

Makine Öğrenmesi ile Zenginleştirilmiş Çok Kriterli Bir Karar Verme Yaklaşımı: Electre Ağacı Yöntemi ve Sürdürülebilir Kalkınma Eğitim Göstergeleri Üzerine Bir Örnek Uygulama

Hasan Arda BURHAN¹

Özet

Çok Kriterli Karar Verme (ÇKKV) yöntemlerinin özellikle son yıllarda sıklıkla kullanılmaya başlayan Makine Öğrenmesi (Machine Learning (ML)) algoritmaları ile entegrasyonu, karmaşık karar verme süreçlerini daha doğru ve dinamik hale getiren önemli bir gelişme olarak öne çıkmaktadır. Bu çalışma, esas olarak Montenegro de Barros vd. (2021)'nin çalışmaları ile literatüre giren ancak henüz Türkçe literatürde kullanılmamış bir ÇKKV-ML temelli sınıflandırma yaklaşımı olan ELECTRE Ağacı (ELECTRE Tree) yönteminin tanıtılmasını amaçlamaktadır. Bu doğrultuda çalışmada Avrupa Birliği İstatistik Ofisinin (EUROSTAT) yayınladığı istatistiklerden yararlanılarak Sürdürülebilir Kalkınma Amaçları (SKA)'ndan 4.sü olan Nitelikli Eğitim amacına ait göstergelerin dahil olduğu bir de örnek illüstratif uygulama yapılmıştır. Örnek uygulama sonucunda dört farklı sınıf elde edilmiş ve SKA 4'e göre en başarılı ülkelerin Danimarka, İrlanda, Hollanda, Finlandiya ve İsveç olmuş; Türkiye ise üçüncü sınıfta yer almıştır. Elde edilen isabetli sınıflandırmalar uyarınca yöntemin etkin çözümler sunabileceği görülmüştür.

Anahtar Kelimeler: ELECTRE Ağacı, ÇKKV, Makine Öğrenmesi, Sınıflandırma

JEL Kodları: C13, C38, I25

A Multi-Criteria Decision-Making Approach Enriched with Machine Learning: The Electre Tree Method and an Illustrative Example on Sustainable Development Education Indicators

Abstract

The integration of Multi-Criteria Decision-Making (MCDM) methods with Machine Learning (ML) algorithms, which have become increasingly widespread in recent years, stands out as a significant development in improving the accuracy and dynamism of complex decision-making processes. This study mainly aims to introduce the ELECTRE Tree method, a classification approach based on MCDM-ML, to the Turkish literature which was first presented by Montenegro de Barros et al. (2021). The study includes an example illustrative application utilizing statistics published by the European Union's Statistical Office (EUROSTAT) to analyze indicators related to the fourth Sustainable Development Goal (SDG 4): Quality Education. According to the results, four distinct classes obtained, with Denmark, Ireland, the Netherlands, Finland, and Sweden emerging as the top-performing countries; while Türkiye was classified in the third group. The accurate classifications indicate that the integration of this method can provide effective.

Keywords: ELECTRE Tree, MCDM, Machine Learning, Classification

JEL Classification: C13, C38, I25

¹ Doç. Dr., Kütahya Dumlupınar Üniversitesi, İİBF, Ekonometri Bölümü, arda.burhan@dpu.edu.tr, orcid.org/0000-0003-4043-2652

1. Giriş

Günümüz dijital dönüşüm çağında kuruluşlar açısından doğru zamanda doğru kararlar almanın artan önemine paralel olarak, elde edilen veriyi değerli içgörülere dönüştürecek analitik süreçler ve buna karşılık gelen yöntem ve beceriler de bir gereklilik haline gelmektedir. Öte yandan karar vericiler açısından geleceğin risk ve belirsizlik barındırması da karar verme sürecini kimi zaman kritik önemde bir durum haline getirebilmektedir (Yaralıoğlu, 2010). Büyük veriye olan bağımlılığın artmasıyla, etkili ve ölçeklenebilir analiz sistemleri geliştirmenin, iş dünyası veya kamu sektörü fark etmeksizin her kuruluş için oldukça önemli olduğu da ifade edilebilmektedir. Bu bağlamda veri analitiği, bir soruna çözüm bulmak veya yeni fırsatları belirlemek için verilerin, analizlerin ve modellemenin kullanılmasını içermektedir (El-Morrvid., 2022). 1950'lerden bu yana, karar verme problemlerini yapılandırmaya yardımcı olacak bir çerçeve sağlamak ve alternatiflerden tercihler oluşturmak amacıyla kullanılan ve veri analitiğinin bir parçası olarak değerlendirilebilecek Çok Kriterli Karar Verme (ÇKKV) yöntemleri, çeşitli kriterlere dayalı olarak seçenekleri değerlendirmek ve sıralamak için yapılandırılmış bir metodoloji sunmaktadır (Taherdoost ve Madanchian, 2023). Literatürde Analitik Hiyerarşi Süreci (AHS), Analitik Ağ Süreci (AAS), Combined Compromise Solution (CoCoSo), Evaluation Based on Distance from Average Solution (EDAS), Multi-objective Optimization Based on Ratio Analysis Plus Full Multiplicative Form (MULTIMOORA), Preference Ranking Organization Method for Enrichment Evaluations (PROMETHEE), VISe Kriterijumska Optimizacija I Kompromisno Resenje (VIKOR) ve Weighted Aggregated Sum Product Assessment (WASPAS) gibi çok sayıda yöntem geliştirilmiş ve araştırmacıların kullanımına sunulmuştur (Kacprzak, 2024). Bununla birlikte, kimi ÇKKV uygulamalarının karar vericilerin öznel değerlendirmelerine dayanması ve bilişsel yanlılıklara açık olması, ayrıca bu uygulamalarda kullanılan yöntemlerin ağırlıklar, eşikler veya normalleştirme gibi geleneksel kavram ve yaklaşımları içermeleri nedeniyle parametre değerlerindeki değişikliklere karşı hassas olabileceği ifade edilmektedir (Fu vd., 2022; Mohanty vd., 2025). Bu doğrultuda Makine Öğrenmesi (*Machine Learning (ML)*) yöntemleri daha nesnel bir yapı sağladıkları için daha iyi bir yaklaşım olarak değerlendirilmektedir (Shidik vd., 2024). Bir veri kümesi içerisindeki kuralları, ilişkileri, desenleri ayırt etmek ve bunları karar alma süreçlerinde kullanmak için analitik bir araç olarak değerlendirilebilecek ML'nin veri analitiğinin etkinliğini büyük ölçüde artırdığı ve bu nedenle büyük dil modelleri, tıp, dolandırıcılık tespiti, görüntü tanıma, kredi analizi, müşteri ilişkileri gibi çok farklı alanlarda kullanılabildiği ifade edilebilmektedir (Liakos vd., 2018; Balali vd., 2020; Buchholz ve Grote, 2023; Wu vd., 2023). Söz konusu alanlarda araştırmacıların karşılaştıkları gerçek yaşam problemlerinin çözümünde kullanılacak ML yöntem(ler)inin seçiminde ise denetimli (*supervised*), denetimsiz (*unsupervised*) ve pekiştirmeli (*reinforcement*) öğrenme olarak ifade edilen yaklaşımlar tercih edilebilmektedir (Uğuz, 2021). Genel anlamda ele alındığında denetimli öğrenmenin tahmin ve sınıflandırma ile, denetimsiz öğrenmenin ise kümeleme amaçlı çalışmalarda kullanıldığı ifade edilmekte iken, pekiştirmeli öğrenmenin, bir veya birden fazla şemada sistemde durum değişiklikleri gibi olası

bir etki yaratacak potansiyel optimal stratejiyi bulmayı amaçladığı belirtilmektedir (Xu, 2019; Chen vd., 2021). Denetimli öğrenme dahilinde gerçekleştirilen regresyon uygulamalarında girdi kümesi vasıtasıyla sayısal çıktı değerleri tahmin edilmekte; sınıflandırma uygulamalarında ise çıktı değişkeni, regresyonda aldığı sayısal değer aksine bir sınıf kodu ile ifade edilmektedir (Alpaydın, 2004). İlgili literatürde sıklıkla kullanılan sınıflandırma algoritmalarına dayalı yöntemlere *k-En Yakın Komşu (k-EYK)*, *Lojistik Regresyon (LR)*, *Naive Bayes (NB)*, *Karar Ağaçları (KA)*, *Rastgele Orman (RO)*, *Destek Vektör Makineleri (DVM)* ve *kernel-DVM (k-DVM)* örnek olarak gösterilebilmektedir. Denetimli öğrenme yaklaşımlarının aksine, denetimsiz öğrenmede ise herhangi bir sınıf kodu olmayıp, yalnızca girdi verilerinin mevcut olduğu ve algoritmaların kendi başlarına öğrenmeleri yoluyla ilgili veri setine ilişkin altta yatan yapının modellenmeye çalışıldığı bir süreç söz konusudur (Shu ve Ye, 2023). Ayrıca denetimsiz öğrenme, *K-means* ve *Hiyerarşik Kümelendirme* gibi tekniklerle birlikte *DBSCAN* gibi diğer yöntemleri de kapsamaktadır (Bao vd., 2019).

