

**T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**YENİKAPI M1 – KIRAZLI M1 HATTI İÇİN İSTASYON VE HAT BAZLI YOLCU TALEP TAHMİNİ VE
RAYLI ULAŞIM SİSTEMLERİNDE SEFER SIKLIĞI BELİRLEMEDE KRİTİK BAŞARI
FAKTÖRLERİNİN ÇOK KRİTERLİ KARAR VERME YÖNTEMLERİ İLE ÖNCELİKLENDİRİLMESİ**

DOKTORA TEZİ

Melek NAR

Enstitü Anabilim Dalı

: ENDÜSTRİ MÜHENDİSLİĞİ

Tez Danışmanı

: Dr. Öğr. Üyesi Seher ARSLANKAYA

Mart 2022

**T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**YENİKAPI M1 – KIRAZLI M1 HATTI İÇİN İSTASYON VE HAT BAZLI YOLCU TALEP TAHMİNİ VE
RAYLI ULAŞIM SİSTEMLERİNDE SEFER SIKLIĞI BELİRLEMEDE KRİTİK BAŞARI
FAKTÖRLERİNİN ÇOK KRİTERLİ KARAR VERME YÖNTEMLERİ İLE ÖNCELİKLENDİRİLMESİ**

DOKTORA TEZİ

Melek NAR

Enstitü Anabilim Dalı : ENDÜSTRİ MÜHENDİSLİĞİ

Bu tez 09/03/2022 tarihinde aşağıdaki jüri tarafından oybirliği/oyçokluğu ile kabul edilmiştir.

Jüri Başkanı

Üye

Üye

Üye

Üye

BEYAN

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim.

Melek NAR
09.03.2022

TEŞEKKÜR

Doktora eğitimim boyunca beni yönlendiren, çalışmamı değerli kılan, ilgi ve desteğini esirgemeyen danışman hocam Dr. Öğr. Üyesi Seher ARSLANKAYA'ya, hayatta bulunduğum noktaya gelebilmemde gösterdiği özveri, yakın ilgisi ve desteğiyle büyük çabası bulunan ve bana olan inançlarından asla vazgeçmeyen anneme, babama ve kardeşime sonsuz teşekkürlerimi bir borç bilirim.

İÇİNDEKİLER

TEŞEKKÜR.....	i
İÇİNDEKİLER	ii
SİMGELER VE KISALTMALAR LİSTESİ.....	v
ŞEKİLLER LİSTESİ	viii
TABLolar LİSTESİ	xi
ÖZET.....	xv
SUMMARY	xvi

BÖLÜM 1.

GİRİŞ	1
1.1. Talep Tahmin Yöntemleri.....	3
1.1.1. Yapay sinir ağı (YSA).....	3
1.1.2. Makine öğrenme (MÖ)	4
1.1.3. Çok değişkenli doğrusal regresyon.....	4
1.1.4. Basit ortalama yöntemi	4
1.2. Çok Kriterli Karar Verme (ÇKKV).....	5
1.2.1. Analitik hiyerarşi süreci (AHP)	6
1.2.2. Adım adım ağırlık değerlendirme oran analizi (SWARA).....	7
1.2.3. İdeal çözüme benzerlik bakımından sıralama performansı tekniği (TOPSİS)	8
1.3. Çalışmanın Amacı.....	9
1.4. Çalışmanın Yöntemi	10
1.5. Çalışmanın Önemi	11
1.6. Çalışmanın Özgün Katkısı	12
1.7. Çalışmanın Planı	12

BÖLÜM 2.

KAYNAK ARAŞTIRMASI.....	14
2.1. Talep Tahmini.....	14
2.2. Çok Kriterli Karar Verme.....	22

BÖLÜM 3.

MATERYAL VE YÖNTEM.....	34
3.1. Materyal	34
3.2. Yöntem.....	37
3.3. Yapay Sinir Ağları.....	37
3.4. Makine Öğrenme Algoritmaları	41
3.4.1. Karar ağacı	42
3.4.2. Rassal orman regresyonu	43
3.4.3. Doğrusal regresyon	44
3.4.4. Polinom regresyon	45
3.4.5. Destek vektör regresyonu	46
3.5. Regresyon Analizi Tekniği.....	47
3.6. Basit Ortalama Yöntemi.....	48
3.7. Farklı Yöntemlerin Değerlendirilmesi	49
3.8. Çok Kriterli Karar Verme Yöntemleri.....	50
3.8.1. Analitik hiyerarşi süreci (AHP)	50
3.8.2. Adım adım ağırlık değerlendirme oran analizi (SWARA).....	56
3.8.3. İdeal çözüme benzerlik bakımından sıralama performansı tekniği (TOPSİS)	58

BÖLÜM 4.

ARAŞTIRMA BULGULARI	61
4.1. Raylı Ulaşımında Talep Tahmin Yöntemleri Uygulaması	62
4.1.1. Raylı ulaşımında yapay sinir ağları ile talep tahmini.....	63
4.1.2. Raylı ulaşımında makine öğrenme algoritmaları ile talep tahmini	85
4.1.3. Raylı ulaşımında regresyon analiz tekniği ile talep tahmini	91
4.1.4. Raylı ulaşımında basit ortalama yöntemi ile talep tahmini.....	95

4.2. Raylı Ulaşımında Çok Kriterli Karar Verme Yöntemleri Uygulaması	98
4.2.1. Problemin AHP yöntemi ile çözümü	98
4.2.1.1. Karar probleminin tanımı	98
4.2.1.2. Hiyerarşinin oluşturulması.....	98
4.2.1.3. Ana kriterler arasında ikili karşılaştırma matrislerinin oluşturulması.....	100
4.2.1.4. Karar alternatifleri için ikili karşılaştırma matrislerinin oluşturulması.....	102
4.2.2. Problemin SWARA yöntemi ile çözümü	115
4.2.3. Problemin TOPSİS yöntemi ile çözümü.....	117
 BÖLÜM 5.	
TARTIŞMA VE SONUÇ	119
5.1. Talep Tahmin Yöntemlerinin Sonuçları	119
5.2. ÇKKV Yöntem Sonuçları	121
 KAYNAKLAR.....	124
EKLER.....	140
ÖZGEÇMİŞ	145

SİMGELER VE KISALTMALAR LİSTESİ

AHP	: Analitik hiyerarşi prosesi / Analytical Hierarchy Process
ANFIS	: Uyarlanabilir nöro-bulanık çıkarım sistemi / Adaptive-Network Based Fuzzy Inference Systems
ANP	: Analitik ağ süreci / Analytic network process
ARAS	: Katkı maddesi oranı değerlendirmesi / Additive ratio assessment
ARIMA	: Otoregresif entegre hareketli ortalama / Autoregressive integrated moving average
ARMA-GRNN	: Otoregresif hareketli ortalama – Genelleştirilmiş regresyonlu sinir ağları / Autoregressive Moving Average - Generalized regression neural network
BIAS	: Taraf tutma, yanlılık
BN	: Bayes ağı / Bayesian network
BP	: Geri yayılım / Backpropagation
CNN-LSTM	: Evrimsel sinir ağı - uzun kısa süreli bellek modeli / Convolutional neural network - Long Short-Term Memory
CO ₂	: Karbondioksit
CT	: Kaos teorisi / Chaos theory
ÇKKV	: Çok kriterli karar verme
DL	: Derin öğrenme / Deep Learning
DVM	: Destek vektör makineleri
EDAS	: Ortalama çözüm uzaklığına dayalı değerlendirme / Evaluation based on distance from average solution
FARE	: Faktör ilişkisi / Factor relationship
GA	: Genetik algoritma
GIS	: Coğrafi bilgi sistemi / Geographic information system

GLM	: Genelleştirilmiş doğrusal model / Generalized linear regression
GUI	: Grafik kullanıcı arayüzü / Graphical user interface
LSTM	: Uzun kısa süreli bellek ağı / Long Short-Term Memory
MABAC	: Çok nitelikli sınır yakınlaştırma alanı karşılaştırması / Multi-attributive border approximation area comparison
MAE	: Ortalama mutlak hata / Mean absolute error
MAPE	: Ortalama mutlak yüzde hata / Mean absolute percentage error
MC_STGC	: Çok topluluklu uzay-zaman grafiği evrimsel ağ / Multi-
N	community spatio-temporal graph convolutional network
ML	: Makine öğrenme / Machine learning
MLP	: Çok katmanlı algılayıcı / Multilayer perceptron
MSE	: Ortalama karesel hata / Mean squared error
MÖ	: Makine öğrenme
MULTIMO	: Oran analizine dayalı çok amaçlı optimizasyon / Multi-
ORA	objective optimization on the basis of ratio analysis
NAR	: Doğrusal olmayan otoregresif sinir ağı modeli / Non-linear autoregressive neural network model
NN	: Sinir ağları / Neural networks
OD	: Başlangıç – varış yeri / Origin - destination
RMSE	: Ortalama karesel hata kökü / Root mean square error
SARIMA	: Mevsimsel otoregresif entegre hareketli ortalama modeli / Seasonal autoregressive integrated moving average
SAW	: Basit katkı ağırlığı / Simple additive weighting
SGD	: Olasılıksal dereceli azalma / Stochastic gradient descent
Sp-LSTM	: Uzay-zamansal uzun kısa süreli bellek modeli / Spatiotemporal long short-term memory model
SSE	: Karesel hatalar toplamı / Sum of Squared Error
SVR	: Destek vektör regresyonu / Support vector regression
SWARA	: Adım adım ağırlık değerlendirme oran analizi / Stepwise weight assessment ratio analysis
SWOT	: Güçlü ve zayıf yönler, fırsatlar ve tehditler / Strengths, weaknesses, opportunities, and threats

TNC	: Ulaşım ağı şirketleri / Transportation network companies
TOPSİS	: İdeal çözüme benzerlik bakımından sıralama performansı teknigi / Technique for Order of Preference by Similarity to Ideal Solution
UBC	: British Columbia Üniversitesi / University of British Columbia
VIKOR	: Çok kriterli optimizasyon ve uzlaşık çözüm / VIseKriterijumska Optimizacija I Kompromisno Resenje
WASPAS	: Ağırlıklı birleşik toplu çarpım değerlendirme / Weighted aggregated sum product assessment
YSA	: Yapay sinir ağı
www	: World wide web
θ	: Toplam eşik değeri

ŞEKİLLER LİSTESİ

Şekil 3.1. Çalışmanın kavramsal modeli.....	36
Şekil 3.2. İnsan beyninin gerçek sinir ağı ve bir YSA	39
Şekil 3.3. Karar ağacı diyagramı.....	43
Şekil 3.4. Rassal orman bilgi yolculuğu.....	44
Şekil 3.5. Destek vektör makine çizimi	47
Şekil 3.6. Örnek hiyerarşi yapısı	52
Şekil 3.7. SWARA yöntemi ile kriter ağırlıklarının belirlenmesi	58
Şekil 3.8. TOPSİS metodolojisini gerçekleştirmek için adım adım prosedür.....	60
Şekil 4.1. Yolcu talep tahmini için çalışmanın adımları.....	62
Şekil 4.2. Modeli en başarılı sonuca ulaştıran yapay sinir ağı mimarisi.....	63
Şekil 4.3. Matlab’a Veri Girişi	64
Şekil 4.4. Matlab’ta değişkenlerin transpozunun alınması	64
Şekil 4.5. Matlab’ta girdi ve çıktı verilerinin sınıflandırılması.....	65
Şekil 4.6. Matlab’ta yapay sinir ağı oluşturma penceresi	66
Şekil 4.7. Yenikapı M1 istasyonu matlab eğitim parametreleri ekranı	66
Şekil 4.8. Yenikapı M1 istasyonu için ağ eğitiminde regresyon değerleri.....	67
Şekil 4.9. Aksaray istasyonu matlab eğitim parametreleri ekranı.....	68
Şekil 4.10. Aksaray istasyonu için ağ eğitiminde regresyon değerleri	69
Şekil 4.11. Emniyet istasyonu matlab eğitim parametreleri ekranı.....	69
Şekil 4.12. Emniyet istasyonu için ağ eğitiminde regresyon değerleri.....	70
Şekil 4.13. Ulubatlı istasyonu matlab eğitim parametreleri ekranı.....	71
Şekil 4.14. Ulubatlı istasyonu için ağ eğitiminde regresyon değerleri	72
Şekil 4.15. Bayrampaşa istasyonu matlab eğitim parametreleri ekranı	73
Şekil 4.16. Bayrampaşa istasyonu için ağ eğitiminde regresyon değerleri.....	73
Şekil 4.17. Sağmalcılar istasyonu matlab eğitim parametreleri ekranı.....	74
Şekil 4.18. Sağmalcılar istasyonu için ağ eğitiminde regresyon değerleri	74

Şekil 4.19. Kocatepe istasyonu matlab eğitim parametreleri ekranı.....	75
Şekil 4.20. Kocatepe istasyonu için ağ eğitiminde regresyon değerleri	75
Şekil 4.21. Otogar istasyonu matlab eğitim parametreleri ekranı.....	76
Şekil 4.22. Otogar istasyonu için ağ eğitiminde regresyon değerleri	76
Şekil 4.23. Esenler istasyonu matlab eğitim parametreleri ekranı	77
Şekil 4.24. Esenler istasyonu için ağ eğitiminde regresyon değerleri.....	77
Şekil 4.25. Menderes istasyonu matlab eğitim parametreleri ekranı	78
Şekil 4.26. Menderes istasyonu için ağ eğitiminde regresyon değerleri.....	79
Şekil 4.27. Üçyüzlü istasyonu matlab eğitim parametreleri ekranı	80
Şekil 4.28. Üçyüzlü istasyonu için ağ eğitiminde regresyon değerleri.....	80
Şekil 4.29. Bağcılar Meydan istasyonu matlab eğitim parametreleri ekranı	81
Şekil 4.30. Bağcılar Meydan istasyonu için ağ eğitiminde regresyon değerleri....	81
Şekil 4.31. Kirazlı M1 istasyonu matlab eğitim parametreleri ekranı	82
Şekil 4.32. Kirazlı M1 istasyonu için ağ eğitiminde regresyon değerleri.....	82
Şekil 4.33. Gerçek veri ve YSA ile istasyon bazlı talep tahmininin karşılaştırılması	83
Şekil 4.34. Günlük test verileri ve YSA ile günlük talep tahmininin karşılaştırılması	84
Şekil 4.35. Günlük test verileri ve Yenikapı istasyonunun YSA ile talep tahmininin karşılaştırılması	84
Şekil 4.36. MÖ algoritmaları talep tahmin sonuçlarının karşılaştırılması	89
Şekil 4.37. Gerçek veriler ile karar ağacı ve YSA talep tahmin sonuçlarının karşılaştırılması	89
Şekil 4.38. Gerçek değer ile istasyon bazlı tahmin değerlerinin karşılaştırılması .	90
Şekil 4.39. Hafta içi için regresyon analizi sonuçlarının ve test değerlerinin karşılaştırılması	94
Şekil 4.40. Hafta sonu için regresyon analizi sonuçlarının ve test değerlerinin karşılaştırılması	95
Şekil 4.41. Hafta içi test değerleri ile basit ortalama yöntemi sonucunda elde edilen değerler	97
Şekil 4.42. Hafta sonu test değerleri ile basit ortalama yöntemi sonucunda elde edilen değerler	97

Şekil 4.43. AHP karar hiyerarşisi	100
---	-----



TABLolar LİSTESİ

Tablo 3.1. AHP önem düzeyleri	52
Tablo 3.2. Rastgele tutarlılık indeksi.....	56
Tablo 4.1. Gerçek verilerin ve YSA çıktılarının istasyon bazında karşılaştırılması.....	85
Tablo 4.2. Yenikapı – Kirazlı hattındaki istasyonlar için MÖ algoritmaları ile elde edilen tahmin verileri	88
Tablo 4.3. Gerçek değer ve istasyon bazlı tahmin değerleri	89
Tablo 4.4. YSA ve MÖ algoritmaları altında elde edilen hata ölçüleri	91
Tablo 4.5. Hafta içi günler için model özeti.....	91
Tablo 4.6. Hafta sonu günler için model özeti	91
Tablo 4.7. Hafta içi için katsayılar	92
Tablo 4.8. Hafta sonu için katsayılar.....	92
Tablo 4.9. Önceki dönem verileri ve basit ortalama yöntemi çıktıları.....	95
Tablo 4.10. Regresyon analizi tekniği ve basit ortalama yöntemi için MAPE değerleri	98
Tablo 4.11. Tanımlanan ana kriter ve karar alternatifleri	99
Tablo 4.12. Kritik başarı faktörü önceliklendirilmesi karşılaştırma matrisi ve önem düzeyleri	100
Tablo 4.13. Ana kriterler için hesaplama tablosu - 1.....	101
Tablo 4.14. Ana kriterler için hesaplama tablosu - 2.....	101
Tablo 4.15. Ana kriterler için hesaplama tablosu - 3.....	101
Tablo 4.16. Ana kriterler için hesaplama tablosu - 4.....	102
Tablo 4.17. Ana kriterler için hesaplama tablosu-5.....	102
Tablo 4.18. Güvenilirlik ana kriterine göre kritik başarı faktörü önceliklendirilmesi karşılaştırma matrisi ve önem.....	102

Tablo 4.19. Güvenilirlik ana kriterine göre karar alternatifleri için hesaplama tablosu-1	103
Tablo 4.20. Güvenilirlik ana kriterine göre karar alternatifleri için hesaplama tablosu-2	103
Tablo 4.21. Güvenilirlik ana kriterine göre karar alternatifleri için hesaplama tablosu-3	103
Tablo 4.22. Güvenilirlik ana kriterine göre karar alternatifleri için hesaplama tablosu-4	104
Tablo 4.23. Güvenilirlik ana kriterine göre karar alternatifleri için hesaplama tablosu-5	104
Tablo 4.24. Sosyal etki ana kriterine göre kritik başarı faktörü önceliklendirilmesi karşılaştırma matrisi ve önem.....	104
Tablo 4.25. Sosyal etki ana kriterine göre karar alternatifleri için hesaplama tablosu-1	105
Tablo 4.26. Sosyal etki ana kriterine göre karar alternatifleri için hesaplama tablosu-2	105
Tablo 4.27. Sosyal etki ana kriterine göre karar alternatifleri için hesaplama tablosu-3	105
Tablo 4.28. Sosyal etki ana kriterine göre karar alternatifleri için hesaplama tablosu-4	106
Tablo 4.29. Sosyal etki ana kriterine göre karar alternatifleri için hesaplama tablosu-5	106
Tablo 4.30. Kalite ana kriterine göre kritik başarı faktörü önceliklendirilmesi karşılaştırma matrisi ve önem.....	106
Tablo 4.31. Kalite ana kriterine göre karar alternatifleri için hesaplama tablosu-1	107
Tablo 4.32. Kalite ana kriterine göre karar alternatifleri için hesaplama tablosu-2	107
Tablo 4.33. Kalite ana kriterine göre karar alternatifleri için hesaplama tablosu-3	107
Tablo 4.34. Kalite ana kriterine göre karar alternatifleri için hesaplama tablosu-4	107

Tablo 4.35. Kalite ana kriterine göre karar alternatifleri için hesaplama tablosu-5	108
Tablo 4.36. Maliyet ana kriterine göre kritik başarı faktörü önceliklendirilmesi karşılaştırma matrisi ve önem.....	108
Tablo 4.37. Maliyet ana kriterine göre karar alternatifleri için hesaplama tablosu-1	108
Tablo 4.38. Maliyet ana kriterine göre karar alternatifleri için hesaplama tablosu-2	109
Tablo 4.39. Maliyet ana kriterine göre karar alternatifleri için hesaplama tablosu-3	109
Tablo 4.40. Maliyet ana kriterine göre karar alternatifleri için hesaplama tablosu-4	109
Tablo 4.41. Maliyet ana kriterine göre karar alternatifleri için hesaplama tablosu-5	109
Tablo 4.42. Kapasite ana kriterine göre kritik başarı faktörü önceliklendirilmesi karşılaştırma matrisi ve önem.....	110
Tablo 4.43. Kapasite ana kriterine göre karar alternatifleri için hesaplama tablosu-1	110
Tablo 4.44. Kapasite ana kriterine göre karar alternatifleri için hesaplama tablosu-2	110
Tablo 4.45. Kapasite ana kriterine göre karar alternatifleri için hesaplama tablosu-3	111
Tablo 4.46. Kapasite ana kriterine göre karar alternatifleri için hesaplama tablosu-4	111
Tablo 4.47. Kapasite ana kriterine göre karar alternatifleri için hesaplama tablosu-5	111
Tablo 4.48. Çevreye duyarlılık ana kriterine göre kritik başarı faktörü önceliklendirilmesi karşılaştırma matrisi ve.....	112
Tablo 4.49. Çevreye duyarlılık ana kriterine göre karar alternatifleri için hesaplama tablosu-1	112
Tablo 4.50. Çevreye duyarlılık ana kriterine göre karar alternatifleri için hesaplama tablosu-2	112

Tablo 4.51. Çevreye duyarlılık ana kriterine göre karar alternatifleri için hesaplama tablosu-3	112
Tablo 4.52. Çevreye duyarlılık ana kriterine göre karar alternatifleri için hesaplama tablosu-4	113
Tablo 4.53. Çevreye duyarlılık ana kriterine göre karar alternatifleri için hesaplama tablosu-5	113
Tablo 4.54. Kritik başarı faktörü seçim probleminde ana kriterlerin ve alternatiflerin öncelik değerleri	114
Tablo 4.55. Uzman-1 için SWARA yönteminin sonuçları	116
Tablo 4.56. Uzman-2 için SWARA yönteminin sonuçları	116
Tablo 4.57. Uzman-3 için SWARA yönteminin sonuçları	116
Tablo 4.58. Birleştirilmiş kriter ağırlıkları	116
Tablo 4.59. Başlangıç karar matrisi.....	117
Tablo 4.60. Normalleştirilmiş karar matrisi	117
Tablo 4.61. Ağırlıklı normalleştirilmiş karar matrisi	117
Tablo 4.62. Pozitif ideal ve negatif ideal çözüm değerleri.....	118
Tablo 4.63. Ayrılma ölçüleri ve ideal çözüm C_i^* değeri.....	118
Tablo 5.1. Kritik Başarı Faktörü Seçim Probleminde Alternatiflerin Öncelik Değerleri	122

ÖZET

Anahtar kelimeler: Demiryolu sistemleri, talep tahmini, yapay sinir ağları, makine öğrenme algoritmaları, regresyon analizi, AHP, SWARA, TOPSİS, COVID-19

Nüfusun ve motorlu araçların hızlı artışı günümüzde ulaşım sorununu da beraberinde getirmiştir. Bu sorun, yolcuların duraklarda bekleme sürelerini en aza indirmek ve yolcu memnuniyetini artırmak için yolcu talep tahmini çalışmalarının önemini arttırmıştır. Bu çalışmada, Yenikapı M1 – Kirazlı M1 metro hattı için literatürdeki diğer çalışmalardan farklı olarak hat bazında ve istasyon bazında olmak üzere iki aşamada talep tahmini yapılmaktadır. İstasyon bazındaki yolcu talep tahmini, yapay sinir ağı ve makine öğrenme (MÖ) algoritmaları tekniği ile yapılmakta ve hata değerleri (MAE, BIAS, MSE, MAPE ve RMSE) karşılaştırılmaktadır. Çalışmanın ikinci aşamasında ise, regresyon analizi ve basit ortalama gibi istatistiksel tekniklerle hat bazında yolcu talep tahmini yapılmakta; ortalama mutlak yüzde hata değerleri hesaplanmakta ve bu değerler karşılaştırılmaktadır. Çalışma sonucunda, istasyon bazında talep tahmini için en başarılı ve güvenilir sonuçların MÖ algoritmalarından biri olan karar ağacı ile elde edildiği görülürken; hat bazında en iyi talep tahmin sonuçları, basit ortalama yöntemi ile elde edilmektedir.

İkinci bir çalışma olarak, raylı ulaşım sistemlerinde sefer sıklığı belirlemede kritik başarı faktörlerinin önceliklendirilmesi ele alınmaktadır. Bu çalışma yapılırken ana kriterler ve karar alternatiflerinin SWARA, TOPSİS ve AHP karar hiyerarşisi ortaya koyulmakta; AHP'nin diğer adımları için önce ikili karşılaştırmalar matrisleri oluşturulmaktadır. AHP ikili karşılaştırma matrisleri uzman mühendislerle hazırlanan Excel tablolarıyla sunulmakta; uzmanların görüşüne dayanılarak SWARA, TOPSİS, AHP yaklaşımı sefer sıklığı optimizasyonundaki kritik başarı faktörleri modeline uygulanmaktadır. AHP ve TOPSİS modeli sonucunda, çalışma kuralları alternatifinin ağırlığı 0,197 ile birincil öncelikli kritik başarı faktörü olarak bulunmaktadır. Benzer şekilde, ana kriterler AHP ve SWARA yöntemi ile önceliklendirilmekte ve güvenilirlik kriterinin birinci öncelikli ana kriter olduğu görülmektedir.

STATION AND LINE-BASED PASSENGER DEMAND FORECASTING FOR YENİKAPI M1-KIRAZLI M1 LINE AND PRIORITIZATION OF CRITICAL SUCCESS FACTORS IN HEADWAY DETERMINATION IN RAILWAY SYSTEMS WITH MULTI-CRITERIA DECISION-MAKING METHODS

SUMMARY

Keywords: Railway systems, demand forecasting, artificial neural networks, machine learning algorithms, regression analysis, AHP, SWARA, TOPSIS, COVID-19

The rapid increase levels of the population and the number of motor vehicles brought about the transportation problem today. This problem has increased the importance of passenger demand forecasting studies in order to minimize passenger waiting times at stops and increase passenger satisfaction. In this study, unlike other studies in the literature, demand forecasting for Yenikapı M1 – Kirazlı M1 metro line is made in two stages, on a line basis and on a station basis. Station-based passenger demand forecasting is made using artificial neural network and machine learning (ML) algorithms and error values (MAE, BIAS, MSE, MAPE and RMSE) are compared. In the second stage of the study, passenger demand forecasting is made on a line basis with statistical techniques such as regression analysis and simple average; mean absolute percent error values are calculated and these values are compared. As a result of the study, it is seen that the most successful and reliable results for station-based demand forecasting are obtained with the decision tree, which is one of the ML algorithms; the best demand forecasting results on a line basis are obtained with the simple average method.

As a second study, the prioritization of critical success factors in determining the headway for railway systems is discussed. While doing this study, the main criteria and decision hierarchy of decision alternatives SWARA, TOPSIS and AHP are revealed; for the other steps of AHP, firstly, pairwise comparison matrices are created. AHP pairwise comparison matrices are presented to expert engineers in Excel tables; based on the opinion of experts, the SWARA, TOPSIS, AHP approach is applied to the critical success factors model in headway optimization. As a result of AHP and TOPSIS model, the working rule alternative is found as the primary critical success factor with the weight of 0.197. Similarly, the main criteria are prioritized by the AHP and SWARA method, and it is seen that the reliability is the first priority main criterion. According to the findings obtained in this research, it was concluded that the lyophilization as powdered minimized the antioxidant activity loses rather than drying as whole or drying in oven.

BÖLÜM 1. GİRİŞ

Kentsel ulaşım, insanların şehir içinde bir yerden başka bir yere yaptıkları yolculuklarıdır. Gittikçe artan metropoliten alanların beraberinde getirdiği nüfus artışı kentsel alanlarda trafik sorununu oluşturmaktadır. Aynı zamanda artan nüfus ile birlikte özel araç kullanım oranının da artması trafik sorununu kaçınılmaz hale getirmektedir. Ulaşım sorununun önüne geçmek için toplu ulaşım türleri desteklenmekte ve teşvik edilmektedir. Bu noktada toplu ulaşım için güvenilir, hızlı ve rahat olan kentsel raylı sistemler ön plana çıkmaktadır.

Demiryolu taşımacılığı, ulaşım sistemimizin önemli bir parçasıdır. Buharlı trenden elektrikli tramvaylara ve lüks trenlere kadar birçok farklı tren çeşidi bulunmaktadır. Demiryolu taşımacılığının birçok avantajı vardır, bu yüzden dünya çapında bir ulaşım yöntemi olarak sıklıkla kullanılmaktadır. Demiryolu taşımacılığının avantajları söz konusu olduğunda, maliyetin düşük olmasının önemi büyüktür. Demiryolu ucuz yakıt maliyetlerine sahiptir. Bunun yanı sıra, demiryolu taşımacılığı diğer ulaşım türlerinden daha çevre dostudur. Ayrıca, demiryolu taşımacılığı, aslında yürüyüş ya da bisiklete binme gibi insan gücüyle yapılan ulaşım dışında seyahat etmenin en çevreci yoludur. Ayrıca, sıkı tarifelerle çalışan trenlerin yolculuk sürelerinden sapmaları nadirdir. Bu sabit rotalar ve tarifeler, demiryolunun en güvenilir ulaşım modlarından biri olduğu anlamına gelmektedir. Hem yolcu hem de yük için trenler, arabalardan, kamyonetlerden ve hatta otobüslerden çok daha büyüktür. Bu, daha kısa sürede daha fazla insan veya eşya taşıyabilecekleri anlamına gelmektedir. Trenler kısa sürede yüksek bir hızla uzun bir mesafe kat edebilir. Bu, onu uzun mesafeli (şehirler arası veya ülke içi gibi) nakliye için ideal kılar. Dünyanın birçok yeri yüksek hızlı trenleriyle ünlüdür (TRANSPORT, 2022).

Bir raylı sistem hattının ana hedefi, bir yolcuyu mümkün olan en kısa sürede bir rota noktasından başka bir rota noktasına taşımaktır. Bu hedefe ulaşmak için işletmenin verimli ve etkin çalışması gerekir. Raylı sistemlerde, sinyalizasyon sistemi, yolcuyu hedeflenen süre içinde güvenli bir şekilde taşımak için tasarlanmıştır. Bu şekilde, iş trafiği için gerekli düzenlemeler yapılabilir. Sinyalizasyon sistemi için en önemli parametre sefer sıklığı olarak tanımlanmaktadır. Sefer sıklığı, bir hattın bir yönünden geçen iki araç arasındaki ön tampondan ön tampona kadar ölçülen zaman aralığıdır (Nakamura, 1998; Riccardo ve Massimiliano, 2012; Suweda, 2016). Patika, kavşak veya rampa noktalarında araçların geçiş yollarını belirler (Jang ve ark. 2011; Akçay ve Kocaarslan, 2019).

Metrolar genellikle bir şehirde dolaşmanın en hızlı ve enerji açısından en verimli yoludur. Elektrikle çalışırlar ve yenilenebilir enerji kaynaklarıyla da kolayca çalıştırılabilirler. Metrolar, ayrılmış altyapı üzerinde dolaşan hatlarla, trafik sıkışıklığını önler ve çok sayıda insanı taşıyarak birçok şehrin bel kemiğini oluştururlar (UITP, 2022).

