

Çok Kriterli Karar Verme ve Makine Öğrenmesi: Entegrasyon ve Uygulamalar

Müzeyyen Özhavzalı¹

Özet

Günümüzde karar verme süreçleri, çok sayıda alternatif ve çelişkili kriterlerin varlığı nedeniyle karmaşıklaşmıştır. Çok Kriterli Karar Verme (ÇKKV) yöntemleri, bu tür problemleri sistematik ve matematiksel yaklaşımlarla çözmeyi sağlar. Ancak, artan veri hacmi ve karmaşık yapı, klasik ÇKKV yöntemlerinin sınırlarını zorlamaktadır. Makine Öğrenmesi (MÖ) ise veriden öğrenme yeteneğiyle, karar destek sistemlerinde önemli avantajlar sunmaktadır. Makina öğrenme dilleri arasında yer alan denetimli, denetimsiz ve pekiştirmeli öğrenme yöntemleri, kriter ağırlıklandırma, alternatif sınıflandırma ve dinamik karar modellerinde kullanılarak ÇKKV yöntemleriyle hibrit yaklaşımlar geliştirilmiştir. Bu birleşim hem karar sürecinin açıklanabilirliğini artırmakta hem de veri tabanlı adaptif karar mekanizmaları sağlamaktadır. Ayrıca, model açıklanabilirliği ve etik karar verme konusu, günümüzdeki araştırmaların önemli odak noktalarındandır. Bu çalışma, ÇKKV yöntemleriyle MÖ yöntemlerinin entegrasyonunu kuramsal ve uygulamalı bir çerçevede ele alarak, karmaşık karar problemlerine yönelik daha esnek, veri odaklı ve açıklanabilir çözümler sunmayı amaçlamaktadır. Geleneksel ÇKKV yöntemleri, yapılandırılmış karar süreçleri oluşturmada güçlü araçlar sunarken; dinamik, büyük ve belirsiz veri ortamlarında yetersiz kalmaktadır. MÖ algoritmaları, geçmiş verilere dayanarak karar fonksiyonlarını öğrenebilir, kriter ağırlıklarını otomatik olarak çıkarabilir ve alternatifleri sınıflandırabilir. Bu bağlamda, denetimli, denetimsiz ve pekiştirmeli öğrenme türleri karar süreçlerine farklı katkılar sağlamaktadır. Uygulamalı örnek olarak, tedarikçi seçiminde Random Forest sınıflandırıcısı ve SMOTE kullanılarak, azınlık sınıfların başarıyla tahmin edilebildiği ve model doğruluğunun %15 oranında arttığı gösterilmiştir. Ayrıca açıklanabilir yapay zekâ (XAI) tekniklerinin, şeffaf ve etik karar sistemlerinin geliştirilmesinde rolü vurgulanmaktadır. Sonuç olarak, ÇKKV ve MÖ'nün birleşimi, karar destek sistemlerini daha güvenilir,

1 Dr.Öğr.Üyesi, Kırıkkale Üniversitesi, Fatma Şenses Sosyal Bilimler MYO, thavzalizmuezeyyen@hotmail.com-ORCID ID 0000-0003-0518-3021

çevik ve kullanıcı dostu hale getirme potansiyeli taşımakta; açıklanabilirlik, etik ve yasal uyumluluk gibi alanlarda ise ileri araştırmaların gerekliliğini ortaya koymaktadır.

1. Giriş

Karmaşık karar verme problemleri, özellikle çok sayıda alternatif ve çelişkili kriterin bulunduğu durumlarda, geleneksel sezgisel yaklaşımlarla yönetilemez hâle gelmiştir. Günümüz iş dünyası ve kamu yönetiminde, büyük veri kaynaklarının artmasıyla birlikte nicel ve analitik karar destek sistemlerine olan ihtiyaç derinleşmiştir (Delen & Zolbanin, 2018). Özellikle karar vericilerin hem niteliksel hem niceliksel faktörleri değerlendirildiği ÇKKV problemleri, matematiksel modelleme teknikleri ile daha rasyonel çözümler sunmaktadır (Zopounidis & Doumpos, 2002).

Günümüzün belirsizliklerle dolu tedarik zinciri, enerji yönetimi ve stratejik planlama gibi alanlarında karar vericilerin çoklu ve çoğu zaman çelişen kriterleri dengelemesi gerekmektedir. Bu tür karmaşık karar durumları için ÇKKV yöntemleri, karar sürecini sistematikleştirerek alternatiflerin nesnel biçimde değerlendirilmesini sağlar. Ağırlıklandırma, sıralama, kıyaslama gibi yapılandırılmış adımlar sayesinde karar verme süreçleri daha rasyonel ve tekrar edilebilir hale gelir (Saaty, 1980).

Makine öğrenmesi ise veriye dayalı örüntü tanıma, sınıflandırma ve tahminleme yetenekleriyle son yıllarda karar destek sistemlerinin önemli bir bileşeni haline gelmiştir. Geleneksel karar yöntemlerinden farklı olarak, makine öğrenmesi algoritmaları geçmiş verilere dayanarak öğrenir ve bu öğrenme süreci sayesinde geleceğe yönelik öngörülerde bulunabilir (Bishop, 2006). Özellikle büyük, dinamik ve yapısal olmayan veri kaynaklarının analizinde makine öğrenmesi güçlü bir araçtır.

ÇKKV yöntemleri, karar sürecini sistematikleştirirken; MÖ ise veriden öğrenerek geleceğe yönelik tahminleme ve sınıflandırma yeteneği sağlar (Bishop, 2006). Bu iki alanın birleşimi, yalnızca statik verilerle değil, değişen çevresel koşullarla da başa çıkabilen hibrit modellerin geliştirilmesine zemin hazırlamaktadır (Tsai & Hsu, 2013). Örneğin, tedarikçi seçiminde hem AHP gibi yapısal ÇKKV yöntemleriyle kriter ağırlıkları belirlenebilir hem de geçmiş performans verilerinden makine öğrenmesi algoritmalarıyla sınıflandırma yapılarak daha dinamik kararlar alınabilir.

Bu hibrit yaklaşım, karar verme sürecini daha esnek, veri odaklı ve çevresel değişimlere duyarlı hale getirir. Ayrıca, SHAP gibi açıklanabilirlik araçlarıyla makine öğrenmesi modellerinin iç karar mekanizmaları da ortaya konularak hem şeffaflık sağlanmakta hem de kullanıcı güveni artırılmaktadır (Lundberg

& Lee, 2017). Dolayısıyla, ÇKKV ve MÖ'nün entegrasyonu yalnızca teknik başarı değil, aynı zamanda açıklanabilir ve etik karar sistemlerinin geliştirilmesi açısından da önemlidir.

Makine öğrenmesinin veri temelli öğrenme becerisi, karar vericinin geçmiş karar örüntülerinden yola çıkarak benzer durumlarda hangi kararın daha uygun olduğunu belirleyebilmesine olanak tanır (Quinlan, 1993). Öte yandan, ÇKKV yöntemlerin avantajı, karar sürecinin şeffaf, hesap verebilir ve metodolojik olarak izlenebilir olmasıdır (Saaty, 1980; Hwang & Yoon, 1981).