Diğer taraftan ÇKKV yöntemlerinin ilklerinden olan ve Roy (1968) tarafından geliştirilen Élimination Et Choix Traduisant la Réalité (ELECTRE) yöntemi, model dahilindeki kriterler için belirlenen eşik değerleri vasıtasıyla alternatif ve kriterler arası uyum-uyumsuzlukların değerlendirilmesine dayanmaktadır (Ömürbek vd., 2016). Bir diğer tanımlama ile ELECTRE yöntemi, her bir kriter için alternatifler arasında ikili üstünlük kıyaslamalarına dayanmaktadır (Yarahoğlu, 2010). Bu bağlamda kusursuz olmayabilen bilgiye dayalı olarak alternatiflerin tercih eşiklerini (tercih edilip edilmeme durumlarını) dikkate alarak karar vericilere büyük bir avantaj sağladığı ifade edilen yöntemin kullanıldığı uygulamaların alternatifler arası seçim, sıralama ve gruplama amaçları doğrultusunda önce *ELECTRE I*, *ELECTRE II* ve *ELECTRE III* gibi varyasyonları geliştirilmiş; literatüre daha sonra tanıtılan versiyonları ise *ELECTRE IV*, *ELECTRE IS*, *ELECTRE Tri-B*, *ELECTRE Tri-C* ve *ELECTRE Tri-NC* olarak adlandırılmıştır (Liu ve Wan, 2019; Liang vd., 2023). Bu çalışmanın odağı dikkate alınarak söz konusu yöntemler arasında öne çıkan ELECTRE Tri-B yöntemi, sınıflandırma problemlerini alternatiflerin her birini önceden tanımlanmış kategorilere yerleştirerek ve bunu da üstünlük (veya sıralama) ilişkisi oluşturarak çözmektedir (Mousseau ve Slowinski, 1998). Bu noktada ikili alternatif karşılaştırma işlemlerinde sınıflandırma ilişkisi, bir alternatifin en az bir diğer alternatif kadar iyi olup olmadığını göstermektedir (Da Silva Sales vd., 2024). Yu (1992) tarafından önerilen ve daha sonra Roy ve Bouyssou (1993) tarafından geliştirilen ve ilk başta ELECTRE Tri adı verilen yöntem, daha sonra Almeida-Dias vd. (2010) tarafından ELECTRE Tri-B olarak yeniden adlandırılmış olup, tedarikçi ve depo seçimi, ürün ve risk değerlendirmeleri başta olmak üzere farklı sınıflandırma temelli karar verme probleminin çözümünde kullanılabilmektedir. Ayrıca, söz konusu problemlerin çözümünde ELECTRE Tri-B yöntemi kullanılırken, kayıtsızlık, tercih ve veto eşikleri, kriter ağırlıkları, referans profillerin sayısı, referans profillerin değerleri ve lambda kesme seviyesi gibi parametrelerin tanımlanmasını gerektirdiği bilinmektedir (Alkan Şener, 2020).

Öte yandan, söz konusu parametreleri belirleme sürecinin zaman alması, karar vericiyi yöntemi uygulamaktan uzaklaştırabilecek veya parametreleri yeterince rafine etmeden, ani ve düşünülmemiş değerler seçmesine yol açabilecek olması nedeniyle Montenegro de Barros vd. (2021) tarafından referans profillerin sayısını veya ELECTRE Tri-B parametrelerinin herhangi bir kombinasyonunu belirleyip optimize edebilen *ELECTRE Ağacı (ELECTRE Tree)* algoritması literatüre tanıtılmıştır. ELECTRE Ağacı yöntemiyle işlem yapılırken tümünün yerine belirli sayıda parametrenin ele alınması ve karar vericinin problem konusundaki deneyiminden faydalanılmasına önem verilir ve böylece algoritma, parametreleri optimize ederek ve karmaşık bir problemi daha küçük parçalara bölerek önyargılı çözümlerden kaçınmayı amaçlar (Da Silva Sales vd., 2024). Öte yandan, ELECTRE Ağacı yönteminin ELECTRE Tri-B algoritması üzerine uzmanlaşarak eksik parametreleri türetme ve eksik bilgileri bütünleştirme konusunda robust niteliğinden ödün vermeden yenilikçi bir yaklaşım sunduğu da ifade edilmektedir (Pereira vd., 2024).

Bu bağlamda çalışmanın amacı, esas olarak henüz Türkçe literatürde üzerine çalışma yapılmamış olan ELECTRE Ağacı yönteminin tanıtılmasıdır. Öte yandan Türkçe literatüre tanıtılmak istenen ELECTRE Ağacı yönteminin anlaşılabilirliğini desteklemek adına çalışma dahilinde bir örnek illüstratif uygulama yapılmıştır. Bu doğrultuda Avrupa Birliği (AB) ülkeleri ve Türkiye, AB İstatistik Ofisi (EUROSTAT) Sürdürülebilir Kalkınma veri tabanı (Bkz. EU (2023)) ve Roszkowska ve Filipowicz-Chomko (2020)'nın çalışmalarında yer alan kriter seti göz önünde bulundurularak Sürdürülebilir Kalkınma Amacı 4 (SKA 4) kapsamında ELECTRE Ağacı yöntemi ile karşılaştırılıp sınıflandırılmıştır. Birleşmiş Milletler (BM) Genel Kurulu 2015 yılında 17 Sürdürülebilir Kalkınma Amacını (SKA) içeren “Dünyamızı Dönüştürmek: 2030 Sürdürülebilir Kalkınma Gündemi” başlıklı 2030 kalkınma gündemini ilan etmesiyle ön plana çıkan SKA'lar, dünya genelindeki hükümetlerin öncelikli amaçları arasında yer almakta olup, sürdürülebilir büyümeyi teşvik etmeyi; refahı, ekonomik büyümeyi, çevresel ve eğitimsel/akademik iyileşmeyi sağlamayı hedeflemektedir (UN, 2015). Örnek uygulama içerisinde yer verilen SKA 4, herkes için yaşam boyu eğitim ve öğrenim fırsatlarını teşvik etmeyi amaçlayan *Nitelikli Eğitim* alt maddesidir (Saini vd., 2023). Çalışmanın sonraki bölümünde yöntem ile ilgili literatür taramasına yer verilmiş olup, bunu takip eden bölümde ELECTRE Ağacı algoritması ve içeriğinde yer alan yöntemler açıklanmıştır. Örnek uygulama ve elde edilen çıktılara dair yorum ve değerlendirmelerin verildiği bölümü ise sonuç ve öneriler takip etmektedir.

2. Literatür Taraması

ELECTRE Ağacı yönteminin içeriğinde ELECTRE Tri-B, -eğer kümeler atama örnekleri yerine kullanılıyorsa- bir kümeleme algoritması veya bir dizi atama örneği, ardından sadeliği ve hesaplama zamanı performansı nedeniyle K-means++ algoritması, son olarak da genetik algoritmaların kombinasyonu bulunmaktadır (Montenegro de Barros vd., 2021). Literatürde, yöntemin tanıtıldığı çalışma dışında henüz 1 (bir) adet uygulama yer almaktadır. Bu nedenle bu bölüm dahilinde, söz

konusu çalışmaya ek olarak yöntemin dayandığı ELECTRE Tri-B içerikli uygulamalara, ayrıca örnek uygulamada ele alınan konuyu literatürde ele alan bazı çalışmalara da yer verilmiştir. ELECTRE Ağacı yönteminin uygulandığı çalışmalarında Da Silva Sales vd. (2024), görüşmeler yoluyla elde ettikleri verileri üzerinden elektronik atık ön arıtma/işleme birimlerinin uygulanabilirliğini Brezilya'daki bir şehir için ele almışlar; Duyarlılık Analizleri (DA)'nin uygulanacağı alternatifler kümesini seçmek için sekiz test gerçekleştirmişler ve alternatifleri “*daha uygulanabilir, orta seviye ve az uygulanabilir*” olmak üzere üç kategoriye ayırmışlardır. Çalışma dahilinde ELECTRE Ağacı yöntemi, 1. ve 2. testlerde tüm parametreler için; 3'ten 8. teste kadar ise seçili parametrelerin tanımlanmalarında kullanılmıştır. Elde edilen sonuçlara göre şehir dahilinde en az iki ön arıtma birimi bulunan alternatifler, bazı DA'den sonra da uygulanabilir görünmüş ve bu durum, daha küçük birimlerin ve daha kısa taşıma mesafelerinin avantajlarını ortaya koymuştur.

