanmıştır. Böylece veri setinin küme yapısı, alternatif bir yöntem ile incelenerek sonuçların karşılaştırmalı olarak değerlendirilmesi amaçlanmıştır. Bu kapsamda Two Step kümeleme yöntemi ile optimal küme sayısı Şekil 6'da gösterildiği gibi $k = 3$ olarak belirlenmiştir.




Şekil 6. Two-Step Kümeleme Yöntemi Sonuçları

Şekil 7, kümeleme analizi sonucunda oluşan kümelerin dağılımını göstermektedir.



Şekil 7. Two-Step Algoritması Küme Dağılım Grafiği

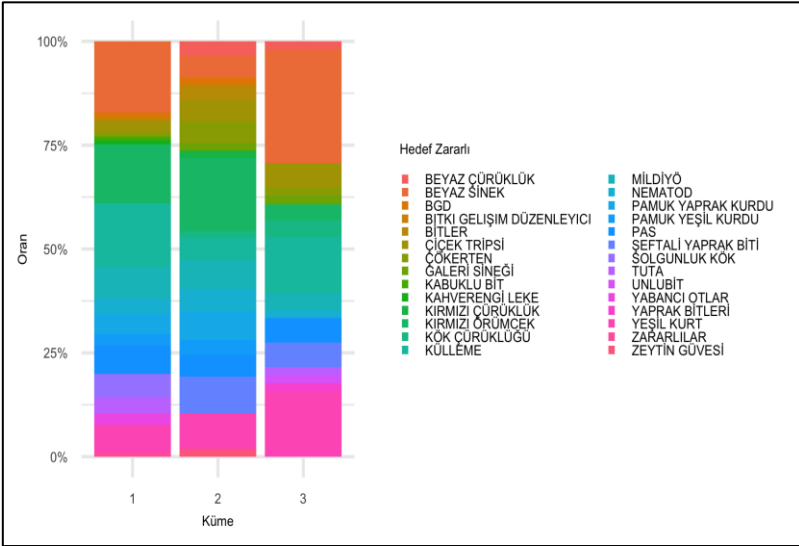
Kümeleme sürecinde hangi parametrelerin kümeleme üzerinde daha belirleyici olduğunu saptamak amacıyla yapılan analiz sonuçları Şekil 8’de sunulmuştur. Bu grafik, pestisitlerin kümelere ayrılmasında rol oynayan değişkenlerin göreceli önem düzeylerini göstermektedir.



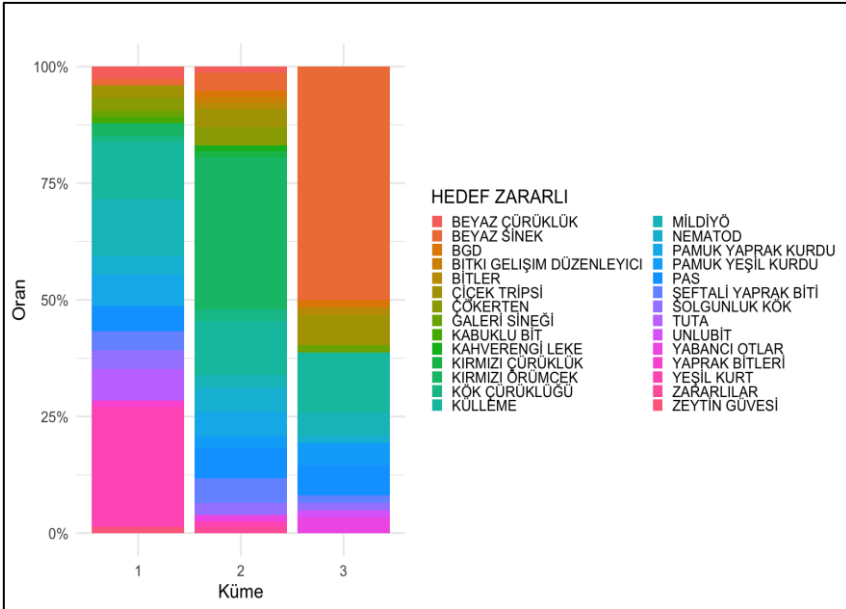
Şekil 8. Kümeleme İçin Değişkenlerin Önem Düzey Grafiği

Grafikte görüldüğü üzere, kümeleme üzerinde en yüksek etkiye sahip olan değişken "Hedef Zararlı" olmuştur. Bu durum, pestisitlerin birbirlerinden ayrışmasında, mücadele ettikleri zararlı organizma türünün en kritik ayırt edici özellik olduğunu kanıtlamaktadır. "Etken Madde" ve "BKU" değişkenleri, kümeleme başarısında orta-yüksek düzeyde bir etki göstermiştir. Raf Ömrü ve Ürün değişkenlerinin kümeleme üzerindeki etkisi diğer parametrelere kıyasla

daha düşük kalmıştır. Bu kapsamda, K-Prototypes ve K-Modes algoritmalarında kümeleme üzerinde en yüksek etkiye sahip değişken olan Hedef Zararlı değişkeni için Şekil 9 ve Şekil 10’da kümelere göre dağılım grafikleri sunulmuştur. Kümeler içerisindeki hedef değişken dağılımları yığılmış çubuk grafikler ile gösterilmiştir. Grafikler ggplot2 (Wickham, 2016) paketi kullanılarak oluşturulmuştur.



Şekil 9. K-Prototypes Algoritmasına Göre ‘Hedef Zararlı’ Değişkeninin Kümelere Göre Dağılımı



Şekil 10. K-Modes Algoritmasına Göre ‘Hedef Zararlı’ Değişkeninin Kümelere Göre Dağılımı

Analiz sonuçları doğrultusunda, K-Prototypes ve K-Modes algoritmalarının pestisitleri gruplandırırken en yüksek ayırt edici güce sahip olduğunu saptadığı 'Hedef Zararlı' değişkenine ait dağılımlar, Şekil 8 ve Şekil 9'da kümelere göre detaylandırılmıştır. Bu grafikler, hangi hedef zararlı grubunun hangi kümede yoğunlaştığını ortaya koymaktadır.

4. Tartışma ve Sonuç

Bu çalışmada, tarım ilaçlarının sahip oldukları çok boyutlu özellikler dikkate alınarak farklı kümeleme algoritmaları aracılığıyla sınıflandırılması amaçlanmıştır. Elde edilen bulgular, pestisitlerin yalnızca kimyasal içerikleri açısından değil; hedef zararlı grupları, kullanım özellikleri ve raf ömrü gibi operasyonel değişkenler bakımından da belirgin biçimde ayrıştığını göstermektedir. Özellikle K-Prototypes, K-Modes ve Two-Step kümeleme algoritmalarının benzer küme yapıları üretmesi, veri setinde doğal ve anlamlı grupların bulunduğunu ortaya koymaktadır.

Çalışmada dikkat çeken en önemli bulgulardan biri, “hedef zararlı” değişkeninin kümeleme üzerinde en yüksek belirleyici güce sahip olmasıdır. Bu sonuç, tarım ilaçlarının sınıflandırılmasında yalnızca etken madde veya ticari ürün özelliklerinin değil, mücadele edilen zararlı organizma yapısının da kritik bir rol oynadığını göstermektedir. Literatürde pestisit çalışmalarının çoğunlukla toksisite, kalıntı düzeyi veya çevresel etkiler üzerine yoğunlaştığı görülmektedir. Ancak bu çalışmada pestisitlerin kullanım amaçları ve hedef organizma ilişkileri üzerinden kümelenmesi, karar destek mekanizmaları açısından daha uygulamaya dönük bir yaklaşım sunmaktadır. Bu yönüyle çalışma, pestisitlerin yalnızca kimyasal risk perspektifinden değil, aynı zamanda operasyonel kullanım örüntüleri açısından da değerlendirilmesi gerektiğini ortaya koymaktadır.

K-Prototypes algoritmasının hem sayısal hem de kategorik değişkenleri birlikte değerlendirebilmesi sayesinde daha bütüncül kümeler oluşturduğu görülmüştür. Özellikle raf ömrü gibi sayısal değişkenlerin analize dahil edilmesi, pestisitlerin yalnızca kategorik özellikler üzerinden değil depolama ve kullanım süreleri bakımından da ayrıştırılabilmesine olanak sağlamıştır. Buna karşılık K-Modes algoritması, yalnızca kategorik değişkenler üzerinden daha sade ancak güçlü bir ayırım yapısı ortaya koymuştur. Two-Step kümeleme yöntemi ise optimum küme sayısını otomatik belirleyebilmesi ve değişken önem düzeylerini gösterebilmesi açısından önemli avantajlar sunmuştur. Bu durum, farklı kümeleme algoritmalarının aynı veri seti üzerinde birlikte kullanılmasının daha güvenilir ve karşılaştırmalı sonuçlar elde edilmesine katkı sağladığını göstermektedir.

Elde edilen kümeler incelendiğinde, bazı pestisit gruplarının standart tarımsal uygulamalarda yaygın olarak kullanıldığı, bazı grupların ise kontrollü koşullarda ve profesyonel uygulamalarda tercih edildiği belirlenmiştir. Özellikle kontrollü saklama koşulları gerektiren pestisitlerin ayrı kümelerde yoğunlaşması, depolama ve lojistik süreçlerinin pestisit yönetiminde önemli bir unsur olduğunu göstermektedir. Ayrıca uzun raf ömrüne sahip ürünlerin belirli kümelerde toplanması, pestisitlerin kullanım stratejileri ile ürün dayanıklılığı arasında anlamlı ilişkiler bulunduğunu ortaya koymaktadır.

Bu çalışma literatüre çeşitli yönlerden katkı sağlamaktadır. İlk olarak, resmi kurum verileri kullanılarak gerçekleştirilen gerçek veri temelli bir kümeleme uygulaması sunulmuştur. İkinci olarak, pestisitlerin yalnızca çevresel veya toksikolojik etkileri değil, çok boyutlu operasyonel özellikleri birlikte değerlendirilmiştir. Üçüncü olarak, K-Prototypes, K-Modes ve Two-Step algoritmalarının aynı veri seti üzerinde karşılaştırmalı biçimde uygulanması sayesinde karma veri yapılarında farklı algoritmaların performansları değerlendirilmiştir. Bu yönleriyle çalışma, pestisit yönetimi alanında veri madenciliği ve kümeleme analizlerinin kullanımına yönelik metodolojik bir çerçeve sunmaktadır.

Bununla birlikte çalışmanın bazı sınırlılıkları bulunmaktadır. Öncelikle analizler, T.C. Tarım ve Orman Bakanlığı veri tabanından elde edilen belirli değişkenler ile sınırlandırılmıştır. Pestisitlerin toksisite düzeyi, çevresel kalıcılığı, uygulama sıklığı ve ekonomik maliyetleri gibi ek değişkenlerin dahil edilmesi daha kapsamlı sonuçlar sağlayabilir. Ayrıca çalışma belirli bir zaman aralığında elde edilen kesitsel verilere dayandığından, pestisit kullanımındaki zamansal değişimler analiz edilememiştir. Kullanılan veri setinin gözlem sayısının sınırlı olması da kümelerin genellenebilirliğini belirli ölçüde etkileyebilmektedir. Gelecek çalışmalarda, pestisitlerin çevresel risk düzeyleri, toksisite indeksleri ve bölgesel kullanım yoğunlukları gibi değişkenlerin modele dahil edilmesi önerilmektedir. Ayrıca yapay zekâ ve derin öğrenme tabanlı yöntemlerin kümeleme algoritmaları ile birlikte kullanılması, pestisitlerin risk sınıflandırmasının daha hassas biçimde gerçekleştirilmesine katkı sağlayabilir. Bunun yanında coğrafi bilgi sistemleri (CBS) destekli mekânsal kümeleme analizleri ile pestisit kullanım örüntülerinin bölgesel ölçekte değerlendirilmesi, sürdürülebilir tarım politikalarının geliştirilmesi açısından önemli katkılar sunabilir.

Sonuç olarak bu çalışma, tarım ilaçlarının çok boyutlu veri yapıları üzerinden anlamlı kümeler altında sınıflandırılabileceğini göstermiştir. Elde edilen bulgular, pestisitlerin daha etkin yönetilmesi, risk gruplarının belirlenmesi ve sürdürülebilir tarım uygulamalarının desteklenmesi açısından önemli bilgiler


sunmaktadır. Ayrıca çalışma, karma veri yapılarının analizinde farklı kümeleme algoritmalarının birlikte kullanılmasının güvenilir ve yorumlanabilir sonuçlar üretmede etkili bir yaklaşım olduğunu ortaya koymaktadır.

KAYNAKÇA

- Akay, Ö., Çelik, C., & Kıral, G. (2021). Using Clustering of Panel Data to Examine Housing Demand of Expatriate Turks and Foreigners: An Application of k-prototype Algorithm. In *Application of Multi-Criteria Decision Analysis in Environmental and Civil Engineering* (pp. 183-195). Cham: Springer International Publishing. https://doi.org/10.1007/978-3-030-64765-0_18
- Arslan, M. (2020). Gıdada pestisit analizi için LC-MS/MS ile çoklu tarama yöntemi geliştirilmesi (Yüksek lisans tezi, İstanbul Üniversitesi-Cerrahpaşa, Adli Tıp ve Adli Bilimler Enstitüsü).
- Bedward, M., & Eppstein, D. (2024). packcircles: Circle Packing (Versiyon 0.3.7). CRAN. <https://CRAN.R-project.org/package=packcircles>
<https://doi.org/10.32614/CRAN.package.packcircles>
- Bholowalia, P., & Kumar, A. (2014). EBK-means: A clustering technique based on elbow method and k-means in WSN. *International Journal of Computer Applications*, 105(9), 17-24.
- De Souza, R. M., Seibert, D., Quesada, H. B., Bassetti, F., Fagundes-Klen, M. R., Bergamasco, R. (2020). Occurrence, impacts and general aspects of pesticides in surfacewater: A review. *Process Safety and Environmental Protection*, 135, 22–37. <https://doi.org/10.1016/j.psep.2019.12.035>
- Deniz, S. S. (2023). Turizm Eğitimi Alan Öğrencilerde Su Okuryazarlığının Kümeleme Analizi ile İncelenmesi: Investigation of Water Literacy in Tourism Education with Cluster Analysis. *Sosyal Bilimlerde Nicel Araştırmalar Dergisi*, 3(2), 152-163.
- Faraj, T. K., EL-Saeid, M. H., Najim, M. M., & Chieb, M. (2024). The impact of pesticide residues on soil health for sustainable vegetable production in arid areas. *Separations*, 11(2), 46. <https://doi.org/10.3390/separations11020046>
- Faria, B. L. S., & Raposo, L. M. (2025). Identification of distinct pesticide poisoning patterns in Brazil: a cross-sectional cluster analysis of epidemiological data. *International Archives of Occupational and Environmental Health*, 98(2), 191-202.
- Gohel, D., & Skintzos, P. (2026). ggiraph: Make 'ggplot2' Graphics Interactive (Versiyon 0.9.6). CRAN. <https://doi.org/10.32614/CRAN.package.ggiraph>
- Hanedar, A., Tanık, A., & Girgin, E. (2023). Yeşil Mutabakat Kapsamında Pestisit Yönetimi ve Türkiye. *Çevre İklim ve Sürdürülebilirlik*, 24(2), 87-96.
- Huang, Z.X. (1998). Extensions to the k-means algorithm for clustering large datasets with categorical values. *Data Min Knowl Disc* 2:283–304.

- IBM. (2025, June 11). *Downloading IBM SPSS Statistics 31*. IBM Support. <https://www.ibm.com/support/pages/downloading-ibm-spss-statistics-31>
- Ji, J., Bai, T., Zhou, C., Ma, C., Wang, Z. (2013). An improved k-prototypes clustering algorithm for mixed numeric and categorical data. *Neurocomputing* 120:590–596. <https://doi.org/10.1016/j.neucom.2013.04.011>
- Kaman, F. B. (2017). Kategorik Verilerde Kümeleme İçin Farklı Algoritmaların Karşılaştırılması. *Sinop Üniversitesi Fen Bilimleri Dergisi*, 2(2), 62-78.
- Kayri, M. (2007). Araştırmalarda İki Aşamalı Kümeleme (Two-Step Clustering) Analizi ve Bir Uygulaması. *Eurasian Journal of Educational Research (EJER)*, (28).
- Khan, S.S. (2007). Computation of Initial Modes for K-modes Clustering Algorithm Using Evidence Accumulation, *IJCAI'07 Proceedings of the 20th International Joint Conference on Artificial Intelligence*, 27842789.
- Li, D., Yin, J., Yu, Z., Gao, Z., Xu, N., & Meng, L. (2025). Artificial intelligence-assisted colorimetric sensor array based on supramolecular self-assembled nanozymes for visual monitoring of pesticide residues. *Sensors and Actuators B: Chemical*, 138493. <https://doi.org/10.1016/j.snb.2025.138493>
- Mei, S. (2024). Transferring knowledge across aquatic species via clustering techniques to unravel patterns of pesticide toxicity. *Science of The Total Environment*, 950, 175385. <https://doi.org/10.1016/j.scitotenv.2024.175385>
- Okazaki, S., (2007). Lessons learned from i-mode: What makes consumers click wireless banner ads?, *Computers in Human Behavior*, 23, 1692–1719. <https://doi.org/10.1016/j.chb.2006.03.018>
- Özari, Ç., & Can, E. N. (2023). Finansal Göstergeler Açısından Borsa İstanbul'da Faaliyet Gösteren Üretim Şirketlerinin Değerlendirilmesi: Silhouette İndeksine ve Elbow Yöntemine Göre K-Ortalamalar ile Kümelenmesi. *Journal of Accounting Institute*, (69), 1-19. <https://doi.org/10.26650/MED.1278850>
- Porter, S. N., Humphries, M. S., Buah-kwofie, A., & Schleyer, M. H. (2018). Accumulation of organochlorine pesticides in reef organisms from marginal coral reefs in South Africa and links with coastal groundwater. *Marine Pollution Bulletin*, 137, 295–305. <https://doi.org/10.1016/j.marpolbul.2018.10.028>
- R, T.C., 2025. R: A language and environment for statistical computing, R Foundation for Statistical Computing.
- Robu, R. G., Holobiuc, A. M., Alexoaci, A. P., Cojanu, V., & Miron, D. (2023). Regional patterns of pesticide consumption determinants in the European Union. *Sustainability*, 15(3), 2070.