Son yıllarda denetimli öğrenme algoritmaları (Random Forest, SVM), denetimsiz yöntemler (K-means, PCA) ve pekiştirmeli öğrenme algoritmaları (Q-learning, DQN) gibi farklı MÖ tekniklerinin ÇKKV çerçevesine entegrasyonu büyük ilgi görmektedir (LeCun et al., 2015). Ancak, etik sorunlar, modelin yorumlanabilirliği ve karar sürecinin açıklanabilirliği gibi konular da önem kazanmıştır (Ribeiro et al., 2016; Vellido et al., 2012).

Bu bölümde, ÇKKV ve MÖ yaklaşımlarının birleşik kullanımı kuramsal bir çerçevede ele alınmakta; farklı yöntemlerin avantajları, entegrasyon stratejileri ve uygulamalı örnekler üzerinden tartışılmaktadır. Ayrıca, derin öğrenme, model yorumlanabilirliği ve etik karar yapıları gibi güncel konulara da değinilmektedir (Kahneman, 2011; Rawls, 1971; Shapley, 1953).

2. ÇKKV Yöntemleri: Genel Bakış

ÇKKV, birden fazla çelişkili kriter altında karar verilmesi gereken durumlar için geliştirilmiş matematiksel ve sistematik yöntemlerin genel adıdır (Zopounidis & Doumpos, 2002). Bu yöntemler, karar vericinin tercihlerini formalize ederek alternatiflerin sıralamasını veya sınıflandırmasını sağlar.

2.1 ÇKKV Yöntemleri: Klasikten Moderne Bir Bakış

Analitik Hiyerarşi Süreci (AHP), Thomas L. Saaty tarafından geliştirilen bir karar verme yöntemidir ve karar problemlerini hiyerarşik yapıya dönüştürerek çözme amaçlar. AHP, karar vericilerin tercihlerini ikili karşılaştırmalar yoluyla belirleyerek, her bir kriterin göreceli önemini hesaplar. Bu sayede, niteliksel uzman görüşleri sayısal verilere dönüştürülerek karar sürecine dahil edilebilir (Saaty, 1980). Yöntemin en önemli avantajı, kullanıcı dostu olması ve karar vericilerin bilişsel yapısına uygun bir değerlendirme süreci sunmasıdır. Ancak, ikili karşılaştırmalarda kullanılan öznel değerlendirmeler ve tutarlılık sorunları, özellikle büyük boyutlu problemlerde yöntemin doğruluğunu etkileyebilir. Ayrıca, AHP çoğunlukla

statik bir yapıya sahiptir; dolayısıyla dinamik ve veri yoğun ortamlarda esnekliği sınırlı olabilir.

TOPSIS (Technique for Order Preference by Similarity to Ideal Solution) yöntemi, Hwang ve Yoon (1981) tarafından geliştirilmiştir. Bu yöntem, ideal ve anti-ideal çözümlerle alternatiflerin arasındaki geometrik uzaklıkları dikkate alarak, en iyi alternatifin ideal çözüme en yakın ve anti-ideale en uzak olan olarak seçilmesini sağlar. TOPSIS'in en önemli katkılarından biri, karar problemlerini nicel olarak ele alabilmesi ve oldukça sistematik bir sıralama mekanizması sunmasıdır (Hwang & Yoon, 1981). Bununla birlikte, kriterler arasındaki korelasyonların dikkate alınmaması ve ağırlıklandırma sürecindeki dengesizlikler, yöntemin performansını zayıflatabilir. Özellikle yüksek boyutlu veya yüksek oranda ilişkilendirilmiş kriterlere sahip modellerde, sonuçlar karar vericiyi yanıltabilir.

VIKOR (VlseKriterijumska Optimizacija I Kompromisno Resenje) yöntemi, çelişkili kriterler altında uzlaşmaya dayalı çözümler üretmeyi hedefleyen bir yöntemdir. Opricovic ve Tzeng (2004) tarafından geliştirilen bu yaklaşım hem grup kararlarını hem de bireysel tercihleri dengeleyerek, karar vericilerin en iyi çözüm konusunda uzlaşmalarını sağlar. VIKOR yöntemi, ideal çözüme yakınlık ile en kötü duruma olan uzaklığı birlikte değerlendirerek alternatiflerin sıralamasını oluşturur (Opricovic & Tzeng, 2004). Bu yöntem özellikle sosyal bilimler, kamu politikası ve mühendislik gibi disiplinlerde çelişkili kriterlerin olduğu durumlarda etkili çözümler sunar. Ancak karar vericilerin tercih ettiği uzlaşma düzeyi (örneğin, strateji katsayısı “v”) sonuçlar üzerinde doğrudan etkili olduğundan, sonuçların hassasiyet analizi ile desteklenmesi önerilir.

PROMETHEE (Preference Ranking Organization Method for Enrichment Evaluations), tercih fonksiyonlarına dayalı bir sıralama yöntemidir. Brans ve Mareschal (2005) tarafından geliştirilen bu yaklaşım, her bir alternatifin diğerlerine göre üstünlüğünü (pozitif ve negatif akış değerleri) hesaplayarak, bir sıralama ortaya koyar. PROMETHEE, özellikle GAIA düzlemi gibi grafiksel araçlarla desteklenerek karar vericilerin modeli daha iyi anlamalarını sağlar (Brans & Mareschal, 2005). Bu yöntem, karar vericilerin subjektif tercihlerini doğrudan modele entegre edebildiği için esnek bir yapı sunar. Bununla birlikte, tercih fonksiyonlarının doğru tanımlanması, yöntemin başarısı açısından kritik öneme sahiptir; yanlış veya eksik tanımlanan tercihler, sıralamanın anlamlılığını zayıflatabilir.

2.2 Güncel ve Modern ÇKKV Yöntemleri:

BWM (Best-Worst Method), ÇKKV alanında Rezaci (2015) tarafından geliştirilen yenilikçi ve etkin bir karar verme yöntemidir. Bu yöntem, geleneksel ikili karşılaştırma temelli yöntemlerde (örneğin AHP) karşılaşılan karşılaştırma yükünü azaltarak karar vericilere daha yalın ve tutarlı bir değerlendirme süreci sunar. BWM'in temel mantığı, karar vericiden öncelikle problemde yer alan kriterler arasından en önemli (best) ve en önemsiz (worst) olan kriterleri belirlemesini istemektir. Ardından, karar vericiden en iyi kriterin diğer tüm kriterlere göre ne derece daha önemli olduğunu ve aynı şekilde, diğer tüm kriterlerin en kötü kritere göre ne derece daha önemli olduğunu değerlendirmesi beklenir (Rezaci, 2015).

Bu değerlendirmeler sonucunda bir optimizasyon modeli kurularak kriter ağırlıkları hesaplanır. Buradaki temel avantaj, karar vericinin tüm kriter çiftleri arasında ikili karşılaştırmalar yapmasına gerek kalmadan, sınırlı sayıda değerlendirme ile karar sürecinin tamamlanabilmesidir. Bu da yöntemin hem zaman açısından verimliliğini artırmakta hem de tutarlılık düzeyini yükseltmektedir. Rezaci (2015), BWM'nin özellikle AHP'ye kıyasla daha yüksek tutarlılık oranlarına sahip olduğunu ve daha az karşılaştırma gerektirdiğini göstererek, yöntemin pratik uygulamalarda ne kadar etkili olabileceğini ortaya koymuştur.