Literatürde yer alan çok sayıda ELECTRE Tri-B içerikli uygulamalara bakıldığında: Arondel ve Girardin (2000), tarımsal uygulamaların, özellikle ekim sistemlerinin çevresel bileşenler üzerindeki etkisini dört etki kategorisi ve üç kriter ailesi tanımlayarak incelemişlerdir. Sonuçlara göre, ELECTRE Tri-B sıralama yönteminin uygulanabilir sonuçlarının, nihai kullanıcıların sorularına cevap verdiği ve bazı zorlukları da işaret ettiği belirtilmiştir. Georgopoulou vd. (2003) Yunanistan'daki bir vaka çalışması üzerinden ELECTRE Tri-B'yi kullanarak potansiyel sera gazı emisyonu azaltma önlemlerini incelemiş ve özellikle enerji sektörü için bir Ulusal Eylem Planı oluşturmayı hedeflemişlerdir. Çalışmada uygulanan yöntemin karşılaşılan sorunlara faydalı içgörüler sunduğu belirtilmekle birlikte potansiyel emisyon azaltma önlemlerinin sayısının çok fazla olması ve nihai amacın bir zaman bağlı uygulanabilirlik ajandası oluşturmak olması nedeniyle önerilen yöntemin aynı zamanda bazı zorluklar ortaya koyduğu ifade edilmiştir. Karakosta vd. (2009) Temiz Kalkınma Mekanizması (TKM)'ni beş farklı gelişmekte olan ülke olan Şili, Çin, İsrail, Kenya ve Tayland için elektrik üretimi alanındaki sürdürülebilir enerji teknolojisi önceliklerinin belirlenmesi yoluyla ve ulusal sürdürülebilir kalkınma öncelikleri bağlamında değerlendirmişlerdir. Analiz, rüzgar enerjisi gibi kaynakların tüm ülkeler için yüksek önceliğe sahip olması gibi anlamlı sonuçlar ortaya koymuş, ayrıca petrolün elektrik üretimi için yüksek öncelikli bir alternatif olarak görülmemesi gerektiğini de göstermiştir. Brito vd. (2010) çalışmalarında doğal gaz boru hatlarındaki riski değerlendirmiş ve boru hattı bölümlerini risk kategorilerine sınıflandırmak amacıyla Fayda Teorisi ve ELECTRE Tri-B yöntemini entegre etmiştir. Önerilen model, her boru hattı bölümünü, bir doğal gaz sızıntısı kazasından kaynaklanan insan, çevresel ve finansal etki boyutlarını göz önünde bulundurarak bir risk kategorisine atamış ve elde edilen sonuçlar, sürecin özellikle insan kaynaklı riskler tarafından etkilendiğini ve tamamen kontrol edilmediğini ortaya koymuştur. Nepomuceno ve Costa (2015) Brezilya'daki bir Üretim Mühendisliği Yüksek Lisans programının öğrencileri ve öğretim üyelerinden alınan algıları kullanarak, yüksek lisans diplomasının mezunlarının mesleki performansları üzerindeki etkilerini, ELECTRE Tri-B yöntemiyle değerlendirmişlerdir. Genel olarak, sonuçlar, programın mezunlarının

profesyonel beceri ve davranışları üzerinde olumlu bir etkisi olduğunu göstermiş, öte yandan en karamsar sınıflandırmanın, öğretim üyelerinin algılarıyla ilişkili olduğu görülmüştür. Şahin vd. (2021) e-öğrenme ortamlarından toplanan etkileşim verilerindeki desenleri keşfetmeyi amaçlamış ve bu nedenle önce etkileşim verilerine dayanarak öğrencileri farklı birimlerde sınıflandırmak, ikinci olarak ise ELECTRE Tri-B yöntemine dayalı sınıflandırma ile gerçek hayattaki sınıflandırma arasındaki ilişkiyi analiz etmek için aynı yöntemi kullanmışlar; elde edilen sonuçlara göre sınıflandırma karşılaştırmaları arasında orta düzeyde bir korelasyon tespit etmişlerdir. Emamat vd. (2022) hisse senedi portföyü seçimi problemi için ELECTRE Tri-B ve FlowSort yöntemlerini uygulamış ve her bir yöntemle elde edilen sonuçları karşılaştırarak bu yöntemlerin hisse senedi portföyü seçimi problemlerindeki performanslarını anlamaya çalışmışlardır. Çalışmada kriterlerin ağırlıklarını belirlemek için ayrıca Best-Worst Method (BWM) uygulanmıştır. Geniş bir hisse senedi havuzundan hisse seçimi yapmak amacıyla ELECTRE Tri-B için dört yaklaşım, FlowSort için 15 yaklaşım ve 19 farklı yaklaşım değerlendirilmiş, sonuçlar model parametresinin tutarsızlıkları en aza indirmek ve modelin gücünü artırmak için doğru şekilde tanımlanması gerektiğini göstermiştir Dell'Anna (2023) uluslararası düzeyde belirlenen sürdürülebilirlik hedefleri bağlamında ELECTRE Tri-B yöntemini İtalya'daki mevcut bina stokunun önceliklendirilmesinde kullanmıştır. Elde edilen sonuçlara göre yüksek başlangıç yatırımı gereksinimlerine rağmen, bina stokunun ekolojik dönüşümünün sağlık etkilerinde önemli azalmalar, daha fazla yeşil iş imkânı ve daha düşük kaynak tüketimi sağlayacağı görülmüştür. Bu çalışmalara ek olarak ELECTRE Tri-B yöntemi literatürde diğer yöntemlerle de birleştirilerek su kaynakları ve şebeke planlama (Carriço vd., 2012; Trojan ve Morais, 2012), güneş enerjisi santralleri (Sánchez-Lozano vd., 2016), kadına yönelik şiddet (De Souza vd., 2023) ve sağlık yönetimi (Rodrigues vd. 2022) gibi çok farklı alanlardaki uygulamalara konu olmuştur.

Öte yandan bu çalışmanın amacı örnek uygulama ile ilgili çıkarımlarda bulunmak olmamasına karşın, literatürde Sürdürülebilir Kalkınma Amaçları (SKA)'ndan 4.sü olan *Nitelikli Eğitim* amacı doğrultusunda ülke değerlendirmelerinin yapıldığı bazı uygulamalara da değinmek gerekirse; Roszkowska ve Filipowicz-Chomko (2020), çalışmalarında SKA 4 gösterge verilerini ve genişletilmiş Technique for Order of Preference by Similarity to Ideal Solution (TOPSIS) yöntemini kullanarak üç bileşik sürdürülebilirlik endeksi oluşturmuş; buna göre AB üye ülkelerinin eğitim alanındaki uygulamalarını 2015 yılı için değerlendirmişlerdir. Sonuçlara göre, Danimarka, İsveç ve Hollanda, üç endeksin tamamında en üst sınıfta yer alırken; Estonya, Slovenya, Belçika, Litvanya ve Letonya gibi ülkeler bir sonraki sınıfta, Slovakya, Yunanistan, Bulgaristan ve Romanya ise üç endeksin tamamında en düşük performans gösteren sınıfta yer almıştır. Kuc-Czarnecka vd. (2023), AB ülkelerinde SKA'nın uygulanma düzeyini değerlendirmek amacıyla, DA temelli bir bileşik gösterge kullanmışlardır. Bu bağlamda klasik bir yöntemin yenilikçi bir şekilde uygulanmasına dayalı olarak hesaplanan değerlere göre SKA 4 bağlamında İrlanda, Fransa, Slovenya ve İsveç en üst ülke grubunda yer alırken, Romanya, Bulgaristan ve Slovakya son üç ülke olarak sınıflandırılmıştır. Karsak ve Uçar

(2024), AB üyesi 20 ülkenin eğitim performansını karşılaştırmak amacıyla, EDAS yöntemini BWM ile entegre eden bir yaklaşım kullanmışlardır. Ayrıca karşılaştırma amacıyla aynı veri setine BWM ağırlıkları kullanılarak TOPSIS, VIKOR ve Combinative Distance-based Assessment (CODAS) yöntemleri de uygulanmıştır. Modelde Programme for International Student Assessment (PISA) test sonuçlarının yanı sıra öğretmen/öğrenci oranı, öğrenme süresi ve Gayri Safi Yurtiçi Hasıla (GSYİH) içindeki ilköğretime yönelik kamu harcamalarının payı da dikkate alınmıştır. Sonuçlara göre, İsveç, Polonya, Belçika ve Slovenya en yüksek performansı gösteren ülkeler olurken; Macaristan, Slovakya ve Litvanya en düşük performans gösteren ülkeler arasında yer almıştır.

3. Yöntem

Montenegro de Barros vd. (2021) tarafından önerilen ELECTRE Ağacı, üç farklı yöntemin birleşiminden oluşmaktadır:

- Belirli bir parametre kümesinin ya da tüm parametrelerin iyimser ya da kötümser perspektiflere ait kurallarla ele alındığı ELECTRE Tri-B yöntemi;
- Performans göstergelerinin sağladığı avantaj nedeniyle K-means++ algoritması;
- Bir metasezgisel yöntem olarak Genetik Algoritmalar (GA).

Bu doğrultuda, içeriğin devamında söz konusu yöntemlere ilişkin açıklamalara yer verilecektir.