- Roever, C., Raabe, N., Lübke, K., Ligges, U., Szepannek, G., Zentgraf, M., & Meyer, D. (2026). *klAR: Classification and Visualization* (R package version 1.7-4). <https://doi.org/10.32614/CRAN.package.klaR>
- Rundle Thiele, S., Kubacki, K., Tkaczynski A., Parkinson, J.,(2015). Using two-step cluster analysis to identify homogeneous physical activity groups, *Marketing Intelligence and Planning*, 33, 522-537. <https://doi.org/10.1108/MIP-03-2014-0050>
- Sabarwal, A., Kumar, K., Singh, R. P. (2018). Hazardous effects of chemical pesticides on human health – Cancer and other associated disorders. *Environmental Toxicology and Pharmacology*, 63, 103–114. <https://doi.org/10.1016/j.etap.2018.08.018>
- Salvagni, J., Ternus, R. Z., & Fuentefria, A. M. (2011). Assessment of the genotoxic impact of pesticides on farming communities in the countryside of Santa Catarina State, Brazil. *Genetic and Molecular Biology*, 34, 122–126. <https://doi.org/10.1590/S1415-47572010005000104>
- Syakur, M. A., Khotimah, B. K., Rochman, E. M. S., & Satoto, B. D. (2018, April). Integration k-means clustering method and elbow method for identification of the best customer profile cluster. In *IOP conference series: materials science and engineering*. IOP Publishing. <https://doi.org/10.1088/1757-899X/336/1/012017>.
- Szepannek, G. (2026). *clustMixType: k-Prototypes Clustering for Mixed Variable-Type Data* (R package version 0.5-1). <https://doi.org/10.32614/CRAN.package.clustMixType>
- Velioğlu, S. D., Güner, K. G., Mehmeti, Z. S., Sağlam, Ö., & Velioğlu, H. M. (2024). Domates ve Hıyar Örneklerinde Element İçeriğinin ve Pestisit Kalıntılarının Araştırılması: Tekirdağ (Türkiye) ve Mamuşa (Kosova) Örneği. *Turkish Journal of Agriculture-Food Science and Technology*, 12(s2), 2328-2337. <https://doi.org/10.24925/turjaf.v12is2.2328-2337.7077>
- Wang, R., Yuan, Y., Yen, H., Grieneisen, M., Arnold, J., Wang, D., Wanf, C., Zhang, M. (2019). A review of pesticide fate and transport simulation at watershed level using SWAT: Current status and research concerns. *Science of the Total Environment*, 669, 512-526. <https://doi.org/10.1016/j.scitotenv.2019.03.141>
- Wickham, H. (2016). *ggplot2: Elegant graphics for data analysis*. Springer.



Stratejik Ham Maddelerin Dış Ticaret Trendleri Analizi

Şahika Ercan¹ & Elifcan Göçmen Polat²

Giriş

Ekonomik işleyiş açısından büyük öneme sahip olan, fakat kıtlık ya da jeopolitik gerilimler sebebiyle tedarikinde ciddi riskler barındıran kaynaklar kritik hammadde olarak tanımlanmaktadır. Stratejik hammaddeler ise ülkelerin yenilenebilir enerji, dijitalleşme, uzay ve savunma sanayisi gibi kilit sektörlerdeki hedeflerine ulaşmasında hayati rol oynayan girdilerdir. Hammaddeler, genel olarak hem ülke ekonomisinin hem de endüstriyel üretimin sürdürülebilmesinde temel yapı taşlarıdır. Devletlerin ekonomik modellerini sürdürülebilirlik ilkeleri çerçevesinde yeniden yapılandırması, bu yeşil dönüşüm teknolojilerinde ihtiyaç duyulan kaynakların önemini daha da ön plana çıkarmaktadır (Polat, 2023). Söz konusu hammaddeler, endüstriyel süreçlerin merkezinde yer alarak sürdürülebilir kalkınma gayelerine erişilmesine doğrudan katkı sağlamaktadır. Özellikle dijital teknolojilerdeki ilerlemeler ve çevre odaklı dönüşüm hamlelerinin ivme kazanması, kritik kaynaklara yönelik küresel talebi ciddi oranda artırmıştır (Göçmen-Polat, 2024). Bu öncü sektörlerde kullanılan girdilerin yakın gelecekte arz ve talep uyumsuzluklarıyla sarsılacağı öngörülmektedir. Üstelik bu maddelerin üretim hacmini artırmak da çeşitli zorlukları beraberinde getirmektedir. Esasen, literatüre stratejik sınıflandırmasının dâhil edilmesi, bu kaynakların sektörel bazdaki önemini vurgulamayı amaçlamaktadır. Bazı kritik ve stratejik hammaddeler birbiriyle örtüşebilir; zira pek çok hammadde, farklı sanayi kollarındaki vazgeçilmez rollerinden ötürü aynı zamanda stratejik birer unsur olarak kabul edilir. Bu iki kavram arasındaki ayrım, hükümetlerin her hammadde türü için daha hassas yasal düzenlemeler yapmasına, kaynak yönetim planları oluşturmalarına ve sınırlı bulunabilirlik ya da lojistik duraksama risklerine karşı daha nokta atışı stratejiler geliştirmesine olanak tanımaktadır. Kritik Hammaddeler Yasası, geri kazanım ve geri dönüşüm süreçlerini optimize ederek bu kaynakların sürdürülebilir biçimde yönetilmesini amaçlasa da bu süreçteki en büyük engel, geleceğe yönelik arz ve talep dengelerinin şeffaf bir şekilde izlenememesidir. Bir hammaddenin döngüsü boyunca üretim kapasitesinin ve dış ticaret seyrinin tahmin edilememesi, tedarik zinciri ve üretim süreçleri üzerindeki etkilerin analiz edilmesini zorlaştırmakta ve sorumlu adımların atılmasını engellemektedir. Bu bağlamda, söz konusu verilerin geleceğe dönük

¹ Araş.Gör., Karabük Üniversitesi, ORCID: 0009-0005-4596-7914

² Doç. Dr., Munzur Üniversitesi, ORCID: 0000-0002-0316-281X

öngörülmesi, Kritik Hammaddeler Yasası'nın hedeflerine ulaşmasında merkezi bir rol oynayabilir. Özellikle isabetli tahmin modelleri vasıtasıyla tedarik risklerinin gözlemlenmesi; kritik kaynakların yeniden kazanımı ve geri dönüştürülmesi gibi iki temel savunma mekanizmasını beslemek adına oldukça değerlidir. Bunun yanı sıra, üretim ya da ithalat hacminde artış trendi beklenen hammaddelerin kritik/stratejik listelerine dâhil edilmesi, bu kaynaklara yönelik proaktif ve özel politikaların üretilmesini kolaylaştıracaktır.

Uluslararası hammadde ticareti kapsamında, ithalat ve ihracat süreçlerini zaman serisi analizleriyle ele alan pek çok akademik çalışma mevcuttur. Örneğin Say vd. (2024), temiz enerji eğilimlerinin gelecekteki yönünü saptayarak bu teknolojilerde ihtiyaç duyulan ham maddelere yönelik talep seviyelerini ve kritik kaynakların stratejik değerini zaman serisi yöntemleriyle ortaya koymuştur. Duran (2016) ise Türkiye özelinde hammadde ve yatırım malı ithalatının ekonomik büyüme üzerindeki etkilerini ve aralarındaki nedensellik bağlarını yine zaman serisi analiz tekniklerinden yararlanarak incelemiştir. Polat vd. (2023) tarafından yapılan çalışmada, Türkiye'nin ithalat verilerinden hareketle gelecek yıllardaki hammadde kritiklik derecesini belirlemek amacıyla bir zaman serisi modeli olan Üstel Düzeltme Tahmini kullanılmıştır. Bu modelden elde edilen eğilimlere göre hammaddelerin risk durumları analiz edilmiştir. Benzer şekilde Uçan ve Saraç (2020), Türkiye'deki ithalat, döviz kuru hareketleri ve ekonomik büyüme performansları arasındaki etkileşimi zaman serisi metodolojisiyle masaya yatırmıştır. Bahsi geçen bu araştırmalar, dış ticaret verileri ile temel makroekonomik göstergeler arasındaki bağları dinamik zaman serileriyle doğrulamaktadır. Güner ve Demir (2022), demir-çelik ithalatının geçmişten günümüze gelişimini inceleyerek yapay sinir ağı modeli aracılığıyla en tutarlı tahmin modelini kurgulamayı hedeflemiştir; bu doğrultuda ithalatın yapısal dinamikleri ve makroekonomik değişkenlerle ilişkisi çözümlenmiştir. Bayar ve Tokpunar (2014), Türkiye'nin ihracat potansiyelini sektörel bazda ele alarak 1998-2012 dönemine ait çeyreklik veriler üzerinden zaman serisi denklemleri kurmuş ve değişkenlerin kısa ile uzun vadeli ilişkilerini analiz etmiştir. Tarımsal hammadde boyutunda Uçum (2016), Türkiye'deki soya üretiminin genel tablosunu çizmek ve geleceğe yönelik arz-ticaret projeksiyonlarını ortaya koymak adına sonraki beş yıllık dönemi tahmin etmiştir; bu süreçte TÜİK'in üretim verileri ile FAO'nun ithalat istatistikleri zaman serisi analizine tabi tutulmuştur. Son olarak Merdan (2023), Türkiye şeker piyasasının güncel durumunu yorumlamak ve gelecek öngörülerinde bulunmak amacıyla zaman serisi yöntemlerinden Üstel Düzeltme Metoduna başvurmuş, analizlerde kullanılan ikincil verileri TÜİK ve TŞFAŞ veri tabanlarından derlemiştir.


Yürüttüğümüz bu çalışmada ise literatürde ilk kez, belirlenen dört farklı sektörel kategori için hammaddelerin yıllara göre ithalat ve ihracat projeksiyonları zaman serisi yöntemleri kullanılarak analiz edilmiştir. Araştırma, elde edilen dış ticaret tahmin sonuçlarına dayanarak, arz sıkıntısı yaşanabilecek

kaynaklar için ikame malzeme arayışları ya da geri dönüşüm modelleri gibi alternatif stratejilerin tasarlanmasına rehberlik edecektir. Ayrıca elde edilen bulgular, dış ticaret hacminde ciddi artış öngörülen bazı hammaddelerin, ulusal veya bölgesel düzeyde kritik/stratejik hammadde envanterlerine dâhil edilmesine yasal ve akademik bir zemin hazırlayacaktır.


Materyal-Yöntem

Veri Analizi

Türkiye'nin madencilik sektörü, ihracat ve ithalat açısından önemli bir ekonomik katkı sağlamaktadır. Maden Tetkik ve Arama (MTA) Genel Müdürlüğünden temin edilen veri seti 1996-2023 yılları arasında Türkiye'nin madencilik ihracatına (Şekil 1) ve ithalatına (Şekil 2) dair yıllık verileri içermektedir. Veriler, endüstriyel hammaddeler, doğal taşlar, metalik madenler ve enerji hammaddeleri olmak üzere dört ana grupta sınıflandırılmıştır. Bu veri seti, Türkiye'nin madencilik sektöründeki ihracat ve ithalat eğilimlerini analiz etmek, sektördeki değişimleri değerlendirmek ve geleceğe yönelik tahminlerde bulunmak için önemli bir kaynak sunmaktadır.



Şekil 1. Maden gruplarına göre ihracat



Şekil 2. Maden gruplarına göre ithalat

Zaman Serileri Analizi

Prophet, zaman serisi tahmini yapmak için kullanılan bir modeldir. Özellikle eksik veriler, mevsimsellik ve tatil etkilerini iyi yönetmektedir. Model, trend, mevsimsellik ve tatil etkileri olmak üzere üç ana bileşenden oluşmaktadır. Her bir bileşen, zaman serisi verilerindeki farklı davranışları yakalamak için kullanılmaktadır. Trend bileşeni, zaman içindeki düzensiz değişimleri ayarlayarak belirlenen değişim noktalarında trendin yönünü değiştirme olanağı sunmaktadır ve böylece modelin uyum yeteneğini artırmaktadır. Mevsimsellik bileşeni, periyodik değişimleri yakalamak için Fourier serileri kullanarak karmaşık tekrar eden desenleri modellemeye yardımcı olmaktadır. Tatil bileşeni, verilerde tatillerin neden olduğu sapmaları belirlemektedir ve bu faktörler birçok zaman serisi veri setinde önemli bir rol oynamaktadır (Maleki vd. 2024).

Prophet modeli, zaman serisini trend + mevsimsellik + tatil etkisi olarak parçalamaktadır:

$$y(t) = g(t) + s(t) + h(t) + \epsilon t$$

$$g(t) = \text{Trend (uzun vadeli değişim)}$$

$$s(t) = \text{Mevsimsellik (dönemsel değişimler)}$$


$$h(t) = \text{Özel günler (tatiller, etkinlikler)}$$

$$\epsilon t = \text{Rastgele hata terimi}$$

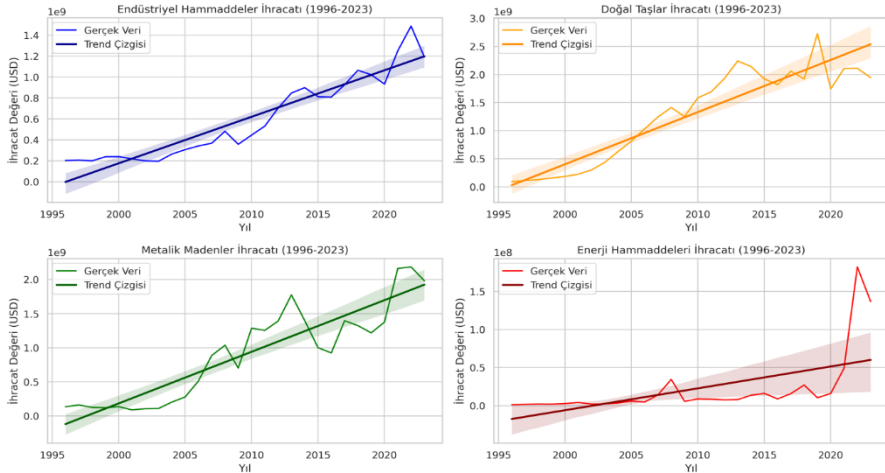
Bulgular

Trend ve Mevsimsellik Analizi

Bu analizler (Şekil 3-Şekil 4), Türkiye'nin maden ihracatında uzun vadeli büyüme trendini koruduğunu ve özellikle son yıllarda belirli sektörlerde büyük sıçramalar yaşandığını göstermektedir.



Şekil 3. Trend ve Mevsimsellik




Şekil 4. Hammaddeler göre ihracat trendleri

- Tüm maden türlerinde genel olarak artış eğilimi vardır.
- Doğal Taşlar ve Metalik Madenler en yüksek ihracat seviyesine sahiptir.
- Endüstriyel Hammaddeler sürekli ve istikrarlı bir büyüme göstermektedir.

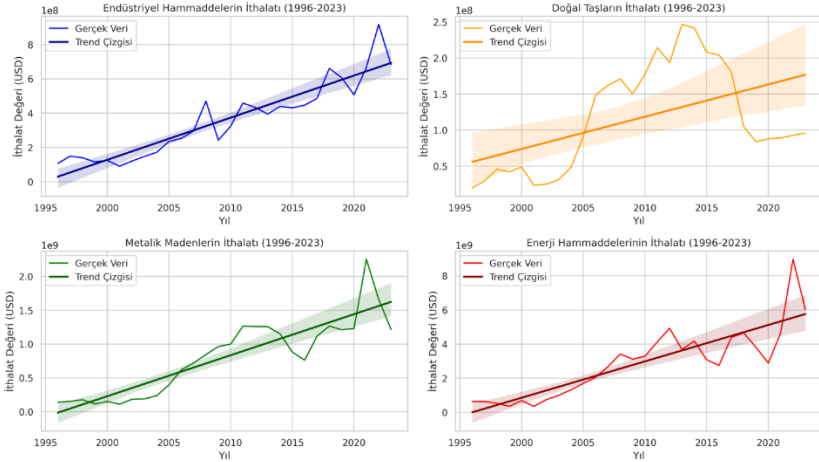
- Enerji Hammaddeleri en düşük seviyede ancak son yıllarda büyük bir yükseliş göstermektedir.
- 2008 Küresel Krizi ve 2020 pandemi dönemi bazı gruplarda dalgalanmalara neden olmuş olabilir.

Bu grafik seti (Şekil 5), 1996-2023 yılları arasında maden gruplarının ithalat değerlerini ve trend çizgilerini ayrı ayrı göstermektedir.



Şekil 5. Trend ve Mevsimsellik

Enerji hammaddeleri ithalatı diğer gruplardan belirgin şekilde yüksek ve 2020 sonrası büyük bir artış eğilimi göstermektedir. Metalik cevherler ve endüstriyel hammaddelerde büyüme daha stabil, ancak enerji sektörüne bağlı olarak değişim gösterebilir (Şekil 6).




Şekil 6. Hammaddeler göre ithalat trendleri

- Endüstriyel hammaddeler ve metalik cevherler daha stabil bir büyüme eğilimindedir.
- Doğal taş ithalatı inşaat sektörüyle bağlantılı olarak dalgalı bir seyir izlemektedir.
- Enerji hammaddeleri ithalatı diğer gruplara kıyasla çok daha hızlı artıyor ve sanayi-enerji bağımlılığı güçlü bir şekilde hissedilmektedir.

Tahmin bulguları

Endüstriyel Hammaddelerin 10 yıllık ihracat (Şekil 7) ve ithalat (Şekil 8) tahminleri sunulmaktadır.



Şekil 7. Endüstriyel Hammaddelerin 10 yıllık ihracat tahminleri

- Model, 2024-2033 yılları arasında büyüme eğilimi öngörmektedir.
- 2028-2033 arasında ihracatta daha büyük bir artış beklenmektedir.
- MAPE değeri %9.33 olduğu için modelin doğruluğu oldukça iyidir.
- Ancak belirsizlik aralığı genişlediği için uzun vadeli tahminlerin güvenilirliği azalmaktadır.

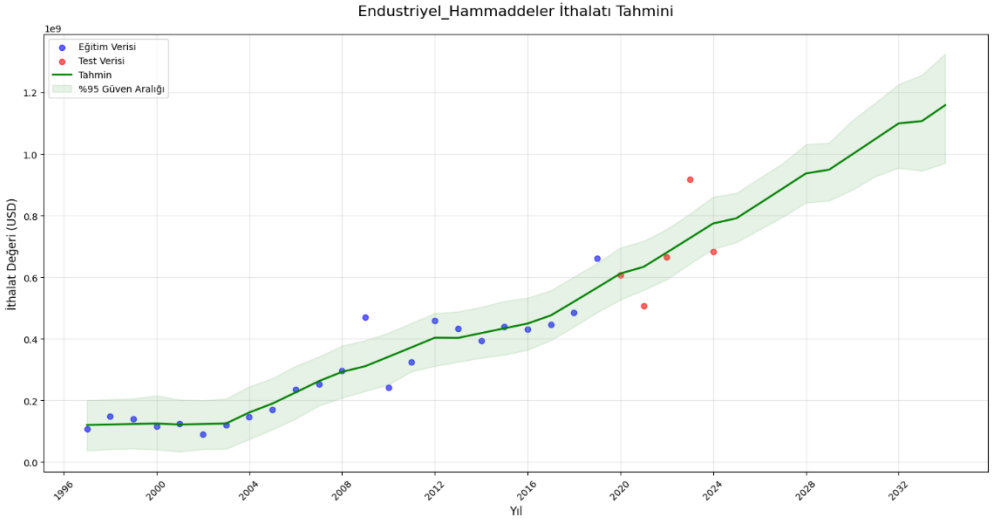
Endüstriyel Hammaddelerin Test dönemi kıyaslamaları ve 10 yıllık tahminleri sunulmaktadır (Tablo 1- Tablo 2).