BWM'in bir diğer önemli özelliği ise öznel yargıların sistematik ve matematiksel bir şekilde modellenmesini sağlamasıdır. Bu, karar vericinin sezgisel bilgilerini nicel veriye dönüştürürken karşılaşılan belirsizlikleri azaltır. Ayrıca, bu yöntemin kolay uygulanabilirliği ve analitik yapısı, özellikle sınırlı bilgiye sahip karar ortamlarında güvenilir sonuçlar üretmesini mümkün kılar. Bu nedenlerle BWM, tedarik zinciri yönetimi, sürdürülebilirlik analizi, risk değerlendirmesi, proje yönetimi gibi birçok farklı alanda yaygın bir şekilde kullanılmaktadır.

DEMATEL (Decision Making Trial and Evaluation Laboratory) yöntemi, çok kriterli karar verme (ÇKKV) yaklaşımlarından biri olarak, kriterler arasındaki nedensellik ilişkilerini ortaya koymak amacıyla geliştirilmiştir. Bu yöntem, özellikle karmaşık ve dinamik sistemlerde, karar verme sürecinde hangi kriterin diğerleri üzerinde daha etkili olduğunu belirlemeye yardımcı olmaktadır. DEMATEL yöntemi, karar kriterleri arasındaki etkileşimleri hem sayısal hem de görsel biçimde analiz ederek, neden-sonuç ilişkilerini ortaya koymakta ve böylece karar vericilere daha bilinçli bir değerlendirme olanağı sunmaktadır (Tzeng, Chiang, & Li, 2007).

DEMATEL'in temel yaklaşımı, kriterler arasında doğrudan ve dolaylı etkileri dikkate alarak bir etkileşim matrisi oluşturmak ve bu matrisi kullanarak kriterlerin toplam etkilerini hesaplamaktır. Elde edilen bu bilgiler, hangi kriterlerin sistemin işleyişinde “neden” ve hangilerinin “sonuç” rolü üstlendiğini belirlemeyi sağlar (Fontela & Gabus, 1976). Bu yönüyle DEMATEL, karar vericilerin sistemin genel yapısını daha iyi anlamalarına ve müdahale edilecek alanları tespit etmelerine yardımcı olan güçlü bir araçtır.

ANP (Analytic Network Process) yöntemi, Thomas Saaty tarafından geliştirilen ve AHP'nin daha gelişmiş bir versiyonu olan bir karar verme yöntemidir. AHP'nin aksine, ANP yöntemi karar verme yapısını hiyerarşik değil, ağ (network) formunda ele alır. Bu ağ yapısı sayesinde kriterler arasında karşılıklı bağımlılıklar, geri beslemeler ve iç içe geçmiş ilişkiler dikkate alınarak daha bütüncül bir analiz yapılabilir (Saaty, 1996). ANP, bu özelliği sayesinde daha karmaşık ve çok boyutlu karar problemlerinde kullanıma uygundur.

ANP'nin önemli katkılarından biri, karar sürecinde yalnızca yukarıdan aşağıya bir akış değil, aynı zamanda kriterler ve alt kriterler arasında çift yönlü etkileşimleri de analiz edebilmesidir. Özellikle sistemsel düşünme gerektiren mühendislik, tedarik zinciri yönetimi, sürdürülebilirlik analizi gibi alanlarda ANP, karar vericilere daha gerçekçi ve etkileşimli bir değerlendirme zemini sunmaktadır. Ancak modelin karmaşık yapısı ve hesaplama yoğunluğu, kullanıcılar açısından öğrenme eğrisini artırabilir.

MACBETH (Measuring Attractiveness by a Categorical Based Evaluation Technique) yöntemi, özellikle kantitatif verilerin mevcut olmadığı, niteliksel değerlendirmenin daha ön planda olduğu durumlarda etkin biçimde kullanılan çok kriterli karar verme yöntemlerinden biridir. Bu yöntemin temelinde, karar vericilerin alternatifler arasındaki çekicilik farklarını sözel yargılarla ifade etmeleri yatmaktadır. Bu sözel yargılar daha sonra sayısal ölçeklere dönüştürülerek karar matrisleri oluşturulur (Bana e Costa & Vansnick, 1994).

MACBETH'in öne çıkan özelliği, psikolojik tutarlılığı ön plana alarak karar vericilerin duygusal ve sezgisel değerlendirmelerini yapay olarak nicelleştirmeye çalışmamasıdır. Böylece daha doğal bir değerlendirme süreci sağlanmakta, karar vericilerin bilişsel yükü azaltılmaktadır. Ayrıca MACBETH, diğer birçok yöntemle kıyasla karar vericilerin tutarsızlıklarını sistematik olarak belirleyip düzeltmeye yönelik araçlar da sunar, bu da yöntemin karar kalitesini artırmasına katkı sağlar.

Fuzzy yöntemi ÇKKV klasik yöntemlerine bulanık mantık ile entegre edilmesi sonucu geliştirilmiştir. Bu yöntemler, karar vericilerin değerlendirmelerinde karşılaşılan belirsizlikleri, sözel ifadeleri ve eksik bilgileri daha iyi modelleyebilmek amacıyla geliştirilmiştir. Örneğin Fuzzy AHP, Fuzzy TOPSIS gibi türevler, klasik AHP ve TOPSIS yaklaşımlarında kullanılan kesin sayısal değerler yerine, bulanık sayılarla çalışarak karar vericilerin daha esnek yargılar oluşturmalarına olanak tanır (Zadeh, 1965; Chen et al., 1992).

Fuzzy yöntemler, özellikle bilgi eksikliği, belirsizlik ve insan faktörünün yoğun olduğu durumlarda klasik yöntemlere göre daha gerçekçi sonuçlar üretmektedir. Bu yöntemlerin avantajı, sözel yargılar (örneğin “biraz daha önemli”, “çok daha önemli”) gibi bulanık ifadelerin matematiksel modellere entegre edilebilmesidir. Böylece karar süreci hem daha esnek hem de karar vericiye daha yakın hale gelir.

Entropy Tabanlı Ağırlıklandırma yöntemi, çok kriterli karar problemlerinde kriter ağırlıklarını belirlemek amacıyla kullanılan nesnel ve veri tabanlı bir yaklaşımdır. Bu yöntemin temelinde bilgi teorisi yer alır ve her bir kriterin sağladığı bilgi miktarı (belirsizlik düzeyi) esas alınarak ağırlıklar hesaplanır (Shannon, 1948). Entropi değeri ne kadar düşükse, kriterin bilgi değeri o kadar yüksektir ve dolayısıyla ağırlığı artar.

Bu yöntem özellikle büyük veri setleriyle çalışılan, uzman görüşlerinin yetersiz veya bulunmadığı durumlarda tercih edilmektedir. Diğer öznel yöntemlerin aksine, Entropy yaklaşımı tamamen gözlemlenen verilere dayanır. Bu nedenle istatistiksel geçerliliği daha yüksektir ve sonuçların objektifliği artırılır. Tedarik zinciri, çevresel etki değerlendirme ve finansal analiz gibi alanlarda sıkça kullanılmaktadır.