Verimli ve yüksek kapasiteli bir ulaşım modu olarak metro, geleceğin sürdürülebilir ulaşımını şekillendirmede her zamankinden daha önemli bir rol oynamaktadır. Metro sistemlerinin artan önemi göz önüne alındığında, hizmet operasyonunu desteklemek için yolcuların talep kalıplarını iyi anlamak çok önemlidir. Yolcu talebinin/yolculuğun doğru ve gerçek zamanlı tahminini yapmak hizmet çizelgelemesi, kalabalık yönetimi ve kesinti yanıtı da dahil olmak üzere çok çeşitli uygulamalarda hayati bir rol oynamaktadır (Cheng ve ark., 2021).

Seyahat talebi tahmini, hem seyahat hem de hizmet planlaması için faydalıdır ve bu nedenle büyük önem taşır. Kentsel multimodal ulaşım sistemlerinin verimli ve etkin çalışması, güvenilir ve doğru talep tahmini girdisi gerektirir (Li ve ark., 2021).

Son on yılda, birçok ülkede yüksek hızlı demiryolunun sürekli gelişiminin olağanüstü temposu dünyanın dikkatini çekmiştir (Cao ve ark., 2021). İnkâr edilemez bir şekilde, yüksek hızlı demir yolu sisteminin hem inşası hem de işletilmesi (planlama gibi ve

demiryolu ağının geliştirilmesi, tren işletme planı, tren veya araç sevk ve güç kaynağı operasyon yönetimi) için doğru tahmininin önemi konusunda geniş bir fikir birliği bulunmaktadır (Guo ve ark., 2014).

1.1. Talep Tahmin Yöntemleri

Tahmin metotları, kantitatif ve kalitatif olarak iki ana başlık altında toplanır. Bunlardan kalitatif olan yöntem türleri kişinin düşüncelerine bağlı bir yöntem olup, kantitatif yöntemler ise matematiksel modellere dayanan, yeterli miktarda sayısal verinin mevcut olduğu durumlarda kullanılır (Karaatlı ve ark., 2012).

1.1.1. Yapay sinir ağı (YSA)

Psikolog Frank Rosenblatt tarafından 1958'de Perceptron olarak adlandırılan yapay sinir ağı modeli, insan beyninin görsel verileri nasıl işlediğini ve bir nesneyi tanımayı nasıl öğrendiğini modellemek için keşfedildi. Bilgisayar mühendisliğinin icadıyla, bilgiyi öğrenme yoluyla depolama ve daha sonraki işlemler için kullanma eğiliminde olan bir algoritma tasarlandı (Singh, 2021). Böylece insan beyni işlevlerine benzer şekilde çalışır; önce çevre aracılığıyla öğrenir, düğümlerde ve sinapslarda depolar ve daha sonra öğrenmeyi uygular (Sexton ve ark., 2002; Singh, 2021).

Yapay Sinir Ağı yapısı, girdi, gizli ve çıktı olmak üzere üç katmandan oluşan yönlendirilmiş bir grafik olan çok katmanlı bir algılayıcı sinir ağı modelidir. Giriş katmanı, ayrı nöronlardaki tüm ortak değişkenlerden oluşur. Aradaki katmanlar, hiyerarşik katmanlara dağılmış nöronlardan oluşan gizli katmanlar olarak adlandırılır, doğrudan gözlemlenemezler ve çıktı katmanı yanıt değişkenlerinden oluşur. Tüm düğümleri (nöronları) birbirine bağlayan yönlendirilmiş kenarlara sinaps denir (Bakar ve Tahir, 2009; Singh 2021).

1.1.2. Makine öğrenme (MÖ)

Tüm makine öğrenimi yaklaşımları, mevcut verilerin kalitesine ve miktarına, yani bunların karmaşıklığına veya rastgeleliğine ve gerçek veri miktarına ve algoritmanın doğru parametreleştirmesine bağlıdır (Raubitsek ve Neubauer, 2021).

Makine Öğrenimi algoritmaları, denetimli öğrenme (Cruz, 2011), denetimsiz (Da Silva ve ark., 2017) ve öğrenmenin pekiştirilmesi (Al-Saegh ve ark., 2021) olarak sınıflandırılabilir (Al-Saegh ve ark., 2021). Bu öğrenme türlerinin her birinin farklı öğrenme hedefleri vardır; örneğin, denetimli öğrenme algoritmalarından bazıları, veri analizi için sınıflandırma ve regresyon için daha iyidir. Bu öğrenme algoritmaları, diğerleri arasında Sinir Ağları (NN) (Rechy-Ramirez ve Hu, 2015), Derin Öğrenme (DL) (Al-Saegh ve ark., 2021), Bayes Ağları (BN) (Rechy-Ramirez ve Hu, 2015) ve Karar Ağaçları (Padfield ve ark., 2019) gibi araçlara sahiptir (Lazcano-Herrera ve ark., 2021).

1.1.3. Çok değişkenli doğrusal regresyon

Regresyon analizi genellikle deneysel veri işleme, ampirik formül ve faktör analizinde kullanılır; regresyon analizi lineer regresyon ve lineer olmayan regresyon olarak ikiye ayrılır. Doğrusal regresyonda, tek bağımlı değişken ve tek bağımsız değişken, tek değişkenli doğrusal regresyon analizi haline gelir ve çok değişkenli doğrusal regresyon analizi, çok değişkenli istatistiksel analizde en yaygın kullanılan yöntemdir (Liang, 2020).

1.1.4. Basit ortalama yöntemi

Basit ortalama yöntemi; geleceğin, geçmişte olanların ortalamasına doğru eğilim göstereceğini varsayarak, talep tahmini bakımından en basit yöntemlerdendir. Basit ortalama yönteminde son n dönemde gerçekleşmiş değerler toplanarak ortalaması alınmakta ve bulunan sonuç tahmini değer olarak kabul edilmektedir (Demirbaş, 2011).

1.2. Çok Kriterli Karar Verme (ÇKKV)

Çok kriterli karar verme (ÇKKV) yöntemi, nitel ve nicel verileri kullanarak alternatifleri sıralamak için etkili bir araçtır (Kondratenko ve ark., 2018). Farklı tekniklerle kombinasyon için birçok tekniğin (ağırlık hesaplama yöntemleri, toplama (Kondratenko ve ark., 2013), sıralama ve dönüşüm yöntemleri (Ahmad ve ark., 2021) çok kriterli karar verme (ÇKKV)'de kullanımı kolaydır.

Akılcı ve doğru karar verme şirketler için en kritik konulardan biridir. Büyük miktarda karmaşık verinin olması karar vericilerin organize etmesini ve uygun yöntemlerle analiz etmesini gerektirir. Günümüzde neredeyse her firmada büyük ölçekli veriler elde edilmekte, yönetilmekte ve analiz edilmektedir. Bu değer ilgili aktörlerin davranış, ihtiyaç ve yeteneklerinin daha iyi anlaşılmasını sağlayan farklı kaynaklardan üretilir. Kurumların karar verme süreçlerinde değişiklik yapması zorunlu hale gelmiştir. (Bilgiç ve ark., 2019; Yalcin ve ark., 2022).

Çok kriterli karar verme (ÇKKV), karar vermede ünlü bir metodolojidir. Bir dizi karar kriterlerinin mevcudiyeti altında karar problemleriyle ilgilenen yöneylem araştırmaları modeli genel sınıfının bir dalıdır. Modellerin büyük sınıfı sıklıkla çok kriterli karar verme (ÇKKV) olarak adlandırılır (Begić ve Afgan, 2007; Zolfani ve Saparauskas, 2013).

20. yüzyılın son çeyreğinden bu yana, çok kriterli karar analizi ile ilgili literatür, çok amaçlı karar verme problemlerinin üstesinden gelmek için çok sayıda yaklaşım ve yöntem önermiş ve uygulamıştır (Wallenius ve ark., 2008; Cinelli ve ark., 2020).

Çok kriterli karar verme (ÇKKV) yöntemleri birden fazla hedef ile karakterize edilen karmaşık bir karar verme durumunu basitleştiren ve karar vericiler tarafından farklı şekilde derecelendirilen sıklıkla çatışan hedefleri içeren bir yapı sağlar (Saarikoski ve ark., 2015; Kalifa ve ark., 2022).

1993 ve 2015 yılları arasında ÇKKV tekniklerinin ulaşım sektörünün farklı alanlarını değerlendirmek için kullandığı 89 makale yayınlanmıştır (Mardani ve ark., 2016; Kalifa ve ark., 2022).

Bu çalışmada, ÇKKV yöntemlerinden, analitik hiyerarşi süreci (AHP), Adım Adım Ağırlık Değerlendirme Oran Analizi (SWARA) ve İdeal Çözüme Benzerlik Bakımından Sıralama Performansı Tekniği (TOPSİS) kullanılmıştır.

1.2.1. Analitik hiyerarşi süreci (AHP)

AHP, 1970’lerde Thomas L. Saaty tarafından kurulmuş olup; karar vericiler tarafından yargı konularını değerlendirmede çeşitli amaçlar için kullanılmaktadır (Saaty, 1987).

AHP, çok amaçlı karmaşık problemleri nitel ve nicel kombinasyon, sistematizasyon ve hiyerarşi özellikleri ile etkin bir şekilde çözebilir. AHP, üst elemanların ağırlığının iki katmanını karşılaştıran ve son olarak alt elemanların ağırlığını entegre olarak hesaplayan düzenli bir hiyerarşik yapı ile kurulur (Saaty, 2004).

AHP bir sistem analiz yöntemidir; ve temel ilkesi; hedefler, kriter ve program gibi komponentteki karmaşık bir sistemi ayırtırmaktır. Daha sonra, ayırık süreçlerin niteliksel ve nicel analizine dayalı olarak karar verme belirlenir. Özellikle, hedef faktör karmaşık olduğunda ve gerekli veriler eksik olduğunda ve karar vericinin ampirik yargısının nicelleştirilmesi gerektiğinde AHP yöntemi kullanılır. AHP, nispeten basit bir hesaplama üreten ve yapay ağırlıklandırma yönteminin öznelliğinin üstesinden gelen nicel olmayan olayların nicel analizi için etkili bir yöntemdir ve birçok bilim adamı bu yöntemi parametrelerin etkin ağırlıklarını optimize etmek için kullanmıştır (Sener ve Davraz, 2013; Azadnia ve ark., 2015; Pacheco ve ark., 2015).

AHP, küresel ağ boyunca karmaşık karar problemleri için güçlü, uyarlanabilir ve dinamik bir işbirlikçi strateji tanır (Asakereh ve ark., 2017).

AHP yaklaşımı hiyerarşik seviyelerde birçok küçük ama birbiriyle bağlantılı alt problemlerin içindeki çok yönlü karar problemini mantıksal olarak ayrıştırarak karar vericilere yardımcı olur (Sindhu ve ark., 2017).

Analitik hiyerarşi süreci (AHP) uzmanların yargılarına dayalı olarak kriterleri ağırlıklandıran en popüler yöntemlerden biridir. Kriter ağırlıklandırma için ikili karşılaştırma matrisleri kullanılır. Bu matrisin unsurları, kriterlerin birbirine göre önemidir. Bu göreceli önem değerleri ilk olarak Saaty (2008) tarafından 1-9 aralığında tanıtılmıştır. 1 eşit önem düzeyini, 3 orta derecede önemi, 5 güçlü önemli düzeyini, 7 çok önemli ve 9 mutlak önem düzeyini ifade etmektedir (Mojaver ve ark., 2022).

1.2.2. Adım adım ağırlık değerlendirme oran analizi (SWARA)

SWARA, çok parametrelili problemlerde kriterler ve alt kriterlerin ağırlıklarını belirlemek için kullanılan karar verme sürecinde önemli rol oynayan yöntemlerden biridir. Bu süreci geliştiren Keršulienė ve ark. (2010)'ye göre, bu yöntemin temel özelliği, ağırlıklandırma sürecinde kriterlerin göreceli önemi konusunda uzman görüşlerini değerlendirebilmesidir. Bu nedenle, çok kriterli problemlerin çözümü için çok kullanışlıdır. Bugüne kadar birçok yazar bu yöntemi çeşitli alanlarda kullanmıştır (Stanujkic ve ark., 2015; Mavi ve ark., 2017; Wang ve ark., 2019; Torkashvand ve ark., 2021).

Uzmanlar, kriterlerin ve ağırlıkların değerlendirilmesinde hayati bir rol oynarlar. Ayrıca, uzmanlar, her karar verme sürecinin kaçınılmaz parçalarıdır, her biri yalnızca her bir kriterin önceliğini belirtir ve ardından, toplam sonuç dikkate alınarak belirleyici faktörler baştan sona sıralanır. Bir uzmanın mantıklı bir karar vermesini sağlayan en önemli faktörler bilgi ve deneyimdir. Yeni çok kriterli karar verme (ÇKKV) yaklaşımlarından adım adım ağırlık değerlendirme oran analizi (SWARA) yönteminde en yüksek sıra en değerli kritere, en düşük sıra ise en az değerli kritere atanmaktadır. Daha sonra, genel sıralamaları belirlemek için sıralamaların ortalama değeri dikkate alınır (Keršulienė ve Turskis, 2011).

SWARA yönteminin en önemli özelliği, yöntem sürecinde ağırlıklı kriterlerin doğruluğuna ilişkin uzman görüşünü değerlendirebilmesidir (Keršuliene ve ark., 2010). Ayrıca uzmanlar birbirlerine danışabilir ve birlikte çalışabilirler, bu da diğer ÇKKV prosedürlerine göre daha somut ve doğru sonuçlar anlamına gelir. Ayrıca, bu yöntem, önceliklerin firmaların veya ulusların politikalarına ve stratejilerine dayandığı durumlarda uygulanabilir; bu nedenle, ağırlıklandırmadan önce sıralamak için kriterlerin değerlendirilmesi gerekli değildir. SWARA'nın bakış açısı FARE, ANP ve AHP gibi diğer benzer ÇKKV yaklaşımlarından tamamen farklıdır (Zolfani ve Saparaskas, 2013).

1.2.3. İdeal çözüme benzerlik bakımından sıralama performansı tekniği (TOPSİS)

Literatürde çok özellikli karar verme problemlerini ele almak için çok çeşitli teknikler bildirilmiştir. TOPSİS (İdeal Çözüme Benzerlik Bakımından Sıralama Performansı Tekniği), 1981'de Hwang ve Yoon tarafından tanıtılan geleneksel çok özellikli karar verme tekniklerinden biridir (Hwang ve ark., 1980; Behzadian ve ark., 2012; Rathi ve ark., 2015; Mittal ve ark., 2016). Çok özellikli karar verme problemlerini sonlu bir dizi alternatiftan çözümler belirleyerek çözmek için kullanılır. Mantıklı karar verme, tercihler ve en mükemmel alternatiflerin yanı sıra zayıf alternatifleri açıklayan bir indeks sağlayan basit bir mantık tabanlı hesaplama yöntemidir (Mittal ve ark., 2016).

TOPSİS, çok kriterli karar analizi problemlerini çözmek için kullanılır (Tzeng ve Huang, 2011; Li ve ark., 2012). TOPSİS, seçilen alternatifin pozitif ideal çözümden en kısa geometrik uzaklığa ve negatif ideal çözümden en uzun geometrik uzaklığa sahip olması gerektiği kavramına dayanmaktadır (Li ve ark., 2022).

TOPSİS, ideal çözüme en kısa mesafe ile en iyi alternatif ve negatif ideal çözümden en uzun mesafe seçimi için çok kriterli bir karar verme analizidir (Arcanjo ve ark., 2020).

Öklid mesafelerini ölçerek bir dizi olası alternatifini sıralamak ve seçmek için pratik ve kullanışlı bir tekniktir. Bu teknik öncelikle, seçilen alternatifin pozitif ideal çözümünden en kısa ve negatif ideal çözümünden en uzun mesafeye sahip olması gerektiği ilkesine dayanmaktadır (Opricovic ve Tzeng, 2004).

1.3. Çalışmanın Amacı

Bu çalışmanın amacı, Yenikapı – Kirazlı metro hattının geçmiş dönem verilerini kullanarak gelecek dönem yolcu taleplerini tahmin etmektir. Bu amacı gerçekleştirirken literatürdeki diğer çalışmalardan farklı olarak hat bazında ve istasyon bazında talep tahmini yapılmıştır. Çalışmada yapay sinir ağları, makine öğrenme algoritmaları (karar ağacı, rassal orman regresyonu, doğrusal regresyon, polinom regresyon, destek vektör regresyonu), regresyon analizi tekniği ve basit ortalama yöntemi kullanılmıştır. Bu teknikler aracılığıyla elde edilen tahmin sonuçlarının, ortalama mutlak hata (MAE), BIAS, ortalama karesel hata (MSE), ortalama mutlak yüzde hata (MAPE) ve ortalama karesel hata kökü (RMSE) hesaplanarak performansları değerlendirilmiştir. Yolcu talep tahmininin kritik önemi vurgulanmış; doğru tahminin sefer sıklığı optimizasyon çalışmalarına önemli bir girdi oluşturacağı bilinciyle çalışma birden fazla teknikle ele alınmıştır.

Yolcu talep tahmini çalışmasına ek olarak bu çalışmada, raylı ulaşım sistemlerinde sefer sıklığı optimizasyonunda kritik başarı faktörleri tartışılmış ve bu faktörlerin önceliklendirilmesi kantitatif tekniklerden SWARA, AHP ve TOPSİS yöntemleri ile araştırılmıştır.

Bu kapsamda;

- Yolcu bekleme sürelerini azaltmak,
- Yolcu konforunu arttırmak,
- Yolcu memnuniyetini arttırmak,

- Raylı ulaşım seferlerindeki sürekliliği sağlamak ve olası aksamaları en aza indirmek için gerekli olan temel bilgi ve prosedürleri belirlemek amaçlanmıştır.

1.4. Çalışmanın Yöntemi

Gerçekleşen tez çalışması:

- Çalışmanın amaçları doğrultusunda raylı ulaşım sistemlerinde yolcu talep tahmini, talep tahmin yöntemleri, sefer sıklığı optimizasyonunda kritik başarı faktörleri, SWARA, AHP, TOPSİS uygulamaları konularında geniş bir literatür taraması yapılması,
- Literatürden elde edilen sonuca göre çalışmanın amacını da dikkate alarak, hazırlanacak olan sistemin kavramsal bir veri akış modelinin oluşturulması,
- Bu veri akış modelinde yolcu talep bilgileri için bir veri analizi gerçekleştirilmesi,
- Türkiye’de ve Dünya’da raylı ulaşım sistemlerinin gelişimi, talep tahmin çalışmaları incelenerek genel bir bakış açısının oluşturulması,
- Talep tahmini çalışmaları, yapay sinir ağı, makine öğrenme algoritmaları, regresyon analizi vb. gibi istatistiksel teknikler, SWARA, AHP, TOPSİS ve benzer uygulamaların incelenmesi, örneklerden yararlanılması,
- Yenikapı – Kirazlı metro hattının geçmiş dönem verileri kullanılarak hat ve istasyon bazlı gelecek dönem yolcu talebi tahmininin yapılması,
- Yolcu talep tahmininin istasyon bazında, yapay sinir ağları ve makine öğrenme algoritmaları kullanılarak yapılması,
- Tahmin modellerinin oluşturulmasında karar ağacı, doğrusal regresyon, rassal orman (sınıflandırma), polinom regresyon ve destek vektör regresyonu gibi makine öğrenme algoritmalarının kullanılması,
- Yolcu talep tahmininin hat bazında, regresyon analizi tekniği ve basit ortalama yöntemi gibi istatistiksel teknikler aracılığıyla yapılması,
- Talep tahmini sonuçları elde edildikten sonra, ortalama mutlak hata (MAE), BIAS, ortalama karesel hata (MSE), ortalama mutlak yüzde hata (MAPE) ve

ortalama karesel hata kökü (RMSE) hesaplanarak performansları değerlendirilmesi,

- İkinci bir çalışma olarak sefer sıklığı optimizasyonu için kritik başarı faktörlerinin ele alınması,
- Ana kriterler ve karar alternatiflerinin SWARA, TOPSİS ve AHP karar hiyerarşisinin ortaya konulması,
- AHP'nin diğer adımları için önce ikili karşılaştırmalar matrisleri oluşturulması,
- AHP ikili karşılaştırma matrislerinin hizmet sektöründe görev alan uzman bir risk mühendisine hazırlanan Excel tablolarıyla sunulması,
- Uzman görüşüne dayanılarak SWARA, TOPSİS, AHP yaklaşımının sefer sıklığı optimizasyonundaki kritik başarı faktörleri modeline uygulanması,
- Elde edilen bulguların karşılaştırılması, irdelenmesi, bulgulardan yola çıkarak, sonuçların ve geleceğe yönelik önerilerin ortaya konulması adımlarından oluşmaktadır.

1.5. Çalışmanın Önemi

Bu çalışma, sefer sıklığı optimizasyonunda kritik başarı faktörlerini; hat ve istasyon tahminini aynı anda temel alan ilk girişimlerden biridir. Literatür incelemeleri sonucunda geçmişte yapılan çalışmaların ağırlıklı olarak demiryolu ulaşım sistemlerinin farklı aşamalarıyla ilgilendiği gözlenmiştir. Bu çalışmada, raylı ulaşım sistemlerinde sefer sıklığı optimizasyonunda kritik başarı faktörleri tartışılmış ve bu faktörlerin önceliklendirilmesi SWARA, AHP ve TOPSİS yöntemi ile araştırılmıştır. Ayrıca, Yenikapı – Kirazlı metro hattının geçmiş dönem verileri kullanılarak gelecek dönem yolcu talebi tahmin edilmiştir. Literatürdeki çalışmalardan farklı olarak bu çalışma talep tahmini için iki aşama içermektedir. Çalışmanın ilk aşamasında hafta içi ve hafta sonu için hat bazında talep tahmini yapılırken; çalışmanın ikinci aşamasında ise istasyon bazında tahmin yapılmaktadır. Çalışmanın hem hat bazında hem de istasyon bazında yapılması literatüre katkı sağlayacaktır.

Yolcu talep tahmininin kritik önemi göz önünde bulundurularak istasyon bazında yapay sinir ağları ve makine öğrenmesi algoritmaları kullanılarak talep tahmini

yapılmış; hat bazındaki tahminleme ise, regresyon analizi tekniği ve basit ortalama yöntemi gibi istatistiksel teknikler aracılığıyla yapılmıştır. Ayrıca, tahmin modellerinin oluşturulmasında karar ağacı, doğrusal regresyon, rassal orman (sınıflandırma), polinom regresyon ve destek vektör regresyonu gibi makine öğrenme algoritmaları ve bunların bir topluluk modeli kullanılmaktadır. Talep tahmini sonuçları elde edildikten sonra, son olarak, ortalama mutlak hata (MAE), BIAS, ortalama karesel hata (MSE), ortalama mutlak yüzde hata (MAPE) ve ortalama karesel hata kökü (RMSE) hesaplanarak performansları değerlendirilmiştir.

1.6. Çalışmanın Özgün Katkısı

Raylı ulaşım sistemlerinde yolcu talep tahmini ve sefer sıklığı optimizasyonundaki kritik başarı faktörlerinin önceliklendirilmesi üzerine yapılan bu çalışmanın en temel özgünlüğü; daha önce literatürde yer almayan hat ve istasyon tahminini aynı anda temel alan ilk girişimlerden biri olmasıdır. Ayrıca, çalışma da eş zamanlı olarak sefer sıklığı optimizasyonunda kritik başarı faktörleri ele alınmıştır. Kritik başarı faktörleri önceliklendirmesi ve yolcu talep tahmini çalışmaları için uygulanan yöntemlerin sonucunda elde edilen sonuçlar karşılaştırılmıştır.

1.7. Çalışmanın Planı

Çalışma beş temel bölümden oluşmaktadır:

Birinci bölümde; Öz, abstract, teşekkür, içindekiler, şekiller dizini, çizelgeler dizini, kısaltmalar ve giriş gibi temel bölümler yer almaktadır.

Çalışmanın ikinci bölümünde 2. bölümünde, yolcu talep tahmini ve SWARA, AHP, TOPSİS yöntemi ile ilgili daha önce yapılan çalışmalara ayrıntılı bir şekilde yer verilmiştir. Bu bölümde literatürdeki benzer çalışmalar incelenmiş çalışmanın gerçekleştirilmesinde rehberlik edecek çalışmaların etkinliği değerlendirilmiştir.

3. bölüm “Materyal ve Yöntem” bölümünde, çalışmada kullanılan materyal ve yöntem açıklanmaktadır. Burada yolcu talep tahmininde kullanılan yapay sinir ağları ve

makine öğrenmesi algoritmaları, regresyon analizi tekniği ve basit ortalama yöntemi gibi istatistiksel teknikler detaylandırılmıştır. Ayrıca, tahmin modellerinin oluşturulmasında kullanılan karar ağacı, doğrusal regresyon, rassal orman (sınıflandırma), polinom regresyon ve destek vektör regresyonu gibi makine öğrenme algoritmalarına yer verilmiştir. Ayrıca, SWARA, TOPSİS, AHP tekniğinin adımlarına, yer verilmiştir. Uzman görüşlerinden elde edilen bilgiler ile çalışmanın içeriği ve planı anlatılmıştır.

4. bölüm “Araştırma Bulguları” kısmında önerilen tahmin sistemin yapısını ve matematiksel formülasyonunu açıklamakta ve önerilen yaklaşımlar arasındaki tahmin performansları karşılaştırılmaktadır. Ayrıca, kritik başarı faktörü önceliklendirme yöntemlerine yer verilmektedir.

5. bölümde, “Tartışma ve Sonuç” kısmında yapay sinir ağı, makine öğrenme algoritmaları, regresyon analizi ve basit ortalama yöntemi uygulamalarından elde edilen sonuçlar; ve ayrıca, SWARA, TOPSİS, AHP tekniklerinden ulaşılan sonuçlar tartışılarak çalışma tamamlanmıştır.

BÖLÜM 2. KAYNAK ARAŞTIRMASI

2.1. Talep Tahmini

Seyahat talebi tahmin modeli olarak da bilinen seyahat talebi modeli, belirli varsayımlara dayalı olarak belirli bir zaman dilimi için seyahatlerin mekansal dağılımını ve seyahat davranışını ve seyahat talebini tahmin etmeyi amaçlar. Seyahat talebi tahmini, gelecekteki seyahat modelini tahmin etme ve bunu nicelleştirme girişimidir (Cyril ve ark., 2018). Toplu taşıma aracını kullanan yolcu sayısının bilinmesi planlama açısından oldukça önemlidir. Literatür incelendiğinde bu tahminin yapılabilmesi için yapay sinir ağları, derin öğrenme, makine öğrenmesi ve istatistiksel yöntemler gibi algoritmaların kullanıldığı görülmektedir.

Literatürde raylı ulaşım sistemleri için az sayıda çalışma mevcuttur ve mevcut çalışmalarda destek vektör regresyon (SVR), bulanık, yapay sinir ağları algoritmaları kullanılmaktadır. Zhao ve Mi (2019), komşu zaman verilerinin alaka düzeyini açıkça dikkate alan kısa vadeli yüksek hızlı demiryolu yolcu talebi tahmini için özellikle tekil spektrum analizi dalgacık paket ayrıştırma - vektör regresyonunu (SVR) destekleyen yeni bir hibrit model önermektedir. Li ve Sheng (2016), çok terimli logit tabanlı ayrık seçim modelleri kullanarak hava ve yüksek hızlı demiryolu entegrasyon hizmetinin pazar payını tahmin etmek için ampirik modeller önermektedir. Önerilen modellerdeki parametreleri tahmin etmek için belirtilen bir tercih anketi yapılmıştır. Dou ve ark. (2013), bulanık küme teorisi, portföy optimizasyonu ve tren operasyon ayarlama teorisini uygulamaktadır. İlk olarak, tatillerde yolcu tahmininde bulunmak için bulanık yolcu talep tahmin modeli kurulmuştur. Sonuçlar, bulanık yolcu tahminlerinin ARIMA modelinden daha doğru olduğunu göstermektedir. Daha sonra yazarlar, tren sevkiyatının toplam işletme maliyetini, hizmet verilmeyen yolcu hacmini, gerekli tren sayısını, istasyon kapasitesini, bölüm kapasitesini ve tren seti konfigürasyonunu göz

önünde bulundurarak ani büyük yolcu akışında tren konuşlandırma teorisini incelemektedir.

Son olarak, tren dağıtım optimizasyon modeli kurulmuş, bu modelin geçerliliği bir örnek çalışma ile gösterilmiştir. Çelebi ve ark. (2009), hafif raylı hizmetlerin operasyonel yönetiminde kullanılacak kısa vadeli yolcu talebi tahmin modelleri geliştirmek için sinir ağlarını benimsemiştir. Çok katmanlı algılayıcı modeli sadece basit mimarisi nedeniyle değil, aynı zamanda yaklaşım problemlerini çözmedeki kanıtlanmış başarısı nedeniyle tercih edilmektedir. Zaman dilimlerindeki önemli mevsimselliği ortadan kaldırmak için her bir zaman dilimi diğerlerinden bağımsız olarak ele alınmış ve her biri için günlük verilere dayalı bir yapay sinir ağı geliştirilmiştir.

Jin ve ark. (2020), değişken mod ayrıştırması, otoregresif hareketli ortalama modeli ve Kernel aşırı öğrenme makinesi temelinde kısa vadeli hava yolcu tahmini için bir yaklaşım geliştirmiştir. Gong (2010), çalışmasında “şehirlerarası yolcu talebi tahmin problemini” formüle etmektedir. Problemi çözmek için ARMA-GRNN olarak adlandırılan bir algoritma önermiştir. Cyril ve ark. (2018), bir Otoregresif Entegre Hareketli Ortalama (ARIMA) modeli kullanarak Trivandrum bölgesinden Kerala’nın diğer beş bölgesine toplu taşıma talebi tahminlerini rapor etmektedir. Kim ve Shin (2016), arama motoru sorgularından büyük verileri kullanarak kısa vadeli hava yolcu talebini tahmin etmek için bir model geliştirmektedir. Bazı tahmin yeteneğine sahip olduğundan emin olmak için, tahmin modelini geliştirirken 1 aylık aralıklarla 0 ila 11 ay arasında değişen zaman kaymaları kullanılmıştır.

Ke ve ark. (2017), yeni bir uzaysal-zamansal DL yaklaşımı aracılığıyla isteğe bağlı yolculuk hizmeti platformu altında kısa vadeli yolcu talebi tahminini araştırmaktadır. Doğru gerçek zamanlı yolcu talebi tahmini, platforma, her bölgedeki yolcu talebini karşılamak için seyir araçlarının mekansal dağılımını yeniden dengelemek için öneriler sunabilmekte ve bu da araç kullanım oranını ve yolcuların memnuniyet derecesini iyileştirmektedir. Li ve ark. (2020), hibrit araç paylaşımı hizmet modları altında yolcu talebini tahmin etmeyi amaçlamaktadır. Fuloria (2020), doğrulama veri

kümelerinin yanı sıra eğitimde tahmin doğruluğu için üstel yumuşatma, çoklu regresyon ve LSTM'yi karşılaştırmaktadır. Bai ve ark. (2019), çok adımlı şehir çapında yolcu talebi tahmini için yeni bir derin öğrenme çerçevesi önermekte ve şehir çapında yolcu talebini bir grafik üzerinde formüle etmekte ve aynı anda mekansal ve zamansal korelasyonları çıkarmak için hiyerarşik grafik evrişim mimarisini kullanmaktadır.