Tablo 1. Endüstriyel Hammaddeler için Test Dönemi Karşılaştırması (2019-2023):

Yıl	Gerçek Değer	Tahmin	Alt Sınır	Üst Sınır
2019	1022.28	1026.25	970.81	1078.76
2020	932.05	1059.69	998.83	1119.69
2021	1249.5	1121.6	1052.06	1193.55
2022	1485.82	1156.38	1073.9	1246.68
2023	1191.69	1189.95	1087.53	1301.72

Tablo 2. Endüstriyel Hammaddeler için 10 Yıllık Tahminler (2024-2033):

Yıl	Tahmin (Milyon USD)	Alt Sınır (Milyon USD)	Üst Sınır (Milyon USD)
2024	1253.21	1100.56	1416.06
2025	1282.77	1102.34	1459.32
2026	1310.87	1086.6	1511.63
2027	1337.45	1084.93	1578.77
2028	1414.53	1118.9	1682.8
2029	1442.75	1107.59	1748.77
2030	1469.41	1099.51	1814.09
2031	1494.46	1078.76	1871.08
2032	1575.85	1117.29	1997.96
2033	1602.73	1081.24	2059.32



Şekil 8. Endüstriyel Hammaddelerin 10 yıllık ithalat tahminleri

- Model, geçmiş verilere iyi uyum sağlamış ve gelecekte ithalat değerlerinin artacağını öngörmektedir.
- 2020 sonrası tahminlerde bazı sapmalar mevcut, ancak genel trendi yakalamış görünmektedir.
- Gelecekte tahmin belirsizliği artıyor, bu da modelin uzun vadeli tahminlerinin daha az güvenilir olabileceğini göstermektedir.
- 2024-2025 yıllarında tahmin edilen değerler test verileriyle oldukça uyumlu, ancak ilerleyen yıllarda sapma oranı artabilir.

Endüstriyel Hammaddelerin test dönemi kıyaslamaları ve 10 yıllık tahminleri sunulmaktadır (Tablo 3- Tablo 4).

Tablo 3. Endüstriyel Hammaddeler Test Tahminleri:


Yıl	Gerçek Değer	Tahmin	Alt Sınır	Üst Sınır
2019	606683793.0	611883419.56	526383333.38	695602183.06
2020	507428976.0	633552331.17	558440793.6	717471460.35
2021	666533089.0	680041634.44	592454448.37	755852873.08
2022	917580001.0	726980502.02	643325941.74	805813327.55
2023	682955417.0	774296527.7	691103052.53	860608406.88

Tablo 4. Endüstriyel Hammaddeler Gelecek 10 Yıl Tahminleri:

Yıl	Tahmin	Alt Sınır	Üst Sınır
2024	791232261.44	713006602.67	873142342.2
2025	839384321.52	754376903.68	921584508.91
2026	887901555.28	795181217.5	969869070.65
2027	936709635.84	841838567.16	1030737768.21
2028	948912191.72	848072647.88	1036406746.27
2029	998727008.61	883198083.85	1108680527.95
2030	1048822608.53	927297211.92	1166426781.7
2031	1099122743.98	954666153.66	1226013640.75
2032	1106592121.99	945276725.59	1256239622.51
2033	1158069695.7	969968932.42	1324686937.66

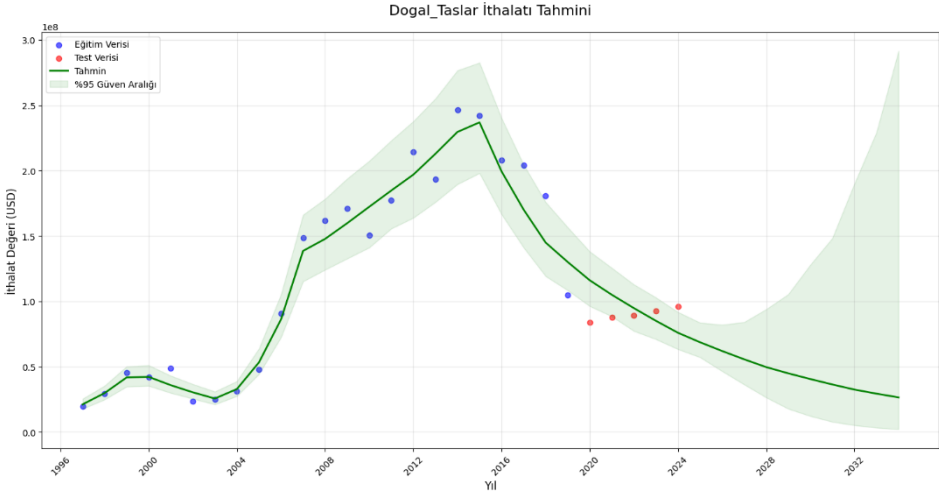
Doğal Taşlar

Doğal Taşlar 10 yıllık ihracat (Şekil 9) ve ithalat (Şekil 10) tahminleri sunulmaktadır.



Şekil 9. Doğal Taşlar 10 yıllık ihracat tahminleri

- Model, 2024 ten itibaren düşüş eğilimi gösteriyor. Ancak geçmiş verilerde böyle bir trend yok, bu yüzden modelin burada hatalı olabileceği düşünülmelidir.
- MAPE değeri %13.15, yani modelin hata oranı makul ama gelecekteki düşüş tahmini sorgulanmalıdır.
- Geniş tahmin aralığı, modelin uzun vadede belirsiz olduğunu göstermektedir.



Şekil 10. Doğal Taşlar 10 yıllık ithalat tahminleri

- Model, 2005-2018 arasındaki artışı ve 2018 sonrası düşüşü başarılı bir şekilde yakalamıştır.
- 2020 ve sonrası için model, ithalatın daha hızlı düşeceğini tahmin ederken, test verileri biraz daha yüksek seviyededir. Bu, modelin düşüşü biraz fazla tahmin ettiğini göstermektedir.
- Güven aralığı zamanla genişliyor, özellikle 2030 sonrası belirsizlik artıyor. Model uzun vadede düşüş tahmin etse de bu kesin bir sonuç değildir.

Doğal taşların ihracat Test dönemi kıyaslamaları ve 10 yıllık tahminleri sunulmaktadır (Tablo 5- Tablo 6).

Tablo 5. Doğal Taşlar için Test Dönemi Karşılaştırması (2019-2023):

Yıl	Gerçek Değer	Tahmin	Alt Sınır	Üst Sınır
2019	2728.67	1920.21	1810.74	2035.68
2020	1744.49	1890.07	1777.26	2009.84
2021	2107.53	1892.71	1749.03	2022.58
2022	2111.65	1862.19	1701.0	2028.4
2023	1944.31	1831.86	1646.51	2028.58

Tablo 6. Doğal Taşlar için 10 Yıllık Tahminler (2024-2033):

Yıl	Tahmin (Milyon USD)	Alt Sınır (Milyon USD)	Üst Sınır (Milyon USD)
2024	1771.78	1491.0	2070.1
2025	1742.06	1377.72	2086.44
2026	1712.56	1309.11	2132.04
2027	1683.29	1202.18	2178.23
2028	1683.43	1147.74	2244.32
2029	1653.71	996.79	2318.86
2030	1624.21	884.68	2324.23
2031	1594.94	794.22	2426.78
2032	1595.08	709.01	2504.64
2033	1565.35	588.2	2553.41

Doğal taşların ithalat Test dönemi kıyaslamaları ve 10 yıllık tahminleri sunulmaktadır (Tablo 7- Tablo 8).

Tablo 7. Doğal Taşlar Test Tahminleri:


Yıl	Gerçek Değer	Tahmin	Alt Sınır	Üst Sınır
2019	83826055.0	116134042.95	96339888.54	138121013.12
2020	87837679.0	105038744.63	88503780.85	125580857.98
2021	89120033.0	94837575.07	77306158.89	112932232.9
2022	92698082.0	85135115.11	71040836.37	102964805.95
2023	95851855.0	75993883.66	63411055.64	91822895.48

Tablo 8. Doğal Taşlar Gelecek 10 Yıl Tahminleri:

Yıl	Tahmin	Alt Sınır	Üst Sınır
2024	68724329.59	57213540.11	83684831.57
2025	62044473.25	46608309.75	82123257.52
2026	55699431.74	36424093.49	84090678.39
2027	49727626.74	26487623.68	93950006.38
2028	44964679.28	17843854.38	105415467.22
2029	40590627.15	12257513.4	127931426.96
2030	36441210.91	7882251.04	148332915.03
2031	32539945.76	5237051.52	189915577.29
2032	29419310.27	3381995.83	229281788.68
2033	26555129.22	2161470.14	291471830.9

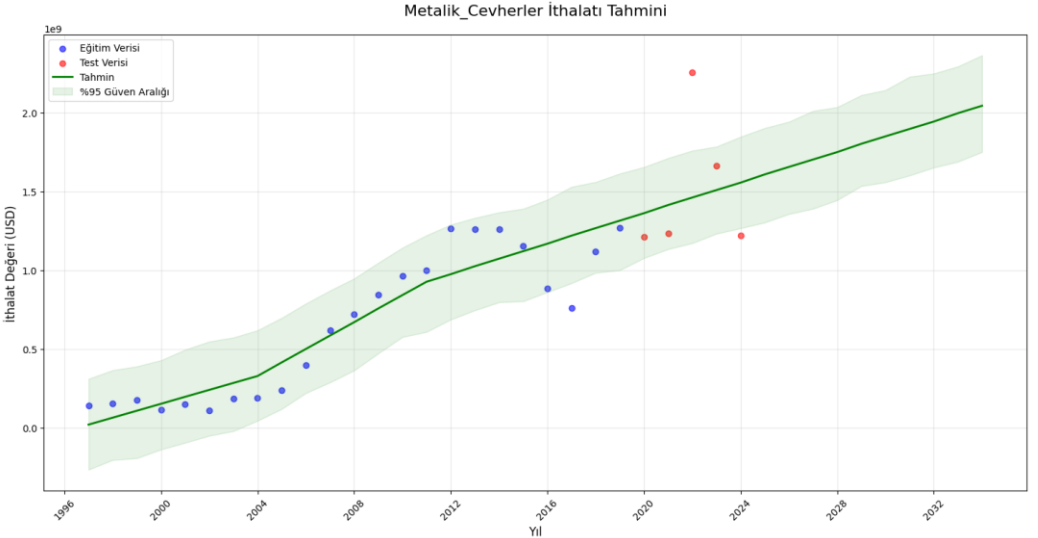
Metalik Madenler

Metalik Madenler 10 yıllık ihracat (Şekil 11) ve ithalat (Şekil 12) tahminleri sunulmaktadır.



Şekil 11. Metalik Madenler 10 yıllık ihracat tahminleri

- Model, 2024-2033 yıllarında artış bekliyor. Bu, geçmiş eğilimlerle tutarlı görünmektedir.
- MAPE %16.22, yani model orta derecede doğruluk göstermektedir.
- Ancak tahmin aralığı genişlediği için belirsizlik fazladır.
- 2028 sonrası tahminlerde ani sıçramalar var, bu modelin fazla iyimser olduğunu gösterebilir.



Şekil 12. Metalik Madenler 10 yıllık ithalat tahminleri

- Model, geçmiş verilere oldukça iyi uyum sağlamış ancak 2020 sonrası test verileri ile tahminlerde bazı farklılıklar vardır.

- Özellikle 2020 ve 2021 yıllarında modelin tahmini, gerçek ithalat değerlerinden düşük kalmıştır.
- Model uzun vadede ithalatın artacağını tahmin ediyor, ancak güven aralığının genişlemesi nedeniyle 2030 sonrası tahminlerin belirsizliği yüksektir.
- Metalik Madenler Test dönemi kıyaslamaları ve 10 yıllık tahminleri sunulmaktadır (Tablo 9- Tablo 10).

Tablo 9. Metalik Madenler için Test Dönemi Karşılaştırması (2019-2023):

Yıl	Gerçek Değer	Tahmin	Alt Sınır	Üst Sınır
2019	1218.09	1557.03	1236.41	1923.63
2020	1375.16	1572.42	1239.38	1883.76
2021	2162.02	1819.25	1485.82	2151.87
2022	2185.41	1834.13	1497.92	2152.94
2023	1982.65	1844.24	1512.36	2174.11

Tablo 10. Metalik Madenler için 10 Yıllık Tahminler (2024-2033):

Yıl	Tahmin (Milyon USD)	Alt Sınır (Milyon USD)	Üst Sınır (Milyon USD)
2024	1850.61	1527.07	2214.65
2025	1847.12	1506.75	2183.7
2026	1839.36	1514.44	2181.04
2027	1827.5	1477.19	2189.94
2028	2118.01	1791.43	2453.83
2029	2104.71	1766.88	2450.64
2030	2087.24	1747.28	2419.05
2031	2065.76	1731.35	2378.71
2032	2385.4	2044.52	2707.4
2033	2362.31	2034.8	2688.14

Metalik Madenler Test dönemi kıyaslamaları ve 10 yıllık tahminleri sunulmaktadır (Tablo 11- Tablo 12).

Tablo 11. Metalik Cevherler Test Tahminleri:


Yıl	Gerçek Değer	Tahmin	Alt Sınır	Üst Sınır
2019	1211136208.0	1360786436.56	1075838763.77	1653652614.96
2020	1230674524.0	1412729276.07	1132179336.49	1710641189.42
2021	2254981270.0	1460238540.2	1170358229.24	1758082497.58
2022	1661489855.0	1507541202.23	1230246754.34	1783341953.94
2023	1217685641.0	1554625472.5	1265168298.89	1845841827.1

Tablo 12. Metalik Cevherler Gelecek 10 Yıl Tahminleri:

Yıl	Tahmin	Alt Sınır	Üst Sınır
2024	1607033685.9	1301310239.8	1901304006.83
2025	1654405514.25	1355192956.3	1941210033.96
2026	1701552989.57	1388853760.7	2009960908.95
2027	1748464511.01	1443239014.77	2033885139.94
2028	1801338095.73	1532580078.28	2110050548.83
2029	1848572488.31	1556957584.4	2142266690.18
2030	1895564776.91	1600138786.94	2226935903.81
2031	1942303549.51	1650122710.91	2247367274.34
2032	1995642505.55	1687040514.53	2292518308.0
2033	2042739462.37	1748819308.97	2363010938.63

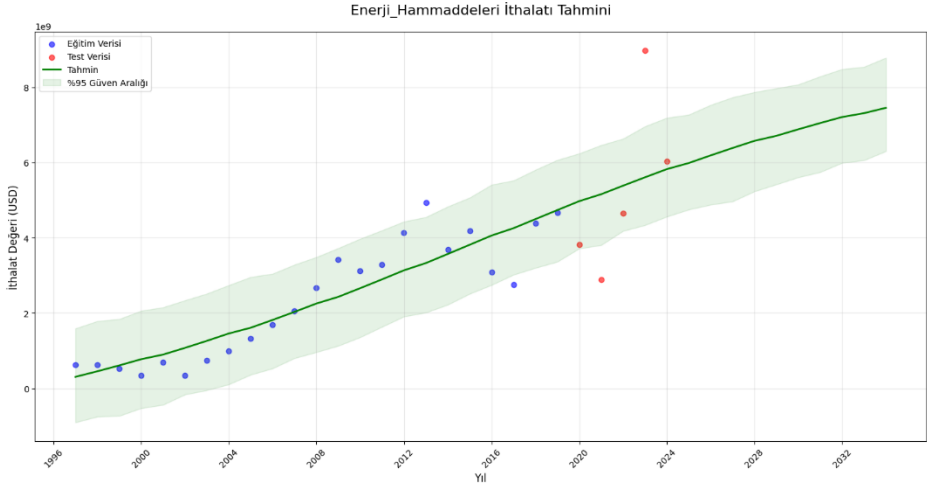
Enerji Hammaddeleri

Enerji Hammaddeleri 10 yıllık ihracat (Şekil 13) ve ithalat (Şekil 14) tahminleri sunulmaktadır.



Şekil 13. Enerji Hammaddeleri 10 yıllık ihracat tahminleri

- Model, geçmişte yaşanan büyük dalgalanmaları yakalayamıyor.
- MAPE %65,11, yani model çok kötü performans göstermektedir.
- Uzun vadeli tahminler düşük büyüme öngörüyor, ancak bu tahminler güvenilir görünmektedir.
- Modelin yeniden eğitilmesi ve optimizasyonu gerekebilir.



Şekil 14. Enerji Hammaddeleri 10 yıllık ithalat tahminleri

- Model geçmiş verilere oldukça iyi uyum sağlamış ancak 2020 sonrası test verileri ile tahminlerde belirgin farklılıklar vardır.
- Özellikle 2020 ve 2021 yıllarında modelin tahmini, gerçek ithalat değerlerinden büyük sapmalar göstermektedir.
- Model uzun vadede ithalatın artacağını tahmin ediyor, ancak bazı test verileri ile tahminler arasında büyük farklar vardır.

Enerji hammaddeleri Test dönemi kıyaslamaları ve 10 yıllık tahminleri sunulmaktadır (Tablo 13- Tablo 14).

Tablo 13. Enerji Hammaddeleri için Test Dönemi Karşılaştırması (2019-2023):

Yıl	Gerçek Değer	Tahmin	Alt Sınır	Üst Sınır
2019	10.31	17.97	9.94	26.18
2020	15.93	18.75	10.27	27.25
2021	48.98	19.53	11.52	27.8
2022	182.13	20.31	12.11	28.97
2023	136.8	21.09	12.93	29.36

Tablo 14. Enerji Hammaddeleri için 10 Yıllık Tahminler (2024-2033):

Yıl	Tahmin (Milyon USD)	Alt Sınır (Milyon USD)	Üst Sınır (Milyon USD)
2024	22.65	14.79	30.8
2025	23.43	16.2	30.94
2026	24.21	16.7	32.21
2027	24.99	17.51	33.15
2028	25.77	17.87	33.4
2029	26.55	18.6	34.21
2030	27.33	19.26	35.61

2031	28.11	19.71	35.76
2032	28.89	20.69	36.58
2033	29.67	21.93	38.02

Enerji hammaddeleri Test dönemi kıyaslamaları ve 10 yıllık tahminleri sunulmaktadır (Tablo 15- Tablo 16).