GRA (Grey Relational Analysis) yöntemi, Deng (1989) tarafından geliştirilen ve özellikle veri eksikliği, belirsizlik ya da sınırlı bilgi içeren durumlarda tercih edilen çok kriterli karar verme yöntemidir. GRA, alternatiflerin ideal çözümle olan benzerliğini ölçerek, karar sürecinde en iyi seçeneğin belirlenmesini sağlar. Bu yöntem, özellikle az veriyle çalışıldığı durumlarda oldukça etkilidir.

GRA'nın temel gücü, karmaşık matematiksel modellemelere ihtiyaç duymadan, sınırlı verilerle karar desteği sağlayabilmesidir. Diğer yöntemlerin aksine, GRA verilerin tam, normal dağılmış ya da istatistiksel özellik taşımasını zorunlu kılmaz. Bu özelliği, yöntemi mühendislik, kalite kontrol, sürdürülebilirlik analizi ve çevresel etki değerlendirme gibi birçok alanda pratik ve güçlü bir araç haline getirmiştir.

2.3 Veri Boyutu ve Klasik ÇKKV Yöntemlerinin Sınırları

Klasik yöntemler, küçük ve yapılandırılmış veri setlerinde başarılı sonuçlar verirken, günümüzde artan veri hacmi, yüksek boyutluluk (curse of dimensionality) ve veri dengesizliği gibi problemler performansı düşürmektedir. Azınlık sınıfların baskılandığı veri setlerinde karar hataları yaşanabilir (Chawla et al., 2002).

Ayrıca, kriterler arasındaki bağımlılık, boyut indirgeme teknikleri (PCA gibi) kullanılarak azaltılabilir (Jain, 2010). Kriter ağırlıkları ise geçmiş performans verilerinden makine öğrenmesi algoritmaları ile öğrenilebilir (Breiman, 2001).

Model açıklana bilirliliği, veri büyüdükçe zorluk kazanır. Bu nedenle, açıklanabilir yapay zekâ (XAI) tekniklerinin ÇKKV süreçlerine entegre edilmesi gereklidir (Ribeiro et al., 2016; Vellido et al., 2012).

3. Makine Öğrenmesi: Temel Kavramlar

Makine Öğrenmesi (MÖ), verilerden örüntü ve ilişkileri keşfederek, gelecekteki karar ve tahminleri otomatikleştiren yapay zekâ dalıdır (Bishop, 2006). MÖ, karar destek sistemlerinde giderek yaygınlaşmakta ve Çok kriterli karar problemlerin yeni çözümler sunmaktadır (Tsai & Hsu, 2013).

3.1 MÖ'nün Kategorileri

- **Denetimli Öğrenme:** Girdi-çıkı ilişkisi bilinen veri üzerinden model eğitilir. Sınıflandırma (SVM, C4.5) ve regresyon problemleri içerir (Quinlan, 1993; Cortes & Vapnik, 1995). ÇKKV'de alternatiflerin sınıflandırılması için kullanılır (Zhang et al., 2020).
- **Denetimsiz Öğrenme:** Etiketlenmemiş veriden yapısal bilgi çıkarılır. Kümeleme (K-means, DBSCAN) ve boyut indirgeme (PCA, t-SNE) yöntemleri dahildir (Jain, 2010). Yüksek boyutlu ÇKKV verilerinde alternatifi grulamada etkilidir (Tsai & Chou, 2014).
- **Pekiştirmeli Öğrenme:** Ajan, ortamla etkileşim kurarak ödül-ceza sinyallerinden karar politikası öğrenir (Sutton & Barto, 2018). Dinamik karar problemlerinde kullanılır (Mnih et al., 2015).

3.2 Veri Dengesizliği ve Artırma Teknikleri

Gerçek dünyada veriler dengesizdir; bazı alternatifler azınlıkta kalabilir, bu da öğrenmeyi zorlaştırır (He & Garcia, 2009). SMOTE gibi teknikler, azınlık sınıfı artırarak model başarısını yükseltir (Chawla et al., 2002).

3.3 Model Açıklanabilirliği ve Etik Boyut

MÖ modelleri karmaşıklıkla açıklanabilirlik zorlaşır. Açıklanabilir Yapay Zekâ (XAI) yöntemleri, karar süreçlerini şeffaflastırır (Ribeiro et al., 2016; Lundberg & Lee, 2017). Shapley değerleriyle kriter katkıları niceliksel olarak analiz edilir (Shapley, 1953).

Etik ilkeler de önemlidir; veri gizliliği, tarafsızlık ve adalet gibi konular MÖ modellerinin güvenilirliği için kritik unsurlardır (Veale & Binns, 2017; Mittelstadt et al, 2016).

3.4 ÇKKV ve Makine Öğrenmesinin Kesişimi: Öğrenme Türlerinin Karar Süreçlerindeki Rolü

ÇKKV yöntemleri, karar vericilerin birden fazla, kimi zaman çelişkili kriteri göz önünde bulundurarak en uygun alternatifi seçmesini sağlayan sistematik yaklaşımlardır. Geleneksel ÇKKV yöntemleri, karar sürecini yapılandırma ve kriterler arasında önem düzeyi belirleme açısından güçlüdür; ancak değişken, büyük ve karmaşık veri ortamlarında sınırlı kalabilir. Bu nedenle, son yıllarda MÖ algoritmaları, ÇKKV süreçlerinin hem otomatikleştirilmesi hem de çevresel değişkenliklere uyum sağlaması açısından tamamlayıcı bir rol üstlenmektedir (LeCun, Bengio, & Hinton, 2015; Tsai & Hsu, 2013).

MÖ ile ÇKKV'nin entegrasyonunda, farklı öğrenme türlerinin karar sürecine katkısı önemlidir. **Denetimli öğrenme (supervised learning)**, etiketlenmiş geçmiş karar verilerinden örüntüleri öğrenerek gelecekteki karar durumları için tahminleme veya sınıflandırma yapar. Örneğin, geçmişteki başarılı tedarikçi seçimlerini analiz ederek, benzer özelliklere sahip yeni tedarikçilerin başarı olasılığını öngörebilir (Zhang, Zhao, & Kumar, 2020). Bu, karar destek sistemlerinin öngörücü hale gelmesini sağlar.

Denetimsiz öğrenme (unsupervised learning) ise verinin etiketlenmemiş olduğu durumlarda kullanılır ve alternatifler arasındaki benzerliklere göre gruplanmasını (clustering) sağlar. Bu yaklaşım, örneğin pazar segmentasyonu, tedarikçi kümelendirme veya kriter ilişkilerinin keşfi gibi yapılarda kullanılabilir (Tsai & Chou, 2014). Böylece karar vericiye önceden farkında olmadığı veri yapıları ve örüntüler sunularak yeni stratejik bakış açıları kazandırılır.

Pekiştirmeli öğrenme (reinforcement learning), dinamik ve geribildirim içeren ortamlarda, ajanların eylemlerine karşılık aldığı ödül-ceza sistemine göre strateji geliştirmesine olanak tanır. Tedarik zinciri optimizasyonu, kaynak planlama ya da üretim çizelgeleme gibi zamanla

değişen karar ortamlarında bu yaklaşım güçlü bir çözüm sağlar (Sutton & Barto, 2018).