Picano ve ark. (2019), Çin'deki en ünlü TNC olan Didi Chuxing'den gelen gerçek verilerle hareket eden yolcu talebi tahmin problemini ele almaktadır. Yolcu taleplerinin gelecekteki davranışını tahmin etmek için yazarlar, karşılık gelen doğrusal olmayan skaler zaman serileriyle başa çıkmak için bir CT yaklaşımı önermektedir. Picano ve ark. (2019), TNC'ler için hizmet taleplerinin tahmini sorununu ele almaktadır. Özellikle farklı gerçek veri kümeleri için farklı algoritmalar sunulmuştur. Analiz edilen üç veri kümesi için tasarlanan tahmin yöntemleri, CT ilkelerine dayanmaktadır ve en büyük Lyapunov üssünün analizi yoluyla ilgili faz uzayı yeniden yapılandırılmış, kaotik davranış incelenmiştir. Ayrıca, çalışılan farklı veri kümeleri için farklı bir BT tabanlı algoritma önerilmiştir.

Alekseev ve Seixas (2002), hava taşımacılığı yolcu talebi tahmininde yapay sinir ağlarına dayalı modeller geliştirmektedir. Nöral işlemenin bu alanda kullanılan geleneksel ekonometrik yaklaşımdan daha iyi performans gösterebildiği ve az sayıda veri noktasının mevcut olduğu pratik koşullarda bile öğrenilen zaman serisi davranışını doğru bir şekilde genelleştirebildiği bulunmuştur.

Li ve ark. (2021), multimodal talep tahmini için bilgi adaptasyonu ile çoklu görev bellek ağı adlı çalışmalarında; multimodal talep tahmin yaklaşımı geliştirmiştir. Çalışmalarında, farklı toplu taşıma modlarından öğrenebilen ve öğrendiği bilgiyi kullanabilen bu yaklaşım; aralıklı gözlemlerle seyahat modunda talep tahmini geliştirmektedir (örneğin, istasyon seyrek modu). Ayrıca, bu çalışma yoğun istasyon yardımı ile istasyon seyrek mod(lar)ının doğruluğunun yolcu talep tahminini iyileştirmesine odaklanmaktadır (yani, daha yeterli bilgi ve yoğun istasyon dağıtımına sahip mod). Spesifik olarak, ilk önce bir uzun ve kısa dönem talep bilgisi ve her bir geçiş modunun çıkarılan zamansal bilgisinin depolanmasına olanak sağlayan bellekle

güçlendirilmiş tekrarlayan ağ dizayn etmişlerdir. Ardından, yoğun istasyon kaynağından seyrek istasyon kaynağına ilgili bilgiyi sağlamak için dikkat temelli bilgi uyarlama modülü geliştirmiş ve entegre etmişlerdir. Greater Sydney bölgesinden toplanan gerçek dünya veri seti üzerindeki deneysel sonuçlar, dört toplu taşıma modunda (otobüs, tren, hafif raylı sistem ve feribot) önerilen yaklaşımın sürekli olarak bir dizi temel yöntemden ve son teknoloji modellerden daha iyi performans gösterdiği sonucunu ortaya koymuştur. Ayrıca, çalışma bulguları multimodal seyahat kayıtlarından gelen bilgiyi birleştirmenin, istasyon seyrek modları için talep tahmini doğruluğunu artırabileceğini göstermektedir.

Bai ve ark. (2021), çok adımlı yolcu talep tahmini için derin boyutlu-zamansal dizi modelleme adlı çalışmalarında; yolcu talep tahmini için uçtan uca derin öğrenme tabanlı bir çerçeve önermektedir. Önerilen model 3 bölümden oluşmaktadır. (1) şehir çapındaki tarihsel araç talebi içindeki mekansal-zamansal korelasyonları çıkarmak için kademeli bir grafik evrişimli tekrarlayan sinir ağı; (2) meteorolojik verileri ve zaman metasını temsil etmek için ayrı ayrı iki çok katmanlı LSTM ağı; (3) yukarıdaki iki parçayı kaynaştırmak ve temsilin kodunu çözmek için bir kodlayıcı-kod çözücü modülü geleceğe yönelik daha uzun bir zaman diliminde tahmin etmek. Önerilen modelin boyutsal-zamansal ilişkileri daha iyi yakalayabildiği ve son teknoloji yöntemlerden daha iyi performans gösterdiği görülmüştür.

Tang ve ark. (2021), bölge düzeyinde boyut-zaman grafiğine dayalı evrişimsel ağda çok topluluklu yolcu talebi adlı çalışmalarında, bölgeler arasındaki mekansal-zamansal korelasyonları keşfederek çok bölgeli düzeyde yolcu talep tahmini yapmışlardır. Önerilen modelde bölgelerdeki zamansal korelasyonu bir vektöre kodlamak için kapılı tekrarlayan birim uygulanmıştır. Öte yandan, uzaysal korelasyonlar bölgeler arasında, grafik evrişim ağı aracılığıyla iki grafiğe kodlanmıştır: coğrafi olarak bitişik grafik ve işlevsel benzerlik grafiği. Ardından, bir tahmin modülü tabanlı Louvain algoritması, çoklu bölgelerin yolcu talebi tahminini gerçekleştirmek için kullanılmıştır. Sayısal sonuçlar, MC_STGCN modelinin hem klasik zaman serisi tahmin yöntemleri hem de derin öğrenme yaklaşımlarından daha iyi performans sergilediğini göstermiştir.

Cheng ve ark. (2021), yolcu akış tahminine seyahat davranışı düzenliliğini dahil etme adlı çalışmalarında, üretici mekanizmayı standart zaman serisi modellerine dönüştürmek ve güçlü seyahat davranışından kaynaklanan düzenliliği bir araya getirerek biniş akışı için yeni bir tahmin çerçevesi önermektedir. Yazarlar, nedensel yapıyı ve uzun menzilli bağımlılıkları yakalayan seyahat davranışına dayalı yolcu akışı verilerinde yeni eşdeğişken olarak önceki iniş yolculuğundan geri dönen akışı incelemektedir. Nedensel ilişkileri özetlemek ve geri dönüş akışını tahmin etmek için geri dönüş olasılık paralelkenarı geliştirmişlerdir. Aynı gün içinde geliş-gidiş yapan iş tipi istasyonlar için bu yöntemin daha etkili olduğunu ortaya koymuşlardır.

Yang ve ark. (2021), kentsel raylı ulaşım gelen yolcu akışı için yeni bir tahmin modeli adlı çalışmalarında, yolcu akışını daha iyi tahmin edebilmek için özgün bir uzun kısa süreli bellek ağı (LSTM) ve dalgacık üzerine kurulu Wave-LSTM modelini ele almışlardır. Bu hibrit yöntemin pratik yolcu akış verileriyle yapılan ampirik bir çalışmada tahmin doğruluğu açısından performansının otoregresif entegre hareketli ortalama (ARIMA), doğrusal olmayan otoregresif sinir ağı (NAR) ve geleneksel LSTM modeli gibi modellerden daha etkili bir performans gösterdiği gözlemlenmiştir.

Luo ve ark. (2021), mekansal-zamansal bağımlılıkları dikkate alan kısa vadeli taksi talebi tahmini için çok görevli bir derin öğrenme modeli adlı çalışmalarında, çok bölgesel düzeyde kısa vadeli taksi talep tahminleri etmek için çok görevli bir derin öğrenme modeli önermektedir. Çeşitli trafik bölgeleri arasındaki nedensellik ilişkilerini araştırmak için doğrusal olmayan Granger nedensellik testi uygulanır; ve çok görevli derin öğrenme modelinin çerçevesini oluşturmak için çekirdek sinir birimi olarak kullanılır.

Yang ve ark. (2021), kentsel raylı sistemler için yolcu hacminin kısa vadeli tahmini: Akıllı kart verilerine dayalı derin öğrenme yaklaşımı adlı çalışmalarında, şehir içi tren istasyonlarında kısa vadeli yolcu hacmini tahmin etmek için derin öğrenme tekniklerine ve büyük verilere dayanan geliştirilmiş bir uzay-zamansal uzun kısa süreli bellek modeli (Sp-LSTM) ele almıştır.

Zuo ve ark. (2021), sinir ağı modeli tabanlı otobüs sisteminde bireysel erişilebilirliğe ilişkin kısa vadeli tahminler adlı çalışmalarında, sinir ağı (NN) modeline dayalı veri yolu sisteminde bireysel erişilebilirlik kısa dönem tahminleri için üç aşamalı bir yöntem önermişlerdir. İlk aşamada, bir NN modeli, yolcuların otobüs yolculuğu görünüşleri arasındaki doğrusal olmayan haritalamanın üstesinden gelmek için tasarlanmıştır. Yolcuların otobüs yolculuğu oluşturma oranlarını dikkate alan bir oran fonksiyonu, daha sonra tasarlanan NN modelinin çıktılarını kullanarak uygulanmıştır. İkinci aşamada, varış noktalarının orijin olasılıkları (OD'ler) tahmin edilen süre içerisinde yolcular tarafından seçilmiştir. Üçüncü aşamada arazi kullanım bilgileri otobüste bireysel erişilebilirliği elde etmek için önceki iki aşamanın sonuçlarıyla birlikte kullanılmıştır. Gerçek verilerle hesaplanan bireysel erişilebilirlik karşılaştırıldığında, önerilen yöntemle hafta içi ve hafta sonu tahmin edilen sonuçların ortalama hataları sırasıyla sadece %8.37 ve %10.13 olarak bulunmuştur.

Rajendran ve ark. (2021), makine öğrenme algoritmaları kullanarak hava taksi kentsel havacılık hizmetlerine yönelik talep tahmini adlı çalışmalarında, farklı zamanlarda hava taksi kentsel hava hareketliliği hizmetlerine olan talebi tahmin etmeye odaklanmaktadır. Makine öğrenme algoritmalarını kullanarak New York şehrinin çeşitli coğrafi bölgelerinde günün belirli saatlerinde talep tahmini yapmışlardır. Sürüşle ilgili çeşitli faktörler (yılın ayı, haftanın günü ve günün saati gibi) ve havayla ilgili değişkenler (sıcaklık, hava koşulları ve görünürlük gibi) dört popüler makine öğrenme algoritması; lojistik regresyon, yapay sinir ağı, rastgele ormanlar ve gradyan arttırma, tahmin edici olarak kullanılmıştır.

Tang ve ark. (2021), otobüs yolcularının gidiş geliş davranışını tahmin etmek için çok aşamalı derin öğrenme yaklaşımları adlı çalışmalarında, akıllı kart verilerini kullanarak yolcuların biniş duraklarını tahmin etmek için çok aşamalı bir makine öğrenme çerçevesi sunmaktadır.

Moonlight ve Prabowo (2021), Juanda Uluslararası Havalimanı'nda yapay zeka yöntemi-geri yayılım sinir ağı kullanılarak yolcu, uçak, bagaj ve kargo için tahmin sistemi adlı çalışmalarında uçak, yolcu, bagaj ve kargo için bir tahmin sistemi

tasarlanmış ve inşa edilmiştir. Bu araştırmanın, Juanda Havalimanı'ndaki altyapı ve hizmetlerin ve tüm tesislerin hazır olma durumunu artırmada dikkate alınması beklenmektedir. Ayrıca bu sistemin de yönetim için karar destek sistemlerinden biri olması beklenmektedir. Bu sistem yapay zeka yöntemlerinden biri olan geri yayılım yapay sinir ağı kullanmaktadır. Önceki araştırmalarda, geri yayılımın, örüntü tanıma veya tahminde en iyi performansa sahip bir yapay sinir ağları yöntemi olduğu bilinmektedir. Tahmin sisteminin eğitim süreci ve tahmin süreci olmak üzere iki ana süreci vardır.

Huang ve ark. (2021), mevsimsel ve doğrusal olmayan lssvm'ye göre tüm hava durumu kısa süreli metro yolcu akışını tahmin etmesi adlı çalışmalarında, yolcu akışının periyodiklik ve doğrusal olmayan özelliklerini çıkarmak için mevsimsel ve doğrusal olmayan en küçük kareler destek vektör makinesi adı verilen paralel bir mimari önermektedir. Önerilen mimarinin performansını değerlendirmek için otomatik gerilemeli entegre hareketli ortalama, uzun kısa süreli bellek ağı ve destek vektör makinesi dahil olmak üzere çeşitli tahmin modelleri kullanılmıştır. Ayrıca yöntem ilk olarak Guangzhou metrosunun en kalabalık istasyonu olan Tiyu Xilu istasyonuna uygulanmıştır. Sonuçlar, önerilen modelin tüm hava ve yıl boyunca yolcu akışı tahminlerini etkin bir şekilde yapabildiğini ve böylece istasyonun yönetimine katkıda bulunduğunu göstermektedir.

Xie ve ark. (2021), iki faktörlü metro ani yolcu akışı tahmin yöntemi faktörler: Pekin'deki Dongsishitiao İstasyonu çalışması adlı çalışmalarında, tahmin doğruluğunu artırmak için giden ve gelen yolcu akışları olmak üzere iki faktörlü ani yolcu akışı tahmin modeli önermişlerdir. Ani yolcu akışını tespit etmek için modelini kullanmış ve daha sonra iki faktörlü veri özelliklerine göre genetik algoritma (GA) ile optimize etmişlerdir.

Zheng ve ark. (2021), kentsel metrolarda anormal büyüklükteki yolcu akışı tahmini için hibrit model adlı çalışmalarında, yolcuların kolektif davranışını yakalamada karmaşık ağ modellerinin avantajını ve gerçek zamanlı verilerdeki hızlı değişiklikleri karakterize etmede çevrimiçi öğrenme algoritmalarının avantajı birleştiren bir çerçeve

önermişlerdir. Önerilen yöntem, anormal koşullar altında yolcu akışı tahmininin doğruluğunu önemli ölçüde artırır. Bu çalışma aynı zamanda ulaşım araştırmaları için disiplinler arası yöntemlerin keşfi olarak hizmet eder.

Han ve ark. (2021), şehir çapında mekansal-zamansal metro yolcu akışı tahmini için bir hibrit GLM modeli adlı çalışmalarında, grafik dikkat ağlarını ve uzun kısa-süreli bellek (LSTM) ağları birleştiren hibrit GLM isimli yeni bir derin öğrenme mimarisi önermişlerdir. Önerilen model, grafik dikkat katmanları aracılığıyla uzamsal bağımlılığı yakalamaktadır ve LSTM katmanları aracılığıyla zamansal bağımlılığı öğrenmektedir. Sonuçlar, bazı tipik veriye dayalı modellerden gelen tahminlerle karşılaştırılmıştır. Hibrit GLM modelin üstünlüğünü sergileyen farklı zaman aralıklarında en küçük ortalama karekök hatasını (RMSE) ve ortalama mutlak yüzde hatasını (MAPE) almaktadır. Özellikle, 10 dakikada, hibrit GLM, RMSE açısından yaklaşık %6-30 ekstra iyileştirme sağlamaktadır.

Wang ve ark. (2021), dinamik hipergraf evrişim ağları ile metro yolcu akış tahmini adlı çalışmalarında, yolcu akış tahmini için dinamik bir uzay-zaman hipergrafı önermişlerdir. Metro sistem topolojisinden ve daha sonra gelişmiş çoklu zaman aralıkları yaya seyahat modellerinden keşfedilen hiper kenarlardan birincil hipergraf oluşturulmaktadır. Ayrıca, hipergraf evrişim ve uzay-zamansal bloklar düğüm düzeyinde tahmin elde etmek, uzamsal ve zamansal özellikleri ayıklamak için önerilmiştir.

Bao-yu ve ark. (2021), derin sinir ağına dayalı kentsel raylı ulaşım sistemi kısa süreli yolcu akışının tahmini adlı çalışmalarında, mevcut kısa vadeli trafik akışını hedefleyen tahmin modellerine derin sinir ağı tahmin modeli önermektedir. Bu model konvolüsyonel sinir ağı ve uzun-kısa süreli bellek sinir ağı, zamanın özelliklerini daha iyi araştırmak için kısa vadeli trafik yolcu akışı verilerinin kombinasyonundan oluşmaktadır. Sonuçlar, zaman tanecikliğinin artmasıyla tahmin modellerinin kesinliğinin arttığını göstermektedir. Mevcut tek model ile CNN-LSTM hibrit modeli karşılaştırıldığında önerilen bu hibrit modelin daha doğru tahmin performansı

sergilediği görülmüş; model hata ölçüleri önemli ölçüde azaltılmış ve uyum iyiliğinin artırılmış olduğu gözlenmiştir.

Li ve ark. (2021), kentsel çok kaynaklı verilere dayalı demiryolu taşımacılığı için kısa vadeli yolcu akış tahmini adlı çalışmalarında, trafik akış tahmin modeli oluşturmak için mevsimsel otoregresif entegre hareketli ortalama modeli (SARIMA) ve destek vektör makineleri (SVM) kullanmışlardır. Model, doğru yolcu gibi büyük ölçekli bir kentsel trafik akışı uyarı sistemi tarafından sağlanan akıllı veriler kullanılarak oluşturulmuştur. Önerilen model, şehir içi raylı ulaşımında yolcu akışının karmaşıklık, doğrusal olmama ve periyodikliğine uyum sağlayabilmektedir.

Li ve ark. (2021), metroya gelen yolcu akışının kısa süreli yolcu akış tahmini ve derin öğrenme adlı çalışmalarında, uygun yapay zeka modeline göre kısa vadeli metro yolcu akış modeli oluşturmakta; kısa vadeli metro yolcu akış tahminini etkileyen korelasyon özelliklerini incelemekte ve mevcut sonuçlarla birleştirmektedir. Ayrıca, veri analizi yoluyla ilgili beş tahmin değişkeni seçmekte ve çok sayıda kaydırmalı kart verisini işlemek için kopula korelasyon katsayısını kullanmakta ve Granger nedensellik korelasyon analizini kullanmaktadır.

2.2. Çok Kriterli Karar Verme

Mojaver ve ark. (2022), AHP/TOPSIS çok kriterli karar verme analizinin birleştirilmesine dayalı plastik atıkların ve geleneksel biyokütlenin havayla gazlaştırılması üzerine karşılaştırmalı çalışma adlı çalışmalarında, biyokütle ve plastik atık gazlaştırma performanslarının karşılaştırılmasını bu çalışmanın ana konusu olarak ele almıştır. Bu çalışmanın önemli yeniliği ve katkısı, geleneksel biyokütle ve plastik atıkların gazlaştırılmasında kullanılan ideal çözüm bağlantılı yöntemle benzer şekilde sipariş performansı için analitik hiyerarşi süreci/tekniki, dikkate alınan kriterlerin önceliklendirilmesi ve gazlaştırma için en iyi hammaddenin seçilmesidir. Çalışmada, alternatif olarak altı tür geleneksel biyokütle ve dört tür plastik atık içeren on tür besleme stoğu seçilmiştir. Çok kriterli karar analizi birleştirilmiş yöntemi, atık polipropilen ve polietilenin en iyi alternatifler olduğunu ortaya çıkarmıştır.

Tahri ve ark. (2022), geniş bir kullanıcı yelpazesi için yeni bulanık-AHP MATLAB tabanlı grafik kullanıcı arayüzü (GUI): çevresel alanında örnek uygulamalar adlı çalışmalarında, MATLAB yazılımında bulanık-AHP algoritmasını ve programını oluşturup, MATLAB tabanlı grafik kullanıcı arayüzü (GUI) uygulaması ile dönüştürmüştür. Bu, karar vericilerin Excel'den aktarılan uzman yargılarına ve bir dizi kriterle dayalı olarak seçimleri ve/veya kriter hedeflerini önceliklendirmesine yardımcı olmak için geniş bir uygulama yelpazesine sahip yeni bir masaüstü aracıdır. Yeni teknik, uzmanların ölçüt seçiminin önemine bağlı olarak her iki taraftan da matris yargısını doldurmasına izin verecek şekilde tasarlanmıştır. Uygulama, orman rekreasyonu ve tarımsal ormancılık vaka çalışmalarında test edilmiş ve uygulanmıştır.

Abdul ve ark. (2022), AHP-VIKOR entegre metodolojisi ile elektrik üretimi için yenilenebilir enerji kaynağına öncelik verilmesi adlı çalışmalarında, çevre sorunlarına ve insan enerji ihtiyaçlarının karşılanmasına verimli bir çözüm sunmayı amaçlamıştır. Bu nedenle, sosyal, ekonomik, enerji kalitesi, politik, teknik, çevresel olmak üzere altı ana kriter ve on altı alt kriter kullanılmış ve gelişmekte olan ülkelerde elektrik üretimi için en uygun yenilenebilir enerji kaynaklarının önceliklendirilmesi için bir değerlendirme modeli geliştirilmiştir. Ayrıca, kapsamlı bir değerlendirme için analitik hiyerarşi süreci ve VIKOR ile entegre yöntem elde edilmiştir. Sonuçlar, ekonomik kriterin (0,353) ağırlıkla ikinci sırada yer alan teknik kriterle göre (0,244) en yüksek ağırlığa sahip olduğunu, bunu sırasıyla çevresel (0,205) ve ağırlıkla enerji kalitesinin (0,098) izlediğini göstermektedir. Politik ve sosyal kriterler (0.057) ve (0.043) ile en düşük ağırlıklara sahiptir. İncelemeden, yenilenebilir kaynakların sürdürülebilir bir elektrik sistemi geliştirmek için yeterli potansiyele sahip olduğunu göstermektedir. Benzer şekilde, model bu kaynaklara öncelik vererek hidroelektrik en iyi yenilenebilir enerji kaynağı seçeneği olduğunu ve bunu rüzgar enerjisinin izlediğini ortaya koymaktadır. Biyokütle enerjisi ve güneş enerjisi üçüncü ve dördüncü sırada yer almıştır.

Awad ve Jung (2022), AHP (analitik hiyerarşi süreci) ile Dubai'de sürdürülebilir kentsel dönüşüm için planlama öğelerinin çıkarılması adlı çalışmalarında, Dubai'de sürdürülebilir kentsel dönüşüm için planlama unsurlarını araştırmak ve türetilen

unsurların ağırlıklarını değerlendirmeyi amaçlamıştır. Metodoloji olarak AHP (Analitik Hiyerarşi Süreci) ile uzman beyin fırtınası yapılarak nihai planlama unsurları belirlenir, uzman anketi yapılır ve sürdürülebilir kentsel dönüşüm planlama unsurlarının önemi analiz edilir. AHP sonuçları, Kentsel Çevre Sektörünün (Ağırlık: 0.254, Sıra: 1) üst planlama unsurlarında en önemli faktör olduğunu bunun yanı sıra Ekonominin ikinci önemli faktör (Ağırlık: 0.235, Sıra: 2) ve Sosyal/Kültürel Sektörlerin (Ağırlık: 0.194, Sıra: 3) ise üçüncü önemli faktör olduğunu göstermektedir. Alt planlama unsurları ile ilgili olarak, Kentsel Çevre Sektöründe Yeşil ve Su Dostu Mekanların (Ağırlık: 0.252, Sıra: 1), Ulaşım Sektöründe Toplu Taşıma Odaklı Sistemin (Ağırlık: 0.254, Sıra: 1) birinci öncelik olduğu görülmektedir. Tarihi ve Kültürel Kaynakların Restorasyonu (Ağırlık: 0,233, Sıra: 1) Sosyal/Kültürel Sektörde, Düşük Gelirli Ailelere Yönelik Politikalar (Ağırlık: 0,257, Sıra: 1) Ekonomik Sektörde ve Enerji Verimliliği Odaklı Sürdürülebilirlik Sektöründe Tasarım (Ağırlık: 0.300, Sıra: 1) birinci öncelik olmuştur.

Andreolli ve ark. (2022), yerçekimi tasarımı endüstriyel binalarda sismik güçlendirme çözümlerinin çok kriterli önceliklendirilmesi için bir AHP modeli adlı çalışmalarında, endüstriyel binaların sismik güçlendirmesi ile uğraşırken karar verme süreçlerini yönlendirmeyi amaçlayan bir Analitik Hiyerarşi Süreci (AHP) modelinin geliştirilmesini ele almaktadır. Özellikle model, yalnızca sismik analiz ve mühendislik değerlendirmelerinin çıktılarını değil, aynı zamanda uygun ağırlıklandırma işlemleri yoluyla üretim kesintisi gibi sosyo-ekonomik yönleri de dikkate almaktadır. Modeli doğrulamak için, basit ve geometrik olarak düzenli bir yapısal şema ile tek katlı bina için üç alternatif güçlendirme çözümünün analizi kullanılmıştır.

Fares ve Lloret (2022), COVID-19 salgını sonrasında olgunluk yönetimi için entegre bir SWOT-AHP-bulanık TOPSİS yaklaşımı: hızlı modadan alınan dersler adlı çalışmalarında, yazarlar, ana faktörleri belirlemek için güçlü yönler, zayıf yönler, fırsatlar ve tehditler analizi yapmıştır. Bu analiz, iç ve dış faktörleri sıralamak için analitik hiyerarşi süreci ile entegre edilmiştir. Daha sonra yazarlar, uyarlanabilirlik ve esnekliğe dayalı SWOT analizinden önemli stratejileri değerlendirmek için ideal çözüme benzerliğe göre tercih sırası için bulanık tekniği kullanmışlardır. Böylece,

yazarlar, pratik ortamlarda faydalı olan ilgili faktörlerin ve kılavuzların öncelikli bir listesini üretmiştir.

Singh ve Mukherjee (2022), proje paydaşlarının önceliklendirilmesi: AHP temelli yaklaşım adlı çalışmalarında, paydaşların önceliklendirilmesi için analitik hiyerarşik süreç (AHP) tabanlı bir model önermiştir. Bu model, kritik paydaş niteliklerine dayanmakta ve proje yönetim ekibinin ortak bilgisini ve bilgeliğini kullanmaktadır. Paydaşların kritik nitelikleri belirlenmekte ve paydaş öncelik sırasına ulaşmak için AHP kullanılmaktadır. Bu öncelikli bilgilerin proje yönetim süreçlerini nasıl iyileştirebileceği ve bunun proje ekiplerinin paydaşlara tutarlı bir şekilde yanıt vermesini nasıl sağlayabileceği de araştırılmıştır.

Asra ve Arpi (2022), çalışmalarında, analitik hiyerarşi sürecini (AHP) kullanarak dondurulmuş orkinos endüstri için alternatif yer tespiti adlı çalışmalarında, Banda Aceh şehrinde yapılacak donmuş orkinos endüstrisi için alternatif bir yer belirlemeyi amaçlamıştır. Bu çalışmada Analitik Hiyerarşi Süreci (AHP) yöntemi kullanılmıştır. Kullanılan kriterler Ton Balığı Üretimi, İnsan Kaynakları, Ulaşım Erişimi, Kurumsal Destek ve Altyapı Varlığıdır. Belirlenecek alternatif yer Kuta Alam Bucağı, Kuta Raja Bucağı, Meuraxa Bucağı ve Syiah Kuala Bucağıdır. AHP yöntemi kullanılarak yapılan hesaplama sonucu, donmuş orkinos endüstrisinin kurulması için en uygun yerin 0,428 ağırlıkla Kuta Alam Bucakları olduğunu, bu nedenle ilçenin donmuş orkinos tesisi için en iyi yer olarak seçildiğini göstermektedir.

Dashtian ve ark. (2022), uzaktan algılama teknolojisi ve AHP süreci kullanılarak belediye katı atık bertaraf alanı seçimi (örnek çalışma: Khesht şehri, Fars Eyaleti, İran) adlı çalışmalarında, çevresel, ekonomik ve mühendislik kriterlerini takip eden coğrafi bilgi sistemi (GIS) ve analitik hiyerarşi süreci (AHP) modelini kullanarak belediye katı atıkları için en uygun depolama sahasının seçilmesini amaçlamıştır. Bu nedenle, literatür gözden geçirilerek, düzenli depolama sahasının bulunması için gerekli parametreler çıkarılmış ve en önemlileri (15 alt kriter) seçilmiş ve dört gruba ayrılmıştır. Sonuçlar, 0,218 ağırlığı ile nehre olan mesafe alt kriterinin en kritik parametre olarak belirlendiğini ve bunu yeraltı suyu derinliğinin takip ettiğini

göstermiştir. Bu şekilde 0.010 ağırlıklı sel parametresi en az önemli değişken olarak kabul edilmiştir. Ayrıca, %50 alan ile orta uygunluk sınıfının en yüksek alana sahip olduğu, %0,8 ile çok yüksek uygunluk sınıfının ise en düşük alana sahip olduğu bulunmuştur. Tutarsızlık oranı, matrislerin yüksek tutarlılığını gösteren 0.04 olarak hesaplanmıştır.

Mamakou ve Roumeliotou (2022), AHP-TOPSİS kullanarak e-mağazaların elektronik hizmet kalitesinin değerlendirilmesi: COVID-19 karantinası sırasında Yunan Kahve zincirleri örneği adlı çalışmalarında, en iyi Yunan kahve zincirlerinin e-mağazalarını elektronik hizmet kalitesine göre değerlendirmek ve sıralamaktır. Veriler, ilk COVID-19 karantinası sırasında uzmanlardan toplanmıştır. Yazarlar, E-S-QUAL modeline dayalı olarak, analitik hiyerarşi sürecini (AHP) ve İdeal Çözüme Benzerlik Bakımından Sıralama Performansı Tekniği (TOPSİS) kullanan 12 adımlı çok kriterli karar verme metodolojisini uygulamışlardır. Sonuçlar, sistem kullanılabilirliği ve yerine getirilmesinin modelin en önemli iki boyutu olduğunu göstermektedir. Kredi kartı bilgilerinin korunması, sipariş sürecinde donmayan web sayfaları, sipariş edilen ürünlerin teslimatı, e-mağaza tarafından sunulan ürün ve hizmetlerin doğruluğu en önemli alt boyutlar olarak kabul edilmektedir.