3.1. ELECTRE Tri-B Yöntemi

ELECTRE Tri-B yöntemi, alternatiflerin önceden tanımlanmış kategorilere atandığı ve bu atamaların, bu kategorilerin sınırlarını belirleyen profiller ile alternatiflerin karşılaştırılmasına dayanan bir ÇKKV yöntemi olarak ifade edilebilmektedir (Şahin vd., 2021). $G = \{g_1, g_2, \dots, g_j\}$ j adet kriterden oluşan bir küme olup, her biri bir ağırlığa (önem düzeyi) w_j sahiptir; ayrıca $X = x_1, x_2, x_3, \dots$ ise R^j içinde, G kümesindeki her kriter için bir alternatif x_i 'nin değerlendirme puanlarını temsil eden bir vektör olup $B = \{b_1, b_2, \dots, b_n\}$ $n + 1$ referans profilinden oluşan bir kümeyi, burada, b_{h-1} ve b_h ise sırasıyla h 'inci sınıfın alt ve üst sınırlarını ifade etmektedir (De Souza vd., 2023). Her sınıf h ve her kriter j için, $g_j(b_h)$ ifadesi, h 'inci sınıfın üst sınırının j 'inci kriter tarafından değerlendirilmesini göstermekte iken her alternatif x_i ve her kriter j için, $g_j(x_i)$ ifadesi, i 'inci alternatifin j 'inci kriter açısından değerlendirilmesini göstermektedir ve üstünlük ilişkisi, $|g_j(x_i) - g_j(b_h)|$ mutlak değerinin önceden belirlenen kayıtsızlık (q_j), tercih (p_j) ve vektör (v_j) eşiklerinden büyük olması durumuna bağlı olup burada $v_j \geq p_j \geq q_j$ 'dir. Daha sonra, üstünlük ilişkilerini elde etmek için aşağıdaki adımlar uygulanır (Montenegro de Barros vd., 2021):

1. Adım: $c_j(x_i, b_h)$ ve $c_j(b_h, x_i)$ kısmi uyum derecelerinin hesaplanması;

$$c_j(x_i, b_h) = \begin{cases} 0 & \text{eğer } g_j(b_h) - g_j(x_i) \geq p_j \\ 1 & \text{eğer } g_j(b_h) - g_j(x_i) < q_j \\ \frac{p_j - g_j(b_h) + g_j(x_i)}{p_j - q_j} & \text{eğer } q_j \leq g_j(b_h) - g_j(x_i) < p_j \end{cases} \quad (1)$$

$$c_j(b_h, x_i) = \begin{cases} 0 & \text{eğer } g_j(b_h) - g_j(x_i) \geq p_j \\ 1 & \text{eğer } g_j(b_h) - g_j(x_i) < q_j \\ \frac{p_j - g_j(x_i) + g_j(b_h)}{p_j - q_j} & \text{eğer } q_j \leq g_j(x_i) - g_j(b_h) < p_j \end{cases} \quad (2)$$

2. Adım: $C(x_i, b_h)$ ve $C(b_h, x_i)$ global uyum derecelerinin hesaplanması;

$$C(x_i, b_h) = \frac{\sum_{j=1}^n w_j c_j(x_i, b_h)}{\sum_{j=1}^n w_j} \quad (3)$$

$$C(b_h, x_i) = \frac{\sum_{j=1}^n w_j c_j(b_h, x_i)}{\sum_{j=1}^n w_j} \quad (4)$$

3. Adım: $D_j(x_i, b_h)$ ve $D_j(b_h, x_i)$ kısmi uyumsuzluk derecelerinin hesaplanması;

$$D_j(x_i, b_h) = \begin{cases} 0 & \text{eğer } g_j(b_h) - g_j(x_i) < p_j \\ 1 & \text{eğer } g_j(b_h) - g_j(x_i) \geq v_j \\ \frac{-p_j - g_j(x_i) + g_j(b_h)}{v_j - p_j} & \text{eğer } p_j \leq g_j(b_h) - g_j(x_i) < v_j \end{cases} \quad (5)$$

$$D_j(b_h, x_i) = \begin{cases} 0 & \text{eğer } g_j(x_i) - g_j(b_h) < p_j \\ 1 & \text{eğer } g_j(x_i) - g_j(b_h) \geq v_j \\ \frac{-p_j - g_j(b_h) + g_j(x_i)}{v_j - p_j} & \text{eğer } p_j \leq g_j(x_i) - g_j(b_h) < v_j \end{cases} \quad (6)$$

4. Adım: “ x_i, b_h ’den daha kötü değildir” ifadesine olan güveni ifade eden $\sigma(x_i, b_h)$ ve $\sigma(b_h, x_i)$ güvenilirlik derecelerinin hesaplanması;

$$\sigma(x_i, b_h) = \begin{cases} C(x_i, b_h) \times \prod_{j=1}^n \frac{1 - D_j(x_i, b_h)}{1 - C(x_i, b_h)} & \text{eğer } D_j(x_i, b_h) > C(x_i, b_h) \\ C(x_i, b_h), & \text{diğer durumlarda} \end{cases} \quad (7)$$

$$\sigma(b_h, x_i) = \begin{cases} C(b_h, x_i) \times \prod_{j=1}^n \frac{1 - D_j(b_h, x_i)}{1 - C(b_h, x_i)} & \text{eğer } D_j(b_h, x_i) > C(b_h, x_i) \\ C(b_h, x_i), & \text{diğer durumlarda} \end{cases} \quad (8)$$

5. Adım: Üstünlük kararı hâlâ önceden belirlenmiş son bir parametreye, (λ) kesme seviyesine bağlıdır;

$$x_i S b_h \quad \text{eğer} \quad \sigma(x_i, b_h) \geq \lambda \quad 0,5 \leq \lambda < 1 \quad (9)$$

Son olarak, her alternatifin bir sınıfa atanması kötümser ve iyimser olmak üzere iki farklı kurala göre belirlenebilir ve kötümser kurala göre, $h = n, n-1, \dots, 0$ için bir alternatif sırasıyla her bir b_h referans profili ile karşılaştırılır. $x_i S b_h$ durumu gerçekleştiğinde alternatifin C_{h+1} sınıfına ait olduğu kabul edilir; öte yandan iyimser kurala göre ise, $h = 1, 2, \dots, n$ için bir alternatif sırasıyla her bir b_h referans

profili ile karşılaştırılır. Eğer $b_h Sx_i$ durumu gerçekleştiğinde alternatifin C_h sınıfına ait olduğu kabul edilir.

3.2. K-means ve K-means++ Algoritmaları

Bir kümeleme analizi yöntemi olarak K-means, aynı kümeye ait olduğu varsayılan bir grup seçenek için ortalama konum (ağırlıklı merkez) kullanarak kümeleri tanımlar (MacKay, 2003). Yinelenen bir algoritması olan yöntemde kümeler, optimal çözüm elde edilene kadar tekrar tekrar iyileştirilir (Kaya vd., 2023). Algoritma, her sınıf için başlangıçta ağırlıklı merkezi belirlemek amacıyla Öklidyen mesafe ya da veri kümesine bağlı olarak diğer yöntemler kullanılarak ortalama mesafeyi hesaplar (Tinsley ve Brown, 2000; Piekut, 2021). Öte yandan yöntem dahiline optimal küme sayısını belirleme sürecinde overfitting ile karşılaşmadan veri değişimini yakalamanın zorluğundan da söz edilmektedir (Matenga, 2022). Bu bağlamda Arthur ve Vassilvitskii (2007) tarafından önerilen K-means++ algoritması, verilen verileri belirli sayıda kümeye ayırabilen en popüler denetimsiz öğrenme algoritmalarından biri olup üç aşamadan oluşmaktadır (Hu vd., 2024):

1. Başlangıçta k adet çekirdek senaryo (merkez) seçilir ve ilk çekirdek senaryo rastgele seçilirken, geri kalan $(k-1)$ senaryolar, aday senaryolar ile seçilen çekirdek senaryolar arasındaki mesafeye dayalı bir piyango süreciyle belirlenir,
2. Talep veri kümesindeki her bir senaryo, kendisine en yakın çekirdek senaryoya atanır ve aynı çekirdek senaryoya atanan senaryolar bir küme oluşturur. Ardından, her küme için talep ortalaması hesaplanır. Bu işlem, tüm çekirdek senaryolar değişmeden kalana kadar tekrarlanır,
3. Tabakalı rastgele örnekleme uygulanır ve her küme için seçilecek senaryo sayısı varyansa dayalı olarak hesaplanır ve senaryolar olasılık dağılımına göre rastgele seçilir.

Öte yandan K-means algoritmasıyla karşılaştırıldığında, rastgele merkez seçimi yerine K-means++ algoritmasının daha iyi bir başlangıç noktası seçme prosedürü sunduğu ifade edilmektedir (Detaylar için Bkz. Arthur ve Vassilvitskii, 2007).

3.3. Genetik Algoritmalar (GA)

1975 yılında yayımlanan *Adaptation in Natural and Artificial Systems* adlı kitabıyla genetik algoritmaların geliştirilmesine öncülük eden John Henry Holland, optimizasyon problemlerine giderek daha iyi çözümler sağlamak amacıyla Darwin'in doğal seçim, çaprazlama ve mutasyon ilkelerine dayanan algoritmalar önermiştir (Estran vd., 2022). Hedef fonksiyonu optimize eden çözümlerden oluşan bir popülasyona ulaşmanın amaçlandığı GA'da bir problem çözümü genellikle bir gen vektörü ile temsil edilmekte iken her gen, optimize edilmesi gereken hedef fonksiyonda bulunan bir değişkenin değerine karşılık gelir ve genlerin bir araya gelmesi kromozom, kromozomların oluşturduğu grup ise popülasyon olarak adlandırılır (Montenegro de Barros vd., 2021). GA genellikle sekizli bir küme olarak tanımlanabilir: $GA = \{C, E, P_0, M, \Phi, I, \Psi, T\}$ ve bu kümede, C birimin kodlama yöntemini, E bireyin uygunluk değerlendirme fonksiyonunu, P_0 başlangıç

popülasyonunu yani başlangıç çözümünü, M popülasyon büyüklüğünü, Φ , Γ , Ψ , sırasıyla seçme, çaprazlama ve mutasyon operatörlerini, T ise GA'nın sonlanma koşulunu ifade etmekte olup GA'nın optimal çözüm arama sürecinde, her iterasyonda bir dizi aday çözüm saklanmakta, çözüm grubundaki en iyi birey belirli bir kurala göre seçilmekte ve daha sonra, bu bireyler üç genetik operatör olan seçme, çaprazlama ve mutasyon operatörleri kullanılarak yeniden birleştirilip yeni bir nesil aday çözüm grubu oluşturulmaktadır (Sun ve Xu, 2016). Buna göre temel olarak bir GA akışı aşağıdaki gibi ifade edilebilir (Khedkar ve Vyas, 2008):

- Rastgele bir başlangıç popülasyonu oluşturulur,
- Mevcut popülasyondaki her birey için uygunluk değeri hesaplanır ve kaydedilir,
- Popülasyon uygunluk değerine göre artan sırayla yeniden düzenlenir,
- Her birey için seçim olasılıkları tanımlanır ve bu olasılıklar uygunluk değeri ile orantılı olacak şekilde belirlenir ve böylece çaprazlama havuzu oluşturulur,
- Genetik operatörler aracılığıyla bireyleri seçerek yeni popülasyon oluşturulur ve bu işlemde bireyler ikiye bölünür ve çaprazlanır,
- Popülasyondan rastgele seçilen bazı bireyleri mutasyona uğrattırılır ve bunlar bir sonraki nesle aktarılır,
- Tatmin edici bir çözüm elde edilene kadar 2. adım tekrarlanır.