Bu bağlamda, MÖ yöntemleri yalnızca büyük veri ile başa çıkmak için değil, aynı zamanda ÇKKV süreçlerinin öğrenen, kendini uyarlayabilen ve dinamik ortamlarda karar kalitesini sürdürebilen yapılar haline gelmesi için kritik önemdedir. ÇKKV ve MÖ'nün kesişiminde yer alan hibrit yaklaşımlar, klasik yöntemlerin sezgisel gücünü, MÖ'nün veri odaklı esnekliğiyle birleştirerek çağdaş karar destek sistemlerinin temelini oluşturmaktadır.

Kısacası Denetimli öğrenme geçmiş karar verilerini modelleyerek öneri sunar (Zhang et al., 2020). Denetimsiz öğrenme alternatiflerin gruplanmasını sağlar (Tsai & Chou, 2014). Pekiştirmeli öğrenme dinamik ortamlar için stratejiler geliştirir (Sutton & Barto, 2018). Bu nedenle MÖ, ÇKKV süreçlerinin otomatikleşmesi ve adaptasyonu için vazgeçilmezdir (LeCun et al., 2015; Tsai & Hsu, 2013).

4. ÇKKV ile MÖ Entegrasyonu: Neden ve Nasıl?

4.1 Entegrasyonun Gerekçesi

Günümüzde ÇKKV problemleri, büyük ve karmaşık veri setleriyle tanımlanmakta; klasik yöntemler bu karmaşıklığı yönetmekte zorlanmaktadır. MÖ, doğrusal olmayan ilişkileri modelleyebilir, ağırlıklandırma süreçlerini otomatikleştirebilir ve sınıflandırma yapabilir (Chen et al., 2021; Tsai & Hsu, 2013). Ayrıca MÖ'nün esnekliği sayesinde karar sistemleri değişen ortamlara uyum sağlar (LeCun et al., 2015).

4.2 Entegrasyon Stratejileri

1. **Ağırlıklandırma için MÖ Kullanımı:** Kriter ağırlıkları geçmiş veriden tahmin edilir (Breiman, 2001; Chen et al., 2021).
2. **Alternatiflerin Kümeleme ile Ön Sınıflandırılması:** K-means, DBSCAN gibi algoritmalar alternatifleri gruplar (Jain, 2010; Tsai & Chou, 2014).
3. **Karar Fonksiyonlarının Öğrenilmesi:** SVM, Random Forest, XGBoost gibi algoritmalar karar modelleri oluşturur (Zhang et al., 2020; Chen & Guestrin, 2016).
4. **Optimizasyon Tabanlı Entegrasyon:** Genetik algoritmalar, pekiştirmeli öğrenme ile parametreler optimize edilir (Holland, 1992; Sutton & Barto, 2018).

5. **Model Seçimi ve Uyumlandırma:**Farklı karar problemleri, farklı makine öğrenmesi algoritmalarıyla daha etkili çözülür. Bu nedenle, problem türüne (sıralama, sınıflandırma, regresyon vb.) göre en uygun algoritmanın seçilmesi kritik bir adımdır. Ayrıca hiperparametre ayarlamaları, çapraz doğrulama ve model uyumu testleri ile öğrenme algoritmaları ÇKKV yapısına entegre edilir (Bishop, 2006; Guyon et al., 2006). Bu strateji, karar modelinin hem doğruluk hem de açıklanabilirlik açısından optimize edilmesini sağlar.

5. Uygulama Örneği: Tedarikçi

Tedarikçi seçimi, maliyet, kalite, teslimat süresi gibi birçok kriteri içeren klasik ÇKKV problemidir (Chan et al.,2017). Bu çalışmada, geleneksel AHP ve TOPSIS yöntemlerine ek olarak, geçmiş performans verileri üzerinde Random Forest sınıflandırıcısı geliştirilmiş ve bu yöntemleri yanında, geçmiş performans verileri üzerinden Random Forest sınıflandırıcısı eğitilmiş; azınlık tedarikçi kategorileri için SMOTE uygulanmıştır. Bu örnekteki veri seti özelliklerine bakıldığında

- Veri seti, 500 tedarikçiye ait maliyet, kalite puanı, teslimat süresi, geçmiş performans skorları gibi 8 farklı özelliği içermektedir.
- Sınıflar, yüksek, orta ve düşük performans olarak üç kategoriye ayrılmıştır.
- Düşük performanslı tedarikçiler, toplam veri setinin %10'unu oluşturarak azınlık sınıfını temsil etmektedir.
- Veri ön işleme aşamasında, eksik değerler ortalama ile doldurulmuş, kategorik veriler one-hot encoding yöntemi ile sayısal hale getirilmiştir.

Bu uygulamadaki Model eğitimi ve parametre ayarlamada ise aşağıdaki yer almaktadır:

- Random Forest modeli, başlangıçta varsayılan parametrelerle eğitilmiş, ardından Grid Search yöntemi ile hiperparametre optimizasyonu yapılmıştır.
- En iyi sonuçlar için, ağaç sayısı (n_estimators) 100, maksimum derinlik (max_depth) 10, minimum yaprak düğümü örnek sayısı (min_samples_leaf) 5 olarak belirlenmiştir.
- Model eğitiminde %70 eğitim ve %30 test veri seti kullanılmıştır.
- Sınıf dengesizliğinin giderilmesi için SMOTE uygulanmıştır; böylece düşük performanslı tedarikçi sayısı artırılarak modelin azınlık sınıflar üzerindeki başarısı desteklenmiştir.

Daha sonra uygulamanın Performans Değerlendirme Metrikleri oluşturulmuş ve Model performansı aşağıdaki metriklerle değerlendirilmiştir:

Tablo 1. Performans Değerlendirme Metrikleri ve Model Performansı Metrikleri

Model	Doğruluk (Accuracy)	Kesinlik (Precision)	Geri Çağırma (Recall)	F1 Skoru
Random Forest (SMOTE)	%89	%87	%85	%86
Random Forest (Orijinal)	%74	%72	%70	%71

Uygulanmanın sonunda ise SMOTE yöntemi ile desteklenen Random Forest modeli, sınıflandırma doğruluğunu %15 oranında artırdığı; özellikle azınlık sınıfı olan düşük performanslı tedarikçilerin doğru sınıflandırılmasında belirgin iyileşme sağlandığı görülmüştür. Bu hibrit yaklaşım, ÇKKV süreçlerinde makine öğrenmesi tekniklerinin etkin entegrasyonunun, tedarikçi seçiminde daha dengeli, güvenilir ve doğru kararlar alınmasına olanak verdiğini ortaya koymuştur.

6. Makine Öğrenmesi Tabanlı Çok Kriterli Karar Destek Sistemleri (ÇKKDS)

Günümüzde ÇKK ve problemlerinin çözümünde, yalnızca klasik karar yöntemlerinin uygulanması yeterli olmamakta; karar vericilerin etkileşimli ve dinamik ortamlarda desteklenmesi gerekmektedir. Bu bağlamda, makine öğrenmesi tabanlı çok kriterli karar destek sistemleri (ÇKKDS) önem kazanmakta ve karar sürecini hem hızlandırmak hem de doğruluk oranını artırmak amacıyla kullanılmaktadır (Delen & Zolbanin, 2018).