Tablo 15. Enerji Hammaddeleri Test Tahminleri:

Yıl	Gerçek Değer	Tahmin	Alt Sınır	Üst Sınır
2019	3814625135.0	4970836974.86	3711832453.12	6237844620.69
2020	2890435815.0	5155187454.62	3803508944.96	6460237018.27
2021	4655088458.0	5381712163.79	4177453090.9	6629736959.21
2022	8982220396.0	5604072339.53	4333197333.86	6957311072.32
2023	6031638855.0	5821691840.66	4558959828.55	7185540934.49

Tablo 16. Enerji Hammaddeleri Gelecek 10 Yıl Tahminleri:

Yıl	Tahmin	Alt Sınır	Üst Sınır
2024	5983959054.65	4747370923.69	7268258565.12
2025	6186362910.45	4876879342.54	7526876308.66
2026	6382799246.0	4963524439.42	7729064756.54
2027	6572990280.04	5230162632.48	7865764736.3
2028	6706543005.95	5415167255.69	7970162112.8
2029	6879396558.22	5603909949.32	8069696680.94
2030	7045651482.27	5741359390.36	8284956458.51
2031	7205296350.95	5986840314.99	8477279296.43
2032	7308101821.26	6056685483.17	8538379803.97
2033	7450401862.02	6297769643.02	8780545429.18

Tablo 17. Başarım Ölçütleri (İhracat verileri)

Maden Grubu	MAPE (%)	MAE	RMSE
Endüstriyel Hammaddeler	9.33	118,135,588.70	168,045,220.94
Doğal Taşlar	13.15	306,153,140.03	398,953,398.09
Metalik Madenler	16.22	273,730,324.71	287,691,863.31
Enerji Hammaddeleri	65.11	63,491,383.28	90,008,589.92

- Endüstriyel Hammaddeler için tahmin modeli, en iyi performansı göstermektedir. MAPE düşük (%9.33) (Tablo 17).
- Doğal Taşlar ve Metalik Madenler için modeller makul ancak doğrulukları çok yüksek değildir.
- Enerji Hammaddeleri için model çok kötü performans göstermektedir (MAPE %65.11). Model, gerçek değerlerle neredeyse hiçbir ilişki kuramamaktadır.

Tablo 18. Başarım Ölçütleri (İthalat verileri)

Kategori	MAE	RMSE	MAPE (%)
Endüstriyel Hammaddeler	85354427.37	110261493.87	11.28
Doğal Taşlar	16529506.78	19099269.75	20.52
Metalik Cevherler	323467238.94	406050186.06	19.32
Enerji Hammaddeleri	1547136451.22	1920930496.29	29.33

- Endüstriyel Hammaddeler için tahmin modeli, en iyi performansı göstermektedir. Modelin MAE değeri 85.35M olup, ortalama hata kabul edilebilir seviyededir. MAPE değeri %11,28 olarak hesaplanmış, bu da modelin tahminlerinde ortalama %11.28 hata yaptığı anlamına gelmektedir (Tablo 18).
- Genel olarak model, tarihsel eğilimleri yakalayabilmiş ancak hata oranları optimize edilmelidir.

Sonuç ve Tartışma

Farklı sektörlerdeki hammaddelerin dış ticaret verilerinin incelendiği bu çalışmada, zaman serileri modelleriyle gelecek projeksiyonu oluşturulmaktadır. Elde edilen bulgular; hız kazanan endüstriyel faaliyetler ve yenilenebilir enerji yatırımlarının, hammadde talebini küresel ölçekte dramatik bir şekilde artıracığını göstermektedir. Bu doğrultuda, özellikle endüstriyel hammaddelerin ithalat ve ihracat değerlerinde öngörülen ivmelenme, bu malzemelerin stratejik kritikliğini ve tedarik zinciri güvenliği ile çevresel sürdürülebilirlik eksenindeki risk yönetiminin önemini bir kez daha ortaya koymaktadır. Sektör bazında yapılan modellemelerde; Metalik Cevherler ve Enerji Hammaddeleri gruplarında talebin yukarı yönlü bir trend izleyeceği tahmin edilmiştir. Ancak, Enerji Hammaddeleri modelindeki yüksek hata oranları tahminlerin güvenilirliğini kısıtlarken; Doğal Taşlar grubu için kurulan model istatistiksel olarak yetersiz kalmış ve yeniden modelleme ihtiyacı doğurmuştur. Metalik Cevherler modelinin öngörü performansını artırmak adına ise ileri düzey veri ön işleme adımlarına gereksinim duyulmaktadır.

Sonuç olarak, projeksiyonların doğruluğunu ve açıklayıcılık gücünü artırmak amacıyla; elektrikli araçlar, batarya üretimi ve yeşil enerji yatırımları gibi makro-sektörel dinamiklerin dışsal değişken olarak modellere entegre edilmesi, veri setlerinin genişletilmesi ve büyük veri analitiği çatısı altında hibrit/kombinasyonel zaman serisi algoritmalarının otomatik optimizasyon araçlarıyla test edilmesi önerilmektedir.


Teşekkür

Bu çalışma, Munzur Üniversitesi Bilimsel Araştırma Projeleri Birimi tarafından desteklenmiştir. Proje No: İHTS2023-06.

Kaynakça

- Bayar, G., & Tokpunar, S. (2014). Türkiye İmalat Sanayi Sektörlerinin İhracatı-Zaman Serisi Analizi. *Sosyoekonomi*, 21(21).
- Dar, A. A., Jain, A., Malhotra, M., Farooqi, A. R., Albalawi, O., Khan, M. S., & Hiba. (2024). Time Series analysis with ARIMA for historical stock data and future projections. *Soft Computing*, 1-12.
- Duran, H. E. (2016). Türkiye’de aramalı, hammadde ithalatı ve ekonomik büyüme. *Gazi İktisat ve İşletme Dergisi*, 2(3), 89-104.
- Gao, D., Kinouchi, Y., Ito K., and Zhao, X., 2003. Time Series Identifying and Modeling with Neural Networks.
- Göçmen, E. (2022). Linear programming with fuzzy parameters for inventory routing problem in effective management of personal protective equipment: a case study of corona virus disease 2019. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, 44(4), 9217-9231.
- Göçmen-Polat, E. (2024). Assessment of Critical Raw Materials by Addressing Sustainable Development Goals Using Fuzzy MCDM Approach. In *Harmonizing Global Efforts in Meeting Sustainable Development Goals* (pp. 164-181). IGI Global.
- Güner, Ş. N., & Demir, H. U. (2022). Yapay sinir ağları ve zaman serileri yöntemi ile demir çelik ithalatı tahmini. *Sakarya İktisat Dergisi*, 11(3), 389-397.
- Maleki, N., Lundström, O., Musaddiq, A., Jeansson, J., Olsson, T., & Ahlgren, F. (2024). Future energy insights: Time-series and deep learning models for city load forecasting. *Applied Energy*, 374, 124067.
- Merdan, K. (2023). Türkiye’de Şekerin Zaman Serileri Analizine Göre Gelecek Eğilimlerinin Belirlenmesi. *Hacettepe Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 41(3), 497-532.
- Palit, A.K., Popovic, D., 2005. *Computational Intelligence in Time Series Forecasting: Theory and Engineering Applications*. Springer-Verlag.
- Polat, E. G. Assessing the Roles of Raw Materials in Sustainable Development Goals: Current Situation and Future Prospects. *International Scientific and Vocational Studies Journal*, 7(2), 176-186.
- Polat, E. G., Yücesan, M., & Gül, M. (2023). A comparative framework for criticality assessment of strategic raw materials in Turkey. *Resources Policy*, 82, 103511.
- Polat, E., & Polat, E. G. (2024, November). Predicting and optimizing maximum flexural strength of planar composite plate shear walls–concrete filled with the application of LR and RSM. In *Structures* (Vol. 69, p. 107353). Elsevier.

- Say, H. M., Öner, M., & Polat, E. G. (2024). İkiz dönüşüm kapsamında kritik hammadde ve teknolojilerinin zaman serileri analizi. *Journal of Research in Business*, 9(2), 519-539.
- Uçan, O., & Saraç, M. (2020). İthalat, döviz kuru ve ekonomik büyüme arasındaki ilişkinin zaman serisi analizi: Türkiye örneği (1994-2018). *Ömer Halisdemir Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 13(4), 696-708.
- Uçum, İ. (2016). ARIMA modeli ile Türkiye soya üretim ve ithalat projeksiyonu. *Tarım Ekonomisi Araştırmaları Dergisi*, 2(1), 24-31.



Statistics-Driven Decision Modeling For Earthquake Damage Vulnerability in Disaster Management

Ezgi Güler¹

1. INTRODUCTION

Disasters are natural or human-induced events that interrupt normal life and cause severe physical, economic, and social losses, with earthquakes standing out due to their high destructive potential and wide spatial impact (Erkal and Değerliyurt, 2009; Kamranzad et al., 2020). Effective disaster management relies on proactive planning across the four key phases—mitigation, preparedness, response, and recovery—to minimize vulnerabilities and ensure coordinated crisis handling (Karaman, 2017). Accordingly, industrial engineering and operations research methods have increasingly been applied to support complex decision-making processes in disaster management.

Risk and vulnerability assessments play a crucial role, particularly during the mitigation and preparedness phases of disaster management. Conducting detailed risk analyses for specific regions enables more precise planning, thereby reducing potential losses and the severity of adverse impacts. Such assessments also support more effective response and recovery strategies following disaster events. Motivated by this need, the present study is grounded in a hybrid decision-making framework designed to enhance the evaluation of disaster-related risks. The main objective of the study is to examine earthquake damage vulnerability for provinces in Türkiye with high seismic risk by employing multi-criteria decision-making approaches and to statistically analyze the obtained findings.

2. MATERIAL AND METHODS

For the earthquake vulnerability assessment, provinces with high seismic hazard levels were first identified. Based on the Active Fault Map published by the General Directorate of Mineral Research and Exploration (MTA), provinces

¹ Asst. Prof. Dr., Department of Industrial Engineering, Faculty of Engineering, Bilecik Şeyh Edebali University, 0000-0001-8789-8244

whose administrative centers are intersected by active faults were classified as high earthquake-risk areas in Table 1 (MTA, 2024). This section presents the methodological framework employed to evaluate earthquake damage vulnerability and to analyze this vulnerability using Multi-Criteria Decision-Making (MCDM) approaches.

2.1. Earthquake Damage Vulnerability Assessment

Vulnerability analyses constitute a critical component of earthquake risk reduction and inherently require an interdisciplinary perspective involving geosciences, structural engineering, architecture, urban planning, and related fields. Within this scope, previous studies that address earthquake damage vulnerability through Multi-Criteria Decision-Making (MCDM) approaches—one of the core domains of industrial engineering—are briefly reviewed, covering the period between 2014 and 2024.

Recent studies on earthquake damage vulnerability assessment predominantly employ integrated MCDM and GIS-based frameworks—ranging from FAHP, AHP, TOPSIS, VIKOR, Grey Relational Analysis, ANN hybrids, and dominance-based models—to weight criteria, map spatial risk, and compare regional seismic sensitivities (Shayannejad and Angerabi, 2014; Karimzadeh et al., 2014; Peng, 2015; Sadrykia et al., 2017; Rezaei and Tahsili, 2018; Yavuz Kumlu and Tüdeş, 2019; Yariyan et al., 2020; Shadman and Islam, 2021; Malakar and Rai, 2022; Özmen, 2024). The criteria employed for earthquake damage vulnerability assessment were determined based on expert judgments and relevant literature (Güler et al. 2021; Güler, 2024): Population Density (Tate, 2012; Yavaşoğlu and Özden, 2017; Yariyan et al., 2020; Jena et al., 2020(a)); Average Household Size (Yariyan et al., 2020; Jena et al., 2020(b)); Total Number of Dwellings (Jena et al., 2020(a)); Number of Industrial Establishments (Jena et al., 2020(a); Jena et al., 2020(b)); Gross Domestic Product (GDP) per capita (Peng, 2015; Murnane et al., 2017); Total Agricultural Area (Sinha et al., 2016).

The decision matrix constructed based on the criteria presented in Table 1 is provided in Table 1 (TURKSTAT, 2024).

Tablo 1. Decision Matrix for Provinces

Provinces	Population Density	Average Household Size	Total Number of Dwellings	Number of Industrial Establishments	Gross Domestic Product (GDP) per capita	Total Agricultural Area
Aksaray	56.542	3.3	103000	20593	64834	4104083
Aydın	141.479	2.77	328000	70139	57879	3693447
Bahkesir	86.237	2.61	377000	70426	72307	3908805.5
Bolu	38.593	2.83	71000	14539	92199	1107323
Bingöl	35.306	3.42	39000	8915	42850	686756
Burdur	38.160	2.63	71000	17377	66660	1576784.3
Bursa	295.452	3.14	754000	170950	96684	2996453.9
Denizli	87.056	2.85	288000	66883	77804	3690190.7
Eskişehir	64.944	2.62	274000	41671	91234	5478027.6
Erzincan	20.247	2.82	56000	9862	84864	1405189
Erzurum	29.983	3.51	130000	25640	46444	4194829
Hakkâri	38.807	4.55	24000	6633	44412	427582
Hatay	305.221	3.53	315000	76409	60937	2379336.8
İzmir	375.246	2.81	1265000	263875	104791	3418311.6
Kahramanmaraş	81.091	3.55	210000	44915	53862	3559292.3
Kayseri	84.945	3.22	376000	68403	75200	5366411
Kocaeli	612.032	3.24	481000	95491	153479	793596
Konya	56.231	3.26	584000	118578	65928	18896147
Kütahya	49.914	2.77	175000	26566	66915	3101750
Manisa	110.074	2.95	353000	76835	84229	5073527
Muğla	82.834	2.71	271000	77767	83892	2049976
Osmaniye	168.495	3.36	101000	22685	56185	1261406
Sakarya	223.897	3.22	240000	54242	77717	1747241.8
Tokat	59.396	2.96	139000	25454	40645	3137225.9

Using the decision matrix presented in Table 1, the evaluations were conducted through MCDM methods. The applied MCDM techniques are described in detail in the subsequent sections.

2.2. Analytic Hierarchy Process (AHP)

The Analytic Hierarchy Process (AHP), introduced by Saaty (1977), is a widely adopted MCDM method that structures decision problems hierarchically, derives criterion weights through expert-based pairwise comparisons, and facilitates the selection of the most beneficial alternative (Oral, Yumuşak and Eren, 2021; Deringöz et al., 2021; Ceylan and Gürsev, 2020).

Step 1: A hierarchical structure including the objective, criteria, and alternatives is first established for the decision problem.

Step 2: Pairwise comparison matrices are then constructed using Saaty's 1–9 scale, and when multiple experts are involved, their judgments are aggregated through the geometric mean to form a unified matrix (Equation 1) (Oral et al., 2021; Ceylan and Gürsev, 2020).

$$D = [d_{ij}]_{n \times n} \quad (1)$$

Step 3: The comparison matrix is column-normalized and the priority vector is computed as the mean of the normalized rows to obtain the relative criterion weights W_i (Oral et al., 2021).

Step 4: The maximum eigenvalue λ_{max} is obtained by multiplying the comparison matrix by the priority vector, forming the weighted sum vector, dividing each element by its corresponding weight, and averaging the resulting ratios (Uzun and Kazan, 2016).

Step 5: Consistency of judgments is assessed through the Consistency Index (CI) and Consistency Ratio (CR), computed as in Equations (2) and (3):

$$CI = (\lambda_{max} - n) / (n - 1) \quad (2)$$

$$CR = CI / RI \quad (3)$$

Here, n denotes the number of criteria and RI represents the Random Index, whose values are provided in the standard RI table (Saaty, 1977). A CR value below 0.10 indicates that the pairwise comparisons are sufficiently consistent for reliable decision-making.

2.3. Preference Ranking Organisation Method for Enrichment Evaluations (PROMETHEE)

PROMETHEE, proposed by Brans et al. (1984), ranks alternatives via pairwise comparisons based on criterion-specific preference functions (Dinçer et al., 2017). The main steps of the PROMETHEE procedure are summarized below:

Step 1: A decision matrix consisting of alternatives, evaluation criteria, and their corresponding weights is constructed. This matrix is also applicable for the other MCDM methods employed in the study.

Step 2: For each criterion, one of the six standard preference functions is selected to model the decision maker's preference structure.

Step 3: Based on the selected preference functions, aggregated preference indices are calculated for each pair of alternatives. The global preference function for the alternative pair (a, b) is determined using Equation (4).

$$p(a, b) = \begin{cases} 0, & f(a) \leq f(b) \\ P[f(a) - f(b), & f(a) \geq f(b) \end{cases} \quad (4)$$

Step 4: Based on the aggregated preference functions, preference indices are computed. For alternatives a and b , evaluated with respect to criterion i having weight w_i ($i = 1, 2, \dots, m$), the preference index is calculated using the formulation given in Equation (5).

$$\pi(a, b) = \frac{\sum_{i=1}^m w_i \times P_i(a, b)}{\sum_{i=1}^m w_i} \quad (5)$$

Step 5: The positive outranking flow (Φ^+) and the negative outranking flow (Φ^-) of each alternative are then determined.

$$\Phi^+(a) = \sum \pi(a, x), \quad x = (a, c, d \dots) \quad (6)$$

$$\Phi^-(a) = \sum \pi(x, a), \quad x = (b, c, d \dots) \quad (7)$$

Step 6: Partial preference relations are derived using PROMETHEE I. For any two alternatives, three possible cases are evaluated; if one of the conditions specified in Equation (8) is satisfied, alternative a is considered to outrank alternative b .

$$\begin{aligned} \Phi^+(a) > \Phi^+(b) \text{ ve } \Phi^-(a) < \Phi^-(b) \\ \Phi^+(a) > \Phi^+(b) \text{ ve } \Phi^-(a) = \Phi^-(b) \\ \Phi^+(a) = \Phi^+(b) \text{ ve } \Phi^-(a) < \Phi^-(b) \end{aligned} \quad (8)$$

-If the condition given in Equation (9) is satisfied, alternatives a and b are regarded as indifferent, indicating no preference difference between them.

$$\Phi^+(a) = \Phi^+(b) \text{ ve } \Phi^-(a) = \Phi^-(b) \quad (9)$$

If the condition specified in Equation (10) holds, the two alternatives are considered incomparable.

$$\begin{aligned} \Phi^+(a) > \Phi^+(b) \text{ ve } \Phi^-(a) > \Phi^-(b) \\ \Phi^+(a) < \Phi^+(b) \text{ ve } \Phi^-(a) < \Phi^-(b) \end{aligned} \quad (10)$$

Step 7: The complete ranking of alternatives is obtained by calculating the net outranking flows using Equation (11). The final ordering is then established by arranging these values in descending order (PROMETHEE II).

$$\Phi(a) = \Phi^+(a) - \Phi^-(a) \quad (11)$$

2.4. Vise Kriterijumska Optimizacija I Kompromisno Resenje (VIKOR)

The VIKOR method was introduced by Opricovic (1998) as a multi-criteria decision-making approach aimed at identifying the most appropriate alternative and a compromise solution in problems involving multiple evaluation criteria (Mardani et al., 2016). The main procedure of the VIKOR method is summarized as follows:

Step 1: For each criterion in the decision matrix, the best (f_i^*) and worst (f_i^-) values are determined. If a criterion has a positive (benefit-type) effect on the decision model, Equations (12) and (13) are applied; if the criterion has a negative (cost-type) impact, Equations (14) and (15) are used (where i denotes the criterion and j denotes the alternative).

$$f_i^* = \min f_{ij} \quad i = 1,2,3, \dots, n \quad (12)$$

$$f_i^- = \max f_{ij} \quad i = 1,2,3, \dots, n \quad (13)$$

$$f_i^* = \max f_{ij} \quad i = 1,2,3, \dots, n \quad (14)$$

$$f_i^- = \min f_{ij} \quad i = 1,2,3, \dots, n \quad (15)$$

Step 2: The decision matrix is first normalized and then weighted using the criterion weights (w_i). Subsequently, the group utility measure (S_j) and the individual regret measure (R_j) are calculated for each alternative.

$$S_j = \sum_{i=1}^n w_i \frac{(f_i^* - f_{ij})}{(f_i^* - f_i^-)} \quad j = 1,2,3 \dots, m \quad (16)$$

$$R_j = \max [w_i \frac{(f_i^* - f_{ij})}{(f_i^* - f_i^-)}] \quad j = 1,2,3 \dots, m \quad (17)$$

Step 3: Using Equation (18), the Q_j value for each alternative is calculated by combining maximum group utility and individual regret weights.

$$Q_j = v \frac{(S_j - S^*)}{(S^- - S^*)} + (1 - v) \frac{(R_j - R^*)}{(R^- - R^*)} \quad (18)$$

Where;

$$S^* = \min_j S_j, \quad S^- = \max_j S_j$$

$$R^* = \min_j R_j, \quad R^- = \max_j R_j$$

Step 4: The alternatives are ordered in ascending order according to their Q_j values.