Wahyuni ve ark. (2022), mesleki öğretmen yeterlik standardı için AHP tabanlı değerlendirme yöntemi adlı çalışmalarında, endüstri dünyasının ihtiyaçlarına göre uyarlanmış öğretimdeki yeterliliği yeterince açıklamak için mesleki liselerdeki öğretmenlerin yeterlilik standartlarını yeniden değerlendirmeyi amaçlamıştır. Bu araştırma, Analitik Hiyerarşi Süreci (AHP) üzerine kurulmuş bir değerlendirme yapısını, meslek lisesi öğretmenleri için bu tür yeterlilik standartlarını sürekli olarak değerlendirmeyi amaçlamaktadır. Değerlendirme modeli dört kritik kriter gerektirir: 1) pedagojik yetkinlik, 2) profesyonel yetkinlik, 3) mesleki yeterlilik ve 4) teknolojik yeterlilik. Bu kriterler ayrıca öğretmen yeterlilik standartlarının etkililiğini ölçmek için 21 alt kriterde toplanır. Bulgular, pedagojik yeterliklerin bu araştırmada en önemli olduğunu göstermektedir.

Vásquez ve ark. (2022), hisse senedi portföy yatırımları için AHP-TOPSIS metodolojisi adlı çalışmalarında, AHP-TOPSIS çok kriterli tekniği kullanarak borsada karar vermek için bir metodoloji sunmaktadır. Önerilen metodoloji, öz sermaye portföylerine yatırımın ekonomik ve finansal teorilerini AHP-TOPSIS çok kriterli teknikle bütünleştirmeyi içermekte; bu, sınırlı sayıda alternatifin niteliksel ve niceliksel kriterler altında hiyerarşik olarak değerlendirilmesine izin vermektedir. Hesaplama sonuçları, Kolombiya hisse senedi piyasasındaki hisse senetlerinde yatırım kararı verme sürecinde karlılık ve risk arasında uygun bir denge bulmak için geleneksel hisse senedi portföyü yatırım kriterlerini ve çok kriterli metodolojileri başarılı bir şekilde entegre etmenin önemini ve verimliliğini göstermektedir.

Lolli ve ark. (2022), iç mekan çevre kalitesi: kriter ağırlıklarının dolaylı olarak ortaya çıkarılmasıyla TOPSIS tabanlı bir yaklaşım adlı çalışmalarında, lojistik regresyona ve tamsayı optimizasyonuna dayalı dolaylı olarak ortaya çıkan bir yaklaşım geliştirmişlerdir. Literatürde iç mekan çevre kalitesi değerlendirmesinde yer alan ana risklere, yani termal konfor, görsel konfor, akustik konfor ve iç hava kalitesine atıfta bulunanlara ağırlık vermek için yalnızca doğrudan ortaya çıkarma kullanılmaktadır. Farklı referans senaryolarında algıladığı genel rahatlığı temel alan bu işçi başına ağırlıkları (yani bireysel ağırlıkları) dolaylı olarak elde etmişlerdir. Bu ağırlıklar daha sonra çalışanın zaman içinde maruz kaldığı toplu, bireysel ve dinamik riskleri haritalayan TOPSIS tabanlı bir risk ölçüsünü hesaplamak için kullanılır. Elde edilen sonuçlar, işçiler tarafından algılanan genel konforu yeniden yapılandırmada Analitik Hiyerarşik Süreç ile karşılaştırıldığında yazarların dolaylı ortaya çıkarma yaklaşımının üstünlüğünü ve ayrıca iç mekan çevre kalitesinde yer alan ana risklere ağırlık verilmesinde yaşın çok önemli bir rol oynadığını vurgulamaktadır.

Forouzandeh ve ark. (2022), evrimsel algoritma ve TOPSIS modeli ile turizme dayalı öneri sistemleri için hibrit bir yöntem adlı çalışmalarında, yapay arı kolonisi algoritması ve bulanık TOPSIS'in bir kombinasyonu ile turizm endüstrisinde yeni bir öneri sistemleri yaklaşımı önermiştir. Sistemi optimize etmek amacıyla İdeal Çözüm Benzerliğe Göre Tercih Sıralaması Teknikleri (TOPSIS) adı verilen çok kriterli bir karar verme yöntemi uygulanmıştır. İlk aşamada, TOPSIS modeli, bu çalışmada yer

alan faktörleri gösteren dört sütunlu bir matris şeklinde pozitif bir ideal çözüm tanımlamaktadır. İkinci aşamada, yapay arı kolonisi algoritması destinasyonlar arasında aramaya başlamakta ve kullanıcılara en iyi turistik yeri önermektedir.

Galik ve ark. (2022), TOPSİS yöntemiyle işgücü piyasası esnekliğinin değerlendirilmesi: sürdürülebilir endüstri ilişkileri adlı çalışmalarında, İdeal Çözüme Benzerliğe Göre Tercih Sıralaması Tekniği'ni (TOPSİS) kullanarak işgücü piyasası esnekliğini değerlendirmektedir. TOPSİS, uzamsal (yani farklı ülkeler) ve zamansal (yani uzun süreli ufuk) terimlerini karşılaştırarak kullanılır. Sürdürülebilir endüstriyel ilişkiler süreçleri, 2009'dan 2018'e kadar 15 Avrupa Birliği Üye Devletinde işgücü piyasasının esnekliğinin şekillendirilmesinde dikkate alınmaktadır. Ülkeler, ulusal düzeyde uygulanan sosyal ve istihdam politikalarına karşı kıyaslama sonuçları için bir temel sağlamak üzere sınıflara ayrılmıştır. Sonuçlar, TOPSİS yönteminin uluslararası işgücü piyasası esnekliğini ölçmek için uygun bir yaklaşım olduğunu göstermektedir.

Shohda ve ark. (2022), madencilik yöntemlerinin seçimi için kademeli ileri geri yayımlı sinir ağlarının uygulanması adlı çalışmalarında, metodolojik olarak genel kriterleri oluşturmak için British Columbia Üniversitesi (UBC) yönteminde dikkate alınan kriterleri referans olarak kullanmıştır. Bu kriterler, kaya kalitesi tanımına (cevher bölgesi, tavan taşı ve taban duvarı) ve kaya maddesi mukavemetine (cevher zonu, tavan taşı ve taban duvarı) ek olarak genel şekil, cevher kalınlığı, cevher dalması ve tenör dağılımından oluşur. İdeal çözüme benzerliğe göre tercih sırası (TOPSİS) tekniği benimsenmiş ve deneysel testlere dayalı olarak geliştirilmiş bir TOPSİS yöntemi geliştirilmiş ve madencilik yöntemi seçiminde kademeli ileri geri yayılım sinir ağlarının uygulanması yoluyla kontrol edilmiştir. Sonuçlar, tüm cevher özelliklerine verilen toplam puanlara dayalı olarak, karar vericilerin farklı madencilik yöntemleri arasında seçim yapmak için kullanabilecekleri göstergeler sağlamaktadır. En iyi madencilik yöntemi 0.70 sıra ile kesme ve doldurma durdurma, ikincisi ise 0.67 sıra ile üst dilimlemedir.

Dehnavi ve ark. (2015), İran'da bölgesel heyelan tehlike değerlendirmesi için adım adım ağırlık değerlendirme oranı analizi (SWARA) tekniği ve uyarlanabilir nöro-

bulanık çıkarım sistemi (ANFIS) kullanan yeni bir hibrit model adlı çalışmalarında, coğrafi bilgi sistemi kullanarak heyelana duyarlı alanları değerlendirmek için adım-ağırlık değerlendirme oranı analizi (SWARA) yöntemine ve uyarlanabilir nöro-bulanık çıkarım sistemine (ANFIS) dayalı yeni bir hibrit model önermektedir. İlk olarak, bir envanter haritasına dayalı olarak, heyelan lokasyonları rasgele iki kısma ayrılmış ve bunların %70'i heyelan tehlike haritasının oluşturulmasında ve %30'u modelin doğrulanması için kullanılmıştır. Daha sonra, litoloji, şev açısı, şev yönü, plan eğriliği, profil eğriliği, rakım, akarsulara uzaklık, faylara uzaklık, yollara uzaklık, arazi kullanımı, sismisite ve yağış gibi on iki heyelan hazırlayıcı faktör analiz için dikkate alınmıştır. Daha sonra tüm faktörler SWARA yöntemi ile ağırlıklandırılmıştır. Predispozan faktörlerin doğası göz önünde bulundurularak, kesikli veriye sahip faktörler ve sürekli veriye sahip faktörler olmak üzere iki gruba ayrıldılar. Kesik verili faktörler için her sınıfın nihai ağırlığı için SWARA yöntemi, sürekli veri içeren faktörler için ise SWARA yönteminden her sınıfın merkezine ilişkin sonuçlar elde edilmiştir. Daha sonra, her bir değer ağırlığını elde etmek için ANFIS kullanılmıştır. Modelden elde edilen tüm değerler daha sonra çalışma alanının heyelan tehlike haritasının oluşturulmasında kullanılmıştır. Son olarak, heyelan tehlike haritası, hem başarı oranı eğrisi hem de tahmin oranı eğrisi kullanılarak alıcı işletim özellikleri ile doğrulanmıştır. Gözlenen heyelanların %70'i birincisi için, kalanı ise ikincisi için kullanılmıştır. Doğrulama sonuçları, başarı oranı eğrisi ve tahmin oranı eğrisi altındaki alanın sırasıyla 0.84 ve 0.80 olduğunu göstermiştir. Ayrıca, heyelan tehlike haritalaması için SWARA yönteminin tahmin performansı araştırılmış ve sonuçlar önerilen modelden elde edilen sonuçlarla karşılaştırılmıştır. Karşılaştırma, geliştirilen modelin heyelan tehlike değerlendirmesi için daha iyi tahmin kabiliyetine sahip olduğunu ortaya koymuştur. Sonuçlar ayrıca, bu çalışmada kullanılan önerilen modelin, İran'da ön arazi kullanımı ve altyapı planlaması için kullanılabilecek tatmin edici ve güvenilir heyelan tehlike haritası ürettiğini göstermiştir.

Ghenai ve ark. (2020), çok kriterli karar verme modeli ve genişletilmiş SWARA/ARAS hibrit yöntemi kullanan yenilenebilir enerji sistemleri için sürdürülebilirlik göstergeleri adlı çalışmalarında, yenilenebilir enerji sistemleri (güneş PV, rüzgar, fosforik asit yakıt hücresi ve katı oksit yakıt hücresi) için sürdürülebilirlik

göstergelerinin değerlendirilmesine ilişkin yeni sonuçlar sunmaktadır. Bu çalışmada çok kriterli karar verme modeli ve hibrit adım adım ağırlık değerlendirme oran analizi/Katkı maddesi oranı değerlendirmesi (SWARA/ARAS) yöntemi kullanılmıştır. Beş sürdürülebilirlik kriteri (kaynak, çevresel, ekonomik, sosyal ve teknoloji) ve on dört alt kategori (alan, malzeme, enerji inşaatı, enerji-yakıt, CO2-inşaatı, CO2-yakıt, sermaye-inşası, sermaye-yakıt, teslim edilen enerji maliyeti, mevcut kurulu kapasite, büyüme oranı, kapasite faktörü, sistem verimliliği ve kullanım ömrü) bu analize dahil edilmiştir. Sürdürülebilirlik göstergelerinin hesaplanması için bu çalışmada üç enerji uzmanına ek olarak genişletilmiş SWARA ve ARAS hibrit yöntemi kullanılmıştır. SWARA-ARAS hibrit yöntemini kullanan dört yenilenebilir enerji teknolojisini beş sürdürülebilirlik kriteri ve on dört alt kategoriye göre sıralamanın nihai sonucu şudur: (1) rüzgar enerjisi sistemleri (karaya dayalı), (2) katı oksit yakıt hücresi , (3) fosforik asit yakıt hücresi ve (4) güneş enerjisi sistemleri (poli-silikon). Hibrit SWARA/ARAS yöntemiyle entegre edilen ÇKKV modelinin, yenilenebilir enerji sistemlerinin sürdürülebilirlik değerlendirmesi, sürdürülebilir enerji gelişimi için yararlı bir metodoloji olduğu bulunmuştur.

Yücenur ve Ipekçi (2021)'nin, bir deniz akıntısı enerji santrali yer seçimi problemi için SWARA/WASPAS yöntemleri adlı çalışmaları, Türkiye'de kurulması planlanan ilk deniz akıntılı enerji üretim tesisi için bir yer seçimi problemi ile ilgilidir. Konum problemini çözmek için 4 ana kriter, 12 kriter ve 3 alternatifli çok kriterli bir karar modeli önerilmiştir. Önerilen modeldeki kriterler SWARA yöntemi ile ağırlıklandırılmış ve modelde buna göre belirlenen alternatifler WASPAS yöntemi ile sıralanmıştır.

Urosevic ve ark. (2017), turizm sektöründe personel seçimine SWARA ve WASPAS yöntemlerine dayalı yaklaşım adlı çalışmalarında, SWARA ve WASPAS yöntemlerinin kullanımına dayalı olarak turizm sektöründe satış müdürü pozisyonu için personel seçimine bir yaklaşım önermektedir.

Karabašević ve ark. (2016), SWARA ve WASPAS yöntemlerine dayalı personel seçimi yaklaşımı adlı çalışmalarında, SWARA ve WASPAS yönteminin kullanımına dayalı personel seçimi sorununa bir yaklaşım önermektedir.

Karabasevic ve ark. (2015a), SWARA ve MULTIMOORA yöntemlerinin uygulanmasına dayalı olarak madencilik endüstrisinde adayların seçimi adlı çalışmalarında, madencilik endüstrisinde adayların işe alınması ve seçilmesi sürecine etkin bir yaklaşım sağlamayı amaçlamaktadır. Önerilen yaklaşım, madencilik endüstrisinde personel seçimi için ÇKKV modellerinin kullanımına dayanmaktadır; yaklaşım, SWARA ve MULTIMOORA yöntemlerine dayalı personel seçimi için bir ÇKKV modeli sağlayacaktır.

Vesković ve ark. (2018), DELPHI-SWARA-MABAC yeni bir entegre model kullanarak demiryolu yönetim modelinin değerlendirilmesi adlı çalışmalarında, Bosna-Hersek topraklarındaki demiryolu yönetim modellerini dikkate almaktadır. Bu modellerin değerlendirilmesi amacıyla DELPHI, SWARA (Adım Adım Ağırlık Değerlendirme Oran Analizi) ve MABAC (Multi-Attributive Border Approximation Area Comparison) yöntemlerinin bir kombinasyonunu içeren yeni bir hibrit model uygulanmıştır. Çalışmanın ilk aşamasında DELPHI Metodu'nda kullanılan 16 uzman notu baz alınarak ölçüt sıralaması belirlenmiştir. Daha sonra toplam 14 karar verici, kriterlerin göreceli ağırlık değerlerini belirlemek için kullanılan SWARA yönteminin uygulanması için bir ön koşul olan karşılıklı kriter etkisini belirlemiştir. Üçüncü aşama, en uygun varyantın değerlendirilmesi ve belirlenmesi için MABAC Metodu'nun uygulanmasını içermektedir. Ayrıca ARAS, WASPAS, SAW ve EDAS yöntemlerinin uygulanmasını içeren bir duyarlılık analizi yapılarak daha önce elde edilen varyant sıralaması doğrulanmıştır.

Karabasevic ve ark. (2017), DELPHI ve uyarlanmış SWARA metodlarının entegre edilerek kriter ağırlıklarının belirlenmesi yaklaşımı adlı çalışmalarında, satış yöneticilerinin değerlendirme kriterlerini oluşturmanın yanı sıra bu kriterlerin ağırlıklarını tanımlamayı amaçlamaktadır. Anket örnekleme, personel alımı ve seçimi alanında 79 alan uzmanıdır. DELPHI tekniği ile uyarlanan SWARA yöntemlerinin

entegrasyonuna dayanan önerilen yaklaşım, kriterlerin ağırlıklarının belirlenmesi amacıyla başarıyla uygulanmış ve kriterlerin tanımlanması ve kriterlerin ağırlıklarının belirlenmesi açısından gereksinimlere tam olarak cevap vermiştir.

Ahmed ve ark. (2022), adım adım ağırlık değerlendirme oran analizi kullanılarak inşaat şirketlerinin performansının değerlendirilmesi adlı çalışmalarında, Irak inşaat sektörü şirketlerinin performansını, gelecekteki projeleri desteklemek için şirket sorumluluğunu ve performansını değerlendirerek Adım Adım Ağırlık Değerlendirme Oranı Analizi'ne (SWARA) dayalı olarak değerlendirilmesi için belirli kriterleri sunmayı ve tartışmayı amaçlamıştır. Bu çalışmada inşaat şirketlerinin değerlendirme kriterleri incelenmiştir. Kriterler 6 ana gruba ayrılmıştır: (a) organizasyon ve yönetim; (b) zaman; (c) kalite; (d) maliyet; (e) kaynak; (f) güvenlik uygulamaları. Ana kriterler kırk dört alt kritere ayrılmıştır. Bu çalışmada SWARA tekniğine göre, inşaat şirketlerinin performansının değerlendirilmesinde en önemli kriterlerin maliyet olduğunu, bunu sırasıyla zaman, kalite, organizasyon ve yönetim, kaynaklar ve son olarak da güvenlik uygulamalarının (sırasıyla %35,7, %24,2, %, %16.3, %11.2, %7.4, %5.2) izlediğini göstermektedir.

Radović ve Stević (2018), SWARA yöntemiyle taşımada kpr'nın değerlendirilmesi ve seçimi adlı çalışmalarında, ulaşım alanında 20 temel performans göstergesinin seçildiği toplam 62 performans göstergesi gösterilmektedir. Araştırma, 13 farklı nakliye şirketinden 19 karar vericinin katılımıyla Sırbistan ve Bosna-Hersek topraklarında yürütülmektedir. Kriterlerin ve alt kriterlerin ilgili ağırlıklarının belirlenmesi için Adım Adım Ağırlık Değerlendirme Oranı Analizi Yöntemi (SWARA) kullanılmaktadır. Elde edilen sonuçlar, en önemli göstergelerin araç kullanımı, gerçekleştirilen güzergahlar ve turlar, ulaşım maliyetleri gruplarına ait olduğunu göstermektedir.

Karabašević ve ark. (2015b), SWARA ve ARAS Yöntemlerine Dayalı Personel Seçimi için ÇKKV Modeli adlı çalışmalarında, personel alımı ve seçimi sürecinde adayların değerlendirilmesi ve seçimi için SWARA ve ARAS yöntemlerine dayalı ÇKKV modeli oluşturmayı amaçlamaktadır. Bir ÇKKV modeli sağlamanın yanı sıra, bu

alışma, ayrıca sayısal rnekte de kullanılacak olan telekomnikasyon endstrisindeki bir satıř yneticisinin (orta ynetim) pozisyonu iin bir dizi deęerlendirme kriteri saęlayamaktadır.



BÖLÜM 3. MATERYAL VE YÖNTEM

Çalışmanın bu bölümünde, çalışmada kullanılan materyal ve yöntemden bahsedilecektir.

3.1. Materyal


Çalışmanın ilk bölümünde, raylı ulaşım sistemlerinde yolcu talep tahmini yapılmıştır; yolcu talep tahmini yapılırken kullanılan materyaller, Yenikapı – Kirazlı hattındaki geçmiş dönem verileridir. Yolcu talep tahmini için gerekli verileri düzenlemek ve toplamak amacıyla Microsoft Office Excel 2010 sürümü kullanılmıştır. Ayrıca, talep tahmini çalışması hat ve istasyon bazlı olmak üzere iki aşamada yapılmıştır. Hat bazlı talep tahmini yapılırken istatistiksel tekniklerden basit ortalama yöntemi ve regresyon analiz tekniği uygulanmış; regresyon analizi için SPSS Statistics 21.0 programı kullanılmıştır. İstasyon bazlı talep tahmini yapılırken ise, yapay sinir ağı ve makine öğrenme algoritmaları kullanılmıştır. YSA ile gelecek yıllara ait yolcu talep tahmini için MATLAB R2017b sürümü kullanılırken; MÖ algoritmaları ile tahminleme yapılırken Python 2.7.18 programı kullanılmıştır.

Ayrıca, ikinci bir çalışma olarak raylı ulaşım sistemlerinde sefer sıklığı belirlemede kritik başarı faktörlerinin önceliklendirilmesi ele alınmıştır. Bu önceliklendirme yapılırken kullanılan materyaller, geçmiş çalışmalardan ve uzman görüşlerinden elde edilen verilerdir. Bu çalışma için kritik başarı faktörlerinin değerlendirilmesine olanak sağlayan bir anket hazırlanmış; hazırlanan anket raylı ulaşım alanında tecrübeli, proje yönetici yardımcısı pozisyonundaki başuzmanların görüşü ile incelenmiş ve değerlendirilmiştir. Anketten elde edilen veriler, kantitatif karar verme tekniklerinden AHP, SWARA ve TOPSİS yöntemleri ile değerlendirilmiştir. Bu çalışmada; literatür çalışmaları detaylıca incelenmiş olup hem literatürde yer alan performans göstergeleri

ve kriterler, hem de raylı ulaşım alanında tecrübeli başuzmanlarla yapılan değerlendirmeler dikkate alınarak 6 ana kriter ve 6 alternatifin ele alınmasına karar verilmiştir. Verilerin düzenlenmesinde ve toplanmasında Microsoft Office Excel 2010 sürümünden yararlanılmıştır.

Çalışmanın kavramsal modeli Şekil 3.1.'de gösterilmiştir. Bu yapı içerisinde verilerin elde edilişi, işleyiş adımları ve yöntemlerine ilişkin bilgileri bulabilmek mümkündür.





Şekil 3.1. Çalışmanın kavramsal modeli

3.2. Yöntem

Bu bölümde, çalışmada kullanılan yöntemlerden bahsedilecektir. Çalışmanın ilk bölümünde, raylı ulaşım sistemlerinde yolcu talep tahmini yapılmıştır. Bu talep tahmini çalışması, hat ve istasyon bazlı olmak üzere iki aşamada ele alınmıştır. Hat bazlı talep tahmini yapılırken, ana kitlenin çok büyük olması nedeniyle (Karahan, 2011) istatistiksel tekniklerden basit ortalama yöntemi ve regresyon analiz tekniği kullanılmıştır. İstasyon bazlı talep tahmini yapılırken ise, talep tahmin çalışmalarında oldukça başarılı olması nedeniyle yapay sinir ağı ve makine öğrenme algoritmaları (karar ağacı, rassal orman regresyonu, doğrusal regresyon, polinom regresyon, destek vektör regresyonu) kullanılmıştır.

Çalışmanın ikinci bölümünde ise, raylı ulaşım sistemlerinde sefer sıklığı belirlemedeki kritik başarı faktörleri önceliklendirilmiştir. Bu önceliklendirme çalışması; çok kriterli karar verme tekniklerinden AHP, SWARA ve TOPSİS yöntemleri ile yapılmıştır.

3.3. Yapay Sinir Ağları

Yapay zekanın gelişimi kuşkusuz çok büyük bir öneme sahiptir, çünkü yapay zeka büyük verileri daha etkili bir insan ikamesi olarak kullanmaktadır. Yapay zeka, genellikle insanlar tarafından gerçekleştirilen entelektüel görevlere odaklanan bir alandır (Choi ve ark., 2020). Yapay zeka, insan beyninin rutin olarak gerçekleştirdiğine benzer karmaşık, akıllı hesaplamalar yapabilen üretim yazılımına adanmış bilgisayar bilimi alanı olarak kurulmuştur (Agatonovic-Kustrin ve Beresford, 2000).

YSA, gürültülü veya doğrusal olmayan verilerle son derece karmaşık eşlemeler gerçekleştirmek için güçlü bir yaklaşımdır (Ko ve Shang, 2011).


Yapay sinir ağlarının (YSA) tasarımı, beynin merkezi sinir sisteminin gerçek sinir ağlarının yapısını bir dereceye kadar simüle etmekte (Jain ve ark., 1996); böylece YSA'lar deneyime dayalı becerileri tanıyabilmekte, sınıflandırabilmekte, öğrenebilmekte ve kazanabilmektedir (Şekil 3.2.). Dikkat çekici bir şekilde, bir

YSA'nın yapısı sinirbilimden (biyolojik sinir ağı) esinlenmiştir, ancak biyolojik nöronların çalışma sistemini doğrudan kopyalamamaktadır (Saxe ve ark., 2021).

Yapay sinir ağı (YSA) en temel ağ yapısıdır. YSA bir girdi katmanı, bir çıktı katmanı ve birkaç gizli katmandan oluşmakta ve her katman birkaç nöron içermektedir (Zhang, 2020). YSA'daki birbirine bağlı her nöron, veri işleme ve sınıflandırma için büyük ölçekli hesaplamalar yapabilen paralel dağıtılmış bir işlemci görevi görmektedir (Yu ve ark., 2015).

1958 yılında, algılayıcı kavramı ve modeli ilk olarak Frank Rosenblatt tarafından önerilmiştir: girdi katmanı ve çıktı katmanından oluşan bir ağ, YSA'ların temelini oluşturan her bir örneğe dayalı ağırlıkları öğrenebilen ilk makine olmuştur (Rosenblatt, 1958; Goodfellow ve ark., 2016; Wang ve ark., 2022). YSA'nın gelişimindeki bir sonraki önemli kilometre taşı, 1982'de girdi ve çıktı verileri arasındaki doğrusal olmayanlığı ortaya koyan John Hopfield'dir (Hopfield, 1982; Patel ve Patel, 2016). Daha sonra Rumelhart ve ark. (1986), yeniden çalışmış, hata geri yayılım (BP) algoritmasını icat etmiştir (Zhang, 2020). Hopfield ağının ilerlemesi ve geri yayılım algoritması eğitimi çok katmanlı algılayıcının (MLP) başarısı ve yaygınlaşmasıyla birlikte, yapay sinir ağları araştırmaları popülerlik kazanmış ve 1990'ların başında zirveye ulaşmıştır (Wang ve ark., 2022).

Yapay ağların tasarımı insan beyninin yapısından ilham aldığından, biyolojik sinir ağlarının işlevini yapay olanlarla karşılaştırmak/inceleme uygun olacaktır (Ibrić ve ark., 2012).



Şekil 3.2. İnsan beyninin gerçek sinir ağı ve bir YSA (Rosenblatt, 1958; Wang ve ark., 2022).

Beynin merkezi sinir sisteminde, bir nöron dendritler tarafından dış uyaranları almakta ve akson boyunca akson ucuna (sinapslara) işlenmiş sinyalleri iletmekte ve ardından nörotransmitterleri serbest bırakmaktadır. Nörotransmitterler sinaptik boşluktan yayılmakta ve sinaps tipine göre alıcı nöronlara uyarıcı veya engelleyici elektrik sinyalleri yaymaktadır. Bir sinapsın gücü (ağırlık), iletilen sinyaller tarafından düzenlenebilmekte; böylece sinapslar öğrenmeye başlayabilmektedir. Aynı adım YSA'ların çalışmasında da gösterilmiştir. Bir nöron, girdisi olarak diğer nöronların çıktısını almakta ve daha sonra bu girdilerin ağırlıklı bir toplamını gerçekleştirmektedir. Toplam eşik değerinden (θ) büyükse, nöron uyarılmış durumdadır ve “1” çıkışına sahiptir, aksi takdirde “0” çıkışı nöronun inhibisyon durumunda olduğunu göstermektedir (Rosenblatt, 1958; Wang ve ark., 2022).

Yapay sinir ağları (YSA), belirli bir veri koleksiyonundaki kalıpları tanıyan ve bu veriler için model üreten bilgisayar programlarıdır. Beyni iki açıdan taklit eder: (1) bilgi, bir öğrenme süreci (deneme-yanılma) yoluyla ağ tarafından edinilir; ve (2) internöron bağlantı güçleri (yani sinaptik ağırlıklar), bilgiyi depolamak için kullanılır (Agatonovic-Kustrin ve Beresford, 2000; Sun ve ark., 2003).

YSA, şu parametrelerle tanımlanmaktadır: (1) farklı nöron katmanları arasındaki ara bağlantı modeli; (2) ara bağlantıların ağırlıklarının güncellenmesi için öğrenme süreci; ve (3) bir nöron girdisini çıktı aktivasyonuna dönüştüren aktivasyon fonksiyonu.

YSA’larda kullanılan aktivasyon fonksiyonları sigmoidal, parçalı lineer, Gauss, üstel, lojistik sigmoidal vb.’dir (Bishop, 2006; Ibric ve ark., 2012).

Ağın eğitimi aslında “öğrenme sürecidir”. Bu öğrenme süreci aşağıdaki gibi gruplandırılabilir (Ibric ve ark., 2012):

- Denetimli öğrenme: ağ ağırlıkları bilinen veriler kullanılarak ayarlandığında, girdi-çıkı çiftlerine bölünür. Denetimli öğrenme, YSA’lar için en sık kullanılan eğitim yöntemidir;
- Denetimsiz öğrenme: etiketlenmemiş verilerde gizli yapı bulmaya çalışma problemini ifade eder. Öğreniciye verilen örnekler etiketsiz olduğu için olası bir çözümü değerlendirmek için herhangi bir hata veya ödül sinyali yoktur;
- Pekiştirmeli öğrenme: doğru girdi / çıktı çiftlerinin hiçbir zaman sunulmamasıyla standart denetimli öğrenmeden farklıdır.

Bir YSA’nın eğitimi, ağın girdileri ve çıktıları olarak kullanılan parametreler arasında en iyi doğrusal olmayan ilişkiyi elde etmek için aslında ağırlık değerlerinin ayarlanmasıdır. Eğitim sürecinin başlangıcında, nöronlar arasındaki ağırlıklar rastgele değerlere sahiptir. Eğitim aşamasında, giriş/çıkış veri çiftleri ağa sunulur ve ağ, giriş-çıkış ilişkilerini arar. Ağ girdi-çıkı sunumunun bir döngüsüne yineleme (dönem) denir. Ağ eğitimi süreci, bazen çok sayıda yineleme yoluyla girdileri çıktılarına başarıyla dönüştüren optimal ağırlık değerlerinin aranması olarak düşünülebilir. Bu süreç genellikle yakınsama olarak adlandırılır (Sun ve ark., 2003). Ağırlık ayarlama sürecinde (yani ağın eğitimi), bazı ara bağlantılar güçlendirilir ve bazıları zayıflatılır, böylece bir sinir ağı daha doğru bir cevap verir (Agatonovic-Kustrin ve Beresford, 2000). Optimal ağırlık değerleri kümesi bulunduğunda, ağ eğitimi durur ve gerçek (eğitim) çıktı değerleri ile ağ tarafından tahmin edilenler arasındaki kare hatası bu noktada minimumdur. Eğitim sürecinin başlangıcında, veriler iki alt gruba ayrılır: eğitim ve test. Eğitim verileri, optimum ağırlık değerlerini aramak için kullanılırken, test verilerini kullanarak ağ, öngörü yeteneğini dahili olarak kontrol eder. Eğitim ve test alt kümeleri için karesel hataların (SSE) toplamı aşağıdaki eşitlik (Denklem 3.1) kullanılarak hesaplanabilir (Basheer ve Hajmeer, 2000):

$$SSE = \frac{1}{N} \sum_{p=1}^N \sum_{i=1}^M (t_{pi} - o_{pi})^2 \quad (3.1)$$

Burada o_{pi} , p th örneğinden i th çıkış düğümünün ağı tarafından tahmin edilen çıktıdır; t_{pi} , p th örneğinden i th çıkış düğümünün eğitim (gerçek) çıktısıdır; N , eğitim örneklerinin sayısı ve M , çıktı düğümlerinin sayısıdır.