6.1 Sistem Mimarisi ve Bileşenleri

ÇKKDS genellikle veri toplama, ön işleme, kriter ağırlıklandırma, alternatiflerin değerlendirilmesi, sonuçların görselleştirilmesi ve kullanıcı etkileşimi bileşenlerinden oluşmaktadır (Kahraman, Cebeci & Ulukan, 2007). Makine öğrenmesi algoritmaları, ön işleme ve ağırlıklandırma adımlarında kritik rol oynamaktadır. Özellikle, algoritmalar geçmiş karar verilerinden öğrenerek kriterlerin önem derecelerini belirleyebilir (Breiman, 2001).

Örneğin, yapay sinir ağları ve destek vektör makineleri gibi denetimli öğrenme yöntemleri, karar vericinin tercihlerine göre karar modellerini eğitebilir (Cortes & Vapnik, 1995). Pekiştirmeli öğrenme tabanlı sistemlerde

ise, ajan karar süreci içerisinde ödül-ceza mekanizmasıyla kendi stratejisini geliştirebilir (Sutton & Barto, 2018).

6.2 Uygulama Alanları

ÇKKDS, finansal risk yönetimi, sağlık hizmetleri, lojistik optimizasyonu, enerji yönetimi ve üretim planlaması gibi çeşitli alanlarda etkin biçimde kullanılmaktadır (Tsai & Hsu, 2013; Wang, Zhang, & Yang, 2018, Bilgin, 2021, Göksu ve et al., 2025). Özellikle enerji sektöründe, yenilenebilir enerji kaynaklarının etkin seçimi için veri odaklı karar destek sistemleri geliştirilmektedir (Cheng, Zhang, & Xia, 2020).

7. Derin Öğrenme ve Çok Kriterli Karar Verme: Yeni Ufuklar

Derin öğrenme, çok katmanlı yapay sinir ağları aracılığıyla karmaşık veri yapılarından anlamlı örüntüler çıkarabilme kapasitesiyle, ÇKKV alanında yeni fırsatlar sunmaktadır (LeCun et al., 2015). ÇKKV birçok alternatifin farklı kriterler açısından değerlendirilerek en uygun kararın verilmesini amaçlayan klasik bir yöntemler bütünüdür. Ancak geleneksel ÇKKV yöntemlerindeki, genellikle karar verici uzmanlığının sınırlı olduğu, büyük ve karmaşık veri kümeleriyle başa çıkmakta zorlanır. Bu noktada derin öğrenme, büyük hacimli, yapısal ya da yapısal olmayan verilerden otomatik olarak anlamlı örüntüler çıkartabilme kapasitesiyle, ÇKKV süreçlerini dönüştürme potansiyeli taşımaktadır (LeCun et al., 2015).

Derin öğrenme, özellikle çok sayıda kriterin etkileşimli olarak değerlendirildiği durumlarda avantaj sunar. Örneğin, akıllı şehir planlamasında hem ekonomik hem çevresel hem de sosyal etkenler göz önünde bulundurularak altyapı yatırımlarının önceliklendirilmesi gerekir. Geleneksel ÇKKV yöntemleri, bu kriterler arasında sabit ağırlıklar atarken, derin öğrenme modelleri kriterler arasındaki doğrusal olmayan ilişkileri öğrenerek daha esnek ve veri odaklı çözümler üretebilir (Goodfellow et al., 2016). Bu, karar vericilere daha gerçekçi ve bağlama duyarlı öneriler sunar.

Örnek olarak, bir sağlık hizmetleri dağıtım sisteminde; hasta memnuniyeti, tedavi süresi, maliyet, kaynak kullanımı gibi kriterler arasında denge kurmak gerekir. Derin öğrenme, geçmiş hastane verileri üzerinden bu kriterler arasındaki karmaşık ilişkileri öğrenerek, farklı senaryolar için optimal çözümler sunabilir. Bu noktada, derin öğrenme kararları açıklanabilirlik açısından desteklemek için karar ağacı gibi yöntemlerle de hibrit modeller oluşturmak mümkündür (Zhang et al., 2020).

Sonuç olarak, derin öğrenme ÇKKV'nin yerine geçmekten ziyade, onu destekleyen ve genişleten bir araçtır. Özellikle yüksek boyutlu ve karmaşık

veri ortamlarında, klasik yöntemlerin ötesinde sezgisel çıkarımlar yapılmasını sağlar. Gelecekte, derin öğrenme tabanlı karar destek sistemlerinin, insan uzmanlığıyla entegre şekilde çalışarak, çok kriterli karar süreçlerini daha etkili ve özerk hale getirmesi beklenmektedir.

7.1 Derin Öğrenmenin ÇKKV'ye Katkısı

ÇKKV problemleri yüksek boyutlu ve heterojen veri setleri içerdiğinde, derin öğrenme modelleri ön plana çıkar (Goodfellow, Bengio, & Courville, 2016). Özellikle görüntü, metin ve zaman serisi verilerinin entegre edildiği karar problemlerinde derin öğrenme, diğer yöntemlere kıyasla üstün performans sağlamaktadır (Zhang, Yang, & Xu, 2020).

Örneğin, sağlık sektöründe hastaların medikal görüntüleri ile elektronik sağlık kayıtlarının birlikte değerlendirilerek kişiselleştirilmiş tedavi planlarının oluşturulması mümkündür (Esteva et al., 2017).

7.2 Derin Öğrenme Modellerinin Açıklanabilirliği

Derin öğrenme modelleri genellikle “kara kutu” olarak adlandırılmakta, bu da karar süreçlerinde güvenilirlik sorunlarına yol açmaktadır. Bu nedenle açıklanabilir yapay zekâ (XAI) yöntemleri geliştirilmiş ve derin modellerin kararlarını şeffaflaştırmak amaçlanmıştır (Samek, Wiegand, & Müller, 2017).

SHAP (SHapley Additive exPlanations) ve LIME (Local Interpretable Model-agnostic Explanations) gibi yöntemler, kriterlerin karar üzerindeki etkisini sayısal ve görsel olarak analiz etmeye olanak tanımaktadır (Ribeiro, Singh, & Guestrin, 2016; Lundberg & Lee, 2017).

8. Model Performansının Değerlendirilmesi

ÇKKV ile MÖ modellerinin başarısı, uygun performans ölçütleri ile değerlendirilmelidir. Bu ölçütler hem doğruluk hem de modelin açıklanabilirliğini içermektedir.

8.1 Performans Ölçütleri

- **Doğruluk, Hassasiyet, Geri Çağırım (Accuracy, Precision, Recall):** Sınıflandırma tabanlı modeller için temel ölçütlerdir (Powers, 2011).
- **ROC Eğrisi ve AUC (Area Under Curve):** Modelin genel performansını gösterir (Fawcett, 2006).
- **Kappa İstatistiği:** Sınıflandırma modellerinin rastgele tahminden farkını ölçer (Cohen, 1960).

- **Model Karmaşıklığı:** Parametre sayısı ve hesaplama süresi de göz önünde bulundurulmalıdır (Bishop, 2006).

8.2 Model Kararının Açıklanabilirlik Değerlendirmesi

Modelin karar sürecini ne kadar iyi açıkladığı, kullanıcı güveni açısından önemlidir. Açıklanabilirlik yöntemlerinin uygulanması, sistemin benimsenmesini kolaylaştırır (Vellido et al., 2012).