Öte yandan yukarıda verilen adımlar, herhangi bir GA uygulaması için genel bir gidiş yolunu temsil etmekte iken Montenegro de Barros vd. (2021) tarafından önerilen ELECTRE Ağacı algoritması dahilinde hedef fonksiyon ile ilgili olarak çözümün kalitesini doğrulamak için doğruluk (*accuracy*) metriği kullanılmış olup doğruluk metriği, atamaların K-means++ atamasıyla hizalanmış çözümlerle karşılaştırılmasıyla hesaplanmaktadır (Detaylar için Bkz. Montenegro de Barros vd., 2021: 592-593).

3.4. ELECTRE Ağacı Algoritması

Montenegro de Barros vd. (2021) tarafından literatüre tanıtılan ELECTRE Ağacı'nda her kriter için en yüksek değer en iyi kategoriye (tercih sırasına göre) atanmakta olup, öte yandan tüm parametrelerin çıkarımı önerilmez; bunun yerine, bu parametrelerin kısmi çıkarımına öncelik verilir ve karar vericinin konu hakkındaki deneyimi dikkate alınır. Parametreleri optimize ederek ve karmaşık bir problemi daha küçük parçalara ayırarak yanlı sonuçları önlemeye çalışan algoritma, yukarıda ELECTRE Tri-B bölümünde açıklandığı üzere iyimser ve kötümser etkileşimleri de dikkate alır (Da Silva Sales vd., 2024). Gösterim amaçlı olarak algoritmanın kod akışının da verildiği çalışmalarında Montenegro de Barros vd. (2021), belirlenmesi gereken parametreler tanımlandıktan sonra algoritmanın takip eden adımlarını şu şekilde açıklamaktadırlar:

- Örnek alternatiflerin örneklem büyüklüğü %10 ile %25, model sayısı 200 ile 1000 arasında belirlenir,

- Önerilen başlangıç GA parametreleri 25 ila 250 nesil, 10 ila 50 kromozomluk bir popülasyon büyüklüğü, bir elit üye, $\mu = 2$ ve $\eta = 1$ şeklinde operatör parametreleri, %1 ile %5 arasında değişen mutasyon oranı şeklinde belirlenir,
- Ele alınan probleme uygun olarak kriterlerin ve alternatiflerin sayısı belirlendikten sonra, ELECTRE Tri-B çözümü ile kümeleme/atama örneklerini karşılaştıran doğruluk metriğini optimize ederek model parametreleri bulunur,
- Bu süreç N kez tekrarlanır ve böylece tüm optimize edilmiş modelleri içeren bir çözüm listesi elde edilir,
- Son olarak, her alternatifin nihai sınıfı çoğunluk oylamasıyla veya belirlenen parametrelere sahip model göz önünde bulundurularak belirlenir.

Öte yandan ele alınan problemin içeriğine göre toplam tekrar sayısı olan N , popülasyon büyüklüğü ve optimize edilecek parametreler değişebilecekken, söz konusu değerlerin optimal veya optimal değere yakın sonuçlar elde etmek için yeterince büyük olması gerektiği, ayrıca küçük veri setleri için yukarıda verilen parametre değerlerinin istenilen sonuçları elde etmede yeterli olacağı ifade edilmiştir (Montenegro de Barros vd., 2021).


4. Veri Seti ve Örnek Uygulama

Çalışmada ELECTRE Ağacı yönteminin Türkçe literatüre tanıtılması amacıyla bir örnek illüstratif uygulama yapılmıştır. Söz konusu uygulama, Avrupa Birliği (AB) ülkeleri ve Türkiye için 2023 EUROSTAT Sürdürülebilir Kalkınma Amaçları (SKA)'ndan 4.sü olan *Nitelikli Eğitim* amacına ait veri setine (Bkz. EU (2023)); ayrıca Roszkowska ve Filipowicz-Chomko (2020)'nın çalışmalarında da kısmen yer alan ve Tablo 1'de tanımlanan kriterlere odaklanmaktadır. A, B, C ve D olmak üzere dört sınıfa ayrılan veri setinde sınıf $A > \text{sınıf } B > \text{sınıf } C > \text{sınıf } D$ ilişkisi bulunmaktadır. Çalışmada dahilindeki tüm analiz ve görselleştirmeler için Python programlama dili kullanılmış olup, analizde kullanılan ELECTRE Ağacı algoritmasına ait Python kodları ise Montenegro de Barros vd. (2021) tarafından ilgili çalışmada paylaşılan <https://github.com/Valdecy/ELECTRE-Tree> GitHub sayfasından alınmıştır.

Tablo 1'den görülebileceği üzere söz konusu uygulama için 27 AB ülkesi ve Türkiye için EUROSTAT veritabanına bağlı olarak 6 kriter belirlenmiştir. Öte yandan her bir kriter, Tablo 1'de belirtilen amaçlar doğrultusunda normalize edilmiştir. Zira ELECTRE Ağacı yönteminin kullanımı sırasında, değerler arasındaki karşılaştırmaların ve tercih ilişkilerinin hesaplanmasının ölçek farklılıklarından etkilenmemesi için normalizasyon işlemi gerekmektedir. İçeriğine K-means++ algoritmasının da dahil olduğu ELECTRE Ağacı uygulaması sonucunda ortaya çıkan sınıflandırma sonuçları Şekil 1'de verilmektedir:

Tablo 1. Uygulamada Yer Alan Ülkeler ve Kriterler

Ülkeler				Kriterler	Kriter Amacı
x1	Belçika	x19	Hollanda	1. Eğitim ve öğretimi erken bırakanlar	Minimizasyon
x2	Bulgaristan	x20	Avusturya	2. Yükseköğretim mezuniyet oranı	Maksimizasyon
x3	Çekya	x21	Polonya	3. Erken çocukluk eğitimi katılım oranı (3 yaş ve üzeri çocuklar)	Maksimizasyon
x4	Danimarka	x22	Portekiz	4. 15 yaşındaki öğrenciler arasında okuma, matematik veya fen bilimlerinde düşük başarı gösterenler	Minimizasyon
x5	Almanya	x23	Romanya	5. Son dört hafta içinde öğrenmeye katılan yetişkinler	Maksimizasyon
x6	Estonya	x24	Slovenya	6. En az temel dijital becerilere sahip bireylerin oranı	Maksimizasyon
x7	İrlanda	x25	Slovakya		
x8	Yunanistan	x26	Finlandiya		
x9	İspanya	x27	İsveç		
x10	Fransa	x28	Türkiye		
x11	Hırvatistan				
x12	İtalya				
x13	G. Kıbrıs				
x14	Letonya				
x15	Litvanya				
x16	Lüksemburg				
x17	Macaristan				
x18	Malta				



Şekil 1. Sınıflandırma Sonuçları

Şekil 1’de yer alan sınıflandırma sonuçlarına göre sırasıyla İsveç, Hollanda, Finlandiya, Danimarka ve İrlanda’nın sınıf A’ya; Lüksemburg, İspanya, Avusturya, Estonya, Slovenya, Portekiz, Belçika, Litvanya ve Letonya’nın sınıf B’ye; yalnızca Polonya’nın sınıf C’ye ve son olarak Türkiye’nin de içinde yer aldığı diğer AB ülkelerinin sınıf D’ye ait olduğu gözlemlenebilmektedir. Bir sonraki adımda ELECTRE Ağacı modelinin belirlediği kriter ağırlıkları ile eşik değerlerini anlamak, karar sınırları ile profillerini görselleştirmek için modelin öğrenme sürecinden elde edilen ortalama parametre değerleri hesaplanmaktadır. Bu sayede


modelin nasıl çalıştığı, profillerin nasıl oluştuğu ve hangi kriterlerin modele nasıl etki ettiğini görülebilmektedir. Buna göre örnek uygulamada söz konusu değerler Montenegro de Barros vd. (2021)'in çalışmasına da uygun olarak örneklem büyüklüğü %10; model sayısı 500, nesil sayısı 30, popülasyon büyüklüğü 15 kromozom olacak şekilde belirlenmiştir ve yalnızca 1 elit üye kullanılmış olup operatör parametreleri olan μ , 2'ye; η ise 1'e, mutasyon oranı ise %5 olacak şekilde ayarlanmıştır. Tablo 2'de, 500 model içeren uygulamaya ait seçili parametreler ve değerleri verilmektedir:

Tablo 2. Modele İlişkin Seçili Parametreler ve Karşılık Gelen Değerler

Parametreler	Değerler
Kriter Ağırlıkları	0,53; 0,48; 0,53; 0,50; 0,43; 0,26
Profil 1	0,64; 0,49; 0,77; 0,63; 0,43; 0,77
Profil 2	0,74; 0,62; 0,84; 0,71; 0,49; 0,77
Profil 3	0,82; 0,73; 0,90; 0,77; 0,56; 0,77
(λ) kesme seviyesi:	0,61
Doğruluk:	0,71


Tablo 2'de verilen kriter ağırlıkları (görelî önem değerleri) incelendiğinde en önemli ilk iki kriter olarak *Eğitim ve Öğretimi Erken Bırakanlar (Kriter 1)* ve *Erken Çocukluk Eğitimi Katılım Oranı (Kriter 3)*'nin öne çıktığını ve bunu yakın bir değerle *15 Yaşındaki Öğrenciler Arasında Okuma, Matematik veya Fen Bilimlerinde Düşük Başarı Gösterenler (Kriter 4)* ve *Yükseköğretim Mezuniyet Oranı (Kriter 2)*'nin takip ettiği görülmektedir. Beşinci kriter olan *Son Dört Hafta İçinde Öğrenmeye Katılan Yetişkinler*'in bu değerlere çok uzak olmadığı; altıncı kriter olan *En Az Temel Dijital Becerilere Sahip Bireylerin Oranı*'nin ise görelî önem ağırlığı en düşük kriter olduğu görülmektedir. ELECTRE Ağacı yönteminde bir profil, kriter ağırlıkları ve değerlerinin belirli kombinasyonlarını temsil eden bir tercih veya koşullar setini ifade etmekte ve bu profiller temelde, alternatifleri (bu durumda ülkeler) kriterler karşısında nasıl performans gösterdiklerine göre gruplandıran karar kuralları veya karar vektörleridir (Detaylar için Bkz. Ramezani, 2019). Bu bağlamda Tablo 2'deki profiller ele alındığında Profil 1'in, kriter 1, 3, 4 ve 6 için nispeten yüksek değerlere sahip olduğu ve kriter 3 ve 6'ya öncelik veren çözümler için iyi bir seçenek olabileceği söylenebilmekte iken, Profil 2'de, kriter 3 ve 6 öne çıkmakta, ayrıca kriter 1 ve 4'te ise orta düzeyde değerler görülmektedir. Bu profilin yine 3. ve 6. kriterlere öncelik veren ancak daha dengeli bir profil olduğu ifade edilebilmektedir. Son olarak Profil 3'te kriter 1, 3 ve 6 en yüksek değerlere sahip olup, bu durum, söz konusu profilin kriter 1 ve 3'ün önceliklendirildiği durumlar için en uygun seçenek olabileceğini göstermektedir. Kabul edilebilir çözümleri belirlemede kullanılan lambda kesme seviyesinin 0.61 olması, bu eşiğin üzerinde bir değere sahip herhangi bir profilin muhtemelen kabul edilebilir olduğunu göstermekte, buna göre özellikle kriter 1, 3 ve 6 için nispeten yüksek değerlere sahip olması nedeniyle Profil 3 en tercih edilen profil olarak öne çıkmaktadır. Öte yandan %71'lik doğruluk oranı ise, modelin çözümleri sınıflandırmada oldukça iyi bir iş çıkardığını ve genel olarak doğru sınıflandırmalar yapıldığını göstermekle birlikte modelin performansının daha da

iyileştirilebilmesinin mümkün olduğunu ifade etmektedir. Yöntemin son adımında ise kullanılan toplam model sayısı dikkate alınmakta (uygulamamızda 500 adet) ve her model alternatifi dört olası sınıftan birine dahil olacak şekilde sınıflandırılmakta; en çok oyu alan sınıf, alternatifin atanması gereken sınıf olarak belirlenmektedir (Montenegro de Barros vd., 2021). Bu doğrultuda elde edilen Şekil 2, karar sınırlarını göstermektedir:




Şekil 2. Doğrusal Olmayan Karar Sınırları

Yukarıda açıklandığı üzere her optimize edilmiş modelin tüm değerlerinin ortalaması alınarak gerçekleştirilen birleştirme prosedürü sonucunda elde edilen parametreler (Bkz. Tablo 2) modeli standart bir ELECTRE Tri-B modeline indirgemekte ve bu model karar sınırlarının her sınıfı bölen düz çizgiler olarak tanımlandığı doğrusal bir sınıflandırıcı olarak düşünülebilmektedir (Montenegro de Barros vd., 2021). Buna göre Şekil 3, birleştirme prosedürüne ait doğrusal karar sınırlarını göstermektedir:



Şekil 3. Doğrusal Karar Sınırları

Son olarak, Şekil 4, AB ülkeleri ve Türkiye için nihai sınıflandırma sonuçlarını göstermektedir:



Şekil 4. Ülke Sınıflandırmaları

Şekil 4'ten görülebileceği üzere, A sınıfındaki AB ülkeleri (Danimarka, İrlanda, Hollanda, Finlandiya ve İsveç) SKA 4'e önem vermekte ve çocukluk döneminde eğitim ve bir anlamda beşeri sermayeye yatırım yaparak sürdürülebilir kalkınma hedeflerini sağlamaya çalışmaktadırlar. Bu ülkeleri sırasıyla B sınıfındaki ülkeler Belçika, Estonya, İspanya, Letonya, Litvanya, Lüksemburg, Avusturya, Portekiz ve Slovenya ve C sınıfındaki tek ülke olan Polonya takip etmektedir. Öte yandan, Türkiye'nin de dahil olduğu D sınıfındaki diğer AB ülkelerinin, SKA 4 çerçevesindeki eğitime hedefleri konusunda diğer ülkelere kıyasla daha zayıf bir çaba sergilemekte oldukları söylenebilmektedir.

5. Sonuç ve Öneriler

Bilişim alanında hızlı gelişmelere sahne olan günümüzde büyük veri kullanımıyla şekillenen karmaşık karar verme süreçleri, güçlü ve sistematik değerlendirme araçlarına olan ihtiyacı her zamankinden daha önemli hale getirmiştir. 1950li yıllardan bu yana Çok Kriterli Karar Verme (ÇKKV) yöntemleri, birden fazla kriterle karakterize edilen karar problemlerini çözmek için yapılandırılmış bir çerçeve sunmakta, aynı zamanda belirsizlikler, riskler ve karmaşık değer sorunlarıyla da başa çıkabilmektedir (Ananda ve Herath, 2009). Diğer taraftan yapay zeka alanındaki hızlı gelişmelerle birlikte ön plana çıkan *Destek Vektör Makineleri (DVM)*, *Karar Ağaçları (KA)*, *Rastgele Orman (RO)*, *k-En Yakın Komşu* gibi Makine Öğrenmesi (*Machine Learning (ML)*) regresyon ve sınıflandırma algoritmalarının ve bunların ÇKKV yöntemleriyle entegrasyonunun, karar alma süreçlerindeki doğruluğu artırabildiği, böylece dinamik, veri odaklı karar alma süreçlerini desteklediği ifade edilmektedir (Kumar ve Pal, 2024). Bu modellerin ayrıca büyük veri kümelerinin ve karmaşık örüntülerin işlenmesi gereken

ortamlarda özellikle başarılı olup, tahminsel içgörüler sağlamaya, verideki gizli eğilimleri belirlemeye, büyük ve sürekli güncellenen verilerin bulunduğu günümüz dünyasında karar süreçlerini optimize etmeye olanak tanıdığı da ifade edilmektedir (Kumar, 2025). Bu bağlamda Montenegro de Barros vd. (2021) tarafından literatüre tanıtılan *ELECTRE Ağacı (ELECTRE Tree)* yöntemi, birden çok kriter içeren karar problemleri aracılığıyla parametre çıkarımlarında bulunmak ve böylece daha etkili çözümler üretmek amacıyla oluşturulmuş bir sınıflandırma ve kriter maksimizasyon algoritması olarak tanımlanabilmektedir. ELECTRE ağacında her kriter için en yüksek değer, en iyi sınıfa atanmakta, tüm parametrelerle ilgili çıkarımda bulunmak yerine bu parametrelerin kısmi çıkarımına öncelik verilmekte ve böylece karar vericinin ele alınan konu ve karar problemi üzerindeki deney ve deneyimleri keşfedilmektedir (Da Silva Sales, vd., 2024).