Ağ eğitimi sürecinde, hem eğitim hem de test veri setleri için hata değişiminin ilerlemesi eş zamanlı olarak değerlendirilir. Eğitim veri seti durumunda, artan gizli düğüm sayısı veya eğitim yinelemeleri (dönemler) ile SSE süresiz olarak azalır (Sun ve ark., 2003). Başlangıçta, eğitim seti için SSE, öğrenme nedeniyle hızla azalırken, sonraki daha yavaş düşüşü ezberlemeye veya fazla uydurmaya atfedilir (eğitim döngülerinin veya gizli düğümlerin sayısı çok büyükse). Test veri seti durumunda, SSE başlangıçta azalır, ancak daha sonra ANN modelinin ezberlenmesi ve fazla takılması nedeniyle artar (Sun ve ark., 2003). Bu nedenle, test hatası artmaya başladığında eğitimin durdurulması ve test hatası minimum olduğunda gizli düğümlerin sayısının seçilmesi önerilir (Sun ve ark., 2003).

3.4. Makine Öğrenme Algoritmaları

Sınıflandırmada, sınıf etiketi adı verilen ve sınıf hedefini gösteren kategorik bir özniteliği tahmin etmek amacıyla veri kümesinin özniteliklerini eğitmek ve test etmek için bir makine öğrenimi algoritması kullanılmaktadır. Bu süreç, model denetimli makine öğrenimi algoritmalarının performansını doğru tahminlerle değerlendirmektedir (Noviantoro ve Huang, 2021).

Denetimli bir makine öğrenimi algoritmasının amacı, N tahmincisi, $x = \{x_1, x_2, \dots, x_N\}$ ve M eğitim örneğine (tarihsel durumlar veya deneyimler) dayalı bir kategorik sonuç vektörü (y) arasındaki ilişkiyi haritalayan fonksiyon (f) çıkarımı yapmaktır. Sağlam model oluşturma ve değerlendirme sağlamak için işlenen veriler eğitim ve test setlerine bölünür. Eğitim veri kümesi, modelin aralarındaki ilişkiyi öğrenebilmesi/ortaya çıkarabilmesi için hem tahmin edicileri hem de ilgili çıktı değişkenini makine öğrenimi modeline besler (Rajendran ve ark., 2021).

ML yöntemleri, istatistiksel yöntemler konusunu ele alabilen girdi ve çıktı verileri arasındaki karmaşık doğrusal olmayan ilişkileri haritalayabilmektedir (Han ve ark., 2021).


Makine öğrenimi yöntemleri, trafik/yolcu akışı modellemede de kapsamlı bir şekilde uygulanmıştır (Wei ve ark., 2021). Bu çalışmada yolcu talep tahmini yapılırken kullanılan makine öğrenimi algoritmaları; karar ağacı, rassal orman regresyonu, doğrusal regresyon, polinom regresyon ve destek vektör regresyonudur.

3.4.1. Karar ağacı

Karar ağacı algoritması, basitliği ve netliği nedeniyle insanlar tarafından kolayca yorumlandığından en popüler ve yaygın sınıflandırma yöntemlerinden biridir. Karar ağacı, değerlerin sınıflarla veya sayısal hedef değerlerle ilişkisine karar vermeyi amaçlayan düğümleri toplamak için hiyerarşik bir yapı veya ağaç yapısı kullanan bir tahmin modeli algoritmasıdır (Wahyono ve ark., 2019).

Bir karar ağacı, iç düğümleri test olarak alınabilen (girdi veri örüntüleri üzerinde) ve yaprak düğümleri (bu örüntülerin) kategorileri olarak alınabilen bir ağaçtır. Bu testler, giriş modeline doğru çıktıyı elde etmek için ağaçtan filtrelenir. Karar Ağacı algoritmaları çeşitli farklı alanlarda uygulanabilir ve kullanılabilir (Navada ve ark., 2011).

Karar ağacı, bir ögenin gözlemlerini (bir dalda temsil edilir), ögenin hedef değeri (yaprakta temsil edilir) hakkında bir sonuca kadar tanımlayan tahmine dayalı bir modeldir. Baş aşağı bir ağaç yapısı ile karşılaştırıldığında; kök ilk veri kümesini temsil ederken, dallar o sınıf etiketine işaret eden özellik ilişkilerini temsil etmektedir ve yapraklar Şekil 3.3.'te gösterilen sınıf etiketlerini temsil etmektedir (Noviantoro ve Huang, 2021).



 ekil 3.3. Karar a acı diyagramı (Noviantoro ve Huang, 2021).


3.4.2. Rassal orman regresyonu

Rassal orman (RF), verilerin sınıflara gruplandırılmasını i eren problemlerin ele alınması i in uygun bir topluluk  ğrenme sınıflandırması ve regresyon y ntemidir. Algoritma, Breiman ve Cutler (2007) tarafından geli tirilmi tir (Akinyelu ve Adewumi, 2014).

Random Forest, denetimli  ğrenme kategorisine ait bir  ğrenme algoritmasıdır. Random Forest, makine  ğreniminde hem sınıflandırma hem de regresyon sorunları i in kullanılı tır. Topluluk  ğrenimi, “verilerden  ğrenme” kavramına dayanmaktadır. Rastgele orman algoritması, bir ok karar a acı olu turmak i in merkezi bir konseptte sahiptir (Svetnik ve ark., 2003).

Rastgele Orman, bir ok a acı birle tirerek ve  ekil 3.4.’te g sterilen her bir karar a acıyla tahminler yaparak  alı maktadır. Geli tirme s reci  u  ekilde tanımlanabilmektedir:  nce e itim k mesinden rastgele noktalar se ilmekte, ardından verilerden karar a a ları olu turulmakta (ikinci adım), karar a a larının sayısı se ilmekte, ardından 1. ve 2. adımlar tekrarlanmakta, son olarak t m girdi verileri i in bir karar a acı olu turulmaktadır. Rastgele orman,  o unlu un se imlerine dayalı

nihai kararı tahmin etmek için her karar ağacıyla birlikte çalışmaktadır. Nihai sonuçlar tutarlı olabilmekte; ancak tüm durumları öngörememektedir. Birlikte, tüm ağaçlar doğru beklenen çıktıyı tahmin etmektedir. Rastgele orman genellikle kapsamlı daha iyi bir modelle sonuçlanmaktadır (Pavlov, 2019; Noviantoro ve Huang, 2021).



Şekil 3.4. Rastal orman bilgi yolculuğu (Noviantoro ve Huang, 2021).

3.4.3. Doğrusal regresyon

Regresyon, bir denetimli öğrenme yaklaşımıdır. Sürekli değişkenleri modellemek ve tahminleri yapmak için kullanılabilmektedir. Gayrimenkul fiyat tahmini, satış tahmini, öğrencilerin sınav puanlarının tahmini, borsadaki hisse senedi fiyatlarındaki hareketlerin tahmini doğrusal regresyon algoritmasının uygulama örnekleridir. Regresyonda etiketli veri kümeleri mevcuttur ve çıktı değişkeni değeri girdi değişken değerleri tarafından belirlenmektedir; bu nedenle denetimli öğrenme yaklaşımıdır. En basit regresyon şekli, veri kümesine düz bir çizgi (düz hiperdüzlem) sığdırmaya çalışılan ve veri kümesinin değişkenleri arasındaki ilişkinin doğrusal olduğu durumlarda mümkün olan doğrusal regresyondur (Ray, 2019).

Doğrusal Regresyon, değişkenler arasındaki ilişkiyi tanımlamak için en yaygın tahmine dayalı modeldir. Tek değişkenli veya çok değişkenli veri türlerinin dışında, kavram doğrusaldır (Seber ve Lee, 2012a; Montgomery ve ark., 2015; Kavitha ve ark., 2016).

Doğrusal regresyon, anlaşılması kolay olma avantajına sahiptir ve ayrıca düzenlileştirme ile aşırı uyum sağlamadan kaçınmak kolaydır. Ayrıca doğrusal modelleri yeni verilerle güncellemek için SGD (Olasılıksal Dereceli Azalma)'yı kullanılabilir. Ortak değişkenler ve yanıt değişkeni arasındaki ilişkinin doğrusal olduğu biliniyorsa, doğrusal regresyon iyi bir uyumdur. Odağı istatistiksel modellemekten veri analizine ve ön işleme kaydırır. Doğrusal Regresyon, veri analizi süreci hakkında bilgi edinmek için iyidir. Ancak, gerçek dünya problemlerini aşırı basitleştirdiği için çoğu pratik uygulama için önerilen bir yöntem değildir (Ray, 2019).

Doğrusal regresyonun dezavantajı, doğrusal olmayan ilişkilerle uğraşılması gerektiğinde bunun uygun olmamasıdır. Karmaşık kalıpları işlemek zordur. Ayrıca doğru polinomları modele uygun şekilde eklemek de zordur. Doğrusal regresyon, birçok gerçek dünya problemini basitleştirir. Ortak değişkenler ve yanıt değişkenleri genellikle doğrusal bir ilişkiye sahip değildir (Ray, 2019).

3.4.4. Polinom regresyon

Polinom Regresyon, bağımlı (y) ve bağımsız değişken (x) arasındaki ilişkiyi n'inci derece polinom olarak modelleyen bir regresyon algoritmasıdır (JAVAPOINT, 2020).

Polinom regresyon, düzensiz değerler arasındaki ilişkiyi modellemek için kullanılır (Kim ve Kim, 2020). Polinom regresyon modelleri, polinom en küçük kareler yöntemini kullanarak n'inci derece polinom olarak bağımlı ve bağımsız değişkenler arasında doğrusal olmayan bir ilişkiye uyar (Bradley ve Srivastava, 1979; Bera ve ark., 2021).

Polinom regresyon, yalnızca bir bağımsız değişken x_i ile çoklu regresyonun özel bir durumudur. Tek değişkenli polinom regresyon modeli şu şekilde (Denklem 3.2) ifade edilebilir (Ostertagová, 2012):

$$y_i = \beta_0 + \beta_1 x_i + \beta_2 x_i^2 + \beta_3 x_i^3 + \dots + \beta_k x_i^k + e_i, i = 1, 2, \dots, n \quad (3.2)$$


Burada k , polinomun derecesidir. Polinomun derecesi modelin sırasıdır. Etkili olarak, bu, çoklu bir modele sahip olmakla aynıdır: $x_1 = x$, $x_2 = x^2$, $x_3 = x^3$, vb.

3.4.5. Destek vektör regresyonu

Destek Vektör Makineleri (DVM), ilk olarak Cortes ve Vapnik (1995) tarafından yapısal risk minimizasyon araştırmasından geliştirilmiştir. Bu fikir, Şekil 3.5.'te gösterildiği gibi en yakın mesafe değerleri arasındaki farkı optimize ederek iki mesafede optimal ayırıcı hiperdüzlemi elde etmektir. SVM, bir destek vektörü ve bir kenar boşluğu kullanarak hiper düzlemi keşfetmektedir (Hsu ve Lin, 2002; Salcedo-Sanz ve ark., 2014).

Destek Vektör Makinesi, sınıflandırma ve regresyon için denetimli öğrenme modellerinden biridir (Efendigil ve Eminler, 2017; Shih ve Rajendran, 2019). Regresyon için Destek Vektör Makinesi'nin özellikle Destek Vektör Regresyonu olduğu söylenir. Destek vektör makinesi, ilgili çekirdek işlevleri, kullanılarak doğrusal veya doğrusal olmayan olabilir (Gunn, 1988; Smola ve Schölkopf, 2004; Kavitha ve ark., 2016).

Bir destek vektör makinesi, regresyon, sınıflandırma veya diğer görevler için kullanılabilen yüksek boyutlu veya sonsuz bir uzayda hiperdüzlem oluşturmaktadır. DVM, makine öğreniminde çok kullanışlı ve yaygın olarak işlev görmesi için uygulama kararlarının hazırlanmasında kapasiteyi ve dönüştürülebilirliği kontrol edebilmektedir (Cortes ve Vapnik, 1995).



Şekil 3.5. Destek vektör makine çizimi (Noviantoro ve Huang, 2021).

3.5. Regresyon Analizi Tekniği

İstatistiksel modellemede, regresyon analizi (Jafari ve ark., 2012; Alahgholi ve ark., 2018; Shirazi ve ark., 2018; Shirazi ve ark., 2018; Shirazy ve ark., 2019; Shirazy ve ark., 2020; Shirazy ve ark., 2020; Adel ve ark., 2021; Nazerian ve ark., 2021) bir bağımlı değişken (genellikle “sonuç” veya “yanıt” değişkeni olarak adlandırılır) ile bir veya daha fazla bağımsız değişken (genellikle “öngörücü”, “ortak değişkenler”, “açıklayıcı değişkenler” veya “özellikler” olarak adlandırılır) arasındaki ilişkileri tahmin etmeye yönelik bir dizi istatistiksel süreçtir (Draper ve Smith, 1998; Allen, 2004; Freund ve ark., 2006; Jafari ve ark., 2012; Seber ve Lee, 2012b; Chatterjee ve Hadi, 2013; Nazerian ve ark., 2021). Regresyon analizinin en yaygın biçimi, belirli bir matematiksel kritere göre verilere en yakından uyan doğrunun (veya daha karmaşık bir lineer kombinasyonun) bulunduğu lineer regresyondur. Regresyon analizi yöntemi aracılığı ile faktörlerde bir değişiklik yapılması durumunda, ilgili değişkende nasıl bir artış veya azalışın oluşacağı ortaya koyulabilir. Açıklayıcı gücü yeterli düzeyde olan güvenilir bir regresyon katsayısı güvenilir tahminler yapmaya olanak sağlar. Regresyon analizinde, dönemsel olarak değişen geçmiş veriler kullanılarak eşitlik geliştirilebilir. Eğer tahmin yapılırken bağımsız değişkenlerin değerleri büyük ölçüde olağandışı değerler ise, tahmin hatasının fazla olması kaçınılmazdır. Geçmiş veriler düzenli ve sürekli ise tahminin tutarlılığı o ölçüde yüksek olacaktır (Ballı, 2014).

Önemli regresyon analizi yöntemleri şunlardır (Nazerian ve ark., 2021):

- Basit doğrusal regresyon
- Çoklu doğrusal regresyon
- Bulanık regresyon
- Lojistik regresyon

Regresyon hesaplama yeteneğine sahip birçok yazılım bulunmaktadır (Nazerian ve ark., 2021). Bu çalışmada, regresyon analizi için SPSS Statistics 21.0 yazılımı kullanılmıştır.

3.6. Basit Ortalama Yöntemi

Basit ortalama yöntemi, geçmiş dönem verilerini tek tek toplamak ve bunları dönem sayısına bölmektir (Çağlar, 2007). Yöntemin avantajı, tüm dönemleri kullanarak düzleştirilmiş bir tahmin sağlaması ve uygulanmasının kolay olmasıdır. Basit ortalama yönteminin matematiksel denklemi Denklem 3.3.'te gösterilmiştir.

$$F_{t+1} = \frac{1}{t} \sum_{i=1}^t Y_i \quad (\text{Meydan, 2007}). \quad (3.3)$$

t = periyot

F_{t+1} = sonraki dönemin tahmini değeri

Y_i = i dönemindeki gerçek talep değeridir.

Yeni bir gözlem, Y_{t+1} mevcut olduğunda; bu yeni değer $t+2$ zamanı için bir tahmin oluşturulurken Denklem 3.3'e eklenir ve Denklem 3.4 elde edilir.

$$F_{t+2} = \frac{1}{t+1} \sum_{i=1}^{t+1} Y_i \quad (\text{Meydan, 2007}). \quad (3.4)$$

3.7. Farklı Yöntemlerin Değerlendirilmesi

Model performansını ve yöntemlerin doğruluğunu değerlendirmek için beş farklı tahmin hatası ölçüsü kullanılmıştır; bunlar MAE, MSE, BIAS ve MAPE (Shih ve Rajendran, 2019), (Nahmias, 2008; Ravindran ve Warsing, 2013; Chopra ve Meindl, 2015) ve RMSE'dir.

$X_1, X_2, \dots, X_n$ gerçek veriler ve $F_1, F_2, \dots, F_n$ tahmin verileri, ve n tahmin hatalarının değerleri, $e_1, e_2, \dots, e_n$, $e_1 = F_1 - X_1$, $e_2 = F_2 - X_2, \dots, e_n = F_n - X_n$ ile verilir.

- Ortalama mutlak hata (MAE): Tüm bireysel hataların eşit ağırlıklara sahip olduğu tahmin hatalarının ortalama önemini ölçer (Denklem 3.5):

$$MAE = \frac{1}{n} \sum_{i=1}^n |e_i|, i = 1, \dots, n \quad (3.5)$$

- Ortalama kare hatası (MSE): Tahmin hatalarının önemini ölçer ve daha büyük hatalar kare alma nedeniyle daha fazla cezalandırılır (Denklem 3.6):

$$MSE = \frac{1}{n} \sum_{i=1}^n |e_i^2| \quad (3.6)$$

- BIAS: Tahminin, tahmin ufku boyunca gerçek arzı olduğundan fazla mı yoksa olduğundan mı az tahmin ettiğinin bir göstergesidir (Denklem 3.7):

$$BIAS = \sum_{i=1}^n e_i \quad (3.7)$$

- Ortalama mutlak yüzde hatası (MAPE): Tahmin hatalarının göreceli önemini yüzde cinsinden ölçer (Denklem 3.8):

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{e_i}{X_i} \right| \times 100 \quad (3.8)$$

- Kök ortalama kare hatası (RMSE): iki veri seti arasında ne kadar hata olduğunu ölçer (Denklem 3.9):

$$RMSE = \sqrt{MSE} \quad (3.9)$$

3.8. Çok Kriterli Karar Verme Yöntemleri

Çok kriterli karar verme (ÇKKV), karar vermede tanınmış bir metodolojidir. Bir dizi karar kriterinin varlığında karar problemleriyle ilgilenen yöneylem araştırması modellerinin genel sınıfının bir dalıdır. Modellerin ana sınıfına sıklıkla ÇKKV denir (Begić ve Afgan, 2007; Zolfani ve Saparauskas, 2013).

Çok kriterli karar verme teknikleri günümüzde popüler olmuştur ve birçok gerçek yaşam problemde faydalıdır. Bu yöntemler genellikle birbiriyle çelişen hedeflerle karmaşık karar problemlerini çözmek için kullanılmaktadır. Gerçek hayatta bir dizi seçenek olduğunda ve en çok tercih edilen seçilmek istendiğindeki bir durumu ifade etmektedir. Bir ÇKKV’de deneyim, beceri, bilgi vb. gibi benzersiz özelliklere sahip bir grup karar verici vardır. Çoğu durumda, karar vericilerin farklı yetenekleri ve ilgi alanları olabilmektedir. Bu nedenle, her bir karar verici, sonuçlar üzerinde farklı bir etkiye sahip olmalıdır. ÇKKV yöntemleri, alternatifleri öznel tercih sırasına göre sıralamaya çalışmaktadır (Behzadian ve ark., 2012; Zyoud ve Fuchs-Hanusch, 2017; Kacprzak, 2019; Hashemi ve ark., 2022).

Bu çalışmada, çok kriterli karar verme yöntemlerinden AHP, SWARA ve TOPSİS kullanılmıştır.

3.8.1. Analitik hiyerarşi süreci (AHP)

Analitik hiyerarşi süreci yöntemi (AHP), Saaty (1980; 1990) tarafından geliştirilen karar verme süreçlerinde en çok kullanılan yöntemlerden biridir (Atanasova-Pacemka ve ark., 2014). Verilen kümenin göreceli önceliğini uygun değer ölçeğine göre nicelleştirmeyi amaçlamaktadır. Karar, genellikle nihai kararı vermesi gereken ve

öncelikleri değerlendirmesi gereken bireyin algısına dayanmakta, tüm karar verme sürecinde karşılaştırılan alternatiflerin tutarlılığının ve korelasyonunun önemini vurgulamaktadır (Saaty, 1980; Saaty, 1990; Atanasova-Pacemka ve ark., 2014).


AHP yöntemi, kriterler ve alternatifler arasındaki ilişkiyi bulmak için basit bir yol ürettiği için çok esnektir. Böylece, bu yöntem, birçok kriter ve nispeten çok sayıda alternatif içeren karmaşık problemler durumunda, kriterlerin gerçek dünyadaki uygunluğunu değerlendirmek ve kriterler arasındaki etkileşimi belirlemek için kullanılmaktadır. Bu yöntemin uygulanmasıyla karmaşık problemler belirli hiyerarşilerde ayrıştırılabilmekte; böylece analiz problemin nicel ve nitel yönlerini içermektedir. AHP, hiyerarşinin tüm seviyelerini birbirine bağlamaktadır. Bu, bir kriterdeki değişikliğin diğer kriter ve alternatifleri nasıl etkilediğinin tanınmasını sağlamaktadır (Atanasova-Pacemka ve ark., 2014).

AHP, karmaşık problemlerin amaç (hedef), kriterler (alt kriterler) ve alternatifler olan belirli unsurların hiyerarşik bir yapısına dallanması ihtiyacına dayanan çok kriterli bir tekniktir (Atanasova-Pacemka ve ark., 2014).

AHP yöntemi uygulaması dört basit adımda açıklanabilmektedir (Atanasova-Pacemka ve ark., 2014):

- Adım 1: Karar verilmesi gereken hiyerarşik bir problem modeli geliştirilmekte; yani karar hiyerarşisi kurulmaktadır. Amaç (hedef) hiyerarşinin en üstünde yer almakta, kriterler ve alt kriterler alt seviyelere koyulmakta ve alternatifler modelin en altında bulunmaktadır (Atanasova-Pacemka ve ark., 2014). Şekil 3.6. bu yapıyı göstermektedir (Nar, 2018).
- Adım 2: Hiyerarşinin her seviyesinde, karar vericinin tercihlerinin Saaty göreceli önem seviyeleri ölçeği kullanılarak ifade edildiği yapı elemanları çiftlerinde karşılaştırma yapılmaktadır. Ölçek, 1 ile 9 arasında sayısal değerlere karşılık gelen, önemi sözlü olarak tanımlayan 5 seviye ve 4 alt seviye içermektedir (Tablo 3.1.).

- Adım 3: Hiyerarşik yapının her seviyesindeki unsurlara göreceli önem değerlendirmeleri, yerel kriterler, alt kriterler ve alternatiflerin hesaplanmasında uygulanabilmektedir (Atanasova-Pacemka ve ark., 2014). Kriterlerin göreceli ağırlıklarını tahmin etmek için özdeğer matrisi yöntemi kullanılmaktadır (Zahedi, 1986; Nar, 2018).
- Adım 4: Daha sonra alternatiflerin genel öncelikleri sentezlenmektedir. Her alternatifin toplam önceliği, daha yüksek seviyelerdeki öğelerin ağırlıkları ile ağırlıklandırılan yerel önceliklerin toplamı ile hesaplanmaktadır (Atanasova-Pacemka ve ark., 2014). Karar alternatifleri değerlendirmesi için kriterlerin nispi ağırlıkları kümelenmektedir (Zahedi, 1986; Nar, 2018).



Şekil 3.6. Örnek hiyerarşi yapısı (Nar, 2018).

Tablo 3.1. AHP önem düzeyleri (Saaty ve Sodenkamp, 2010)

Önem Yoğunluğu	Tanım	Açıklama
1	Eşit Önem	İki faaliyet amaca eşit düzeyde katkıda bulunur.
3	Birinin diğerine göre çok az önemli olması	Tecrübe ve yargı bir faaliyeti diğerine çok az tercih ettirir.
5	Kuvvetli derecede önemli	Tecrübe ve yargı bir faaliyeti diğerine çok kuvvetli bir derecede tercih ettirir.
7	Çok kuvvetli düzeyde önemli	Bir faaliyet güçlü bir şekilde tercih edilir ve baskınlığı uygulamada rahatlıkla görülür.
9	Aşırı derecede önemli	Bir faaliyetin diğerine tercih edilmesine ilişkin kanıtlar çok büyük güvenilirliğe sahiptir.
2,4,6,8	Orta Değerler	Uzlaşma gerektiğinde kullanmak üzere yukarıda listelenen yargılar arasına düşen değerler.

AHP yönteminin matematiksel modeli hakkında aşağıda detaylı bilgi verilmiştir (Atanasova-Pacemka ve ark., 2014):

Karşılaştırılan n eleman varsa, karşılaştırma sonuçları $n \times m$ boyutunda A matrisini oluşturur (Denklem 3.10):

$$A = \begin{bmatrix} a_{11} & a_{12} & \dots & a_{1m} \\ a_{21} & a_{22} & \dots & a_{2m} \\ \dots & \dots & \dots & \dots \\ a_{n1} & a_{n2} & \dots & a_{nm} \end{bmatrix} \quad (3.10)$$

Matrisin elemanları veya karşılaştırılan kriterler arasındaki oran şu formülle ifade edilir (Denklem 3.11):

$$\alpha_{ij} = \frac{w_i}{w_j} \quad (3.11)$$

Burada w_i/w_j terimi, amaca ulaşmak için i . kriterin j . kriterden ne kadar daha önemli olduğunu ifade etmektedir. İkili karşılaştırma için oran aşağıdaki formülle ifade edilir (Denklem 3.12):

$$\alpha_{ij} = \frac{1}{a_{ji}} \quad (3.12)$$

Bir sonraki adım, normalleştirilmiş bir matris elde etmektir (Denklem 3.13).

$$B = [b_{ij}] \quad (3.13)$$

B matrisinin elemanları şu şekilde hesaplanır (Denklem 3.14):

$$b_{ij} = \alpha_{ij} / \sum_{i=1}^n \alpha_{ij} \quad (3.14)$$

Ağırlıkların hesaplanması, yani özvektör (Denklem 3.15)

$$w = [w_i] \quad (3.15)$$

normalleştirilmiş matris B 'yi formüle göre matrisin her satırı için aritmetik ortalama hesaplayarak gerçekleştirilmektedir (Denklem 3.16):

$$w_i = \sum_{j=1}^n b_{ij} / n \quad (3.16)$$

AHP yönteminde karşılaştırma matrisinin tutarlılığı hakkında aşağıda detaylı bilgi verilmiştir (Atanasova-Pacemka ve ark., 2014):

Tutarlılık, ikili karşılaştırmalarla ilgili olarak karar vericinin tutarlı bir yargısı anlamına gelmektedir. Matematiksel olarak, eğer tüm i, j ve k için (Denklem 3.17);

$$a_{ij} a_{jk} = a_{ik} \quad (3.17)$$

ise, A karşılaştırma matrisinin tutarlı olduğu söylenir.

Tüm karşılaştırma matrislerinin tutarlı olması olağandışıdır. Gerçekten de, insan yargısının bu matrislerin oluşturulmasının temeli olduğu göz önüne alındığında, bir miktar “makul” derecede tutarsızlık beklenmekte ve buna müsamaha gösterilmektedir.

Bir tutarlılık seviyesinin “makul” olup olmadığını belirlemek için, karşılaştırma matrisi A için ölçülebilir bir ölçüm geliştirmemiz gerekmektedir. A matrisi mükemmel bir şekilde tutarlı olduğunda, tüm sütunların aynı olduğu normalleştirilmiş bir C matrisi üretmektedir (Denklem 3.18):

$$C = \begin{bmatrix} \frac{w_1}{w_1} & \frac{w_1}{w_2} & \dots & \frac{w_1}{w_n} \\ \frac{w_2}{w_1} & \frac{w_2}{w_2} & \dots & \frac{w_2}{w_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{w_n}{w_1} & \frac{w_n}{w_2} & \dots & \frac{w_n}{w_n} \end{bmatrix} \quad (3.18)$$

C'nin, i sütununun öğelerini w_i 'ye bölerek orijinal karşılaştırma matrisi A elde edilir (Denklem 3.19):

$$A = \begin{bmatrix} 1 & \frac{w_1}{w_2} & \dots & \frac{w_1}{w_n} \\ \frac{w_2}{w_1} & 1 & \dots & \frac{w_2}{w_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{w_n}{w_1} & \frac{w_n}{w_2} & \dots & 1 \end{bmatrix} \quad (3.19)$$

Ortaya çıkan oran karşılaştırmaları şu şekilde gösterilmektedir (Denklem 3.20):

$$\begin{bmatrix} \frac{w_1}{w_1} & \frac{w_1}{w_2} & \dots & \frac{w_1}{w_n} \\ \frac{w_2}{w_1} & \frac{w_2}{w_2} & \dots & \frac{w_2}{w_n} \\ \frac{w_1}{w_1} & \frac{w_2}{w_2} & \dots & \frac{w_n}{w_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{w_n}{w_1} & \frac{w_n}{w_2} & \dots & \frac{w_n}{w_n} \end{bmatrix} \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_n \end{bmatrix} = n \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_n \end{bmatrix} \quad (3.20)$$

Terimi elde etmek için $n \times w$ matris sağda w ile çarpılır. Daha kompakt bir şekilde, w 'nin göreceli ağırlıkların sütun vektörü olduğu göz önüne alındığında, $w_i, i = 1, \dots, n$, A aşağıdaki durumlarda tutarlıdır (Denklem 3.21):

$$Aw = nw \quad (3.21)$$

A 'nın tutarlı olmadığı durumda, w_i göreceli ağırlığı, normalleştirilmiş C matrisindeki i satırının n öğelerinin ortalaması ile yaklaşık olarak bulunur. $\bar{w}$ hesaplanan ortalama vektörü olarak kabul edilirse, şu şekilde gösterilebilir (Denklem 3.22):

$$A\bar{w} = \lambda_{\max} \bar{w}, \lambda_{\max} \geq n \quad (3.22)$$

Bu durumda, karşılaştırmaya ilişkin temel değer ($\lambda_{\max}$) n 'ye ne kadar yakınsa, A karşılaştırma matrisi o kadar tutarlıdır. Bu gözleme dayanarak, AHP tutarlılık oranını şu şekilde hesaplar (Denklem 3.23):

$$CR = \frac{CI}{RI} \quad (3.23)$$

CI , A 'nın tutarlılık indeksidir ve şu şekilde hesaplanır (Denklem 3.24):

$$CI = \frac{\lambda_{\max} - n}{n-1} \quad (3.24)$$

RI , A 'nın rastgele tutarlılık indeksidir ve değeri, ilk satırın (n) satır sayısını, yani matris boyutunu göstermekte, ikinci satır ise rastgele tutarlılık indeksini (Tablo 3.2.) belirtmektedir:

Tablo 3.2. Rastgele tutarlılık indeksi

n	1	2	3	4	5	6	7	8	9	10
RI	0	0	0,52	0,89	1,11	1,25	1,35	1,40	1.45	1.49

$CR \leq 0,1$ ise, tutarsızlık seviyesi kabul edilebilir. Aksi takdirde, tutarsızlık yüksektir ve karar vericinin daha iyi tutarlılık elde etmek için A'nın a_{ij} unsurlarını yeniden tahmin etmesi gerekebilir.