9. Etik, Güvenlik ve Yasal Düzenlemeler

ÇKKV ve MÖ entegrasyonunda etik ve yasal konular kritik öneme sahiptir. Özellikle karar destek sistemleri insanların hayatını etkileyen sonuçlar doğurabileceğinden, tarafsızlık, gizlilik ve şeffaflık temel unsurlardır (Mittelstadt et al, 2016).

9.1 Etik İlkeler

- **Adalet:** Modellerin önyargısız ve ayrımcı olmayan kararlar vermesi gerekir (Veale & Binns, 2017).
- **Gizlilik:** Veri sahiplerinin haklarına saygı gösterilmeli ve kişisel bilgiler korunmalıdır (Dwork, 2006).
- **Şeffaflık:** Karar süreçleri kullanıcılar ve paydaşlar için anlaşılır ve izlenebilir olmalıdır (Doshi-Velez & Kim, 2017).

9.2 Güvenlik Riskleri

Makine öğrenmesi modelleri, özellikle derin öğrenme tabanlı olanlar, manipülasyona açıktır. Adversarial saldırılar ve veri sızıntıları, sistemlerin güvenilirliğini ciddi şekilde tehdit etmektedir (Szegedy et al., 2014). Bu nedenle, güvenlik protokolleri geliştirilmesi ve modellerin sürekli izlenmesi zorunludur (Papernot et al., 2018).

9.3 Yasal Düzenlemeler

Avrupa Birliği'nin Genel Veri Koruma Yönetmeliği (GDPR), kişisel verilerin korunması konusunda sıkı standartlar getirmiştir (Voigt & Von dem Bussche, 2017). Bu tür yasal düzenlemeler, ÇKKV ve makine öğrenmesi sistemlerinin tasarım ve uygulama süreçlerinde dikkate alınmalıdır.

10. Gelecek Araştırma Yönelimleri

ÇKKV ve makine öğrenmesinin entegrasyonunda halen pek çok açık konu bulunmaktadır:

- **Gerçek zamanlı karar destek sistemleri geliştirilmesi:** Hızla değişen ortamlara uyarlabilir modeller (Nguyen et al., 2020).
- **Açıklanabilir derin öğrenme yöntemlerinin geliştirilmesi:** Kullanıcı dostu, güvenilir modeller (Adadi & Berrada, 2018).
- **Çoklu karar verici sistemleri:** Farklı paydaşların tercihlerinin bütünleştirilmesi (Nguyen & Nahavandi, 2017).
- **Etik ve sosyal etkilerin modellenmesi:** Kararların toplumsal etkilerinin analiz edilmesi (Greene, Hoffmann, & Stark, 2019).

11. Sonuç ve Öneriler

Çok kriterli karar verme problemlerinin çözümünde makine öğrenmesi yaklaşımları, klasik yöntemlerin sınırlarını aşmakta ve daha dinamik, veriye dayalı karar süreçleri geliştirmektedir. Bu yöntemin başarı anahtarları problemlerdeki modellerin daha açıklanabilir ve etik sorumlulukların olması olarak belirtilebilir.

Bu çalışma, çok kriterli karar verme yöntemleri ile makine öğrenmesinin entegrasyonunun teorik ve uygulamalı yönlerini kapsamlı biçimde ele almıştır. Veri odaklı ve dinamik karar problemlerinde bu hibrit yaklaşımlar performans ve esneklik açısından önemli avantajlar sağlamaktadır. Ancak açıklana bilirlik, etik, güvenlik ve yasal uyumluluk gibi alanlarda halen aşılması gereken zorluklar bulunmaktadır. Birçok ülkede yapılan çalışmalar da bu doğrultuda gelişmekte olup, özellikle yerel veri setleriyle uyumlu modellerin geliştirilmesi, alan için kritik bir gereklilik olarak öne çıkmaktadır (Özdemir & Şahin, 2021; Yıldırım & Kaya, 2019).

Gelecekte, derin öğrenme tabanlı XAI yöntemlerinin, gerçek zamanlı karar destek sistemlerinde kullanımı, pekiştirmeli öğrenme ile çevresel değişimlere adaptasyon ve etik karar yapılarının matematiksel modellenmesi araştırma alanları olacaktır (Rawls, 1971; Kahneman, 2011).

Kaynakça

- Adadi, A., & Berrada, M. (2018). Peeking inside the black-box: A survey on explainable artificial intelligence (XAI). *IEEE Access*, 6, 52138–52160. <https://doi.org/10.1109/ACCESS.2018.2870052>
- Bana e Costa, C. A., & Vansnick, J. C. (1994). MACBETH—An interactive path towards the construction of cardinal value functions. *International Transactions in Operational Research*, 1(4), 489–500. <https://doi.org/10.1111/j.1475-3995.1994.00369.x>
- Bilgin, G. (2021). Makine öğrenmesi algoritmaları kullanarak erken dönemde diyabet hastalığı riskinin araştırılması. *Journal of Intelligent Systems: Theory and Applications*, 4(1), 55-64.
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer.
- Brans, J. P., & Mareschal, B. (2005). PROMETHEE methods. In J. Figueira, S. Greco, & M. Ehrgott (Eds.), *Multiple criteria decision analysis: State of the art surveys* (pp. 163–195). Springer. https://doi.org/10.1007/978-1-4939-3094-4_6
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32.
- Chan, F. T. S., Kumar, V., Tiwari, M. K., Lau, H. C. W., & Choy, K. L. (2017). Supplier selection: A review of literature and an integrated framework. *Computers & Industrial Engineering*, 106, 212-223.
- Chawla, N. V., Bowyer, K. W., Hall, L. O., & Kegelmeyer, W. P. (2002). SMO-TE: Synthetic minority over-sampling technique. *Journal of Artificial Intelligence Research*, 16, 321–357. <https://doi.org/10.1613/jair.953>
- Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. *KDD*.
- Chen, S. J., Hwang, C. L., & Hwang, F. P. (1992). *Fuzzy multiple attribute decision making: Methods and applications*. Springer.
- Chen, W., Liu, L., Xu, X., & Li, J. (2021). Integrating machine learning in multi-criteria decision-making. *Expert Systems with Applications*, 173, 114624.
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273–297. Çelik, F., & Yılmaz, S. (2020). Enerji sektöründe çok kriterli karar verme yöntemlerinin uygulanması. *Enerji ve Yönetim Dergisi*, 12(2), 89-102.
- Delen, D., & Zolbanin, H. M. (2018). The analytics paradigm in business research. *Journal of Business Research*, 90, 186–195.
- Deng, J. (1989). Introduction to grey system theory. *The Journal of Grey System*, 1(1), 1–24.
- Doshi-Velez, F., & Kim, B. (2017). Towards a rigorous science of interpretable machine learning. arXiv preprint arXiv:1702.08608.