Step 5: Validity conditions are then examined to verify whether the top-ranked alternative truly represents the best compromise solution. If these

conditions are satisfied, the alternative with the minimum Q value is accepted as the optimal choice.

2.5. TOPSIS (Technique for Order Preference by Similarity to Ideal Solution)

TOPSIS, proposed by Hwang and Yoon (1981), identifies the best alternative as the one closest to the positive ideal solution and farthest from the negative ideal solution (Özcan et al., 2017). The procedural steps of the TOPSIS method are summarized as follows:

Step 1: Once the decision matrix is formed, each element is normalized using the square root of the column-wise sum of squares to obtain matrix R (Equation (19)).

$$r_{ij} = \frac{f_{ij}}{\sqrt{\sum_{i=1}^m f_{ij}^2}} \quad (19)$$

Step 2: The weighted normalized decision matrix (V) is then constructed. After determining the relative importance weights of the evaluation criteria (w_i), each element of the normalized matrix R is multiplied by its corresponding criterion weight.

Step 3: The positive ideal solution (A^*) and the negative ideal solution (A^-) are subsequently derived using Equations (20) and (21). In these formulations, set I represents benefit (maximization) criteria, whereas set I' denotes cost (minimization) criteria.

$$A^* = \{(max_j v_{ij} \mid i \in I), (min_j v_{ij} \mid i \in I')\} \quad (20)$$

$$A^* = \{v_1^+, v_2^+, \dots, v_n^+\}$$

$$A^- = \{(min_j v_{ij} \mid i \in I), (max_j v_{ij} \mid i \in I')\} \quad (21)$$

$$A^- = \{v_1^-, v_2^-, \dots, v_n^-\}$$

Step 4: The separation measures from the positive ideal solution (S_j^+) and the negative ideal solution (S_j^-) are calculated using the formulations provided in Equations (22) and (23).

$$S_j^+ = \sqrt{\sum_{j=1}^n (v_{ij} - v_j^+)^2} \quad (22)$$

$$S_j^- = \sqrt{\sum_{j=1}^n (v_{ij} - v_j^-)^2} \quad (23)$$

Step 5: The relative closeness of each alternative to the ideal solution (RC) is computed using Equation (24). The alternatives are then ranked in descending

order of RC values, and the alternative with the highest score is identified as the most preferred option.

$$RC = \frac{S_j^-}{S_j^- + S_j^+} \quad (24)$$

2.6. Borda Count Technique

The Borda Count method, originally proposed by Jean-Charles de Borda in 1784, is a voting-based aggregation approach that enables the consolidation of multiple rankings into a single composite order (Meşe and Özdemir, 2022). The technique assumes equal importance for each ranking source and is favored for its simplicity and transparency in classification performance. In an evaluation involving m alternatives, the top-ranked alternative receives a score of $m-1$, the second-ranked alternative $m-2$, and so on, until the lowest-ranked alternative obtains a score of 0. The mathematical formulation of the method is presented in Equation (25).

$$b_i = \sum_{k=1}^n (M - r_{ik}) \quad (25)$$

Where;

r_{ik} : denotes the rank of the i -th alternative under the k -th criterion,

M : the total number of alternatives.

2.7. Kendall's Tau-b Correlation Coefficient

Kendall's Tau-b correlation coefficient, proposed by Kendall (1938), is a non-parametric measure used to examine the association between ordinal or ranked variables. The magnitude of the Kendall's Tau-b coefficient is interpreted as follows: values greater than 0.50 indicate a strong relationship, 0.36–0.49 an important relationship, 0.20–0.35 a moderate relationship, 0.10–0.19 a weak relationship, and values below 0.10 suggest no meaningful association. To compute the coefficient, the first data series is arranged in ascending order. For each observation Y_i in the second series, the number of subsequent values greater than $Y_i(a_i)$ and the number smaller than $Y_i(b_i)$ are counted. Summing these across all observations yields $N_a = \sum a_i$ and $N_b = \sum b_i$. The Kendall's Tau-b coefficient is then calculated using Equation (26), based on the difference between concordant and discordant pairs.

$$\tau = \frac{N_a - N_b}{N(N-1)/2} \quad (26)$$

3. RESULTS

3.1. Findings Obtained from the AHP Method

Within the scope of the study, a panel consisting of three decision-makers evaluated the earthquake damage vulnerability criteria using the scale presented in Table 2. The resulting weights of the evaluation criteria derived from the AHP analysis are given in Table 2.

Table 2. Criteria Weights Obtained from the AHP Method

Criteria	Weights (w_i)
Average Household Size	0.236
Total Number of Dwellings	0.172
Number of Industrial Establishments	0.099
Gross Domestic Product (GDP) per capita	0.130
Total Agricultural Area	0.066

In the PROMETHEE, VIKOR, and TOPSIS methods, the criterion weights obtained through the AHP approach were adopted. According to the AHP results, population density was identified as the most critical earthquake damage vulnerability criterion with a weight of 0.296, whereas total agricultural area was determined to be the least influential criterion with a weight of 0.066.

3.2. Findings from the PROMETHEE Method

Within the scope of the study, the Visual PROMETHEE software package was utilized to implement the PROMETHEE analysis. The preference function was specified as the Type V (linear) function, and all criteria were considered in a maximization sense. Based on the computations performed via the software, the ranking of alternatives derived from the PROMETHEE method is presented in Table 3.

Table 3. Ranking of Provinces Based on the PROMETHEE Method

Provinces	Rank	Provinces	Rank
Aksaray	17	Hatay	5
Aydın	8	İzmir	1
Bahkesir	6	Kahramanmaraş	15
Bolu	19	Kayseri	7
Bingöl	24	Kocaeli	2
Burdur	21	Konya	11
Bursa	3	Kütahya	16
Denizli	10	Manisa	4
Eskişehir	12	Muğla	13
Erzincan	22	Osmaniye	14
Erzurum	20	Sakarya	9
Hakkari	23	Tokat	18

According to the PROMETHEE results, İzmir was identified as the province with the highest earthquake damage vulnerability, whereas Bingöl ranked last among the evaluated provinces.

3.3. Findings from the VIKOR Method

Within the scope of the study, the parameter ν —representing the weight of the strategy that maximizes group utility—was set to 0.5, implying that the decision-maker group adopted a compromise-oriented stance. All criteria were treated as benefit-type (maximization) criteria. Based on the computations performed in Excel, the ranking results obtained from the VIKOR method are presented in Table 4.

Table 4. Ranking of Provinces Based on the VIKOR Method

Provinces	S_i	R_i	Q_i	Rank
Aksaray	0.840	0.278	0.842	17
Aydın	0.822	0.236	0.675	7
Balıkesir	0.844	0.263	0.793	14
Bolu	0.893	0.287	0.921	21
Bingöl	0.887	0.289	0.922	22
Burdur	0.944	0.287	0.969	23
Bursa	0.559	0.172	0.211	2
Denizli	0.823	0.263	0.772	12
Eskişehir	0.852	0.274	0.837	16
Erzincan	0.914	0.296	0.973	24
Erzurum	0.843	0.292	0.891	18
Hakkâri	0.750	0.287	0.790	13
Hatay	0.648	0.154	0.229	3
İzmir	0.442	0.212	0.244	4
Kahramanmaraş	0.788	0.266	0.751	11
Kayseri	0.763	0.264	0.721	10
Kocaeli	0.398	0.160	0.021	1
Konya	0.687	0.278	0.701	9
Kütahya	0.897	0.282	0.905	20
Manisa	0.774	0.251	0.687	8
Muğla	0.839	0.265	0.794	15
Osmaniye	0.797	0.222	0.605	6
Sakarya	0.728	0.194	0.445	5
Tokat	0.905	0.277	0.896	19

According to the VIKOR results, Kocaeli emerged as the province with the highest earthquake damage vulnerability, while Erzincan was identified as the least vulnerable among the evaluated provinces.

3.4. Findings from the TOPSIS Method

Within the scope of the study, all criteria were treated as benefit-oriented (maximization). Based on the calculations performed in Excel, the ranking results obtained from the TOPSIS method are presented in Table 5.

Table 5. Ranking of Provinces Based on the TOPSIS Method

Provinces	Sj+	Sj-	RC	Rank
Aksaray	0,220	0,022	0,090	17
Aydın	0,187	0,051	0,213	7
Balıkesir	0,199	0,043	0,178	11
Bolu	0,227	0,020	0,079	21
Bingöl	0,231	0,013	0,055	23
Burdur	0,228	0,012	0,050	24
Bursa	0,124	0,118	0,487	3
Denizli	0,202	0,038	0,159	12
Eskişehir	0,209	0,035	0,145	14
Erzincan	0,233	0,016	0,064	22
Erzurum	0,226	0,020	0,083	19
Hakkâri	0,231	0,030	0,117	16
Hatay	0,148	0,097	0,396	4
İzmir	0,092	0,171	0,650	2
Kahramanmaraş	0,208	0,032	0,134	15
Kayseri	0,198	0,045	0,185	10
Kocaeli	0,096	0,198	0,673	1
Konya	0,194	0,078	0,286	6
Kütahya	0,219	0,021	0,086	18
Manisa	0,192	0,049	0,202	9
Muğla	0,204	0,038	0,155	13
Osmaniye	0,194	0,050	0,203	8
Sakarya	0,171	0,070	0,292	5
Tokat	0,219	0,019	0,080	20

According to the TOPSIS results, Kocaeli was identified as the province with the highest earthquake damage vulnerability, whereas Burdur ranked last among the evaluated provinces.

3.5. Findings Obtained from the Borda Count Technique

The final ranking obtained by aggregating the results of the PROMETHEE, TOPSIS, and VIKOR methods through the Borda count technique is presented in Table 6.

Table 6. Final Ranking of Provinces Based on the Borda Count Technique

Provinces / MCDM	PROMETHEE	TOPSIS	VIKOR	Total Borda Score	Final Rank
	Borda Value	Borda Value	Borda Value		
Aksaray	7	7	7	21	16
Aydın	16	17	17	50	7
Balıkesir	18	13	10	41	11
Bolu	5	3	3	11	21
Bingöl	0	1	2	3	24
Burdur	3	0	1	4	22
Bursa	21	21	22	64	3
Denizli	14	12	12	38	12
Eskişehir	12	10	8	30	15
Erzincan	2	2	0	4	22
Erzurum	4	5	6	15	19
Hakkâri	1	8	11	20	17
Hatay	19	20	21	60	4
İzmir	23	22	20	65	2
Kahramanmaraş	9	9	13	31	13

Kayseri	17	14	14	45	9
Kocaeli	22	23	23	68	1
Konya	13	18	15	46	8
Kütahya	8	6	4	18	18
Manisa	20	15	16	51	6
Muğla	11	11	9	31	13
Osmaniye	10	16	18	44	10
Sakarya	15	19	19	53	5
Tokat	6	4	5	15	19

After aggregating the results of all applied MCDM methods using the Borda count technique, Kocaeli emerged as the province with the highest earthquake damage vulnerability, whereas Bingöl ranked last in the final ordering. Additionally, Muğla–Kahramanmaraş, Erzincan–Burdur, and Erzurum–Tokat were identified as tied groups occupying the same rank positions.

3.6. Findings from Kendall’s Tau-b Correlation Coefficient Analysis

Kendall’s Tau-b correlation coefficients were computed in SPSS to examine the pairwise associations among the rankings obtained from different methods. The correlation results indicate strong and positive relationships between all MCDM-based rankings (PROMETHEE–TOPSIS: 0.754; PROMETHEE–VIKOR: 0.667; TOPSIS–VIKOR: 0.870), demonstrating a high level of consistency and mutual support among the applied techniques. Similarly, strong positive correlations were observed between the Borda count results and the individual MCDM rankings, confirming the robustness of the aggregated ordering. According to the final Borda ranking, Kocaeli was identified as the province with the highest earthquake damage vulnerability, whereas Bingöl occupied the last rank.

4. DISCUSSION

The results demonstrate that the proposed statistics-driven hybrid MCDM framework provides a robust and consistent approach for assessing earthquake damage vulnerability in disaster management. The convergence of PROMETHEE, VIKOR, and TOPSIS rankings—supported by strong Kendall’s Tau-b correlations—confirms the reliability of the integrated model, highlighting population density, housing stock, and industrial concentration as key amplifiers of vulnerability. The identification of Kocaeli and other highly urbanized provinces as the most vulnerable regions emphasizes the critical role of exposure and socio-economic accumulation alongside seismic hazard characteristics. Overall, the findings indicate that data-driven multi-criteria decision models can effectively support proactive mitigation and preparedness strategies by enabling policymakers to prioritize high-risk regions in a systematic and evidence-based manner.


Acknowledgement: This study was derived from the doctoral dissertation completed by Ezgi Güler in 2024, entitled “Evaluation of temporary shelter areas with GIS-Intuitionistic fuzzy multi-criteria approach and proposal of a mathematical model for evacuation optimization” In addition, a part of this research was submitted to the BAP Project of Kocaeli University.

REFERENCES

- Brans, J.P., Mareschal, B., Vincke, P. (1984). PROMETHEE: a new family of outranking methods in multicriteria analysis. In: Brans, J.P. (ed.) *Operational Research*. IFORS, 84, 477–490. North Holland, Amsterdam.
- Ceylan, Z., Gürsev, S. (2020). AHP ve TOPSIS Yöntemleri ile Bilgi Teknolojileri Projelerinde Scrum-Kanban-Şelale Uygulamaları Karşılaştırması. *Bilişim Teknolojileri Dergisi*, 13(3), 329-339.
- Deringöz, A., Danışan, T., Eren T. (2021). Endüstriyel giyilebilir teknolojilerin ÇKKV yöntemleri ile değerlendirilmesi ve seçimi. *Ergonomi*, 4(1), 10-21.
- Dinçer, S. E., Ekin, E., Karakaş, K. S. (2017). Promethee yöntemiyle uçak komponentlerinin önceliklendirilmesi problemlerine çözüm yaklaşımı. *Social Sciences Research Journal*, 6(3), 106-125.
- Erkal, T., & Değerliyurt, M. (2009). Türkiye’de afet yönetimi. *Doğu Coğrafya Dergisi*, 14(22), 147-164.
- Güler, E., Avcı, S., & Aladağ, Z. (2021). Türkiye’de illerin deprem hasar görebilirlik sıralamasında çok kriterli karar verme tekniklerinin başarısının copeland yöntemi ile değerlendirilmesi. *Journal Of Industrial Engineering (Turkish Chamber Of Mechanical Engineers)*, 32(3), 414-437.
- Güler, E. (2024). Geçici barınma alanlarının CBS-sezgisel bulanık çok kriterli yaklaşım ile değerlendirilmesi ve tahliye optimizasyonu için matematiksel model önerisi. Yayınlanmamış doktora tezi. Kocaeli Üniversitesi, Kocaeli, Türkiye.
- Hwang, C. L., & Yoon, K. (1981). *Multiple attribute decision making: Methods and applications*. Berlin: Springer.
- Jena, R., Pradhan, B., Beydoun, G., Nizamuddin, Ardiansyah, Sofyan, H., & Affan, M. (2020(a)). Integrated model for earthquake risk assessment using neural network and analytic hierarchy process: Aceh province, Indonesia. *Geoscience Frontiers*, 11(2), 613-634.
- Jena R., Pradhan, B., & Beydoun, G. (2020(b)). Earthquake vulnerability assessment in Northern Sumatra province by using a multicriteria decision-making model. *International Journal of Disaster Risk Reduction*, 46, 1-14.
- Kamranzad, F., Memarian, H., & Zare, M. (2020). Earthquake risk assessment for Tehran, Iran. *ISPRS International Journal of Geo-Information*, 9(7), 430.
- Karaman, Z. T. (2017). Afet Yönetimine Giriş ve Türkiye’de Örgütlenme. *Bütünleşik Afet Yönetimi* (Ed. Zerrin Toprak Karaman, Asuman Altay), Birleşik Matbaacılık, İzmir, 1-39.
- Karimzadeh, S., M. Miyajima, R. Hassanzadeh, R. Amiraslzadeh, B. Kamel (2014). A GIS-based seismic hazard, building vulnerability and human loss

- assessment for the earthquake scenario in Tabriz. *Soil Dynamics and Earthquake Engineering* 66: 263-280.
- Kendall, M. G. (1938). A new measure of rank correlation. *Biometrika*, 30(1-2), 81-93.
- Malakar, S., & Rai, A. K. (2022). Earthquake vulnerability in the Himalaya by integrated multi-criteria decision models. *Natural Hazards*, 1-25.
- Mardani, A., Zavadskas, E. K., Govindan, K., Amat Senin, A., & Jusoh, A. (2016). VIKOR technique: A systematic review of the state of the art literature on methodologies and applications. *Sustainability*, 8(1), 37.
- Meşe, B., & Özdemir, L. (2022). Entropi temelli TOPSIS ve BORDA sayım yöntemleri ile gıda işletmelerinin performanslarının değerlendirilmesi. *Alanya Akademik Bakış*, 6(3), 2809-2829.
- MTA (2024). Erişim adresi: <https://www.mta.gov.tr/v3.0/hizmetler/yenilenmis-dirifay-haritalari>
- Murnane, R. J., Daniell, J. E., Schäfer, A. M., Ward, P. J., Winsemius, H. C., Simpson, A., & Toro, J. (2017). Future scenarios for earthquake and flood risk in Eastern Europe and Central Asia. *Earth's Future*, 5(7), 693-714.
- Opricovic, S. (1998). *Multicriteria Optimization of Civil Engineering Systems*, Faculty of Civil Engineering, Belgrade.
- Oral N., Yumuşak, R., Eren T. (2021). AHP ve ANP yöntemleri kullanılarak tehlikeli madde depo yeri seçimi: Kırıkkale ilinde bir uygulama. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 10(1), 115-124.
- Özcan, E. C., Ünlüsoy, S., Eren T. (2017). ANP ve TOPSIS yöntemleriyle Türkiye'de yenilenebilir enerji yatırım alternatiflerinin değerlendirilmesi. *Selçuk Üniversitesi Mühendislik, Bilim ve Teknoloji Dergisi*, 5(2), 204-219.
- Özmen, M. (2024). DBDM: Dominance Based Decision Making and GIS Integrated Earthquake Vulnerability Assessment Of Elazığ/Türkiye. *IEEE Access*.
- Peng, Y. (2015). Regional earthquake vulnerability assessment using a combination of MCDM methods. *Annals of Operations Research*, 234(1), 95-110.
- Rezaei, A., & Tahsili, S. (2018). Urban vulnerability assessment using AHP. *Advances in Civil Engineering*.
- Sadrykia, M., Delavar, M. R., & Zare, M. (2017). A GIS-based fuzzy decision making model for seismic vulnerability assessment in areas with incomplete data. *ISPRS International Journal of Geo-Information*, 6(4), 119.
- Saaty, T. L. (1977). A scaling method for priorities in hierarchical structures. *Journal of Mathematical Psychology*, 15, 234-281.