Önceki bölümlerde ifade edildiği üzere bu çalışmanın esas amacı, ELECTRE Ağacı sınıflandırma yönteminin Türkçe literatüre tanıtılmasıdır. Bu doğrultuda çalışmada ELECTRE Ağacı yöntemi kullanılarak AB ülkeleri ve Türkiye'nin, AB İstatistik Ofisinin (EUROSTAT) yayınladığı istatistiklerden (Bkz. EU (2023)) ve Filipowicz-Chomko (2020)'nin çalışmalarında da yer alan kriter setinden yararlanılarak *Sürdürülebilir Kalkınma Amacı SKA (4): Nitelikli Eğitim* kapsamında sınıflandırıldığı bir örnek illüstratif uygulama yapılmıştır. Bölüm 4'te ifade edildiği üzere ELECTRE Ağacı yöntemi dahilindeki en önemli kavramlardan olan profiller, bu bağlamda örnek uygulamada ele aldığımız ülkeleri kriterler karşısında nasıl performans gösterdiklerine göre gruplandıran karar vektörleri olarak tanımlanabilmektedir. ELECTRE Ağacı uygulaması sonucunda elde edilen sonuçlara göre Profil 3'ün, özellikle kriter 1, 3 ve 6 için nispeten yüksek değerlere sahip olması nedeniyle en tercih edilen profil olarak öne çıktığı görülmüştür (Bkz. Tablo 2). Buna göre Danimarka, İrlanda, Hollanda, Finlandiya ve İsveç'in en yüksek performans gösteren ülkeler olarak sınıflandırılmaları, bu ülkelerin özellikle 1, 3 ve 6. kriterler; yani *Eğitim ve öğretimi erken bırakma, Erken çocukluk eğitimi katılım oranı* ve *En az temel dijital becerilere sahip bireylerin oranı* göstergeleri açısından uyguladıkları etkin eğitim politikaları ile sürekli olarak yüksek değerlere sahip olduklarını ve bu nedenle söz konusu ülkelerin, en yüksek profil olan *Profil 3* eşliğini aşarak birinci sınıfta yer aldıklarını ifade etmektedir. Öte yandan Belçika, Estonya, İspanya, Letonya, Litvanya, Lüksemburg, Avusturya, Portekiz ve Slovenya'nın ikinci en iyi grupta sınıflandırılmaları, bu ülkelerin eğitim göstergelerinde genel olarak iyi performans gösterdiklerini; ancak en üst sıralardaki ülkelerle kıyaslandığında bazı alanlarda eksiklikler yaşadıklarını ve bu nedenle orta seviye (*Profil 2*) eşliğini geçebilmelerine rağmen en yüksek seviyeye ulaşamadıklarını göstermektedir. Diğer yandan Türkiye'nin en düşük performans gösteren grupta yer alması, Türkiye'nin de dahil olduğu bu ülkelerin önemli SKA 4 göstergeleri açısından ilk profil eşliğinin (*Profil 1*) altında kaldıklarını ve bu ülkelerle diğer AB ülkeleri arasında önemli farklar olduğunu işaret etmektedir. Buna göre örnek illüstratif uygulamada ELECTRE Ağacı modelinin ortaya koyduğu sınıflandırmanın, yüksek performans gösteren ülkelerin en üst profil eşiklerini sürekli olarak karşıladıklarını veya aştıklarını; daha düşük sıralardaki ülkelerin ise ilk karar sınırına ulaşmakta zorlandıklarını gösterdiği açıklıkla ifade

edilebilmektedir. Son olarak elde edilen %71 doğruluk oranı, sınıflandırma sonuçlarının tutarlı bir yapıya sahip olduğunu göstermekte ve elde edilen bulguların güvenilirliğini desteklemektedir.

Her ne kadar çalışmanın amacı bu örnek uygulama bağlamında eğitim politikalarına dair ile ilgili çıkarımlarda bulunmak olmasa da, elde edilen bu sonuçların literatürde benzer konuya odaklanan Roszkowska ve Filipowicz-Chomko (2020), Kuc-Czarnecka vd. (2023), Popelo vd. (2023) ve Karsak ve Uçar (2024) gibi çalışmalarda elde edilen sonuçlar ile yakın oldukları da söylenebilmektedir. Sonuç olarak, ELECTRE Ağacı analizinde, diğer sınıflandırma algoritmalarında olduğu gibi kriterler açısından benzer performans kalıpları gösteren alternatifler aynı sınıfa gruplandırılmaktadır. Söz konusu sınıflandırmalar ise her alternatifin önceden tanımlanmış ve sınıfların alt-üst limit değerlerini içeren profil ve kriterlere göre karşılaştırılmasıyla elde edilmektedir (Montenegro de Barros vd., 2021). Bu bağlamda EUROSTAT tarafından belirlenen SKA 4 kriterlerine göre birbirilerine yakın performans gösteren ülkelerin aynı sınıfın içinde yer aldıkları ve elde edilen sonuçların halihazırdaki literatür ile uyumlu olduğu görülebilmektedir. Öte yandan çalışmada yer verilen örnek uygulamaya konu olan modelde görülen yüksek doğruluk seviyesi, modelin konu olduğu uygulamanın başarısını göstermekle birlikte, gelecek çalışmalarda söz konusu doğruluk seviyesi yöntem parametrelerine farklı değerler verilmesi yoluyla geliştirilebilecektir. Ayrıca farklı ve daha büyük veri setleri ve diğer ML algoritmalarının kullanımı ile yöntemin daha da kapsamlı hale getirilmesi mümkün olabilmektedir. Böylece gelecek çalışmalarda daha iyi sınıflandırma sonuçları ve değerli içgörülerin elde edilmesi de sağlanabilecektir. Öte yandan bu çalışmanın temel amacı doğrultusunda Türkçe literatürde ELECTRE Ağacı yönteminin bundan sonra makale, tez vb. bilimsel çalışmalarda sıklıkla kullanılır duruma geleceği düşünülmektedir.

Kaynaklar

Alkan Şener, S. (2020). *ELECTRE III, ELECTRE TRI ve TOPSIS Yöntemleri ile İş Yapma Kolaylığı Endeksi Verileri Üzerine Bir Uygulama*, (Doktora Tezi), Sivas Cumhuriyet Üniversitesi.

Almeida-Dias, J., Figueira, J. R., Roy, B. (2010), “Electre Tri-C: A Multiple Criteria Sorting Method Based on Characteristic Reference Actions”, *European Journal of Operational Research*, 204(3): 565-580.

Alpaydın, E. (2004), *Introduction to Machine Learning*, The MIT Press, Cambridge.

Ananda, J., Herath, G. (2009), “A Critical Review of Multi-Criteria Decision Making Methods with Special Reference to Forest Management and Planning”, *Ecological Economics*, 68(10): 2535-2548.

Arondel, C., Girardin, P. (2000), “Sorting Cropping Systems on the Basis of Their Impact on Groundwater Quality”, *European Journal of Operational Research*, 127(3): 467-482.

- Arthur, D., Vassilvitskii, S. (2007), “K-means++: The Advantages of Careful Seeding”, *Proceedings of the Eighteenth Annual ACM-SIAM Symposium on Discrete Algorithms (SODA 2007)*, Philadelphia, USA, 1027-1035.
- Balali, F., Nouri, J., Nasiri, A., Zhao, T. (2020), *Data Intensive Industrial Asset Management*, Springer, Cham.
- Bao, W., Lianju, N., Yue, K. (2019), “Integration of Unsupervised and Supervised Machine Learning Algorithms for Credit Risk Assessment”, *Expert Systems with Applications*, 128: 301-315.
- Brito, A. J., de Almeida, A. T., Mota, C. M. (2010), “A Multicriteria Model for Risk Sorting of Natural Gas Pipelines Based on ELECTRE TRI Integrating Utility Theory”, *European Journal of Operational Research*, 200(3): 812-821.
- Buchholz, O., Grote, T. (2023), “Predicting and Explaining with Machine Learning Models: Social Science as a Touchstone”, *Studies in History and Philosophy of Science*, 102: 60-69.
- Carriço, N., Covas, D. I., Almeida, M. C., Leitão, J. P., Alegre, H. (2012), “Prioritization of Rehabilitation Interventions for Urban Water Assets Using Multiple Criteria Decision-Aid Methods”, *Water Science and Technology*, 66(5): 1007-1014.
- Chen, Y., Wu, X., Hu, A., He, G., Ju, G. (2021), “Social Prediction: A New Research Paradigm Based on Machine Learning”, *Journal of Chinese Sociology*, 8: 1-21.
- Da Silva Sales, I. J., De Amorim, P. L., De Souza, R. G. (2024), “Multi-Criteria Analysis of The Feasibility of E-Waste Pre-Treatment Units in a Brazilian City”, *Environment Systems and Decisions*, 44(2): 412-423.
- De Souza, J. L., Costa, S. W., Costa, F. A., Medeiros, A. M., DeSouza, G. N., Seruffo, M. C. (2023), “A Classification Model for Municipalities in the Paraense Amazon Regarding the Risk of Violence Against Women: A Multicriteria Approach”, *PLoS one*, 18(10): e0292323.
- Dell’Anna, F. (2023), “An ELECTRE TRI B-Based Decision Framework to Support the Energy Project Manager in Dealing with Retrofit Processes at District Scale”, *Sustainability*, 15(2): 1250.
- El-Morr, C., Jammal, M., Ali-Hassan, H., El-Hallak, W. (2022), *Machine Learning for Practical Decision Making*, Springer, Cham.
- Emamat, M. S., Mota, C. M., Mehregan, M. R., Sadeghi Moghadam, M. R., Nemery, P. (2022), “Using ELECTRE-TRI and FlowSort Methods in a Stock Portfolio Selection Context”, *Financial Innovation*, 8(1): 11.
- Estran, R., Souchaud, A., Abitbol, D. (2022), “Using a Genetic Algorithm to Optimize an Expert Credit Rating Model”, *Expert Systems with Applications*, 203: 117506.