$\lambda_{\max}$ 'ın değeri $A\bar{w} = \lambda_{\max} \bar{w}$ 'dan hesaplanmaktadır (Denklem 3.25).

$$\sum_{j=1}^n a_{ij} \bar{w} = \lambda_{\max} \bar{w}_i, \quad i = 1, \dots, n \quad (3.25)$$

$$\sum_{i=1}^n \bar{w}_i = 1 \quad (3.26)$$

(Denklem 3.26) eşitliği verildiğinde,

$$\sum_{i=1}^n (\sum_{j=1}^n a_{ij} \bar{w}) = \lambda_{\max} \sum_{i=1}^n \bar{w}_i = \lambda_{\max} \quad (3.27)$$

elde edilir (Denklem 3.27).

Bu, $\lambda_{\max}$ 'ın değerinin önce $A\bar{w}$ sütun vektörünü hesaplayarak ve ardından öğelerini toplayarak belirlenebileceği anlamına gelmektedir.

3.8.2. Adım adım ağırlık değerlendirme oran analizi (SWARA)

Keršulienė ve ark. (2010), kriterlerin değerlendirilmesi ve ağırlıklandırılması için bir SWARA yöntemi geliştirmiştir. SWARA'nın kullanımı diğer ÇKKV araçlarına göre nispeten daha kolaydır. SWARA yöntemi şimdiye kadar çeşitli alanlarda farklı problemlerin çözümünde uygulanma yolunu bulmuştur (Singh ve Modgil, 2020). SWARA'nın adımları şunlardır (Keršulienė ve ark., 2010):

Adım 1. İlgili değerlendirme kriterleri kümesini belirlenir ve bunlar beklenen önemlerine göre azalan düzende sıralanır (Şekil 3.7.).

Adım 2. İkinci kriterden başlanarak, j kriterinin s_j görelî önemi önceki (j - 1) kritere göre belirlenir ve bu her bir özel kriter için yapılır.

Adım 3. K_j katsayısı aşağıdaki gibi belirlenir (Denklem 3.28):

$$K_j = 1, j = 1$$

$$K_j = S_j + 1, j > 1 \quad (3.28)$$


Adım 4. Yeniden hesaplanan q_j ağırlığı aşağıdaki gibi belirlenir (Denklem 3.29):

$$q_j = 1, j = 1$$

$$q_j = (q_j - 1) / K_j, j > 1 \quad (3.29)$$

Adım 5. Değerlendirme kriterlerinin w_j görelî ağırlıkları aşağıdaki gibi belirlenir (Denklem 3.30):

$$W_j = q_j / \sum_{k=1}^n q_k \quad (3.30)$$




Şekil 3.7. SWARA yöntemi ile kriter ağırlıklarının belirlenmesi (Keršulienė ve Turskis, 2014).

3.8.3. İdeal çözüme benzerlik bakımından sıralama performansı tekniği (TOPSİS)

1981 yılında Hwang ve Yoon tarafından geliştirilen TOPSİS, kavram ve uygulamada basit bir sıralama yöntemidir. Standart TOPSİS yöntemi, aynı anda pozitif ideal çözüme en kısa mesafeye ve negatif ideal çözüme en uzak mesafeye sahip alternatifleri seçmeye çalışır. Pozitif ideal çözüm fayda kriterlerini maksimize eder ve maliyet

kriterlerini minimize eder, negatif ideal çözüm ise maliyet kriterlerini maksimize eder ve fayda kriterlerini minimize eder. TOPSİS, öznitelik bilgisini tam olarak kullanır, alternatiflerin temel bir sıralamasını sağlar ve öznitelik tercihlerinin bağımsız olmasını gerektirmez (Chen ve Hwang, 1992; Yoon ve Hwang, 1995; Behzadian ve ark., 2012). Bu tekniği uygulamak için öznitelik değerleri sayısal, monoton artan veya azalan olmalı ve ölçülebilir birimlere sahip olmalıdır.

Şekil 3.8., TOPSİS'i uygulamak için Hwang ve Yoon'un (1981) adım adım prosedürünü sunar. Başlangıç karar matrisi oluşturulduktan sonra, karar matrisinin normalleştirilmesi ile işleme başlanır. Bunu, Adım 2'de ağırlıklı normalleştirilmiş karar matrisinin oluşturulması, Adım 3'te pozitif ve negatif ideal çözümlerin belirlenmesi ve Adım 4'te her bir alternatif için ayırma ölçülerinin hesaplanması takip eder. Prosedür, göreceli yakınlık katsayısının hesaplanmasıyla sona erer. Alternatifler (veya adaylar) kümesi, yakınlık katsayısının azalan sırasına göre sıralanabilir.



Şekil 3.8. TOPSIS metodolojisini gerçekleştirmek için adım adım prosedür (Behzadian ve ark., 2012).

BÖLÜM 4. ARAŞTIRMA BULGULARI

Çalışmanın ilk bölümünde, Yenikapı M1 – Kirazlı M1 hattındaki geçmiş dönem verileri kullanılarak, raylı ulaşım sistemlerinde yolcu talep tahmini sonucunda ulaşılan bulgulardan bahsedilmiştir. Yolcu talep tahmini çalışması istasyon ve hat bazlı olmak üzere iki aşamada yapıldığından; ilk olarak istasyon bazlı talep tahmin çalışmasının sonuçlarına yer verilmiştir. İstasyon bazlı talep tahmini çalışması, yapay sinir ağı ve makine öğrenme algoritmaları ile yapılmıştır. YSA ile gelecek yıllara ait yolcu talep tahmini bulguları MATLAB R2017b programı ile elde edilirken; MÖ algoritmaları ile tahminleme bulguları Python 2.7.18 programı aracılığı ile elde edilmiştir. Daha sonra, hat bazlı talep tahmin çalışmasının sonuçlarına yer verilmiştir. Hat bazlı talep tahmini çalışması ise, istatistiksel tekniklerden basit ortalama yöntemi ve regresyon analiz tekniği ile yapılmıştır; regresyon analizi için çalışma bulguları SPSS Statistics 21.0 programı ile elde edilmiştir.

Ayrıca, talep tahmin sonuçları elde edildikten sonra, modelinin performansını ve yöntemlerin doğruluğunu değerlendirmek için beş farklı tahmin hatası ölçüsü kullanılmıştır; bunlar ortalama mutlak hata (MAE), BIAS, ortalama karesel hata (MSE), ortalama mutlak yüzde hata (MAPE) ve ortalama karesel hata (RMSE)'dir. Elde edilen bulgular bu bölümde detaylandırılmıştır.

Daha sonra, ikinci bir çalışma olarak, raylı ulaşım sistemlerinde sefer sıklığı belirlemede kritik başarı faktörlerinin önceliklendirilmesi ele alınmıştır. Bu çalışma yapılırken ana kriterler ve karar alternatiflerinin SWARA, TOPSİS ve AHP karar hiyerarşisi ortaya koyulmuş; AHP'nin diğer adımları için önce ikili karşılaştırmalar matrisleri oluşturulmuştur. AHP ikili karşılaştırma matrisleri uzman mühendislerle hazırlanan Excel tablolarıyla sunulmuş; uzmanların görüşüne dayanılarak SWARA, TOPSİS, AHP yaklaşımı sefer sıklığı optimizasyonundaki kritik başarı faktörleri

modeline uygulanmıştır. Uzman mühendislere uygulanan bu anketin, belirtilen üç ÇKKV tekniği uygulaması sonucunda elde edilen bulguları bu bölümde detaylı bir şekilde anlatılmıştır.


4.1. Raylı Ulaşımda Talep Tahmin Yöntemleri Uygulaması

Bu bölümde geçmiş dönem (2019 yılı) verileri kullanılarak Yenikapı M1 - Kirazlı M1 hattı için gelecek dönem yolcu talep tahmini yapılmıştır. Talep tahmin çalışması; yapay sinir ağları, makine öğrenme algoritmaları ve istatistiksel tekniklerden regresyon analizi, basit ortalama yöntemleri ile yapılmaktadır. Bu çalışmada, talep tahmini iki aşamadan oluşmaktadır.

İlk olarak, YSA ve makine öğrenmesi algoritmaları kullanılarak Yenikapı M1 - Kirazlı M1 hattındaki tüm istasyonlar için istasyon bazlı günlük tahmin yapılmıştır.

Çalışmanın ikinci aşamasında ise, regresyon analizi tekniği ve basit ortalama yöntemi gibi istatistiksel teknikler kullanılarak hat için talep tahmini yapılmıştır.


Yolcu talep tahmini için çalışmanın adımları Şekil 4.1.'de gösterilmiştir.



Şekil 4.1. Yolcu talep tahmini için çalışmanın adımları

4.1.1. Raylı ulaşımda yapay sinir ağları ile talep tahmini


Çalışmanın bu aşamasında istasyon bazlı tahmin için test verileri (Yenikapı M1 - Kirazlı M1 hattı geçmiş dönem verileri) kullanılmıştır. YSA yöntemine ilişkin eğitim ve test verileri MATLAB R2017b yazılım ortamına aktarılmıştır. Yapay sinir ağı yapısında gizli katman sayılarını, bu katmanlardaki nöron sayısını, katmanların aktivasyon fonksiyonunu, α öğrenme hızı ve momentum katsayılarını belirlemek için deneme yanılma yöntemi kullanılarak çeşitli kombinasyonlar denenmiş ve en düşük hataya sahip parametreler elde edilmiştir. En başarılı deney, 5 nöronlu giriş katmanı, 20 nöronlu gizli katman ve 1 nöronlu çıkış katmanına sahip yapay sinir ağıdır. Levenberg-Marguardt bir eğitim işlevi olarak kullanılmıştır. En düşük hataya sahip yapay sinir ağı mimarisi Şekil 4.2.'de verilmiştir.



Şekil 4.2. Modeli en başarılı sonuca ulaştıran yapay sinir ağı mimarisi

Uygulamanın bağımlı değişkeni günlük yolcu talebidir. Gün, mevsim, hafta, sefer sayısı ve ortalama sefer sıklığı ise uygulamanın bağımsız değişkenleri olarak ele alınmıştır. Yenikapı M1 – Kirazlı M1 hattındaki on üç istasyon için de bağımsız değişkenler dikkate alınarak ayrı ayrı input dosyaları oluşturulmuştur. Benzer şekilde, bağımlı değişken olan talep değerlerinden ise target dosyası her bir istasyon için ayrı ayrı oluşturulmuştur. Ayrıca, uygulamada ileri beslemeli yapay sinir ağı tercih edilmiştir. İleri beslemeli YSA kullanım sebebi tahmin çalışmalarındaki başarısıdır. Yapay sinir ağı modeli MATLAB R2017b programı kullanılarak oluşturulmuştur.

Geçmiş dönem verileri excel ortamında gözden geçirildikten sonra MATLAB R2017b programına aktarılmıştır. Import data tıklanarak MATLAB R2017b programına gözden geçirilen değerlerin girişleri yapılır (Şekil 4.3.).




Şekil 4.3. Matlab'a Veri Girişi

MATLAB R2017b programına tanımlanan değerlerin transpoze edilmesi gerekmektedir. Veriler transpoze edilirken Şekil 4.4.'teki komutlar programın komut ekranına yazılmıştır.

```
Command Window
>> input=input';
>> target=target';
>> Training_input=Training_input';
>> Training_target=Training_target';
fx >> nntool|
```

Şekil 4.4. Matlab'ta değişkenlerin transpozunun alınması


Komut ekranına nntool komutu yazılarak enter tuşuna basılır. Açılan Neural Network/Data Manager (nntool) penceresinde girdi ve çıktı verileri sınıflandırılır (Şekil 4.5.).



Şekil 4.5. Matlab'ta girdi ve çıktı verilerinin sınıflandırılması


Verilerin sınıflandırılmasından sonra New tıklanarak yeni bir ağ oluşturulur. Yeni bir ağ yaratma penceresi Şekil 4.6.'da gösterilmiştir. Network penceresinde oluşturmak istenilen ağ ile ilgili özellikler seçilir. Bu pencere aracılığı ile ağın tipi, eğitim girdi - çıktı verileri, eğitim ve öğrenme fonksiyonları, performans fonksiyonu, katman sayısı, gizli hücre sayısı, nöron sayısı ve aktivasyon fonksiyon bilgileri girilir ve açılan butonlardan ilgili seçimler yapılır. Akabinde, Create butonuna tıklanarak ağ yaratma işlemi gerçekleştirilir.

Bu uygulamada, Yenikapı için, eğitim fonksiyonu TRAINLM, nöron sayısı 20 ve transfer fonksiyonu ise, TANSIG olarak tercih edildiğinde en başarılı sonuca ulaşılmıştır.




Şekil 4.6. Matlab'ta yapay sinir ağı oluşturma penceresi

Şekil 4.7.'deki matlab penceresinin “Train” sekmesinde ağın eğitim işlemi gerçekleştirilir. Bu pencere aracılığı ile momentum ve öğrenme katsayısı, çevrim sayısı gibi öğrenme performansını etkileyen parametreler seçilerek Train Network butonuna basılır. Bu şekilde oluşturulan yapay sinir ağı eğitilir.




Şekil 4.7. Yenikapı M1 istasyonu matlab eğitim parametreleri ekranı

Matlab'ta Yenikapı M1 İstasyonu için öğrenmeden sonra elde edilen regresyon grafiği Şekil 4.8.'de gösterilmektedir. Bu grafiğe göre en düşük değer 0.76597 olan test kümesine aittir. Buradan da anlaşılacağı üzere öğrenme işlemi başarıyla gerçekleştirilmiştir. Bağımsız değişken olarak belirlediğimiz faktörler en az 0.77 oranında yolcu talebini etkilemektedir.




Şekil 4.8. Yenikapı M1 istasyonu için ağ eğitiminde regresyon değerleri

Aksaray İstasyonu için ağın öğrenmesini etkileyen parametreler doldurularak ağın eğitimi başlatılır (Şekil 4.9.).




Şekil 4.9. Aksaray istasyonu matlab eğitim parametreleri ekranı

Şekil 4.10.'da Aksaray İstasyonu için yapılan tahmine ilişkin regresyon grafikleri bulunmaktadır. Grafikler incelendiğinde ağın eğitim ve test R değerlerinin yaklaşık %72 değerini aldığı görülmüştür. Bu değerlerin kabul edilebilir olduğu değerlendirilmiştir.




Şekil 4.10. Aksaray istasyonu için ağ eğitiminde regresyon değerleri

Emniyet İstasyonu öğrenme parametreleri penceresi Şekil 4.11.'deki gibi doldurularak ağ eğitimi başlatılmıştır.




Şekil 4.11. Emniyet istasyonu matlab eğitim parametreleri ekranı

Şekil 4.12.'deki Emniyet İstasyonu regresyon değerlerinin %84 ile yaklaşık %89 arasında olduğu görülmektedir. Bu grafiğe göre en yüksek değer 0.88842 olan test kümesine aittir. Bu sonuçtan bu istasyon için yapay sinir ağı tahmin gücünün Yenikapı M1 ve Aksaray istasyonlarına göre daha iyi olduğunu anlaşılr. Şöyle ki, YSA bu veri setini öğrenmede daha başarılı olmuştur ve genel olarak verilerin %87'lik kısmı bu YSA modeli ile açıklanabilmektedir.




Şekil 4.12. Emniyet istasyonu için ağ eğitiminde regresyon değerleri

Ulubatlı İstasyonu için çevrim sayısı, momentum ve öğrenme katsayısı gibi öğrenme parametreleri doldurularak Train Network butonuna basılır. Bu şekilde Ulubatlı İstasyonu için yapay sinir ağı eğitilir (Şekil 4.13.).




Şekil 4.13. Ulubatlı istasyonu matlab eğitim parametreleri ekranı

Şekil 4.14. Ulubatlı İstasyonu için R grafiklerini açıklamaktadır. Burada validasyon R değeri 0.85564 olarak bulunmuştur. Eğitim değeri yaklaşık %81 iken test değeri ise; %79'dur. Bu model için YSA modelinin başarısı genel olarak %81 ile açıklanabilmektedir.




Şekil 4.14. Ulubathı İstasyonu için ağ eğitiminde regresyon değerleri

Bayrampaşa İstasyonu eğitim parametreleri Şekil 4.15.'te gösterilmiştir. Bu istasyon için eğitim R değeri 0.70873 olarak bulunmuştur. YSA'nın bu veri集中的 başarısı genel olarak yaklaşık %70 olarak gözükmektedir (Şekil 4.16.).




Şekil 4.15. Bayrampaşa istasyonu matlab eğitim parametreleri ekranı




Şekil 4.16. Bayrampaşa istasyonu için ağ eğitiminde regresyon değerleri

Şekil 4.17. Sağmalcılar M1 İstasyonu için öğrenme parametreleri penceresini gösterirken Şekil 4.18. regresyon değerlerini açıklamaktadır. Modelin bu verilerdeki başarısı genel olarak 0.73559 bulunmuştur. Eğitim değeri %72, test değeri yaklaşık %79 ve validasyon değeri ise %75 olarak görülmektedir. Buradan verilerin genel olarak yaklaşık %74'ünün bu YSA modeli ile açıklanabileceği sonucuna ulaşılabilir.




Şekil 4.17. Sağmalcılar istasyonu matlab eğitim parametreleri ekranı




Şekil 4.18. Sağmalcılar istasyonu için ağ eğitiminde regresyon değerleri

Kocatepe İstasyonu için ağ yaratma işlemi sonrasında öğrenme parametreleri Şekil 4.19.'daki gibi tanımlanır. Sonrasında yapay sinir ağı eğitimi başlatılır. Validasyon değeri yaklaşık %76 bulunurken genel olarak verilerin %69'u bu YSA modeli ile açıklanabilmektedir. Ayrıca test ve eğitim için de R değeri %67 olarak bulunmuştur (Şekil 4.20.).




Şekil 4.19. Kocatepe istasyonu matlab eğitim parametreleri ekranı




Şekil 4.20. Kocatepe istasyonu için ağ eğitiminde regresyon değerleri

Otogar İstasyonu için eğitim parametreleri Şekil 4.21.'de gösterilmiş olup istasyonun regresyon değerleri Şekil 4.22.'de verilmiştir. Regresyon değerlerinden test değeri %80 iken validasyon değeri %82'dir. Bu grafiğe göre en yüksek değer 0.82207 olan validasyon kümesine aittir. Bu sonuçtan bu istasyon için yapay sinir ağı tahmin gücünün Kocatepe istasyonuna göre daha iyi olduğunu anlaşılr. Ayrıca, YSA bu veri setini öğrenmede daha başarılı olmuştur ve genel olarak verilerin yaklaşık %78'lik bölümü bu YSA modeli ile açıklanabilmektedir.




Şekil 4.21. Otogar istasyonu matlab eğitim parametreleri ekranı




Şekil 4.22. Otogar istasyonu için ağ eğitiminde regresyon değerleri

Esenler İstasyonu öğrenme parametreleri penceresi Şekil 4.23.'teki gibi doldurularak ağ eğitimi başlatılmıştır. Eğitilen ağın Esenler İstasyonu için regresyon değerleri Şekil 4.24.'te gösterilmiştir. Bu istasyon için R değerleri %60 ile %61 arasında bulunmuştur. Genel olarak verilerin %61'i bu YSA modeli ile açıklanabilmektedir.




Şekil 4.23. Esenler istasyonu matlab eğitim parametreleri ekranı




Şekil 4.24. Esenler istasyonu için ağ eğitiminde regresyon değerleri

Menderes İstasyonu eğitim parametreleri Şekil 4.25.'te gösterilmiştir. Bu istasyon için eğitim R değeri 0.58721 olarak bulunmuştur. Buradan genel olarak verilerin yaklaşık %57'sinin bu YSA modeli ile açıklanabildiği sonucuna varmak mümkündür (Şekil 4.26.).

Esenler İstasyonu öğrenme parametreleri penceresi Şekil 4.23.'teki gibi doldurularak ağ eğitimi başlatılmıştır. Eğitilen ağın Esenler İstasyonu için regresyon değerleri Şekil 4.24.'te gösterilmiştir. Bu istasyon için R değerleri %60 ile %61 arasında bulunmuştur. Genel olarak verilerin %61'i bu YSA modeli ile açıklanabilmektedir.




Şekil 4.25. Menderes istasyonu matlab eğitim parametreleri ekranı




Şekil 4.26. Menderes istasyonu için ağ eğitiminde regresyon değerleri

Üçyüzlü İstasyonu için ağ yaratma işlemi sonrasında öğrenme parametreleri Şekil 4.27.'deki gibi tanımlanır. Daha sonra bu istasyon için yapay sinir ağı eğitimi başlatılır. Eğitimi tamamlanan ağın validasyon değeri %75 bulunurken genel olarak verilerin yaklaşık %64'ünün bu YSA modeli ile açıklanabildiğini söylemek mümkündür (Şekil 4.28.).




Şekil 4.27. Üçyüzlü istasyonu matlab eğitim parametreleri ekranı




Şekil 4.28. Üçyüzlü istasyonu için ağ eğitiminde regresyon değerleri

Bağcılar Meydan İstasyonu eğitim parametreleri Şekil 4.29.'da gösterilmiştir. Bu istasyon için eğitim R değeri 0.54154 olarak bulunmuştur. Şekil 4.30.'dan görüldüğü üzere genel olarak verilerin yaklaşık %53'ünün bu YSA modeli ile açıklanabildiği sonucuna varmak mümkündür.




Şekil 4.29. Bağcılar Meydan istasyonu matlab eğitim parametreleri ekranı




Şekil 4.30. Bağcılar Meydan istasyonu için ağ eğitiminde regresyon değerleri

Kirazlı M1 İstasyonu öğrenme parametreleri penceresi Şekil 4.31.'deki gibi doldurularak ağ eğitimi başlatılmıştır. Bu istasyon için test R değeri 0.75867 olarak bulunmuştur. YSA'nın bu veri setindeki başarısı genel olarak yaklaşık %64 olarak gözükmemektedir (Şekil 4.32.).




Şekil 4.31. Kirazlı M1 istasyonu matlab eğitim parametreleri ekranı




Şekil 4.32. Kirazlı M1 istasyonu için ağ eğitiminde regresyon değerleri

Gerçek veriler ve YSA ile istasyon bazlı en başarılı talep tahmininin karşılaştırılması Şekil 4.33.'te gösterilmektedir. Yapay sinir ağının genel olarak toplam yolcu sayısına ilişkin istasyon bazlı test verilerine çok yakın sonuçlar verdiği görülmektedir. Talebi etkileyen fazla değişken bulunması yapay sinir ağı modeli performansı için olumlu gözükmemektedir.




Şekil 4.33. Gerçek veri ve YSA ile istasyon bazlı talep tahmininin karşılaştırılması

Günlük bazda karşılaştırma yapıldığında, yapay sinir ağının toplam yolcu sayısının günlük test verilerine çok yakın sonuçlar verdiği görülmektedir. Günlük test verilerinin ve YSA ile günlük talep tahmininin karşılaştırılması Şekil 4.34.'de verilmiştir.



Şekil 4.34. Günlük test verileri ve YSA ile günlük talep tahmininin karşılaştırılması

Ayrıca, günlük test verilerinin ve Yenikapı İstasyonunun YSA ile talep tahmininin karşılaştırılması Şekil 4.35.'te verilmiştir.



Şekil 4.35. Günlük test verileri ve Yenikapı istasyonunun YSA ile talep tahmininin karşılaştırılması

MATLAB 2017b programı ile istasyon bazında karşılaştırma yapılmıştır. Yenikapı M1 – Kirazlı M1 hattındaki 2019'a ait gerçek veriler ve YSA çıktıları Tablo 4.1.'de verilmiştir.

Tablo 4.1. Gerçek verilerin ve YSA çıktılarının istasyon bazında karşılaştırılması

İstasyonlar	Gerçek Veriler	YSA Tahmin Değerleri
Yenikapı M1	21.580.918	22.359.554
Aksaray	10.512.904	15.114.789
Emniyet	6.786.245	8.131.640
Ulubatlı	4.976.793	4.717.769
Bayrampaşa	4.068.294	4.793.001
Sağmalcılar M1	5.940.868	5.993.238
Kocatepe	11.540.092	13.806.921
Otogar	6.335.930	9.274.460
Esenler	4.968.780	4.015.545
Menderes	5.295.528	5.722.780
Üçyüzlü	4.733.464	4.481.730
Bağcılar Meydan	5.718.710	5.319.202
Kirazlı M1	14.012.546	14.844.106

4.1.2. Raylı ulaşımında makine öğrenme algoritmaları ile talep tahmini

Bu bölümde Yenikapı M1 - Kirazlı M1 hattı geçmiş dönem verileri kullanılarak Yenikapı M1 - Kirazlı M1 hattı için gelecek dönem yolcu talep tahminleri yapılmakta ve veriler istasyon bazlı tahmin için kullanılmaktadır.

Talebi tahmin etmek için karar ağacı, lineer regresyon, polinom regresyon, destek vektör makinesi ve rassal orman algoritmaları Python 2.7.18 programı ile uygulanmaktadır. Bahsedilen makine öğrenmesi algoritmaları uygulanırken Python 2.7.18 programının 'pandas' kütüphanesi kullanılmıştır; kütüphanede kullanılan kodlar EK 1'de görülmektedir (PANDAS.PYDATA, 2020; SCİKİT-LEARN, 2020).

- Karar Ağacı: Uygulamada, öncelikle, güncel veri formatı csv formatındaki dosyaya aktarılmaktadır. Aktarım yapıldıktan sonra her istasyon için ayrı ayrı csv dosyası okutulmaktadır. Makine karar ağacı algoritması için eğitilmekte ve tahmin yaptırılmaktadır. Karar ağacı algoritmasını uygulamak için Python 2.7.18 programında 'DecisionTreeRegressor' fonksiyonu kullanılmıştır; kütüphanede kullanılan kodlar EK 1'de görülebilir (PANDAS.PYDATA, 2020; SCİKİT-LEARN, 2020).
- Doğrusal Regresyon: Aynı işlem doğrusal regresyon algoritması için de uygulanarak tahmin verileri elde edilmektedir; güncel veri formatı csv formatındaki dosyaya aktarılmaktadır. Aktarım yapıldıktan sonra her istasyon için ayrı ayrı csv dosyası okutulmaktadır. Makine doğrusal regresyon

algoritması için eğitilmekte ve tahmin yaptırılmaktadır. Doğrusal regresyon algoritmasını uygulamak için Python 2.7.18 programında 'Linear Regression' fonksiyonu kullanılmıştır; kütüphanede kullanılan kodlar EK 1'de görülebilir (PANDAS.PYDATA, 2020; SCİKİT-LEARN, 2020).

- **Rassal Orman Regresyonu:** Rassal orman regresyonu algoritması için güncel veri formatı csv formatındaki dosyaya aktarılmaktadır. Aktarım yapıldıktan sonra her istasyon için ayrı ayrı csv dosyası okutulmaktadır. Daha sonra rassal orman algoritması için makine eğitilmektedir. Rassal orman algoritması kullanılarak eğitilen makinenin verilen verilere göre bir tahmin yapması sağlanmaktadır. Uygulamada, `random_state`, modelin çıktısını çoğaltılamaz hale getirmekte, bu nedenle `random_state` değeri belli olduğunda, aynı parametreler ve aynı eğitim verileri verilirse aynı sonuçları üretecektir. `n_estimators` = kaç tane karar ağacı oluşturulacağını belirtmektedir. Rassal orman regresyon algoritmasını uygulamak için Python 2.7.18 programında 'Random Forest Regressor' fonksiyonu kullanılmıştır; kütüphanede kullanılan kodlar EK 1'de görülebilir (PANDAS.PYDATA, 2020; SCİKİT-LEARN, 2020).
- **Polinom Regresyon:** Polinom regresyonu algoritması için güncel veri formatı csv formatındaki dosyaya aktarılmaktadır. Aktarım yapıldıktan sonra her istasyon için ayrı ayrı csv dosyası okutulmaktadır. Polinom regresyon işlemi yapılırken eğitim sütunundaki değerler, makine eğitilmeden önce, `PolynomialFeatures` fonksiyonu ile dönüştürülmektedir. Buradaki derece (degree) parametresi polinomun derecesidir; derece ne kadar artarsa o kadar sağlıklı sonuç alınabilmektedir. Tahmin, makine polinom regresyon algoritması için eğitildikten sonra yapılmaktadır. Polinom regresyon algoritmasını uygulamak için Python 2.7.18 programında 'Polynomial Features' fonksiyonu kullanılmıştır; kütüphanede kullanılan kodlar EK 1'de görülebilir (PANDAS.PYDATA, 2020; SCİKİT-LEARN, 2020).
- **Destek Vektör Regresyonu:** Destek vektör regresyonu algoritması için güncel veri formatı csv formatındaki dosyaya aktarılmaktadır. Aktarım yapıldıktan sonra her istasyon için ayrı ayrı csv dosyası okutulmaktadır. Daha sonra destek vektör regresyonu algoritması için makine eğitilmektedir. Destek vektör

regresyonu algoritması kullanılarak eğitilen makinenin verilen verilere göre bir tahmin yapması sağlanmaktadır. Ardından, gerçek veriler ölçeklenmektedir. Son olarak, makine eğitildikten sonra destek vektör regresyonu için ölçeklendirilmiş verilere göre tahmin yapılmaktadır. Destek vektör regresyonu algoritmasını uygulamak için Python 2.7.18 programında 'Standard Scaler' fonksiyonu kullanılmıştır; kütüphanede kullanılan kodlar EK 1'de görülebilir (PANDAS.PYDATA, 2020; SCİKİT-LEARN, 2020).


Python 2.7.18 programının 'pandas' kütüphanesi kullanılarak elde edilen tahmin verileri Tablo 4.2.'de verilmiştir.