- Shadmaan, S., & Islam, A. I. (2021). Estimation of earthquake vulnerability by using analytical hierarchy process. *Natural Hazards Research*, 1(4), 153-160.
- Shayannejad, A., & Angerabi, B. A. (2014). Earthquake Vulnerability Assessment in urban areas using MCDM Case study: The central part of 6 district of Tehran Municipality. *International Review for Spatial Planning and Sustainable Development*, 2(2), 39-51.
- Sinha, N., Priyanka, N., & Joshi, P. K. (2016). Using spatial multi-criteria analysis and ranking tool (SMART) in earthquake risk assessment: A case study of Delhi region, India. *Geomatics, Natural Hazards and Risk*, 7(2): 680-701.
- Tate, E. (2012). Social vulnerability indices: a comparative assessment using uncertainty and sensitivity analysis. *Natural Hazards*, 63(2), 325347.
- TURKSTAT, 2024. Veri Portalı. <https://veriportali.tuik.gov.tr/tr>
- Uzun S., Kazan, H. (2016). Çok kriterli karar verme yöntemlerinden AHP TOPSIS ve PROMETHEE karşılaştırılması: Gemi inşada ana makine seçimi uygulaması. *Journal of Transportation and Logistics*, 1(1), 99-113.
- Yariyan, P., Zabihi, H., Wolf, I. D., Karami, M., & Amiriyani, S. (2020). Earthquake risk assessment using an integrated Fuzzy Analytic Hierarchy Process with Artificial Neural Networks based on GIS: A case study of Sanandaj in Iran. *International Journal of Disaster Risk Reduction*, 50, 1-17.
- Yavaşoğlu, F., ve Özden Ç.V. (2017). Coğrafi Bilgi Sistemleri (CBS) tabanlı Analitik Hiyerarşi Süreci kullanılarak deprem hasar riski analizi: Kadıköy örneği. *TÜBAV Journal of Science*, 10(3), 28-38.
- Yavuz Kumlu, K. B., & Tüdeş, Ş. (2019). Determination of earthquake-risky areas in Yalova City Center (Marmara region, Turkey) using GIS-based multicriteria decision-making techniques (analytical hierarchy process and technique for order preference by similarity to ideal solution). *Natural Hazards*, 96(3), 999-1018.



A Picture Fuzzy MEREC-AROMAN Model for Selecting the Maintenance Policy of Ship Main Engines

Doğan Şengül¹ & Mahmut Emin Sarıkaya²

1. Introduction

Maritime transport carries the overwhelming majority of world trade, and the main engine is the single most critical machinery item on board a merchant ship. An unexpected main engine failure can immobilise the vessel, threaten the safety of the crew, cause pollution and generate very large commercial losses. The way in which the engine is maintained therefore has a direct effect on safety, reliability, cost and environmental performance. Choosing among the available maintenance policies is consequently one of the most consequential engineering management decisions taken by a shipping company.

Four maintenance policies dominate marine practice. Corrective maintenance (*CM*) repairs an item only after it has failed. Preventive maintenance (*PM*) replaces or overhauls items on a fixed time or running hours schedule. Predictive maintenance (*PdM*) uses measured trends to forecast the remaining useful life and to intervene shortly before failure. Condition-based maintenance (*CBM*) triggers action when monitored parameters cross predefined thresholds. Each policy has its own profile of cost, risk, technical demand and organisational effort, so no single policy is best for every ship or every operating profile.

The selection of a maintenance policy is naturally a Multi-Criteria Decision Making (*MCDM*) problem because it requires the simultaneous treatment of several conflicting criteria such as life-cycle cost, reliability, safety and feasibility. *MCDM* has been applied extensively to marine and offshore maintenance. Hybrid models that combine the Analytic Hierarchy Process (*AHP*) with the Technique for Order of Preference by Similarity to Ideal Solution (*TOPSIS*) or with the Preference Ranking Organisation Method for Enrichment Evaluations (*PROMETHEE*) have been used for ship machinery, and group decision models have aggregated the opinions of several marine engineers. These

¹ PhD in Industrial Engineering, Department of Software Engineering, Faculty of Engineering and Natural Sciences, İstanbul Sabahattin Zaim University, İstanbul, Türkiye. ORCID: 0000-0002-2285-3907

² Department of Business, İstanbul Sabahattin Zaim University, İstanbul, Türkiye, ORCID: 0009-0007-1392-6151

studies confirm that the problem is well suited to *MCDM*, yet they also reveal two recurring limitations.

The first limitation concerns the representation of uncertainty. Expert judgements about a maintenance policy are rarely crisp. An engineer may partly support a policy, partly oppose it and may also deliberately abstain because the evidence is mixed. Ordinary fuzzy sets record only a degree of membership and intuitionistic fuzzy sets add only a degree of non-membership (Zadeh, 1965; Atanassov, 1986), so neither can record the neutral or abstaining attitude separately. Picture Fuzzy Sets (*PFS*), introduced by Cuong (2014), resolve this by attaching to every element a positive, a neutral and a negative degree, together with an implied refusal degree. This four-way structure mirrors the way marine experts actually reason, where support, abstention, opposition and refusal coexist.

The second limitation concerns the choice of weighting and ranking techniques. Many maritime studies rely on subjective weights elicited by pairwise comparison, which may raise consistency and auditability concerns. The Method based on the Removal Effects of Criteria (*MEREC*) derives objective weights from the data themselves by measuring how much the overall performance of the alternatives changes when each criterion is removed (Keshavarz-Ghorabae et al., 2021). The Alternative Ranking Order Method Accounting for Two-Step Normalization (*AROMAN*) is a recent ranking technique whose distinctive feature is the coupling of linear and vector normalisation, which produces a more faithful data structure than a single normalisation (Bošković et al., 2023). *MEREC* provides defensible objective weights and *AROMAN* provides a robust ranking, yet to the best of the authors' knowledge neither *MEREC* nor *AROMAN*, and certainly not their picture fuzzy combination, has been used for maritime maintenance policy selection.

This chapter addresses both gaps. It develops a picture fuzzy *MEREC-AROMAN* model and applies it to the selection of a maintenance policy for a ship main engine. The contributions are the following. First, the chapter formulates *MEREC* and *AROMAN* inside the picture fuzzy environment and assembles them into a single transparent procedure. Second, it provides three detailed proofs that establish the theoretical soundness of the model, namely order preservation of the picture fuzzy normalisation, boundedness of the *AROMAN* aggregation and stability of the *MEREC* weights under the removal effect. Third, it reports a simulation study comprising a parameter sweep, a rank reversal test and a comparison with *PROMETHEE* using the Spearman rank correlation coefficient. Fourth, it draws out the importance of the model for practitioners and supports the discussion with an illustrative worked example aimed at marine engineers.

1.1 Related work and the research gap

Multi-criteria methods have a long record in marine maintenance. Emovon, Norman and Murphy (2018) combined the Delphi method with *AHP* and

PROMETHEE for ship machinery systems, and Emovon (2016) used a Delphi, *AHP* and *TOPSIS* model for the cooling pump of a marine diesel engine. Asuquo, Wang, Zhang and Phylip-Jones (2019) built a group *TOPSIS* model for marine and offshore machinery. Karatuğ, Arslanoğlu and Guedes Soares (2022) applied *AHP* and *TOPSIS* to autonomous ship machinery and favoured a combination of condition-based and time-based maintenance. Lazakis and Ölçer (2016) used a fuzzy group method for a ship diesel generator and ranked preventive and predictive maintenance ahead of corrective maintenance. Animah and Shafiee (2019) combined *AHP* and *PROMETHEE* for critical shipboard machinery. The reviews of Shafiee (2015), of Al-Najjar and Alsyouf (2003) and of Patil et al. (2022) confirm that maintenance policy selection is a recognised *MCDM* task with economic, technical, safety, environmental and feasibility criteria.

On the methodological side, *MEREC* was introduced by Keshavarz-Ghorabae, Amiri, Zavadskas, Turskis and Antucheviciene (2021) as an objective weighting method, and it has since been extended to fuzzy (Saidin et al., 2023), Pythagorean fuzzy (Chaurasiya & Jain, 2023) and picture fuzzy (Fan et al., 2024) settings. *AROMAN* was introduced by Bošković et al. (2023) and was combined with *MEREC* by Kara et al. (2024) in a crisp competitiveness study, but not in a picture fuzzy form and not in the maritime field. Rank reversal, the change of order when an alternative is added or removed, is a known limitation of many methods and has been studied by Wang and Luo (2009), by Aires and Ferreira (2018) and by Mufazzal and Muzakir (2018), which is why a rank reversal test is included here. No earlier study combines picture fuzzy information, *MEREC* weighting and *AROMAN* ranking, and none applies this combination to maritime maintenance. This chapter fills that gap and adds the theoretical guarantees that applied studies less often include.

The remainder of the chapter is organised as follows. Section 2 reviews the picture fuzzy preliminaries. Section 3 presents the proposed model step by step. Section 4 states and proves the three theoretical properties. Section 5 applies the model to the ship main engine. Section 6 reports the simulation study. Section 7 discusses the importance for practitioners and gives the worked example. Section 8 concludes.

2. Picture fuzzy preliminaries

This section recalls the definitions and operators that the model relies upon. Throughout, X denotes a finite universe of discourse.

2.1 Picture fuzzy sets

A Picture Fuzzy Set (*PFS*) A on X is defined by a positive membership function, a neutral membership function and a negative membership function, written as follows.

$$A = \{ \langle x, \mu_A(x), \eta_A(x), \nu_A(x) \rangle : x \in X \} \quad (1)$$

Here $\mu_A(x)$, $\eta_A(x)$ and $\nu_A(x)$ lie in the unit interval and satisfy the constraint below, which limits their sum.

$$0 \leq \mu_A(x) + \eta_A(x) + \nu_A(x) \leq 1 \quad (2)$$

The refusal degree $\pi_A(x)$, which captures the part of the judgement that is withheld, is the residual given in equation (3).

$$\pi_A(x) = 1 - (\mu_A(x) + \eta_A(x) + \nu_A(x)) \quad (3)$$

A triple $\alpha = (\mu, \eta, \nu)$ that meets the constraint in equation (2) is called a Picture Fuzzy Number (*PFN*). The positive, neutral and negative degrees represent support, abstention and opposition respectively, which is the four-way attitude that motivates the use of picture fuzzy information for expert judgement.

2.2 Score and accuracy functions

To compare picture fuzzy numbers a score function and an accuracy function are used. For a *PFN* $\alpha = (\mu, \eta, \nu)$ the score and the accuracy are defined as follows.

$$S(\alpha) = \frac{1 + \mu - \nu}{2} \quad (4)$$

$$H(\alpha) = \mu + \eta + \nu \quad (5)$$

The score lies in the unit interval, it increases with the positive degree and it decreases with the negative degree. The preference order between two *PFNs* is decided first by the score and, when scores are equal, by the accuracy. Formally $\alpha > \gamma$ if $S(\alpha) > S(\gamma)$, and if $S(\alpha) = S(\gamma)$ then $\alpha > \gamma$ when $H(\alpha) > H(\gamma)$.

2.3 Picture fuzzy weighted averaging operator

Group judgements are combined with the Picture Fuzzy Weighted Averaging (*PFWA*) operator (Garg, 2017; Jana et al., 2019; Tian et al., 2019). Given *PFNs* $\alpha_e = (\mu_e, \eta_e, \nu_e)$ for experts $e = 1, \dots, t$ with weights ζ_e that sum to one, the operator is given in equation (6).

$$PFWA = (1 - \prod_{e=1}^t (1 - \mu_e)^{\zeta_e}, \prod_{e=1}^t \eta_e^{\zeta_e}, \prod_{e=1}^t \nu_e^{\zeta_e}) \quad (6)$$

The aggregated triple again satisfies the picture fuzzy constraint, so the operator maps a collection of expert *PFNs* to a single *PFN*. The result of this operator is the entry of the aggregated decision matrix used in the model.

2.4 Operational laws on picture fuzzy numbers

The averaging operator of equation (6) is built on two operational laws. For two picture fuzzy numbers the addition is given in equation (7), and for a positive scalar the scalar multiplication is given in equation (8). Both laws keep the result

inside the picture fuzzy domain, which is why the aggregated judgement is again a valid picture fuzzy number.

$$\alpha_1 \oplus \alpha_2 = (\mu_1 + \mu_2 - \mu_1\mu_2, \eta_1\eta_2, \nu_1\nu_2) \tag{7}$$

$$\zeta \alpha = (1 - (1 - \mu)^\zeta, \eta^\zeta, \nu^\zeta), \zeta > 0 \tag{8}$$

Applying the scalar multiplication with the expert weights and then adding across the experts yields the weighted averaging operator. The neutral and negative degrees combine multiplicatively, so an alternative scores well only when the experts agree on strong support with little abstention or opposition.

3. The proposed picture fuzzy *MEREC-AROMAN* model

The model has four stages. The first stage gathers the linguistic judgements of the experts and turns them into a single aggregated picture fuzzy decision matrix. The second stage maps every picture fuzzy number to a score. The third stage derives objective criteria weights with *MEREC*. The fourth stage ranks the alternatives with *AROMAN*. A comparison with *PROMETHEE* and the rank agreement measured by the Spearman coefficient complete the procedure. The overall procedure is summarised in Figure 1 and set out as Algorithm 1.

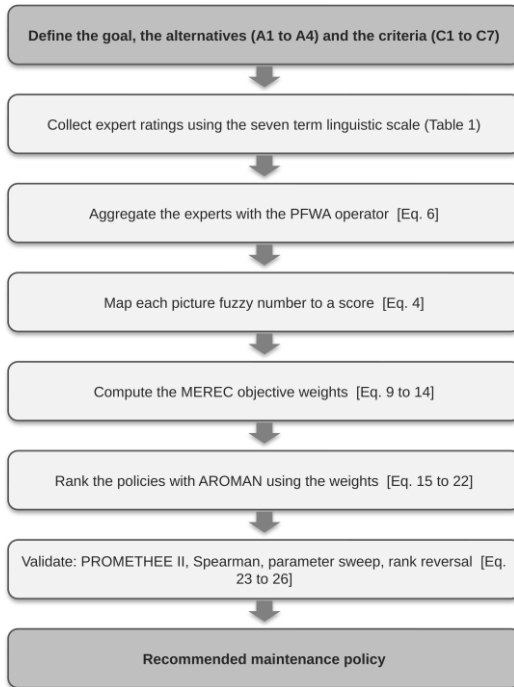


Figure 1. Flowchart of the proposed picture fuzzy *MEREC-AROMAN* model.
Source: The authors.

Algorithm 1. Picture fuzzy MEREC-AROMAN

Input: the expert weights, the linguistic ratings of the alternatives on the criteria and the criterion types.

Output: a ranking of the alternatives.

1. Map each linguistic rating to a picture fuzzy number using the scale of Table 1.
2. Aggregate the experts with the *PFWA* operator to form the picture fuzzy decision matrix. [Eq. 6]
3. Apply the score function to every entry to obtain the score matrix. [Eq. 4]
4. *MEREC* weights:
 - a. Normalise the score matrix in benefit and cost form. [Eq. 9, 10]
 - b. Compute the overall performance of each alternative. [Eq. 11]
 - c. Recompute the performance with each criterion removed and form the removal effects. [Eq. 12, 13]
 - d. Normalise the removal effects to obtain the criterion weights. [Eq. 14]
5. *AROMAN* ranking:
 - a. Apply the min-max and the vector normalisation in benefit and cost form. [Eq. 15 to 18]
 - b. Form the averaged normalisation with the coefficient β , then weight it. [Eq. 19, 20]
 - c. Sum the cost and the benefit parts and compute the final score. [Eq. 21, 22]
6. Order the alternatives by decreasing final score.
7. Validate with *PROMETHEE* II and the Spearman coefficient, a parameter sweep and a rank reversal test. [Eq. 23 to 26]

3.1 Stage one: linguistic rating and aggregation

Let the alternatives be indexed by $i = 1, \dots, m$ and the criteria by $j = 1, \dots, n$. Each of the t experts rates every alternative on every criterion using a linguistic term that maps to a picture fuzzy number through the scale in Table 1. The experts' judgements are merged with the *PFWA* operator of equation (6), using the expert weights, to obtain the aggregated picture fuzzy decision matrix with entries $x_{ij} = (\mu_{ij}, \eta_{ij}, \nu_{ij})$.