- EU. (2023), *Sustainable Development Goals Database*, <https://ec.europa.eu/eurostat/web/sdi/database>, (19.01.2025).
- Fu, S., Lyu, H., Wang, Z., Hao, X., Zhang, C. (2022), “Extracting Historical Flood Locations from News Media Data by the Named Entity Recognition (NER) Model to Assess Urban Flood Susceptibility”, *Journal of Hydrology*, 612: 128312.
- Georgopoulou, E., Sarafidis, Y., Mirasgedis, S., Zaimi, S., Lalas, D. P. (2003), “A Multiple Criteria Decision-Aid Approach in Defining National Priorities for Greenhouse Gases Emissions Reduction in the Energy Sector”, *European Journal of Operational Research*, 146(1): 199-215.
- Hu, S., Dong, Z. S., Dai, R. (2024), “A Machine Learning Based Sample Average Approximation for Supplier Selection with Option Contract in Humanitarian Relief”, *Transportation Research Part E: Logistics and Transportation Review*, 186: 103531.
- Kacprzak, D. (2024), “A New Extension of the EDAS Method in a fuzzy Environment for Group Decision-Making”, *Decision*, 51(3): 263-277.
- Karakosta, C., Doukas, H., Psarras, J. (2009), “Directing Clean Development Mechanism Towards Developing Countries' Sustainable Development Priorities”, *Energy for Sustainable Development*, 13(2): 77-84.
- Karsak, E. E., Ucar, E. (2024). “Education Policy Assessment of Countries Using an Integrated Decision-Making Approach”, *e-mentor*, 107(5): 20-28.
- Kaya, S. K., Ayçin, E., Pamucar, D. (2023), “Evaluation of Social Factors within the Circular Economy Concept for European Countries”, *Central European Journal of Operations Research*, 31(1): 73-108.
- Khedkar, R. A., Vyas, V. (2008). “Real Coded Genetic Algorithm for Minimizing Wavelength and Number of Hops in Virtual Wavelength Path Routed WDM Network”, *2008 IET International Conference on Wireless, Mobile and Multimedia Networks*, Beijing, China, 113-116.
- Kuc-Czarnecka, M., Markowicz, I., Sompolska-Rzechuła, A. (2023), “SDGs Implementation, Their Synergies, and Trade-Offs in EU Countries–Sensitivity Analysis-Based Approach”, *Ecological Indicators*, 146: 109888.
- Kumar, R. (2025), “A Comprehensive Review of MCDM Methods, Applications, and Emerging Trends”, *Decision Making Advances*, 3(1): 185-199.
- Kumar, R., Pal, K. K. (2024), “Artificial Intelligence (AI)-Driven Transformation: Sustainable Development of Agro-Based Industries in Bihar”, *International Journal for Multidisciplinary Research*, 6(2): 1-8.
- Liakos, K., Busato, P., Moshou, D., Pearson, S., Bochtis, D. (2018), “Machine Learning in Agriculture: A Review”, *Sensors*, 18(8): 2674-2703.
- Liang, W., Rodríguez, R. M., Wang, Y. M., Goh, M., Ye, F. (2023), “The Extended ELECTRE III Group Decision Making Method Based on Regret Theory Under

Probabilistic Interval-Valued Hesitant Fuzzy Environments”, *Expert Systems with Applications*, 231: 120618.

Liu, X., Wan, S. P. (2019), “A Method to Calculate the Ranges of Criteria Weights in ELECTRE I and II Methods”, *Computers & Industrial Engineering*, 137: 106067.

MacKay, D. J. (2003), *Information Theory, Inference and Learning Algorithms*, Cambridge University Press, Cambridge.

Matenga, Z. (2022), “Assessment of Energy Market’s Progress Towards Achieving Sustainable Development Goal 7: A Clustering Approach”, *Sustainable Energy Technologies and Assessments*, 52: 102224.

Mohanty, A., Mohapatra, A. G., Mohanty, S. K., Mohanty, A. (2025), “Fuzzy Systems”, *Multi-Criteria Decision-Making and Optimum Design with Machine Learning: A Practical Guide*, V. Nguyen, N. Vo, V. Truong, V. Nguyen (Eds.), CRC Press, Boca Raton: 4-46.

Montenegro de Barros, G. M., Pereira, V., Roboredo, M. C. (2021), “ELECTRE Tree: A Machine Learning Approach to Infer ELECTRE Tri-B Parameters”, *Data Technologies and Applications*, 55(4): 586-608.

Mousseau, V., Slowinski, R. (1998), “Inferring an ELECTRE TRI Model from Assignment Examples”, *Journal of Global Optimization*, 12: 157-174.

Nepomuceno, L. D., Costa, H. G. (2015), “Analyzing Perceptions About the Influence of a Master Course over the Professional Skills of Its Alumni: A Multicriteria Approach”, *Pesquisa Operacional*, 35(1): 187-211.

Ömürbek, N., Karaatlı, M., Cömert, H. G. (2016), “AHP-SAW ve AHP-ELECTRE Yöntemleri ile Yapı Denetim Firmalarının Değerlendirmesi”, *Yönetim Bilimleri Dergisi*, 14(27): 171-199.

Pereira, V., Babilio, M. P., Santos, C. H. (2024), *Enhancing decision analysis with a large language model: pydecision a comprehensive library of MCDA methods in python*, <https://arxiv.org/pdf/2404.06370> (10.01.2025).

Piekut, M. (2021), “The Consumption of Renewable Energy Sources (RES) by the European Union Households Between 2004 and 2019”, *Energies*, 14(17): 5560.

Popelo, O., Kholiavko, N., Hryhorkiv, M., Kosmii, O., Oleksiienko, O., Zhavoronok, A. (2023), “EU Higher Education Institution Toward the Sustainable Development”, *Management Theory and Studies for Rural Business and Infrastructure Development*, 45(2): 124.

Ramezani, R. (2019), “Estimation of the Profiles in Posteriori ELECTRE TRI: A Mathematical Programming Model”, *Computers & Industrial Engineering*, 128: 47-59.

Rodrigues, K. T., Martins, C. L., dos Santos Neto, J. B., Fogaça, D. R., Ensslin, S. R. (2022), “Decision-Making Model to Assess Organizational Climate in

Healthcare Organizations”, *International Journal of Decision Support System Technology*, 14(1): 1-19.

Roy, B. (1968), “Classement et Choix en Présence de Points de Vue Multiples”, *Revue Française D'informatique Et De Recherche Opérationnelle*, 2(8): 57-75.

Roy, B., Bouyssou, D. (1993), *Aide Multicritère à la Décision: Méthodes et Cas*, Economica, Paris.

Roszkowska, E., Filipowicz-Chomko, M. (2020). “Measuring Sustainable Development in the Education Area Using Multi-Criteria Methods: A Case Study”, *Central European Journal of Operations Research*, 28(4): 1219-1241.

Sánchez-Lozano, J. M., García-Cascales, M. S., Lamata, M. T. (2016), “Comparative TOPSIS-ELECTRE TRI Methods for Optimal Sites for Photovoltaic Solar Farms: Case Study in Spain”, *Journal of Cleaner Production*, 127: 387-398.

Saini, M., Sengupta, E., Singh, M., Singh, H., Singh, J. (2023), “Sustainable Development Goal for Quality Education (SDG 4): A Study on SDG 4 to Extract the Pattern of Association Among the Indicators of SDG 4 Employing a Genetic Algorithm”, *Education and Information Technologies*, 28(2): 2031-2069.

Shidik, G. F., Saputra, F. O., Saraswati, G. W., Winarsih, N. A., Rohman, M. S., Pramunendar, R. A., ... , Hasibuan, Z. A. (2024), “Indonesian Disaster Named Entity Recognition from Multi Source Information Using Bidirectional LSTM (BILSTM)”, *Journal of Open Innovation: Technology, Market, and Complexity*, 10(3): 100358.

Shu, X., Ye, Y. (2023), “Knowledge Discovery: Methods from Data Mining and Machine Learning”, *Social Science Research*, 110: 102817.

Sun, W., Xu, Y. (2016), “Financial Security Evaluation of the Electric Power Industry in China Based on a Back Propagation Neural Network Optimized by Genetic Algorithm”, *Energy*, 101: 366-379.

Şahin, M., Ulucan, A., Yurdugül, H. (2021), “Learner Classification Based on Interaction Data in E-learning Environments: the ELECTRE TRI Method”, *Education and Information Technologies*, 26(2): 2309-2326.

Taherdoost, H., Madanchian, M. (2023), “Multi-Criteria Decision Making (MCDM) Methods and Concepts”, *Encyclopedia*, 3(1): 77-87.

Tinsley, H. E., Brown, S. D. (2000), *Handbook of Applied Multivariate Statistics and Mathematical Modeling*, Academic Press, Cambridge.

Trojan, F., Morais, D. C. (2012), “Using Electre TRI to Support Maintenance of Water Distribution Networks”, *Pesquisa Operacional*, 32: 423-442.

UN. (2015), *Transforming Our World: The 2030 Agenda for Sustainable Development*, <https://documents-dds-ny.un.org/doc/UNDOC/GEN/N15/291/89/PDF/N1529189.pdf>, (19.01.2025).

Uğuz, S. (2021), *Makine Öğrenmesi - Teorik Yönü ve Python Uygulamaları ile Bir Yapay Zeka Ekolü*, Nobel Akademik Yayıncılık, Ankara.

Wu, R., Kang, D., Chen, Y., Chen, C. (2023), “Assessing Academic Impacts of Machine Learning Applications on a Social Science: Bibliometric Evidence from Economics”, *Journal of Informetrics*, 17(3): 101436.

Xu, N. (2019), “Understanding the Reinforcement Learning”, *Journal of Physics: Conference Series*, 1207: 1-6.

Yaralıoğlu, K. (2010), *Karar Verme Yöntemleri*, Detay Yayıncılık, Ankara.

Yu, W. (1992), “ELECTRE TRI: Aspects Méthodologiques et Manuel D'utilisation”, *Document du LAMSADE*, 74.