Tablo 4.2. Yenikapı – Kirazlı hattındaki istasyonlar için MÖ algoritmaları ile elde edilen tahmin verileri


Algoritma/ İstasyon	Yenikapı M1	Aksaray	Emniyet	Ulubatlı	Bayrampaşa	Sağmalcılar M1	Kocatepe	Otogar	Esenler	Menderes	Üçyüzlü	Bağcılar Meydan	Kirazlı M1
Karar Ağacı	21.604.501	10.539.75	6.789.353	4.975.577	4.082.877	5.942.904	11.565.433	6.214.932	4.976.127	5.300.183	4.736.340	5.766.335	14.030.227
Doğrusal		10.336.05											
Regresyon	20.450.369	5	6.077.873	4.660.471	3.884.512	5.648.917	11.866.587	6.546.065	4.893.702	5.191.985	4.583.896	5.670.679	13.324.303
Rassal													
Orman		10.554.03											
Regresyonu	22.009.946	2	7.080.301	5.103.849	4.148.025	6.056.633	11.382.133	6.198.917	4.992.412	5.329.567	4.789.098	5.739.671	14.302.624
Polinom		10.372.54											
Regresyon	21.029.558	7	6.232.495	4.759.887	3.989.601	5.749.993	12.058.786	6.775.188	4.998.213	5.249.843	4.681.280	5.805.516	13.614.183
Destek													
Vektör		10.422.91											
Regresyonu	22.033.163	8	6.958.298	5.084.261	4.121.065	6.003.844	11.569.292	6.108.937	5.015.730	5.350.201	4.787.869	5.776.229	14.134.258

Şekil 4.36., hattaki istasyonlar için makine öğrenimi algoritmalarının tahmin sonuçlarının karşılaştırmasını göstermektedir:



Şekil 4.36. MÖ algoritmaları talep tahmin sonuçlarının karşılaştırılması

Toplam yolcu sayısının istasyon bazında (gerçek veri, yapay sinir ağı ve karar ağacı) karşılaştırılması Şekil 4.37.'de verilmiştir:



Şekil 4.37. Gerçek veriler ile karar ağacı ve YSA talep tahmin sonuçlarının karşılaştırılması

Gerçek veriler ile YSA'lar ve ML algoritmaları için tahmin değeri Tablo 4.3.'te gösterilmiştir.


Tablo 4.3. Gerçek değer ve istasyon bazlı tahmin değerleri

İstasyon	Gerçek Veri	YSA Çıktısı	Karar Ağacı Çıktısı	Doğrusal Regresyon Çıktısı	Rassal Orman Regresyonu Çıktısı	Polinom Regresyon Çıktısı	Destek Vektör Regresyonu Çıktısı
Yenikapı M1	21.580.918	22.359.554	21.604.501	20.450.369	22.009.946	21.029.558	22.033.163
Aksaray	10.512.904	15.114.789	10.539.756	10.336.055	10.554.032	10.372.547	10.422.918
Emniyet	6.786.245	8.131.640	6.789.353	6.077.873	7.080.301	6.232.495	6.958.298
Ulubatlı	4.976.793	4.717.769	4.975.577	4.660.471	5.103.849	4.759.887	5.084.261
Bayrampaşa	4.068.294	4.793.001	4.082.877	3.884.512	4.148.025	3.989.601	4.121.065
Sağmalcılar M1	5.940.868	5.993.238	5.942.904	5.648.917	6.056.633	5.749.993	6.003.844

Tablo 4.3. (Devamı)

Kocatepe	11.540.092	13.806.921	11.565.433	11.866.587	11.382.133	12.058.786	11.569.292
Otogar	6.335.930	9.274.460	6.214.932	6.546.065	6.198.917	6.775.188	6.108.937
Esenler	4.968.780	4.015.545	4.976.127	4.893.702	4.992.412	4.998.213	5.015.730
Menderes	5.295.528	5.722.780	5.300.183	5.191.985	5.329.567	5.249.843	5.350.201
Üçyüzlü	4.733.464	4.481.730	4.736.340	4.583.896	4.789.098	4.681.280	4.787.869
Bağcılar	5.718.710	5.319.202	5.766.335	5.670.679	5.739.671	5.805.516	5.776.229
Meydan							
Kirazlı							
M1	14.012.546	14.844.106	14.030.227	13.324.303	14.302.624	13.614.183	14.134.258

Şekil 4.38.'de görüldüğü gibi bir makine öğrenmesi algoritması olan karar ağacı en iyi yolcu talep tahminini yapmıştır.



Şekil 4.38. Gerçek değer ile istasyon bazlı tahmin değerlerinin karşılaştırılması

Tahmin değerleri hem YSA hem de MÖ algoritmalarıyla elde edildikten sonra BIAS, MAE, MSE, MAPE ve RMSE ile değerlendirme yapılmıştır. Hatalar her algoritma için ayrı ayrı hesaplanmıştır. MAE, MSE, BIAS, MAPE ve RMSE sırasıyla, Denklem 3.5, 3.6, 3.7, 3.8, 3.9'da belirtildiği gibi hesaplanmaktadır.

YSA ve MÖ algoritmaları altında elde edilen hata ölçüleri Tablo 4.4.'te verilmiştir.

Tablo 4.4. YSA ve MÖ algoritmaları altında elde edilen hata ölçüleri

Hata	Yöntem					Dester Vektör Regresyonu
	Yapay Sinir Ağı	Karar Ağacı	Doğrusal Regresyon	Rassal Orman Regresyonu	Polinom Regresyon	
BIAS	778.636	23.583	1.130.549	429.028	551.360	452.245
MAE	2.133	65	3.097	1.175	1.511	1.239
			3.501.756.27	504.287.73		
MSE	1.661.024.714	1.523.720	8	9	832.870.821	560.343.945
MAPE	0,0099	0,0003	0,0144	0,0054	0,0070	0,0057
RMSE	46,1871	8,0381	55,6542	34,2844	38,8661	35,1998

Yenikapı M1 - Kirazlı M1 hattı için istasyon bazlı tahmin yapılırken kullanılan yöntemlerin (yapay sinir ağları ve makine öğrenmesi algoritmalarından karar ağacı, doğrusal regresyon, rassal orman regresyonu, polinom regresyon ve destek vektör regresyonu) BIAS, MAE, MSE, MAPE ve RMSE hata oranları karşılaştırılmış; bu veri setinde MAPE oranları; karar ağacı için %0,03, rassal orman için %0,54, ve destek vektör regresyonu için %0,57 olarak bulunmuştur. Sonuçlardan da anlaşılacağı üzere, en doğru tahmin makine öğrenmesi algoritmaları ile elde edilmiştir.

4.1.3. Raylı ulaşımında regresyon analiz tekniği ile talep tahmini

Bu bölümde, Yenikapı M1 - Kirazlı M1 hattı geçmiş dönem verileri kullanılarak Yenikapı M1 - Kirazlı M1 hattı için gelecek dönem hat bazlı yolcu talep tahminleri yapılmıştır. Talep tahmini, SPSS Statistics 21.0 programında en küçük kareler yöntemi kullanılarak yapılmıştır. Bu yöntemle hafta içi ve hafta sonu yolcu talep tahminleri hat bazında yapılmıştır. Uygulamada, öncelikle test verileri hafta içi ve hafta sonu olmak üzere iki gruba ayrılmıştır. Daha sonra veriler SPSS Statistics 21.0 programına aktarılmıştır. Regresyon analizi sonuçlarına göre model, hafta içi sonucuna göre yaklaşık %95 oranında başarılı olmuştur (Tablo 4.5.); hafta sonu sonucuna göre ise %86 başarılı bulunmuştur (Tablo 4.6.).

Tablo 4.5. Hafta içi günler için model özeti

Model	R	R Square	Adjusted R Square
1	,977 ^a	,954	,949

Tablo 4.6. Hafta sonu günler için model özeti

Model	R	R Square	Adjusted R Square
1	,927 ^a	,860	,854

Tablo 4.7. hafta içi katsayılar tablosunu gösterirken, Tablo 4.8. hafta sonu katsayılar tablosunu belirtmektedir. Katsayılar tablosundaki değerler, regresyon denkleminde kullanılacak regresyon katsayılarını ve önem düzeylerini vermektedir (Tablo 4.7., 4.8.).

Tablo 4.7. Hafta içi için katsayılar

Model	Unstandardized Coefficients		Standardized Coefficients		
	B	Std. Error	Beta	t	Sig.
1 (Constant)	-202980,131	106543,892		-1,905	,063
Pazartesi	1,678	,292	,252	5,749	,000
Salı	1,727	,325	,258	5,314	,000
Çarşamba	,457	,547	,065	,834	,409
Perşembe	2,011	,609	,308	3,299	,002
Cuma	1,353	,345	,248	3,916	,000

Tablo 4.8. Hafta sonu için katsayılar

Model	Unstandardized Coefficients		Standardized Coefficients		
	B	Std. Error	Beta	t	Sig.
1 (Constant)	1077192,668	105946,505		10,167	,000
Cumartesi	3,613	,473	,784	7,643	,000
Pazar	,932	,588	,163	1,586	,119

Tablo 4.7.'deki katsayı değerleri regresyon modeline dönüştürüldüğünde Pazartesi günü için Denklem 4.1 elde edilmektedir.

$$b_1 = \text{Pazartesi}$$

$$y_1 = a + b_1 X_1$$

$$y_1 = -202980,131 + 1,678 X_1 \quad (4.1)$$

Denklem 4.1'e X_1 (gerçek veri) değeri yazıldığında Pazartesi günü için tahmin değerleri elde edilmektedir.

Pazartesi günü için yapılan çalışma haftanın 7 günü için uygulanmıştır. Tablo 4.7.'deki katsayı değerleri regresyon modeline dönüştürüldüğünde Salı, Çarşamba, Perşembe, Cuma günleri için sırasıyla Denklem 4.2, 4.3, 4.4, 4.5 elde edilmektedir.

$b_2 = \text{Salı}$

$$y_2 = a + b_2 X_2$$

$$y_2 = -202980,131 + 1,727 X_2 \quad (4.2)$$

$b_3 = \text{Çarşamba}$

$$y_3 = a + b_3 X_3$$

$$y_3 = -202980,131 + 0,457 X_3 \quad (4.3)$$

$b_4 = \text{Perşembe}$

$$y_4 = a + b_4 X_4$$

$$y_4 = -202980,131 + 2,011 X_4 \quad (4.4)$$

$b_5 = \text{Cuma}$

$$y_5 = a + b_5 X_5$$

$$y_5 = -202980,131 + 1,353 X_5 \quad (4.5)$$

Denklem 4.2'ye X_2 , Denklem 4.3'e X_3 , Denklem 4.4'e X_4 , Denklem 4.5'e X_5 gerçek veri değerleri yazıldığında sırasıyla Salı, Çarşamba, Perşembe, Cuma günleri için tahmin değerleri elde edilmektedir.

Tablo 4.8.'deki katsayı değerleri regresyon modeline dönüştürüldüğünde Cumartesi günü için Denklem 4.6 elde edilmektedir.

$b_6 = \text{Cumartesi}$

$$y_6 = a + b_6 X_6$$

$$y_6 = 1077192,668 + 3,613 X_6 \quad (4.6)$$

Denklem 4.6'ya X_6 (gerçek veri) değeri yazıldığında Cumartesi günü için tahmin değerleri elde edilmektedir.

Benzer şekilde, Tablo 4.8.'deki katsayı değerleri regresyon modeline dönüştürüldüğünde Pazar günü için Denklem 4.7 elde edilmektedir.

$b_7 = \text{Pazar}$


$$y_7 = a + b_7 X_7$$

$$y_7 = 1077192,668 + 0,932X_7 \quad (4.7)$$

Denklem 4.7'ye X_7 (gerçek veri) değeri yazıldığında Pazar günü için tahmin değerleri elde edilmektedir.


Test değerleri bu denklem ile test edildiğinde hafta içi için 0,01 ve hafta sonu için 0,04 MAPE (ortalama mutlak yüzde hatası) değerleri elde edilmiştir. Şekil 4.39. ve Şekil 4.40. gerçek değeri ve regresyon çıktısını göstermektedir.

Şekil 4.39., hafta içi için regresyon analizi sonuçlarının ve test değerlerinin karşılaştırmasını göstermektedir.



Şekil 4.39. Hafta içi için regresyon analizi sonuçlarının ve test değerlerinin karşılaştırılması

Şekil 4.40., Hafta sonları için regresyon analizi sonuçlarının ve test değerlerinin karşılaştırmasını göstermektedir.



Şekil 4.40. Hafta sonu için regresyon analizi sonuçlarının ve test değerlerinin karşılaştırılması

4.1.4. Raylı ulaşım da basit ortalama yöntemi ile talep tahmini

Bu bölümde, Yenikapı M1 - Kirazlı M1 hattı geçmiş dönem verileri kullanılarak Yenikapı M1 - Kirazlı M1 hattı için gelecek dönem hat bazlı yolcu talep tahminleri yapılmıştır. Uygulamada, basit ortalama yöntemi ele alınmış; geçmiş dönemdeki (gerçekleşmiş değerler) tüm yolcuların ortalaması alınarak hesaplama yapılmıştır. Bulunan sonuç talep tahmin değerini vermektedir. İlk olarak, önceki dönem verileri hafta içi ve hafta sonu olarak gruplara ayrılmış; Denklem 3.3 ve Denklem 3.4'te belirtilen basit ortalama yöntemi formülleri modele uygulanmıştır. Önceki dönem verileri (gerçek veri) ve basit ortalama yöntemiyle elde edilen talep tahmin verileri Tablo 4.9.'da gösterilmiştir.


Tablo 4.9. Önceki dönem verileri ve basit ortalama yöntemi çıktıları

Hafta İçi Yolcu Talebi	Hafta İçi Yolcu Talep Tahmini	Hafta Sonu Yolcu Talebi	Hafta Sonu Yolcu Talep Tahmini
2.025.123	2.176.391	634.854	772.038
2.113.992	2.172.189	714.642	768.228
2.165.580	2.170.616	795.734	766.779
2.170.861	2.170.483	761.821	767.541
2.166.298	2.170.493	780.742	767.395
2.177.536	2.170.388	787.956	767.728
2.233.456	2.170.563	778.684	768.222
2.237.059	2.172.060	656.098	768.471
2.260.222	2.173.572	788.718	765.858


Tablo 4.9. (Devamı)

2.319.676	2.175.541	855.186	766.377
2.262.472	2.178.744	835.137	768.351
2.307.455	2.180.564	861.863	769.803
2.258.889	2.183.264	680.809	771.761
2.244.085	2.184.839	785.750	769.866
2.132.544	2.186.049	777.663	770.191
2.172.791	2.184.978	767.445	770.340
2.175.915	2.184.739	805.998	770.283
2.079.938	2.184.570	796.652	770.970
1.918.410	2.182.596	627.253	771.455
1.966.334	2.177.703	694.259	768.784
1.993.737	2.173.860	688.237	767.429
1.954.471	2.170.644	691.810	766.015
1.992.575	2.166.851	608.116	764.713
2.026.301	2.163.846	711.087	762.013
2.045.208	2.161.515	713.130	761.150
2.077.905	2.159.577	734.721	760.350
1.995.285	2.158.238	719.909	759.930
2.021.034	2.155.610	690.359	759.284
1.962.538	2.153.473	677.492	758.190
1.921.387	2.150.490	679.570	756.929
1.899.428	2.146.965	659.466	755.739
1.898.887	2.143.215	630.724	754.280
1.728.949	2.139.568	532.587	752.436
1.858.581	2.133.530	631.778	749.203
1.912.528	2.129.545	649.987	747.501
2.008.897	2.126.445	722.052	746.108
2.077.931	2.124.789	739.052	745.769
2.338.218	2.124.138	1.043.731	745.676
2.163.561	2.127.071	735.270	749.759
2.269.457	2.127.564	788.128	749.563
2.255.332	2.129.456	823.466	750.078
2.258.818	2.131.112	791.299	751.043
2.246.517	2.132.771	763.698	751.566
2.185.191	2.134.229	773.594	751.722
2.240.488	2.134.874	799.273	751.998
2.264.463	2.136.194	821.983	752.589
2.331.065	2.137.778	818.190	753.446
2.270.327	2.140.135	759.505	754.236
2.229.270	2.141.703	784.941	754.299
2.241.035	2.142.746	774.119	754.664
2.231.323	2.143.902	749.489	754.893
2.184.773	2.144.919	686.642	754.830

Şekil 4.41. hafta içi için gerçek değeri ve basit ortalama yöntem çıktısını gösterirken,
 Şekil 4.42. hafta sonu için gerçek değeri ve basit ortalama yöntem çıktısını göstermektedir.



Şekil 4.41. Hafta içi test değerleri ile basit ortalama yöntemi sonucunda elde edilen değerler



Şekil 4.42. Hafta sonu test değerleri ile basit ortalama yöntemi sonucunda elde edilen değerler

Yenikapı M1 - Kirazlı M1 hattı için hat bazlı tahmin değerleri regresyon analizi ve basit ortalama yöntemi ile elde edildikten sonra MAPE ile değerlendirme yapılmıştır. Hatalar iki yöntem için ayrı ayrı hesaplanmıştır. MAPE 3.8’de belirtildiği gibi modele uygulanmıştır.

Bu yöntem için MAPE (ortalama mutlak yüzde hatası) değerleri hafta içi 0,001, hafta sonu 0,002 olarak elde edilmiştir.

Ortalama mutlak yüzde hatası (MAPE), Denklem 3.8’de belirtildiği üzere regresyon analizi ve basit ortalama yöntemi ile bulunan tahminler için hesaplanmıştır. Her iki yöntem için de MAPE değeri Tablo 4.10.’da verilmiştir.

Tablo 4.10. Regresyon analizi tekniği ve basit ortalama yöntemi için MAPE değerleri

	Yöntem	
	Regresyon Analiz Tekniği	Basit Ortalama Yöntemi
Hafta İçi	0,01	0,001
Hafta Sonu	0,04	0,002

Regresyon analizi ve basit ortalama yöntemi ile elde edilen tahmin sonuçlarından da anlaşılacağı gibi, hat bazında yolcu talebi tahmininde basit ortalama yöntemi daha başarılı olmuştur.

4.2. Raylı Ulaşımın Çok Kriterli Karar Verme Yöntemleri Uygulaması

Bu bölümde raylı ulaşım sistemlerinde sefer sıklığı optimizasyonunda kritik başarı faktörleri tartışılmış ve bu faktörlerin önceliklendirilmesi AHP, SWARA ve TOPSİS yöntemi ile araştırılmıştır.

4.2.1. Problemin AHP yöntemi ile çözümü

Sefer sıklıkları optimizasyonunda 6 ana kriter ve 6 kritik başarı faktörü AHP yöntemi ile aşağıdaki adımlarda belirtildiği üzere önceliklendirilmiştir.

4.2.1.1. Karar probleminin tanımı

Karar problemi, sefer sıklığı optimizasyonunda kritik başarı faktörlerinin öncelik seviyelerinin ortaya koyulmasını sağlayan bir sistem tasarlamaktadır.

4.2.1.2. Hiyerarşinin oluşturulması

Hiyerarşi yapısını oluşturacak amaç, sefer sıklığı optimizasyonunda kritik başarı faktörü seçimidir. Çalışmada, “sosyal etki, kalite, maliyet, kapasite, çevre bilinci ve güvenilirlik” olmak üzere 6 ana kriter belirtilmiştir (Canci ve Onden, 2013; Hamurcu ve Eren, 2017).

Ana kriterler, problemin amacına göre sefer sıklığı optimizasyonunda kritik başarı faktörü önceliklendirmeyi sağlayacak şekilde oluşturulmuştur. Ele alınan ana kriterler;


- Sosyal etki (Hamurcu ve Eren, 2017),
- Kalite (Canci ve Onden, 2013),
- Maliyet (Canci ve Onden, 2013),
- Kapasite (Canci ve Onden, 2013),
- Çevre bilinci (Canci ve Onden, 2013),
- Güvenilirlik' tir (Canci ve Onden, 2013).

Tanımlanan tüm ana kriter ve karar alternatifleri Tablo 4.11.'de görülmektedir. Problemin oluşturulan hiyerarşik modeli ise Şekil 4.43.'te yer almaktadır. Burada ele alınan problemin amacı, belirlenen ana kriterler ve karar alternatifleri için AHP modeli görülmektedir.

Tablo 4.11. Tanımlanan ana kriter ve karar alternatifleri

Karar Problemi	Ana Kriterler	Karar Alternatifleri
Sefer Sıklığı Optimizasyonunda Kritik Başarı Faktörü Seçimi	Güvenilirlik	Hat Karakteristikleri
	Kalite	Yolcu Akımı
	Maliyet	Servis Standartları
	Kapasite	Araçlar
	Çevreye Duyarlılık	İşletme Faktörleri
	Sosyal Etki	Çalışma Kuralları

Problemin karar hiyerarşisini oluştururken kullanılan 6 ana kriter ve 6 karar alternatifi Şekil 4.43'te verilmiştir.



Şekil 4.43. AHP karar hiyerarşisi

4.2.1.3. Ana kriterler arasında ikili karşılaştırma matrislerinin oluşturulması

Çalışmanın bu bölümünde ikili karşılaştırma matrisleri yer alacaktır. Öncelikle, ana kriterler arasındaki önem düzeyi, ana kriterler arasında ikili karşılaştırma matrisleri oluşturularak belirlenecektir (Tablo 4.12.). Belirlenen ana kriter ve kritik başarı faktörlerinin (alternatiflerin) AHP tekniği ile ağırlıklandırılması yapılmıştır.

Sefer sıklığı optimizasyonunda kritik başarı faktörlerinin önceliğini değerlendirmek için oluşturulan ana kriterlerin birbirlerine göre önem derecelerini saptayabilmek için uzmanın vereceği yargıların sayısallaştırıldığı ikili karşılaştırma matrisi Tablo 4.12.'de verilmiştir. Uzman, güvenilirlik ana kriterinin kalite, kapasite ve çevreye duyarlılık ana kriterlerinden Saaty ölçeğine göre 4 derece daha önemli olduğunu matrislere aktarmıştır.

Tablo 4.12. Kritik başarı faktörü önceliklendirilmesi karşılaştırma matrisi ve önem düzeyleri

Kritik Başarı Faktörü	Sosyal Etki	Kalite	Maliyet	Kapasite	Çevreye Duyarlılık	Güvenilirlik	Önem Düzeyi
Sosyal Etki	1	7	1	1	4	1	0,252301679
Kalite	1/7	1	1/4	1	1	1/4	0,064565935
Maliyet	1	4	1	2	3	1	0,229285806
Kapasite	1	1	1/2	1	1	1/4	0,107290342
Çevreye Duyarlılık	1/4	1	1/3	1	1	1/4	0,072032336
Güvenilirlik	1	4	1	4	4	1	0,274523902
TUTARLILIK ORANI:			0,049424			TOPLAM	1

Tablo 4.12.'ye ulaşabilmek için ilk olarak Tablo 4.13.'te belirtildiği gibi sütun toplamaları hesaplanmaktadır.

Tablo 4.13. Ana kriterler için hesaplama tablosu - 1

Kritik Başarı Faktörü	Sosyal Etki	Kalite	Maliyet	Kapasite	Çevreye Duyarlılık	Güvenilirlik
Sosyal Etki	1	7	1	1	4	1
Kalite	1/7	1	1/4	1	1	1/4
Maliyet	1	4	1	2	3	1
Kapasite	1	1	1/2	1	1	1/4
Çevreye Duyarlılık	1/4	1	1/3	1	1	1/4
Güvenilirlik	1	4	1	4	4	1
SÜTUN TOPLAMI	123/28	18	49/12	10	14	15/4

Sonra her satır Tablo 4.13.'te hesaplanan sütun toplamına bölünerek Tablo 4.14. elde edilir.

Tablo 4.14. Ana kriterler için hesaplama tablosu - 2

Kritik Başarı Faktörü	Sosyal Etki	Kalite	Maliyet	Kapasite	Çevreye Duyarlılık	Güvenilirlik
Sosyal Etki	28/123	7/18	12/49	1/10	2/7	4/15
Kalite	4/123	1/18	3/49	1/10	1/14	1/15
Maliyet	28/123	2/9	12/49	1/5	3/14	4/15
Kapasite	28/123	1/18	6/49	1/10	1/14	1/15
Çevreye Duyarlılık	7/123	1/18	4/49	1/10	1/14	1/15
Güvenilirlik	28/123	2/9	12/49	2/5	2/7	4/15

Akabinde, satır toplamı hesaplanmakta ve satır aritmetik ortalamaları bulunarak Tablo 4.15.'e ulaşılmaktadır.

Tablo 4.15. Ana kriterler için hesaplama tablosu - 3

Kritik Başarı Faktörü	Sosyal Etki	Kalite	Maliyet	Kapasite	Çevreye Duyarlılık	Güvenilirlik	Satır Toplamı	Satır Ortalaması
Sosyal Etki	0,227642	0,388889	0,244898	0,100000	0,285714	0,266667	1,513810	0,252301679
Kalite	0,032520	0,055556	0,061224	0,100000	0,071429	0,066667	0,387396	0,064565935
Maliyet	0,227642	0,222222	0,244898	0,200000	0,214286	0,266667	1,375715	0,229285806
Kapasite	0,227642	0,055556	0,122449	0,100000	0,071429	0,066667	0,643742	0,107290342
Çevreye Duyarlılık	0,056911	0,055556	0,081633	0,100000	0,071429	0,066667	0,432194	0,072032336
Güvenilirlik	0,227642	0,222222	0,244898	0,400000	0,285714	0,266667	1,647143	0,274523902

Satır ortalamaları kriterlerin önem düzeylerini göstermektedir. Uzmanın Saaty ölçeğine göre oluşturduğu matris ile önem düzeyleri matrisi çarpılarak Tablo 4.16.'ya ulaşılmaktadır.

Tablo 4.16. Ana kriterler için hesaplama tablosu - 4

								v	v/w
1	7	1	1	4	1			0,252301679	1,60349262
0,14	1	0,25	1	1	0,25			0,064565935	0,40516327
1	4	1	2	3	1	*		0,229285806	1,44505282
1	1	0,5	1	1	0,25			0,107290342	0,67946417
0,25	1	0,33	1	1	0,25		=	0,072032336	0,45125932
1	4	1	4	4	1			0,274523902	1,73166584
									6,355458
									6,275186
									6,302409
									6,332948
									6,264677
									6,307887

Tutarlılık göstergesi ve tutarlılık oranı Tablo 4.17.'de hesaplanarak matrisin 0,1'den küçük olduğu için tutarlı olduğu sonucuna ulaşılmaktadır.

Tablo 4.17. Ana kriterler için hesaplama tablosu-5

En büyük özdeğer,
$\lambda_{\max} = (6,355458 + 6,275186 + 6,302409 + 6,332948 + 6,264677 + 6,307887) / 6 = 6,35004$
Rassallık göstergesi (RG) tablodan; $n=6$ için $RG=1,24$ 'tür.
Tutarlılık göstergesi (CI) = $(6,306427 - 6) / (6 - 1) = 0,061285$
Tutarlılık Oranı (CR) = $0,061285 / 1,24 = 0,049424$
$0,049424 < 0,1$ olduğu için matris tutarlı sayılabilmektedir.

4.2.1.4. Karar alternatifleri için ikili karşılaştırma matrislerinin oluşturulması

Ana kriterlerin ikili karşılaştırmasından sonra, her bir alternatif tüm ana kriterler açısından değerlendirilmiştir. Karşılaştırmalar değerlendirilirken uzman görüşü dikkate alınmıştır (Tablo 4.18.).

Güvenilirlik ana kriterine göre karar alternatifleriyle ilgili yargılar Tablo 4.18'de verilmiştir. Uzman, güvenilirlik ana kriterine göre, hat karakteristikleri faktörünün yolcu akımı, servis standartları ve araçlar faktörlerinden daha önemli olduğunu 5 rakamı ile sayısalılaştırmıştır.

Tablo 4.18. Güvenilirlik ana kriterine göre kritik başarı faktörü önceliklendirilmesi karşılaştırma matrisi ve önem düzeyleri

Güvenilirlik	Hat Karakteristikleri	Yolcu Akımı	Servis Standartları	Araçlar	İşletme Faktörleri	Çalışma Kuralları	Önem Düzeyi
Hat Karakteristikleri	1	5	5	5	7	7	0,511469105
Yolcu Akımı	1/5	1	1	3	1	1	0,109769311
Servis Standartları	1/5	1	1	2	1	1/3	0,089548723
Araçlar	1/5	1/3	1/2	1	1/3	1/3	0,050789741
İşletme Faktörleri	1/7	1	1	3	1	1	0,104718806
Çalışma Kuralları	1/7	1	3	3	1	1	0,133704313
TUTARLILIK ORANI:		0,052313				TOPLAM	1

Tablo 4.18.'e ulaşabilmek için öncelikle Tablo 4.19.'da belirtildiği gibi sütun toplamaları hesaplanmaktadır.

Tablo 4.19. Güvenilirlik ana kriterine göre karar alternatifleri için hesaplama tablosu-1

Güvenilirlik	Hat Karakteristikleri	Yolcu Akımı	Servis Standartları	Araçlar	İşletme Faktörleri	Çalışma Kuralları
Hat						
Karakteristikleri	1	5	5	5	7	7
Yolcu Akımı	1/5	1	1	3	1	1
Servis						
Standartları	1/5	1	1	2	1	1/3
Araçlar	1/5	1/3	1/2	1	1/3	1/3
İşletme						
Faktörleri	1/7	1	1	3	1	1
Çalışma						
Kuralları	1/7	1	3	3	1	1
SÜTUN TOPLAMI	66/35	28/3	23/2	17	34/3	32/3

Daha sonra, her satır Tablo 4.19.'da hesaplanan sütun toplamına bölünerek Tablo 4.20. elde edilmiştir.

Tablo 4.20. Güvenilirlik ana kriterine göre karar alternatifleri için hesaplama tablosu-2

Güvenilirlik	Hat Karakteristikleri	Yolcu Akımı	Servis Standartları	Araçlar	İşletme Faktörleri	Çalışma Kuralları
Hat						
Karakteristikleri	35/66	15/28	10/23	5/17	21/34	21/32
Yolcu Akımı	7/66	3/28	2/23	3/17	3/34	3/32
Servis						
Standartları	7/66	3/28	2/23	2/17	3/34	1/32
Araçlar	7/66	1/28	1/23	1/17	1/34	1/32
İşletme						
Faktörleri	5/66	3/28	2/23	3/17	3/34	3/32
Çalışma						
Kuralları	5/66	3/28	6/23	3/17	3/34	3/32

Akabinde, satır toplamı hesaplanır ve satır aritmetik ortalamaları bulunarak Tablo 4.21.'e ulaşılmaktadır.

Tablo 4.21. Güvenilirlik ana kriterine göre karar alternatifleri için hesaplama tablosu-3

Güvenilirlik	Hat Karakteristikleri	Yolcu Akımı	Servis Standartları	Araçlar	İşletme Faktörleri	Çalışma Kuralları	Satır Toplamı	Satır Ortalaması
Hat								
Karakteristikleri	0,530303	0,535714	0,434783	0,294118	0,617647	0,656250	3,068815	0,511469105
Yolcu Akımı	0,106061	0,107143	0,086957	0,176471	0,088235	0,093750	0,658616	0,109769311
Servis								
Standartları	0,106061	0,107143	0,086957	0,117647	0,088235	0,031250	0,537292	0,089548723
Araçlar	0,106061	0,035714	0,043478	0,058824	0,029412	0,031250	0,304738	0,050789741
İşletme								
Faktörleri	0,075758	0,107143	0,086957	0,176471	0,088235	0,093750	0,628313	0,104718806
Çalışma								
Kuralları	0,075758	0,107143	0,260870	0,176471	0,088235	0,093750	0,802226	0,133704313

Satır ortalamaları kriterlerin önem düzeylerini göstermektedir. Uzmanın Saaty ölçeğine göre oluşturduğu matris ile önem düzeyleri matrisi çarpılarak Tablo 4.22.'ye ulaşılmaktadır.