3.2 Stage two: scoring

Every aggregated picture fuzzy number is converted to a crisp performance value with the score function of equation (4), giving a real matrix with entries $s_{ij} = S(x_{ij})$ in the open unit interval. The score matrix is the input to both the weighting and the ranking stages, so the picture fuzzy information enters the later computations through the score, with the accuracy reserved for breaking ties. This is the device through which the linear and vector normalisation act on picture fuzzy data.

3.3 Stage three: objective weights by *MEREC*

MEREC derives the weight of a criterion from how much the overall performance of the alternatives changes when that criterion is removed. A criterion whose removal strongly changes the performances is influential and receives a large weight. The four steps are as follows.

First, the score matrix is normalised so that all entries fall in the half-open unit interval. For a beneficial criterion the smallest score is placed in the numerator, and for a non-beneficial criterion the score is divided by the largest score, as in equations (9) and (10).

$$n_{ij} = \frac{\min_k s_{kj}}{s_{ij}} \quad (\text{beneficial}) \quad (9)$$

$$n_{ij} = \frac{s_{ij}}{\max_k s_{kj}} \quad (\text{non - beneficial}) \quad (10)$$

Second, the overall performance of each alternative is computed with a logarithmic measure, equation (11).

$$S_i = \ln\left(1 + \frac{1}{n} \sum_j |\ln n_{ij}|\right) \quad (11)$$

Third, the performance is recomputed with criterion j removed, equation (12), and the removal effect of the criterion is the total absolute change over all alternatives, equation (13).

$$S'_{ij} = \ln\left(1 + \frac{1}{n} \sum_{k \neq j} |\ln n_{ik}|\right) \quad (12)$$

$$E_j = \sum_i |S'_{ij} - S_i| \quad (13)$$

Fourth, the weights are obtained by normalising the removal effects, equation (14). The weights are nonnegative and sum to one.

$$w_j = \frac{E_j}{\sum_t E_t} \quad (14)$$

3.4 Stage four: ranking by *AROMAN*

AROMAN couples a linear and a vector normalisation, averages them, weights them and finally aggregates the cost and benefit contributions through a balance parameter. The benefit-oriented convention is used, so that for every criterion a larger normalised value is better; cost criteria are inverted at the normalisation step. The steps are as follows.

The min-max normalisation, equation (15) for beneficial criteria and equation (16) for non-beneficial criteria, places every value in the unit interval.

$$a_{ij} = \frac{s_{ij} - \min_k s_{kj}}{\max_k s_{kj} - \min_k s_{kj}} \quad (\text{beneficial}) \quad (15)$$

$$a_{ij} = \frac{\max_k s_{kj} - s_{ij}}{\max_k s_{kj} - \min_k s_{kj}} \quad (\text{non - beneficial}) \quad (16)$$

The vector normalisation, equation (17) for beneficial criteria and equation (18) for non-beneficial criteria, uses the Euclidean norm of the column.

$$b_{ij} = \frac{s_{ij}}{\sqrt{\sum_k s_{kj}^2}} \quad (\text{beneficial}) \quad (17)$$

$$b_{ij} = 1 - \frac{s_{ij}}{\sqrt{\sum_k s_{kj}^2}} \quad (\text{non - beneficial}) \quad (18)$$

The two normalisations are merged into an aggregated averaged value with the coefficient β in the unit interval, equation (19).

$$\gamma_{ij} = \frac{\beta a_{ij} + (1 - \beta) b_{ij}}{2} \quad (19)$$

The averaged values are weighted, equation (20), and then summed separately over the cost and the benefit criteria, equation (21).

$$\gamma_{ij}^* = w_j \gamma_{ij} \quad (20)$$

$$L_i = \sum_{j \in \text{cost}} \gamma_{ij}^*, \quad R_i = \sum_{j \in \text{benefit}} \gamma_{ij}^* \quad (21)$$

The final *AROMAN* score combines the two sums through the type balance λ , which is taken as the total weight of the cost criteria, equation (22). A larger score denotes a more preferred alternative.

$$S_i^{AR} = L_i^\lambda + R_i^{1-\lambda}, \quad \lambda = \sum_{j \in \text{cost}} w_j \quad (22)$$

3.5 Comparison with *PROMETHEE* and rank agreement

To check the ranking, the same score matrix and the same *MEREC* weights are fed to the *PROMETHEE* II method (Brans & Vincke, 1985; Behzadian et al., 2010). With a linear preference function whose preference threshold p_j equals the range of criterion j , the preference of alternative a over alternative b and the multi-criteria preference index are given in equations (23) and (24).

$$P_j(a, b) = \min\{1, \max\{0, \frac{d_j(a,b)}{p_j}\}\} \quad (23)$$

$$\pi(a, b) = \sum_j w_j P_j(a, b) \quad (24)$$

The leaving, entering and net flows are defined in equation (25), and alternatives are ranked by the net flow.

$$\varphi_a^+ = \frac{1}{m-1} \sum_b \pi(a, b), \quad \varphi_a^- = \frac{1}{m-1} \sum_b \pi(b, a), \quad \varphi_a = \varphi_a^+ - \varphi_a^- \quad (25)$$

The agreement between the *AROMAN* ranking and the *PROMETHEE* ranking is measured by the Spearman rank correlation coefficient (Spearman, 1904),

equation (26), where d_i is the rank difference of alternative i and k is the number of alternatives.

$$\rho = 1 - \frac{6 \sum_i d_i^2}{k(k^2 - 1)} \quad (26)$$

4. Theoretical properties

This section establishes three properties of the model. The first guarantees that the picture fuzzy normalisation is faithful to the preference order. The second guarantees that the ranking score cannot grow without bound. The third guarantees that the objective weights are stable. All three were also confirmed numerically over tens of thousands of random picture fuzzy problems, as reported in Section 6.

4.1 Order preservation of the picture fuzzy normalisation

Theorem 1 (order preservation). Fix a criterion and let its picture fuzzy scores lie in the open unit interval and not all be equal. Let the aggregated averaged value be defined by equations (15) to (19). Then for a beneficial criterion the value γ_{ij} is a strictly increasing function of the score s_{ij} , and for a non-beneficial criterion it is strictly decreasing. Consequently the normalisation preserves the picture fuzzy preference order on every beneficial criterion and reverses it on every cost criterion, which is exactly what a criterion to be minimised requires.

Proof. Fix the criterion and write the column scores as a list with smallest value l and largest value u , where $l < u$. The Euclidean norm of the column, call it V , is a positive constant that is the same for every entry of the column, so within the column it does not depend on the alternative being normalised.

Consider first a beneficial criterion. The min-max value is $a_{ij} = (s_{ij} - l)/(u - l)$ and the vector value is $b_{ij} = s_{ij}/V$. Differentiating the aggregated averaged value with respect to the score gives a strictly positive quantity, shown below.

$$\frac{d \gamma_{ij}}{d s_{ij}} = \frac{1}{2} \left(\frac{\beta}{u - l} + \frac{1 - \beta}{V} \right) > 0$$

Since the derivative is positive for every admissible β , the value is strictly increasing in the score. Therefore a higher score, which by Section 2.2 is a more preferred picture fuzzy number, yields a larger normalised value, so the preference order is preserved.

Consider next a non-beneficial criterion. Here the min-max value is $a_{ij} = (u - s_{ij})/(u - l)$ and the vector value is $b_{ij} = 1 - s_{ij}/V$. The derivative of the aggregated value is the negative of the previous expression and is therefore strictly negative, so the value is strictly decreasing in the score. A larger

magnitude on a cost criterion, which is less desirable, thus receives a smaller benefit-oriented value, as required.

If two scores are equal then both normalisations return equal values, so the alternatives remain tied and the accuracy-based refinement of the preference order is never contradicted. Finally the weighting multiplies each column by the nonnegative weight, which cannot change the within-criterion order, and the final aggregation of equation (22) is increasing in each cost sum and benefit sum because the power functions with exponents λ and $1 - \lambda$ are increasing on the nonnegative axis. Hence improving an alternative on any beneficial criterion, or lowering its magnitude on any cost criterion, cannot reduce its *AROMAN* score. The model is monotone with respect to the picture fuzzy preference order. ■

4.2 Boundedness of the *AROMAN* aggregation

Theorem 2 (boundedness). For every alternative the aggregated averaged value satisfies $0 \leq \gamma_{ij} \leq 1/2$. Writing W_c for the total weight of the cost criteria and W_b for the total weight of the benefit criteria, with $W_c + W_b = 1$, the *AROMAN* score is bounded as below, independently of the number of alternatives.

$$0 \leq S_i^{AR} \leq \left(\frac{W_c}{2}\right)^\lambda + \left(\frac{W_b}{2}\right)^{1-\lambda} \leq \frac{3}{2}$$

Proof. The min-max value lies in the unit interval by construction, for both the beneficial and the non-beneficial forms, since its numerator lies between zero and the denominator. The vector value also lies in the unit interval: for a beneficial criterion s_{ij}/V is at most one because the square of any entry is at most the sum of the squares, and for a non-beneficial criterion the complement lies in the unit interval by the same inequality. A convex combination of two numbers in the unit interval again lies in the unit interval, and dividing by two gives the stated range for γ_{ij} .

Multiplying by the weight gives values between zero and half the weight. Summing over the cost criteria shows that the cost sum is at most $W_c/2$, and summing over the benefit criteria shows that the benefit sum is at most $W_b/2$. Because the exponents lie in the unit interval and the power function is increasing on the nonnegative axis, raising the cost sum to the power λ and the benefit sum to the power $1 - \lambda$ and adding yields the upper bound. For the final numerical bound, both bases are at most one half, each power is therefore at most one, and the maximum of the sum of the two powers over the admissible range of the exponent equals three halves, attained at the extreme values of the exponent. Non-negativity is immediate since every quantity is nonnegative. ■

In the illustrative engine case the total cost weight is 0.376, the total benefit weight is 0.624 and the type balance is 0.376, so the theorem caps the score at

about 1.02, while the largest score actually obtained is 0.875. The computed scores respect the bound, as they must.

4.3 Stability of the *MEREC* weights under the removal effect

Theorem 3 (weight stability). Let the normalised performance entries lie in the half-open unit interval and let $g_i = (1/n) \sum_j | \ln n_{ij} |$. Then the *MEREC* weights are nonnegative and sum to one; they are invariant to positive scaling of any criterion column; every removal contribution is bounded by the corresponding normalised log magnitude; and deleting an alternative that is not a column extreme changes each removal effect by exactly that alternative own contribution, so the weight vector stays in an explicitly bounded neighbourhood.

Proof. Part one. Each removal effect is a sum of absolute differences, so it is nonnegative, and dividing by the positive total of the removal effects gives weights that are nonnegative and sum to one. Part two. For a beneficial criterion the normalisation is the column minimum divided by the entry; multiplying the column by a positive constant multiplies both the minimum and the entry by that constant, so the ratio is unchanged, and the cost form is invariant by the same cancellation. Because the normalised matrix is unchanged, every performance, every removal effect and every weight is unchanged, so the weights depend only on the relative pattern within each column and not on its scale.

Part three. Let $\delta_{ij} = (1/n) | \ln n_{ij} |$, which is nonnegative. The removed term is a single summand of g_i , so the quantity that remains after removal is nonnegative and the argument below is at least one, which makes the removal contribution nonnegative. Using the elementary inequality that the logarithm of one plus a nonnegative number does not exceed that number, the contribution is bounded as shown.

$$\ln(1 + g_i) - \ln(1 + g_i - \delta_{ij}) = \ln\left(1 + \frac{\delta_{ij}}{1 + g_i - \delta_{ij}}\right) \leq \delta_{ij}$$

Summing over the alternatives gives a removal effect that is at most the average absolute log magnitude of the criterion, a bound that is linear in the data. A bounded perturbation of the logarithmic data therefore produces a bounded perturbation of every removal effect, which is the desired stability.

Part four. The only way alternatives interact in *MEREC* is through the column minimum for beneficial criteria and the column maximum for cost criteria. If an alternative is neither the minimiser of any beneficial column nor the maximiser of any cost column, then deleting it leaves these extremes, and hence the whole normalised matrix for the survivors, unchanged. The new removal effect is then the old one minus the deleted alternative own contribution, and by part three this change is at most the average absolute log magnitude of that alternative. The unnormalised effect vector therefore moves by a bounded amount, the normalised

weights lie in an explicitly bounded neighbourhood of the original weights, and a dominated or non-pivotal alternative cannot materially disturb the weights. This is consistent with the absence of rank reversal observed when a dominated alternative is added or removed in Section 6. ■

5. Application to a ship main engine

The model is applied to the selection of a maintenance policy for the main engine of a merchant ship. The four policies introduced in Section 1, namely corrective, preventive, predictive and condition-based maintenance, are the alternatives, labelled A1 to A4. Three experts take part, namely a chief engineer, a fleet superintendent and a classification surveyor, with weights 0.40, 0.35 and 0.25 that reflect their familiarity with day-to-day engine operation. The judgements used below are illustrative and were prepared by the authors to demonstrate the procedure; in a real study they would be elicited from the named roles.

5.1 Linguistic scale and criteria

The experts express their judgements with the seven-term linguistic scale of Table 1, each term mapping to a picture fuzzy number whose three degrees sum to at most one. The criteria are listed in Table 2. They were drawn from the maritime maintenance literature and grouped into the economic, technical, safety, environmental and feasibility categories that recur in maintenance strategy selection.

Table 1. Seven-term picture fuzzy linguistic scale.

Linguistic term	Code	Positive (μ)	Neutral (η)	Negative (ν)
Very low	VL	0.10	0.05	0.80
Low	L	0.25	0.10	0.60
Medium low	ML	0.40	0.10	0.45
Medium	M	0.50	0.10	0.35
Medium high	MH	0.60	0.10	0.25
High	H	0.75	0.10	0.10
Very high	VH	0.90	0.05	0.05

Source: The authors.

Table 2. Evaluation criteria for ship main engine maintenance policy selection.

Code	Criterion	Type	Category
C1	Life-cycle cost	Cost	Economic
C2	Reliability and availability	Benefit	Technical
C3	Safety and risk reduction	Benefit	Safety
C4	Operational downtime	Cost	Technical
C5	Environmental compliance	Benefit	Environmental
C6	Implementation feasibility	Benefit	Feasibility
C7	Spare parts inventory burden	Cost	Economic

Source: The authors, based on Al-Najjar and Alsyouf (2003), Shafiee (2015) and Patil et al. (2022).

5.2 Aggregation and scoring

Each expert filled the rating matrix, and the three matrices were merged with the *PFWA* operator of equation (6). The aggregated picture fuzzy decision matrix is shown in Table 3. Applying the score function of equation (4) to every entry gives the score matrix of Table 4, which is the common input to the weighting and ranking stages.

Table 3. Aggregated picture fuzzy decision matrix (positive, neutral, negative).

Criterion	A1 corrective	A2 preventive	A3 predictive	A4 condition-based
C1	(0.467,0.100,0.382)	(0.644,0.100,0.199)	(0.750,0.100,0.100)	(0.705,0.100,0.138)
C2	(0.291,0.100,0.558)	(0.568,0.100,0.281)	(0.750,0.100,0.100)	(0.874,0.059,0.059)
C3	(0.306,0.100,0.543)	(0.577,0.100,0.272)	(0.705,0.100,0.138)	(0.862,0.064,0.064)
C4	(0.819,0.078,0.078)	(0.538,0.100,0.311)	(0.306,0.100,0.543)	(0.215,0.084,0.645)
C5	(0.306,0.100,0.543)	(0.568,0.100,0.281)	(0.719,0.100,0.126)	(0.705,0.100,0.138)
C6	(0.874,0.059,0.059)	(0.750,0.100,0.100)	(0.437,0.100,0.412)	(0.538,0.100,0.311)
C7	(0.568,0.100,0.281)	(0.719,0.100,0.126)	(0.291,0.100,0.558)	(0.314,0.100,0.535)

Source: the authors.

Table 4. Score matrix obtained from the score function.

Criterion	Type	A1	A2	A3	A4
C1	Cost	0.542	0.723	0.825	0.784
C2	Benefit	0.366	0.643	0.825	0.907
C3	Benefit	0.382	0.653	0.784	0.899
C4	Cost	0.870	0.613	0.382	0.285
C5	Benefit	0.382	0.643	0.797	0.784
C6	Benefit	0.907	0.825	0.513	0.613
C7	Cost	0.643	0.797	0.366	0.390

Source: The authors.

5.3 Objective weights

The *MEREC* procedure of equations (9) to (14) was applied to the score matrix. The removal effects and the resulting weights are reported in Table 5 and drawn in Figure 2. Reliability and availability carries the largest weight, followed closely by operational downtime and by safety, which together account for more than half of the total weight. Life-cycle cost receives the smallest weight, because the four policies are separated less by cost than by the technical and safety criteria, so removing cost changes the overall performances only slightly. This is the objective signal that *MEREC* is designed to capture.

Table 5. *MEREC* removal effects and objective weights.

Criterion	Type	Removal effect	Weight
C1	Cost	0.0708	0.0588
C2	Benefit	0.2202	0.1827
C3	Benefit	0.2031	0.1685
C4	Cost	0.2176	0.1806
C5	Benefit	0.1903	0.1579
C6	Benefit	0.1388	0.1152
C7	Cost	0.1646	0.1365

Source: The authors.

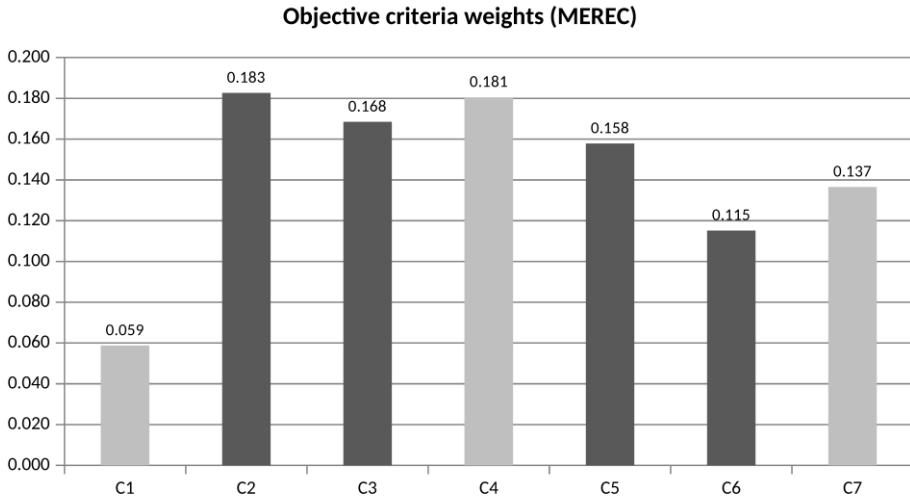


Figure 2. Objective criteria weights produced by *MERECE*.

Source: The authors.