- Dwork, C. (2006). Differential privacy. In Proceedings of the 33rd International Colloquium on Automata, Languages and Programming (ss. 1-12).
- Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8), 861–874. <https://doi.org/10.1016/j.patrec.2005.10.010>
- Fontela, E., & Gabus, A. (1976). The DEMATEL Observer: DEMATEL 1976 Report. Battelle Geneva Research Center.
- Greene, D., Hoffmann, A. L., & Stark, L. (2019). Better, nicer, clearer, fairer: A critical assessment of the movement for ethical artificial intelligence and machine learning. In *Proceedings of the 52nd Hawaii International Conference on System Sciences* (pp. 2122–2131). University of Hawai'i at Manoa. <https://doi.org/10.24251/HICSS.2019.258>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep learning. MIT Press.
- Göksu, S., Sezen, B., & Balcıoğlu, Y. S. (2025). Production performance prediction using machine learning. *Kahramanmaraş Sütçü İmam University Journal of Engineering Sciences*, 28(1), 65–79.28(1), 65–79.
- He, H., & Garcia, E. A. (2009). Learning from imbalanced data. *IEEE Transactions on Knowledge and Data Engineering*, 21(9), 1263–1284.
- Holland, J. H. (1992). Genetic algorithms. *Scientific American*, 267(1), 66-73.
- Hwang, C. L., & Yoon, K. (1981). *Multiple Attribute Decision Making*. Springer.
- Jain, A. K. (2010). Data clustering: 50 years beyond K-means. *Pattern Recognition Letters*, 31(8), 651–666.
- Kahneman, D. (2011). *Thinking, Fast and Slow*. Farrar, Straus and Giroux.
- Kahraman, C., Cebeci, U., & Ulukan, Z. (2007). Multi-criteria supplier selection using fuzzy AHP. *Logistics Information Management*, 16(6), 382–394. <https://doi.org/10.1108/09576050310503367>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- Lundberg, S. M., & Lee, S.-I. (2017). A unified approach to interpreting model predictions. *NIPS*. 30, 4765–4774.
- Mittelstadt, B. D., Allo, P., Taddeo, M., Wachter, S., & Floridi, L. (2016). The ethics of algorithms: Mapping the debate. *Big Data & Society*, 3(2), 2053951716679679.
- Mnih, V., Kavukcuoglu, K., Silver, D., Rusu, A. A., Veness, J., Bellemare, M. G., Graves, A., Riedmiller, M., Fidjeland, A. K., Ostrovski, G., Petersen, S., Beattie, C., Sadik, A., Antonoglou, I., King, H., Kumaran, D., Wierstra, D., Legg, S., & Hassabis, D. (2015). Human-level control through deep reinforcement learning. *Nature*, 518(7540), 529–533. <https://doi.org/10.1038/nature14236>

- Nguyen, T., & Nahavandi, S. (2017). Multi-criteria decision making: An overview of different methods and applications. *IEEE Systems Journal*, 11(4), 4119–4121. <https://doi.org/10.1109/JSYST.2016.2600721>
- Opricovic, S., & Tzeng, G. H. (2004). Compromise solution by MCDM methods: A comparative analysis of VIKOR and TOPSIS. *European Journal of Operational Research*, 156(2), 445–455. [https://doi.org/10.1016/S0377-2217\(03\)00020-1](https://doi.org/10.1016/S0377-2217(03)00020-1)
- Özdemir, A., & Şahin, S. (2021). The Impact of Data Preprocessing Techniques on Performance in Machine Learning-Based Decision Support Systems. *Journal of Information Technologies*, 14(2), 112-123.
- Quinlan, J. R. (1993). *C4.5: Programs for Machine Learning*. Morgan Kaufmann.
- Papernot, N., McDaniel, P., Goodfellow, I., Jha, S., Celik, Z. B., & Swami, A. (2018). Practical black-box attacks against machine learning. In *Proceedings of the 2017 ACM on Asia Conference on Computer and Communications Security* (ss. 506-519).
- Powers, D. M. W. (2011). Evaluation: From precision, recall and F-measure to ROC, informedness, markedness and correlation. *Journal of Machine Learning Technologies*, 2(1), 37–63.
- Rawls, J. (1971). *A Theory of Justice*. Harvard University Press.
- Rezaei, J. (2015). Best-worst multi-criteria decision-making method. *Omega*, 53, 49–57. <https://doi.org/10.1016/j.omega.2014.11.009>
- Ribeiro, M. T., Singh, S., & Guestrin, C. (2016). “Why should I trust you?”: Explaining the predictions of any classifier. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 1135–1144). ACM. <https://doi.org/10.1145/2939672.2939778>
- Saaty, T. L. (1980). *The Analytic Hierarchy Process: Planning, priority setting, resource allocation*. McGraw-Hill.
- Saaty, T. L. (1996). *Decision making with dependence and feedback: The analytic network process*. RWS Publications.
- Samek, W., Wiegand, T., & Müller, K. R. (2017). Explainable artificial intelligence: Understanding, visualizing and interpreting deep learning models. *IEEE Signal Processing Magazine*, 34(6), 52-65. <https://doi.org/10.1109/MSP.2017.2745201>
- Shannon, C. E. (1948). A mathematical theory of communication. *The Bell System Technical Journal*, 27(3), 379–423. <https://doi.org/10.1002/j.1538-7305.1948.tb01338.x>
- Shapley, L. S. (1953). A value for n-person games. *Contributions to the Theory of Games*, 2, 307–317.
- Sutton, R. S., & Barto, A. G. (2018). *Reinforcement Learning: An Introduction*. MIT Press.

- Szegedy, C., Zaremba, W., Sutskever, I., Bruna, J., Erhan, D., Goodfellow, I., & Fergus, R. (2014). Intriguing properties of neural networks. arXiv preprint arXiv:1312.6199.
- Tsai, C.-F., & Hsu, Y.-F. (2013). Combining decision trees and data mining techniques for MCDM. *Expert Systems with Applications*, 40(9), 3525-3536.
- Tsai, C.-F., & Chou, S.-C. (2014). Hybrid MCDM and clustering approaches. *Applied Soft Computing*, 24, 76-84.
- Tzeng, G. H., Chiang, C. H., & Li, C. W. (2007). Evaluating intertwined effects in e-learning programs: A novel hybrid MCDM model based on factor analysis and DEMATEL. *Expert Systems with Applications*, 32(4), 1028-1044. <https://doi.org/10.1016/j.cswa.2006.02.004>
- Wang, J., Zhang, X., & Yang, Y. (2018). Multi-criteria decision-making approach for power plant site selection. *Energy*, 165, 765-776.
- Veale, M., & Binns, R. (2017). Fairness in machine learning. *IEEE Symposium on Security and Privacy Workshops*.
- Vellido, A., Martín-Guerrero, J. D., & Lisboa, P. J. G. (2012). Making machine learning models interpretable. In *Proceedings of the 20th European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning (ESANN 2012)* (pp. 163-172). i6doc Publishing.
- Voigt, P., & Von dem Bussche, A. (2017). The EU General Data Protection Regulation (GDPR). Springer.
- Yıldırım, E., & Kaya, Ö. (2019). Application of Multi-Criteria Decision-Making Methods in the Healthcare Sector: The Case of Turkey. *Journal of Industrial Engineering*, 30(4), 245-256.
- Zhang, Z., Zhao, L., & Wang, J. (2020). A hybrid deep learning framework for multi-criteria decision making. *Expert Systems with Applications*, 159, 113571. <https://doi.org/10.1016/j.cswa.2020.113571>
- Zopounidis, C., & Doumpos, M. (2002). Multicriteria classification and sorting methods: A literature review. *European Journal of Operational Research*, 138(2), 229-246. [https://doi.org/10.1016/S0377-2217\(01\)00153-6](https://doi.org/10.1016/S0377-2217(01)00153-6)