5.4 Ranking

AROMAN was applied to the score matrix with the *MERECE* weights, the normalisation coefficient set to one half and the type balance set to the total cost weight, which is 0.376. The cost sum, the benefit sum, the *AROMAN* score and the rank of each policy are reported in Table 6, together with the *PROMETHEE* net flow and its rank for comparison. Both methods place condition-based maintenance first, predictive maintenance second, preventive maintenance third and corrective maintenance last. The Spearman coefficient of equation (26) between the two rankings equals 1.00, a complete agreement that supports the credibility of the result and is illustrated in Figure 3.

Table 6. *AROMAN* and *PROMETHEE* results for the main engine.

Alt.	Policy	Cost sum	Benefit sum	<i>AROMAN</i> score	Rank	<i>PROMETHEE</i> flow	Rank
A1	Corrective	0.063	0.081	0.561	4	-0.463	4
A2	Preventive	0.065	0.168	0.686	3	-0.129	3
A3	Predictive	0.132	0.194	0.826	2	0.215	2
A4	Condition-based	0.143	0.224	0.875	1	0.376	1

Source: The authors.




Figure 3. Agreement between the picture fuzzy *AROMAN* and *PROMETHEE* preferences.

Source: The authors.

6. Simulation study

Three computational experiments probe the behaviour of the model: a sweep over the two method parameters, a rank reversal test and a comparison with *PROMETHEE* over many random problems measured by the Spearman coefficient.

6.1 Parameter sweep

The normalisation coefficient and the type balance were each varied from 0.1 to 0.9 in steps of 0.1, giving 81 combinations, a range in the spirit of the coefficient study of Thinh and Van Dua (2024). In every combination condition-based maintenance remained first and the complete order remained unchanged, so the Spearman coefficient against the baseline ranking equalled 1.00 throughout. Figure 4 plots the *AROMAN* scores across the whole range of the normalisation coefficient: the four curves never cross, which is the visual counterpart of the monotonicity established in Theorem 1. A further test perturbed each criterion weight by plus or minus twenty per cent, and the ranking again did not change. The decision is therefore robust to the analyst settings.

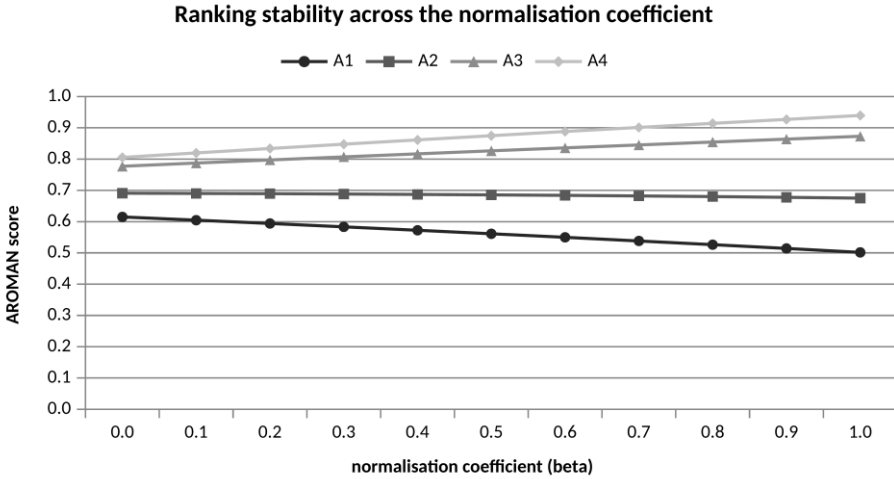


Figure 4. *AROMAN* scores across the normalisation coefficient, showing no rank crossing.
Source: The authors.

6.2 Rank reversal test

Each policy was removed in turn and the weights and ranking were recomputed for the survivors. In every case the relative order of the remaining policies matched the order in the full problem, so no rank reversal occurred. A dominated dummy policy that is worst on every criterion in preference terms was then added; it was ranked last and the order of the original policies was preserved. For the well separated policies of this case the model is therefore free of rank reversal, which is consistent with Theorem 3 part four, since the removed and added policies are not column extremes that drive the weights.

6.3 Agreement with *PROMETHEE* over random problems

To go beyond the single case, 3000 random picture fuzzy problems were generated, each with four to eight policies and seven criteria, by drawing every expert rating uniformly from the linguistic scale and aggregating as in the model. For each problem the picture fuzzy *MEREC-AROMAN* ranking and the *PROMETHEE* ranking were compared. The mean Spearman coefficient was 0.951 with a median of 1.00, the two methods produced an identical ranking in 53.2 per cent of the problems, and the agreement was at least 0.9 in 85.6 per cent of the problems. The mean Kendall coefficient was 0.908. The distribution is shown in Figure 5. Over the same problems the rank reversal frequency on deletion was 30.0 per cent for the picture fuzzy *AROMAN* and 28.4 per cent for *PROMETHEE*, which shows that the proposed method is broadly comparable to *PROMETHEE* in rank reversal behaviour, while its single case behaviour was fully stable. The summary of all experiments is given in Table 7.

Rank agreement over 3000 random problems (mean = 0.951)




Figure 5. Distribution of the Spearman agreement over 3000 random problems.

Source: The authors.

Table 7. Summary of the simulation experiments.

Experiment	Setting	Result
Parameter sweep	81 settings of the two parameters in 0.1 to 0.9	Condition-based first in all; Spearman 1.00
Weight perturbation	each weight changed by $\pm 20\%$	Ranking unchanged; Spearman 1.00
Rank reversal, deletion	remove each policy in turn	Order of survivors preserved in all cases
Rank reversal, addition	add a dominated policy	Full order preserved
Agreement, random	3000 problems, 4 to 8 policies	Mean Spearman 0.951; median 1.00
Reversal frequency	17900 deletion trials	AROMAN 30.0%; PROMETHEE 28.4%

Source: The authors.

7. Importance for practitioners

The model is built for the people who actually decide how a ship engine is maintained, namely chief engineers, fleet superintendents, technical managers and classification surveyors. Its value to them rests on five points.

First, the weights are objective and auditable. Because *MEREC* reads the weights from the decision data rather than from a pairwise comparison, no party can overstate the importance of a favoured criterion, and the weighting can be reproduced by anyone who has the rating matrix. This matters when a maintenance budget must be defended to an owner or to a flag administration.

Second, the picture fuzzy input is honest about doubt. A marine engineer is often willing to support a policy in part, to oppose it in part and to abstain on the rest because the evidence is incomplete. The positive, neutral and negative degrees record this directly, and the refusal degree records the part of the

judgement that is withheld, so the model does not force experts into false certainty.

Third, the ranking is robust. The parameter sweep, the weight perturbation and the rank reversal test all left the order unchanged, and the agreement with *PROMETHEE* was very high, so a manager can act on the recommendation without fear that it is an artefact of an arbitrary setting. The detailed proofs give the same assurance in theory: the ranking responds monotonically to better judgements, it cannot take arbitrarily large values, and the weights do not change abruptly when the alternative set changes.

Fourth, the model supports fleet standardisation and modern requirements. Once the criteria and the linguistic scale are fixed, the same procedure can be applied to every engine in a fleet, which makes maintenance policy choices comparable across ships and over time. Because reliability, downtime and safety dominate the objective weights, the method naturally aligns with the move towards condition monitoring and predictive techniques that classification societies and owners now encourage for safety and for decarbonisation.

Fifth, the method is light to run. It needs only a rating matrix and a short calculation, so it can be embedded in a planned maintenance system or a spreadsheet on board, and it produces a transparent score that can be revisited whenever the operating profile, the fuel, the trade or the regulatory context changes.

7.1 An illustrative example for practitioners

Consider a chief engineer who must recommend a maintenance policy for the main engine of a bulk carrier and who wants to justify the choice to the owner. The engineer follows the model as a short recipe. To begin, the three experts rate each policy against the seven criteria of Table 2 using the words of Table 1. Take the safety criterion C3 and the condition-based policy A4. The chief engineer, the fleet superintendent and the classification surveyor rate its safety as very high, high and very high. Mapping these words through Table 1 and merging them with the operator of equation (6) and the expert weights 0.40, 0.35 and 0.25 gives the picture fuzzy number (0.862, 0.064, 0.064). Its score from equation (4) is the value below.

$$S = \frac{1 + 0.862 - 0.064}{2} = 0.899$$

A score this close to one tells the engineer that the panel strongly supports the safety of condition-based maintenance with very little opposition and almost no abstention. Repeating the calculation for every cell produces the score matrix of Table 4.

Next the engineer reads the objective weights from Table 5. The data say that reliability, downtime and safety together drive the decision, while raw life-cycle cost carries little weight because the four policies do not differ much in the way cost separates them. This is a useful message in itself: for this engine the argument should be made on availability and safety, not on headline price. Finally the engineer reads the ranking from Table 6, where condition-based maintenance comes first, ahead of predictive, preventive and corrective maintenance. The recommendation can be defended on three grounds. The weights came from the data and not from opinion, the result did not change when the method parameters and the weights were varied, and an independent method, *PROMETHEE*, produced the same order. If the owner later questions one judgement, say by arguing that condition monitoring is harder to implement than assumed, the engineer simply lowers the feasibility rating of A4, recomputes in a few seconds and shows whether the conclusion still holds. In the present case the lead of condition-based maintenance is wide enough that a single softer judgement does not overturn it.

8. Conclusion

This chapter proposed a picture fuzzy *MEREC-AROMAN* model for selecting the maintenance policy of a ship main engine and applied it to a choice among corrective, preventive, predictive and condition-based maintenance. The model joins three ideas that had not been combined for maritime maintenance before: picture fuzzy judgements that record support, abstention, opposition and refusal; objective weights from the removal effects of the criteria; and a ranking built on a two-step linear and vector normalisation. In the illustrative engine case condition-based maintenance was preferred, the ranking was stable across the method parameters and the weights, and the agreement with *PROMETHEE* was complete in the case study and high on average across thousands of random problems.

The chapter also contributed three detailed proofs. The picture fuzzy normalisation preserves the preference order, so the model is monotone with respect to better judgements. The *AROMAN* aggregation is bounded by an explicit constant that does not depend on the number of alternatives. The *MEREC* weights are nonnegative, sum to one, are invariant to the scale of the data and are stable when a non-pivotal alternative is added or removed. Each proof was confirmed numerically over tens of thousands of random problems.

This study has limitations that also frame the further work. The expert ratings are illustrative rather than elicited from a real panel, so the numerical outcome should be read as a demonstration of the procedure and not as a fleet recommendation. The case considers a single engine with one set of criteria and one set of expert weights, and the weights of the experts were fixed rather than derived from a consistency measure. The simulation also showed that, in common

with the established methods it was compared against, the model is not free of rank reversal in general, even though the engine case was fully stable.

Several extensions are worth pursuing. The criteria and the linguistic scale could be tuned to particular ship types or trades. The expert weights could themselves be derived from a consistency measure. Interval valued or spherical fuzzy versions could be developed for even richer uncertainty, and the model could be embedded in a planned maintenance system so that the policy is revisited automatically as monitored data accumulate. The combination of objective weighting, a robust ranking and transparent proofs gives engineers and practitioners a decision aid that is both rigorous and practical.

Declarations

Funding. This research received no external funding. **Conflicts of interest.** The authors declare no conflict of interest. **Data availability.** The numerical ratings used in the case study are illustrative and were prepared by the authors to demonstrate the procedure. The reproducibility materials are available from the corresponding author upon reasonable request.

References

- Aires, R. F. F., & Ferreira, L. (2018). The rank reversal problem in multi-criteria decision making: A literature review. *Pesquisa Operacional*, 38(2), 331-362. <https://doi.org/10.1590/0101-7438.2018.038.02.0331>
- Al-Najjar, B., & Alsyouf, I. (2003). Selecting the most efficient maintenance approach using fuzzy multiple criteria decision making. *International Journal of Production Economics*, 84(1), 85-100. [https://doi.org/10.1016/S0925-5273\(02\)00380-8](https://doi.org/10.1016/S0925-5273(02)00380-8)
- Animah, I., & Shafiee, M. (2019). Maintenance strategy selection for critical shipboard machinery systems using a hybrid AHP-PROMETHEE and cost benefit analysis: A case study. *Journal of Marine Engineering & Technology*, 20, 312-323. <https://doi.org/10.1080/20464177.2019.1572705>
- Asuquo, M. P., Wang, J., Zhang, L., & Phylip-Jones, G. (2019). Application of a multiple attribute group decision making model for selecting appropriate maintenance strategy for marine and offshore machinery operations. *Ocean Engineering*, 179, 246-260. <https://doi.org/10.1016/j.oceaneng.2019.02.065>
- Atanassov, K. T. (1986). Intuitionistic fuzzy sets. *Fuzzy Sets and Systems*, 20(1), 87-96. [https://doi.org/10.1016/S0165-0114\(86\)80034-3](https://doi.org/10.1016/S0165-0114(86)80034-3)
- Behzadian, M., Kazemzadeh, R. B., Albadvi, A., & Aghdasi, M. (2010). PROMETHEE: A comprehensive literature review on methodologies and applications. *European Journal of Operational Research*, 200(1), 198-215. <https://doi.org/10.1016/j.ejor.2009.01.021>
- Bošković, S., Švadlenka, L., Jovčić, S., Dobrodolac, M., Simić, V., & Bacanin, N. (2023). An alternative ranking order method accounting for two-step normalisation (AROMAN): A case study of the electric vehicle selection problem. *IEEE Access*, 11, 39496-39507. <https://doi.org/10.1109/ACCESS.2023.3265818>
- Brans, J. P., & Vincke, P. (1985). A preference ranking organisation method: The PROMETHEE method for multiple criteria decision-making. *Management Science*, 31(6), 647-656. <https://doi.org/10.1287/mnsc.31.6.647>
- Chaurasiya, R., & Jain, D. (2023). Hybrid MCDM method on Pythagorean fuzzy set and its application. *Decision Making: Applications in Management and Engineering*, 6(1), 379-398. <https://doi.org/10.31181/dmame0306102022c>
- Cuong, B. C. (2014). Picture fuzzy sets. *Journal of Computer Science and Cybernetics*, 30(4), 409-420.
- Emovon, I. (2016). Ship system maintenance strategy selection based on Delphi-AHP-TOPSIS methodology. *World Journal of Engineering and Technology*, 4(2), 252-260. <https://doi.org/10.4236/wjet.2016.42024>

- Emovon, I., Norman, R. A., & Murphy, A. J. (2018). Hybrid *MCDM* based methodology for selecting the optimum maintenance strategy for ship machinery systems. *Journal of Intelligent Manufacturing*, 29(3), 519-531. <https://doi.org/10.1007/s10845-015-1133-6>
- Fan, J., Lei, T., & Wu, M. (2024). *MEREC-MABAC* method based on cumulative prospect theory for picture fuzzy sets: Applications to wearable health technology devices. *Expert Systems with Applications*, 255, 124749. <https://doi.org/10.1016/j.eswa.2024.124749>
- Garg, H. (2017). Some picture fuzzy aggregation operators and their applications to multicriteria decision-making. *Arabian Journal for Science and Engineering*, 42(12), 5275-5290. <https://doi.org/10.1007/s13369-017-2625-9>
- Jana, C., Senapati, T., Pal, M., & Yager, R. R. (2019). Picture fuzzy Dombi aggregation operators: Application to *MADM* process. *Applied Soft Computing*, 74, 99-109. <https://doi.org/10.1016/j.asoc.2018.10.021>
- Kara, K., Yalçın, G. C., Acar, A. Z., Simic, V., Konya, S., & Pamučar, D. (2024). The *MEREC-AROMAN* method for determining sustainable competitiveness levels: A case study for Turkey. *Socio-Economic Planning Sciences*, 91, 101762. <https://doi.org/10.1016/j.seps.2023.101762>
- Karatuğ, Ç., Arslanoğlu, Y., & Guedes Soares, C. (2022). Determination of a maintenance strategy for machinery systems of autonomous ships. *Ocean Engineering*, 266, 113013. <https://doi.org/10.1016/j.oceaneng.2022.113013>
- Keshavarz-Ghorabae, M., Amiri, M., Zavadskas, E. K., Turskis, Z., & Antucheviciene, J. (2021). Determination of objective weights using a new method based on the removal effects of criteria (*MEREC*). *Symmetry*, 13(4), 525. <https://doi.org/10.3390/sym13040525>
- Lazakis, I., & Ölçer, A. (2016). Selection of the best maintenance approach in the maritime industry under fuzzy multiple attributive group decision-making environment. *Proceedings of the Institution of Mechanical Engineers, Part M*, 230(2), 297-309. <https://doi.org/10.1177/1475090215569819>
- Mufazzal, S., & Muzakkir, S. M. (2018). A new multi-criterion decision making method based on proximity indexed value for minimising rank reversals. *Computers & Industrial Engineering*, 119, 427-438. <https://doi.org/10.1016/j.cie.2018.03.045>
- Patil, A. S., Soni, G., Prakash, A., & Karwasra, K. (2022). Maintenance strategy selection: A comprehensive review of current paradigms and solution approaches. *International Journal of Quality & Reliability Management*, 39(3), 675-703. <https://doi.org/10.1108/IJQRM-04-2021-0105>
- Saidin, M. S., Lee, L. S., Marjugi, S. M., Ahmad, M. Z., & Seow, H. V. (2023). Fuzzy method based on the removal effects of criteria (*MEREC*) for determining

- objective weights in multi-criteria decision-making problems. *Mathematics*, 11(6), 1544. <https://doi.org/10.3390/math11061544>
- Shafiee, M. (2015). Maintenance strategy selection problem: An MCDM overview. *Journal of Quality in Maintenance Engineering*, 21(4), 378-402. <https://doi.org/10.1108/JQME-09-2013-0063>
- Spearman, C. (1904). The proof and measurement of association between two things. *American Journal of Psychology*, 15(1), 72-101. <https://doi.org/10.2307/1412159>
- Thin, H. X., & Van Dua, T. (2024). Enhancing understanding of changes in solution rankings with variations in user coefficients in the AROMAN method. *International Journal of Mechanical Engineering and Robotics Research*, 13(3), 354-361. <https://doi.org/10.18178/ijmerr.13.3.354-361>
- Tian, C., Peng, J. J., Zhang, S., Zhang, W. Y., & Wang, J. Q. (2019). Weighted picture fuzzy aggregation operators and their applications to multi-criteria decision-making problems. *Computers & Industrial Engineering*, 137, 106037. <https://doi.org/10.1016/j.cie.2019.106037>
- Wang, Y. M., & Luo, Y. (2009). On rank reversal in decision analysis. *Mathematical and Computer Modelling*, 49(5-6), 1221-1229. <https://doi.org/10.1016/j.mcm.2008.06.019>
- Zadeh, L. A. (1965). Fuzzy sets. *Information and Control*, 8(3), 338-353. [https://doi.org/10.1016/S0019-9958\(65\)90241-X](https://doi.org/10.1016/S0019-9958(65)90241-X)