Tablo 4.22. Güvenilirlik ana kriterine göre karar alternatifleri için hesaplama tablosu-4

								V	V/W
1	5	5	5	7	7			0,511469105	3,43097
0,2	1	1	3	1	1			0,109769311	0,692404
0,2	1	1	2	1	0,33	X		0,089548723	0,552033
0,2	0,33	0,5	1	0,33	0,33			0,050789741	0,312761
0,14	1	1	3	1	1			0,104718806	0,661716
0,14	1	3	3	1	1			0,133704313	0,840813
									6,708069
									6,307812
									6,164606
									6,157965
									6,31898
									6,288604

Tutarlılık göstergesi ve tutarlılık oranı Tablo 4.23.'te hesaplanarak matrisin 0,1'den küçük olduğu için tutarlı olduğu sonucuna ulaşılmaktadır.

Tablo 4.23. Güvenilirlik ana kriterine göre karar alternatifleri için hesaplama tablosu-5

En büyük özdeğer,
$\text{Lamdamax} = (6,708069 + 6,307812 + 6,164606 + 6,157965 + 6,31898 + 6,288604) / 6 = 6,324339$
Rassallık göstergesi (RG) tablodan; $n=6$ için $\text{RG}=1,24$ 'tür.
Tutarlılık göstergesi (CI) = $(6,324339 - 6) / (6 - 1) = 0,064868$
Tutarlılık Oranı (CR) = $0,064868 / 1,24 = 0,052313$
$0,052313 < 0,1$ olduğu için matris tutarlı sayılabilmektedir.

Sosyal etki ana kriterine göre karar alternatifleriyle ilgili yargılar Tablo 4.24.'te verilmiştir. Uzman, sosyal etki ana kriterine göre, hat karakteristikleri faktörünün yolcu akımı, servis standartları ve araçlar faktörlerinden daha az önemli olduğunu 1/4 rakamı ile sayısallaştırmıştır.

Tablo 4.24. Sosyal etki ana kriterine göre kritik başarı faktörü önceliklendirilmesi karşılaştırma matrisi ve önem düzeyleri

Sosyal Etki	Hat Karakteristikleri	Yolcu Akımı	Servis Standartları	Araçlar	İşletme Faktörleri	Çalışma Kuralları	Önem Düzeyi
Hat							
Karakteristikleri	1	1/4	1/4	1/4	7	1/5	0,076598148
Yolcu Akımı	4	1	1	1	8	2	0,245977047
Servis							
Standartları	4	1	1	1	7	2	0,241591082
Araçlar	4	1	1	1	7	2	0,241591082
İşletme							
Faktörleri	1/7	1/8	1/7	1/7	1	1/8	0,026151202
Çalışma							
Kuralları	5	1/2	1/2	1/2	8	1	0,168091438
TUTARLILIK ORANI:		0,058469				TOPLAM	1

Tablo 4.24.'e ulaşabilmek için öncelikle Tablo 4.25.'te belirtildiği gibi sütun toplamaları hesaplanmaktadır.

Tablo 4.25. Sosyal etki ana kriterine göre karar alternatifleri için hesaplama tablosu-1

Sosyal Etki	Hat Karakteristikleri	Yolcu Akımı	Servis Standartları	Araçlar	İşletme Faktörleri	Çalışma Kuralları
Hat Karakteristikleri						
İ	1	1/4	1/4	1/4	7	1/5
Yolcu Akımı	4	1	1	1	8	2
Servis Standartları	4	1	1	1	7	2
Araçlar	4	1	1	1	7	2
İşletme Faktörleri	1/7	1/8	1/7	1/7	1	1/8
Çalışma Kuralları	5	1/2	1/2	1/2	8	1
SÜTUN TOPLAMI	127/7	31/8	109/28	109/28	38	293/40

Daha sonra, her satır Tablo 4.25.'te hesaplanan sütun toplamına bölünerek Tablo 4.26. elde edilmiştir.

Tablo 4.26. Sosyal etki ana kriterine göre karar alternatifleri için hesaplama tablosu-2

Sosyal Etki	Hat Karakteristikleri	Yolcu Akımı	Servis Standartları	Araçlar	İşletme Faktörleri	Çalışma Kuralları
Hat Karakteristikleri	7/127	2/31	7/109	7/109	7/38	8/293
Yolcu Akımı	28/127	8/31	28/109	28/109	4/19	80/293
Servis Standartları	28/127	8/31	28/109	28/109	7/38	80/293
Araçlar	28/127	8/31	28/109	28/109	7/38	80/293
İşletme Faktörleri	1/127	1/31	4/109	4/109	1/38	5/293
Çalışma Kuralları	35/127	4/31	14/109	14/109	4/19	40/293

Akabinde, satır toplamı hesaplanır ve satır aritmetik ortalamaları bulunarak Tablo 4.27.'ye ulaşılmaktadır.

Tablo 4.27. Sosyal etki ana kriterine göre karar alternatifleri için hesaplama tablosu-3

Sosyal Etki	Hat Karakteristikleri	Yolcu Akımı	Servis Standartları	Araçlar	İşletme Faktörleri	Çalışma Kuralları	Satır Toplamı	Satır Ortalaması
Hat Karakteristikleri	0,055118	0,064516	0,064220	0,064220	0,184211	0,027304	0,459589	0,076598148
Yolcu Akımı	0,220472	0,258065	0,256881	0,256881	0,210526	0,273038	1,475862	0,245977047
Servis Standartları	0,220472	0,258065	0,256881	0,256881	0,184211	0,273038	1,449546	0,241591082
Araçlar	0,220472	0,258065	0,256881	0,256881	0,184211	0,273038	1,449546	0,241591082
İşletme Faktörleri	0,007874	0,032258	0,036697	0,036697	0,026316	0,017065	0,156907	0,026151202
Çalışma Kuralları	0,275591	0,129032	0,128440	0,128440	0,210526	0,136519	1,008549	0,168091438

Satır ortalamaları kriterlerin önem düzeylerini göstermektedir. Uzmanın Saaty ölçeğine göre oluşturduğu matris ile önem düzeyleri matrisi çarpılarak Tablo 4.28.'e ulaşılmaktadır.

Tablo 4.28. Sosyal etki ana kriterine göre karar alternatifleri için hesaplama tablosu-4

								v	v/w
1	0,25	0,25	0,25	7	0,2		0,076598148	0,4755647	6,2085659
4	1	1	1	8	2	x	0,245977047	1,5809443	6,4272025
4	1	1	1	7	2		0,241591082	1,5547931	6,4356394
4	1	1	1	7	2		0,241591082	1,5547931	6,4356394
0,14	0,125	0,14	0,14	1	0,125		0,026151202	0,156279	5,975978
5	0,5	0,5	0,5	8	1		0,168091438	1,1248714	6,6920208

Tutarlılık göstergesi ve tutarlılık oranı Tablo 4.29.'da hesaplanarak matrisin 0,1'den küçük olduğu için tutarlı olduğu sonucuna ulaşılmaktadır.

Tablo 4.29. Sosyal etki ana kriterine göre karar alternatifleri için hesaplama tablosu-5

En büyük özdeğer,
$\lambda_{\max} = (6,208566 + 6,427203 + 6,435639 + 6,435639 + 5,975978 + 6,692021) / 6 = 6,362508$
Rassallık göstergesi (RG) tablodan; n=6 için RG=1,24'tür.
Tutarlılık göstergesi (CI) = $(6,362508 - 6) / (6 - 1) = 0,072502$
Tutarlılık Oranı (CR) = $0,072502 / 1,24 = 0,058469$
$0,058469 < 0,1$ olduğu için matris tutarlı sayılabilmektedir.

Kalite ana kriterine göre karar alternatifleriyle ilgili yargılar Tablo 4.30'da verilmiştir. Uzman, kalite ana kriterine göre, hat karakteristikleri faktörünün çalışma kuralları faktöründen daha önemli olduğunu 2 rakamı ile sayısallaştırmıştır.

Tablo 4.30. Kalite ana kriterine göre kritik başarı faktörü önceliklendirilmesi karşılaştırma matrisi ve önem düzeyleri

Kalite	Hat Karakteristikleri	Yolcu Akımı	Servis Standartları	Araçlar	İşletme Faktörleri	Çalışma Kuralları	Önem Düzeyi
Hat Karakteristikleri	1	3	1/2	4	1/3	2	0,150809814
Yolcu Akımı	1/3	1	1/5	2	1/6	1/2	0,058076616
Servis Standartları	2	5	1	6	1/3	3	0,237989746
Araçlar	1/4	1/2	1/6	1	1/7	1/3	0,03886827
İşletme Faktörleri	3	6	3	7	1	5	0,421618545
Çalışma Kuralları	1/2	2	1/3	3	1/5	1	0,09263701
TUTARLILIK ORANI:					0,022509	TOPLAM	1

Tablo 4.30.'a ulaşabilmek için öncelikle Tablo 4.31.'de belirtildiği gibi sütun toplamaları hesaplanmaktadır.

Tablo 4.31. Kalite ana kriterine göre karar alternatifleri için hesaplama tablosu-1

Kalite	Hat Karakteristikleri	Yolcu Akımı	Servis Standartları	Araçlar	İşletme Faktörleri	Çalışma Kuralları
Hat Karakteristikleri	1	3	1/2	4	1/3	2
Yolcu Akımı	1/3	1	1/5	2	1/6	1/2
Servis Standartları	2	5	1	6	1/3	3
Araçlar	1/4	1/2	1/6	1	1/7	1/3
İşletme Faktörleri	3	6	3	7	1	5
Çalışma Kuralları	1/2	2	1/3	3	1/5	1
SÜTUN TOPLAMI	85/12	35/2	26/5	23	457/210	71/6

Daha sonra, her satır Tablo 4.31.'de hesaplanan sütun toplamına bölünerek Tablo 4.32. elde edilmiştir.

Tablo 4.32. Kalite ana kriterine göre karar alternatifleri için hesaplama tablosu-2

Kalite	Hat Karakteristikleri	Yolcu Akımı	Servis Standartları	Araçlar	İşletme Faktörleri	Çalışma Kuralları
Hat Karakteristikleri	12/85	6/35	5/52	4/23	70/457	12/71
Yolcu Akımı	4/85	2/35	1/26	2/23	35/457	3/71
Servis Standartları	24/85	2/7	5/26	6/23	70/457	18/71
Araçlar	3/85	1/35	5/156	1/23	30/457	2/71
İşletme Faktörleri	36/85	12/35	15/26	7/23	210/457	30/71
Çalışma Kuralları	6/85	4/35	5/78	3/23	42/457	6/71

Akabinde, satır toplamı hesaplanır ve satır aritmetik ortalamaları bulunarak Tablo 4.33.'e ulaşılmaktadır.

Tablo 4.33. Kalite ana kriterine göre karar alternatifleri için hesaplama tablosu-3

Kalite	Hat Karakteristikleri	Yolcu Akımı	Servis Standartları	Araçlar	İşletme Faktörleri	Çalışma Kuralları	Satır Toplamı	Satır Ortalaması
Hat Karakteristikleri	0,141176	0,171429	0,096154	0,173913	0,153173	0,169014	0,904859	0,150809814
Yolcu Akımı	0,047059	0,057143	0,038462	0,086957	0,076586	0,042254	0,348460	0,058076616
Servis Standartları	0,282353	0,285714	0,192308	0,260870	0,153173	0,253521	1,427938	0,237989746
Araçlar	0,035294	0,028571	0,032051	0,043478	0,065646	0,028169	0,233210	0,03886827
İşletme Faktörleri	0,423529	0,342857	0,576923	0,304348	0,459519	0,422535	2,529711	0,421618545
Çalışma Kuralları	0,070588	0,114286	0,064103	0,130435	0,091904	0,084507	0,555822	0,09263701

Satır ortalamaları kriterlerin önem düzeylerini göstermektedir. Uzmanın Saaty ölçeğine göre oluşturduğu matris ile önem düzeyleri matrisi çarpılarak Tablo 4.34.'e ulaşılmaktadır.

Tablo 4.34. Kalite ana kriterine göre karar alternatifleri için hesaplama tablosu-4

						V		V/W	
1	3	0,5	4	0,33	2	0,150809814	0,9239158	6,1263636	
0,33	1	0,2	2	0,167	0,5	0,058076616	0,3499071	6,0249231	
2	5	1	6	0,33	3	0,237989746	1,4802472	6,2197941	
0,25	0,5	0,167	1	0,14	0,33	0,03886827	0,2349501	6,0447797	
3	6	3	7	1	5	0,421618545	2,6717399	6,3368651	
0,5	2	0,33	3	0,2	1	0,09263701	0,5636603	6,0846122	

Tutarlılık göstergesi ve tutarlılık oranı Tablo 4.35.'te hesaplanarak matrisin 0,1'den küçük olduğu için tutarlı olduğu sonucuna ulaşılmaktadır.

Tablo 4.35. Kalite ana kriterine göre karar alternatifleri için hesaplama tablosu-5

En büyük özdeğer,
$\text{Lamdmax}=(6,126364+6,024923+6,219794+6,04478+6,336865+6,084612)/6=6,139556$
Rassallık göstergesi (RG) tablodan; n=6 için RG=1,24'tür.
Tutarlılık göstergesi (CI) = $(6,139556-6)/(6-1)=0,027911$
Tutarlılık Oranı (CR) = $0,027911/1,24=0,022509$
$0,022509<0,1$ olduğu için matris tutarlı sayılabilmektedir.

Maliyet ana kriterine göre karar alternatifleriyle ilgili yargılar Tablo 4.36.'da verilmiştir. Uzman, maliyet ana kriterine göre, hat karakteristikleri faktörünün yolcu akımı, servis standartları ve araçlar faktörlerinden daha az önemli olduğunu 1/5 rakamı ile sayısallaştırmıştır.

Tablo 4.36. Maliyet ana kriterine göre kritik başarı faktörü önceliklendirilmesi karşılaştırma matrisi ve önem düzeyleri

Maliyet	Hat Karakteristikleri	Yolcu Akımı	Servis Standartları	Araçlar	İşletme Faktörleri	Çalışma Kuralları	Önem Düzeyi
Hat Karakteristikleri	1	1/5	1/5	1/5	1/7	1/7	0,03218501
Yolcu Akımı	5	1	1	3	1	1	0,211385755
Servis Standartları	5	1	1	2	1	1/3	0,168557886
Araçlar	5	1/3	1/2	1	1/3	1/3	0,093126374
İşletme Faktörleri	7	1	1	3	1	1	0,222496866
Çalışma Kuralları	7	1	3	3	1	1	0,27224811
TUTARLILIK ORANI:					0,030078	TOPLAM	1

Tablo 4.36.'ya ulaşabilmek için öncelikle Tablo 4.37.'de belirtildiği gibi sütun toplamaları hesaplanmaktadır.

Tablo 4.37. Maliyet ana kriterine göre karar alternatifleri için hesaplama tablosu-1

Maliyet	Hat Karakteristikleri	Yolcu Akımı	Servis Standartları	Araçlar	İşletme Faktörleri	Çalışma Kuralları
Hat Karakteristikleri	1	1/5	1/5	1/5	1/7	1/7
Yolcu Akımı	5	1	1	3	1	1
Servis Standartları	5	1	1	2	1	1/3
Araçlar	5	1/3	1/2	1	1/3	1/3
İşletme Faktörleri	7	1	1	3	1	1
Çalışma Kuralları	7	1	3	3	1	1
SÜTUN TOPLAMI	30	68/15	67/10	61/5	94/21	80/21

Daha sonra, her satır Tablo 4.37.'de hesaplanan sütun toplamına bölünerek Tablo 4.38. elde edilmiştir.

Kapasite ana kriterine göre karar alternatifleriyle ilgili yargılar Tablo 4.42.'de verilmiştir. Uzman, kapasite ana kriterine göre, hat karakteristikleri faktörünün araçlar, işletme faktörleri ve çalışma kuralları faktörlerinden daha az önemli olduğunu 1/7 rakamı ile sayısallaştırmıştır.

Tablo 4.42. Kapasite ana kriterine göre kritik başarı faktörü önceliklendirilmesi karşılaştırma matrisi ve önem düzeyleri

Kapasite	Hat Karakteristikleri	Yolcu Akımı	Servis Standartları	Araçlar	İşletme Faktörleri	Çalışma Kuralları	Önem Düzeyi
Hat Karakteristikleri	1	1/3	1/9	1/7	1/7	1/7	0,027568793
Yolcu Akımı	3	1	1/5	1/3	1/3	1/3	0,066869667
Servis Standartları	9	5	1	1	3	2	0,308236735
Araçlar	7	3	1	1	2	1	0,226529313
İşletme Faktörleri	7	3	1/3	1/2	1	1/5	0,127199481
Çalışma Kuralları	7	3	1/2	1	5	1	0,240813817
TUTARLILIK ORANI:				0,050292		TOPLAM	1

Tablo 4.42.'ye ulaşabilmek için öncelikle Tablo 4.43.'te belirtildiği gibi sütun toplamaları hesaplanmaktadır.

Tablo 4.43. Kapasite ana kriterine göre karar alternatifleri için hesaplama tablosu-1

Kapasite	Hat Karakteristikleri	Yolcu Akımı	Servis Standartları	Araçlar	İşletme Faktörleri	Çalışma Kuralları
Hat Karakteristikleri	1	1/3	1/9	1/7	1/7	1/7
Yolcu Akımı	3	1	1/5	1/3	1/3	1/3
Servis Standartları	9	5	1	1	3	2
Araçlar	7	3	1	1	2	1
İşletme Faktörleri	7	3	1/3	1/2	1	1/5
Çalışma Kuralları	7	3	1/2	1	5	1
SÜTUN TOPLAMI	34	46/3	283/90	167/42	241/21	491/105

Daha sonra, her satır Tablo 4.43.'te hesaplanan sütun toplamına bölünerek Tablo 4.44. elde edilmiştir.

Tablo 4.44. Kapasite ana kriterine göre karar alternatifleri için hesaplama tablosu-2

Kapasite	Hat Karakteristikleri	Yolcu Akımı	Servis Standartları	Araçlar	İşletme Faktörleri	Çalışma Kuralları
Hat Karakteristikleri	1/34	1/46	10/283	6/167	3/241	15/491
Yolcu Akımı	3/34	3/46	18/283	14/167	7/241	35/491
Servis Standartları	9/34	15/46	90/283	42/167	63/241	210/491
Araçlar	7/34	9/46	90/283	42/167	42/241	105/491
İşletme Faktörleri	7/34	9/46	30/283	21/167	21/241	21/491
Çalışma Kuralları	7/37	9/46	45/283	42/167	105/241	105/491

Akabinde, satır toplamı hesaplanır ve satır aritmetik ortalamaları bulunarak Tablo 4.45.'e ulaşılmaktadır.

Tablo 4.48. Çevreye duyarlılık ana kriterine göre kritik başarı faktörü önceliklendirilmesi karşılaştırma matrisi ve önem düzeyleri

Çevreye Duyarlılık	Hat Karakteristikleri	Yolcu Akımı	Servis Standartları	Araçlar	İşletme Faktörleri	Çalışma Kuralları	Önem Düzeyi
Hat Karakteristikleri	1	3	5	2	1/3	1/5	0,169024588
Yolcu Akımı	1/3	1	3	1	1/2	1/3	0,106413864
Servis Standartları	1/5	1/3	1	1/2	1/3	1/3	0,059016359
Araçlar	1/2	1	2	1	1/2	1/5	0,092132115
İşletme Faktörleri	3	2	3	2	1	1	0,240291595
Çalışma Kuralları	5	3	3	5	1	1	0,33312148
TUTARLILIK ORANI:				0,090217		TOPLAM	1

Tablo 4.48.'e ulaşabilmek için öncelikle Tablo 4.49.'da belirtildiği gibi sütun toplamaları hesaplanmaktadır.

Tablo 4.49. Çevreye duyarlılık ana kriterine göre karar alternatifleri için hesaplama tablosu-1

Çevreye Duyarlılık	Hat Karakteristikleri	Yolcu Akımı	Servis Standartları	Araçlar	İşletme Faktörleri	Çalışma Kuralları
Hat Karakteristikleri	1	3	5	2	1/3	1/5
Yolcu Akımı	1/3	1	3	1	1/2	1/3
Servis Standartları	1/5	1/3	1	1/2	1/3	1/3
Araçlar	1/2	1	2	1	1/2	1/5
İşletme Faktörleri	3	2	3	2	1	1
Çalışma Kuralları	5	3	3	5	1	1
SÜTUN TOPLAMI	301/30	31/3	17	23/2	11/3	46/15

Daha sonra, her satır Tablo 4.49.'da hesaplanan sütun toplamına bölünerek Tablo 4.50. elde edilmiştir.

Tablo 4.50. Çevreye duyarlılık ana kriterine göre karar alternatifleri için hesaplama tablosu-2

Çevreye Duyarlılık	Hat Karakteristikleri	Yolcu Akımı	Servis Standartları	Araçlar	İşletme Faktörleri	Çalışma Kuralları
Hat Karakteristikleri	30/301	9/31	5/17	4/23	1/11	3/46
Yolcu Akımı	10/301	3/31	3/17	2/23	3/22	5/46
Servis Standartları	6/301	1/31	1/17	1/23	1/11	5/46
Araçlar	15/301	3/31	2/17	2/23	3/22	3/46
İşletme Faktörleri	90/301	6/31	3/17	4/23	3/11	15/46
Çalışma Kuralları	150/301	9/31	3/17	10/23	3/11	15/46

Akabinde, satır toplamı hesaplanır ve satır aritmetik ortalamaları bulunarak Tablo 4.51.'e ulaşılmaktadır.

Tablo 4.51. Çevreye duyarlılık ana kriterine göre karar alternatifleri için hesaplama tablosu-3

Çevreye Duyarlılık	Hat Karakteristikleri	Yolcu Akımı	Servis Standartları	Araçlar	İşletme Faktörleri	Çalışma Kuralları	Satır Toplamı	Satır Ortalaması
Hat Karakteristikleri	0,099668	0,290323	0,294118	0,173913	0,090909	0,065217	1,014148	0,169024588
Yolcu Akımı	0,033223	0,096774	0,176471	0,086957	0,136364	0,108696	0,638483	0,106413864
Servis Standartları	0,019934	0,032258	0,058824	0,043478	0,090909	0,108696	0,354098	0,059016359
Araçlar	0,049834	0,096774	0,117647	0,086957	0,136364	0,065217	0,552793	0,092132115
İşletme Faktörleri	0,299003	0,193548	0,176471	0,173913	0,272727	0,326087	1,441750	0,240291595
Çalışma Kuralları	0,498339	0,290323	0,176471	0,434783	0,272727	0,326087	1,998729	0,33312148

Satır ortalamaları kriterlerin önem düzeylerini göstermektedir. Uzmanın Saaty ölçeğine göre oluşturduğu matris ile önem düzeyleri matrisi çarpılarak Tablo 4.52.'ye ulaşılmaktadır.

Tablo 4.52. Çevreye duyarlılık ana kriterine göre karar alternatifleri için hesaplama tablosu-4

						V		V/W	
1	3	5	2	0,33	0,2	0,169024588	1,1135327	6,5879925	
0,33	1	3	1	0,5	0,33	0,106413864	0,6614491	6,2158165	
0,2	0,33	1	0,5	0,33	0,33	0,059016359	0,3632302	6,154738	
0,5	1	2	1	0,5	0,2	0,092132115	0,5878611	6,3806316	
3	2	3	2	1	1	0,240291595	1,6546279	6,8859166	
5	3	3	5	1	1	0,33312148	2,3754873	7,130994	
						X	=		

Tutarlılık göstergesi ve tutarlılık oranı Tablo 4.53.'te hesaplanarak matrisin 0,1'den küçük olduğu için tutarlı olduğu sonucuna ulaşılmaktadır.

Tablo 4.53. Çevreye duyarlılık ana kriterine göre karar alternatifleri için hesaplama tablosu-5

En büyük özdeğer,
$\lambda_{\max} = (6,587993 + 6,215817 + 6,154738 + 6,380632 + 6,885917 + 7,130994) / 6 = 6,559348$
Rassallık göstergesi (RG) tablodan; $n=6$ için $RG=1,24$ 'tür.
Tutarlılık göstergesi (CI) = $(6,559348 - 6) / (6 - 1) = 0,11187$
Tutarlılık Oranı (CR) = $0,11187 / 1,24 = 0,090217$
$0,090217 < 0,1$ olduğu için matris tutarlı sayılabilmektedir.

Kararların tutarlı olduğu sonucuna varılmıştır, çünkü elde edilen tüm tutarlılık oranları 0,1'den düşüktür.

6 ana kriter ile 6 karar alternatifinin değerlendirilmesi sonucunda Tablo 4.54.'e ulaşılmıştır. Tablo 4.54.'te, ana kriterlerin önem düzeyleri ile, her bir alternatifin önem düzeyleri çarpılmış ve nihai önem düzeyleri elde edilmiştir. Alternatiflerin önem düzeyleri kendi aralarında toplanmış ve karar vermemize yardımcı olacak olan ağırlıklara ulaşılmıştır (Arsu ve Ozcifci, 2013; Nar, 2018).

Tablo 4.54. Kritik başarı faktörü seçim probleminde ana kriterlerin ve alternatiflerin öncelik değerleri

Ana Kriter Öncelik Değeri	Ana Kriter	Hat Karakteristikleri	Yolcu Akımı	Servis Standartları	Araçlar	İşletme Faktörleri	Çalışma Kuralları	Tutarlılık Oranı	Hat Karakteristikleri	Yolcu Akımı	Servis Standartları	Araçlar	İşletme Faktörleri	Çalışma Kuralları
0,2523017	Sosyal Etki	0,0765981	0,245977	0,2415911	0,2415911	0,0261512	0,1680914	0,058469	0,0193258	0,0620604	0,0609538	0,0609538	0,006598	0,0424098
0,0645659	Kalite	0,1508098	0,0580766	0,2379897	0,0388683	0,4216185	0,092637	0,022509	0,0097372	0,0037498	0,015366	0,0025096	0,0272222	0,0059812
0,2292858	Maliyet	0,032185	0,2113858	0,1685579	0,0931264	0,2224969	0,2722481	0,030078	0,0073796	0,0484678	0,0386479	0,0213526	0,0510154	0,0624226
0,1072903	Kapasite	0,0275688	0,0668697	0,3082367	0,2265293	0,1271995	0,2408138	0,050292	0,0029579	0,0071745	0,0330708	0,0243044	0,0136473	0,025837
0,0720323	Çevreye Duyarlılık	0,1690246	0,1064139	0,0590164	0,0921321	0,2402916	0,3331215	0,090217	0,0121752	0,0076652	0,0042511	0,0066365	0,0173088	0,0239955
0,2745239	Güvenilirlik	0,5114691	0,1097693	0,0895487	0,0507897	0,1047188	0,1337043	0,052313	0,1404105	0,0301343	0,0245833	0,013943	0,0287478	0,036705
TOPLAM									0,1919862	0,159252	0,176873	0,1296999	0,1445394	0,197351

Uzman görüşü ile elde edilen sonuçlar, “çalışma kurallarının” alternatifinin sefer sıklığı optimizasyonu açısından en önemli faktör olduğunu ortaya koymaktadır. Bunu takiben, hat karakteristikleri alternatifi ikinci; servis standartları alternatifi ise, üçüncü önemli faktör olarak yerini almıştır.

4.2.2. Problemin SWARA yöntemi ile çözümü

Bu bölümde, sefer sıklığı optimizasyonundaki ana kriterler, SWARA yöntemi ile önceliklendirilmiştir. Çalışma üç ayrı uzman tarafından ele alınmıştır.

Uygulamanın birinci adımında, değerlendirme kriterleri kümesi belirlenmiş ve bu kriterler uzmanlar tarafından tahmine dayalı olarak önem derecelerine göre sıralanmıştır. Bu sıralama en önemli kriterden başlanarak en önemsiz kriter kadar yapılmıştır.

İkinci adımda, kriterler birbirleri ile kıyaslanmıştır. Kıyaslama işlemi $(j-1)$. kriter ile j . kriter arasında yapılmıştır. Böylece, $(j-1)$. kriterin j . kriterle oranla ne kadar önemli olduğu tespit edilmiştir. Bu tespit edilen değere (S_j) , “ortalama değerin karşılaştırmalı önemi” adı verilmiştir (Keršulienė ve ark., 2010). Bu değerin belirlenmesinde uzmanlar, 0 ile 1 arasında 5 sayısının katları olan sayıları kullanmışlardır (Adalı ve Işık, 2017; Ulutaş, 2019).

Üçüncü adımda ise, K_j katsayısı Denklem 3.28’de belirtildiği gibi hesaplanmıştır.

Üçüncü adımın ardından dördüncü adımda, yeniden hesaplanmış ağırlık q_j değeri Denklem 3.29’da belirtildiği gibi hesaplanmıştır.

Beşinci adımda, her bir kriterle ait ağırlık w_j Denklem 3.30’da belirtildiği gibi hesaplanmıştır.

Yukarıda belirtilen beş adım, her bir uzman için ayrı ayrı uygulanmıştır. Tablo 4.55., Tablo 4.56. ve Tablo 4.57. sırasıyla Uzman-1, Uzman-2 ve Uzman-3 için SWARA yönteminin sonuçlarını göstermektedir.

Tablo 4.55. Uzman-1 için SWARA yönteminin sonuçları

Kriterler	Sıralama	Kriterlerin Sıralanışı	S _j	K _j	q _j	w _j
Sosyal Etki	1	Sosyal Etki		1,00	1,00	1,00
Güvenilirlik	2	Güvenilirlik	0,05	1,05	0,95	0,49
Maliyet	6	Kalite	0,55	1,55	0,61	0,24
Kalite	3	Çevreye Duyarlılık	0,05	1,05	0,59	0,27
Çevreye Duyarlılık	4	Kapasite	0,15	1,15	0,51	0,30
Kapasite	5	Maliyet	0,10	1,10	0,46	0,30

Tablo 4.56. Uzman-2 için SWARA yönteminin sonuçları

Kriterler	Sıralama	Kriterlerin Sıralanışı	S _j	K _j	q _j	w _j
Sosyal Etki	3	Maliyet		1,00	1,00	1,00
Güvenilirlik	2	Güvenilirlik	0,20	1,20	0,83	0,45
Maliyet	1	Sosyal Etki	0,15	1,15	0,72	0,28
Kalite	4	Kalite	0,40	1,40	0,52	0,25
Çevreye Duyarlılık	5	Çevreye Duyarlılık	0,15	1,15	0,45	0,27
Kapasite	6	Kapasite	0,10	1,10	0,41	0,30

Tablo 4.57. Uzman-3 için SWARA yönteminin sonuçları

Kriterler	Sıralama	Kriterlerin Sıralanışı	S _j	K _j	q _j	w _j
Sosyal Etki	2	Güvenilirlik		1,00	1,00	1,00
Güvenilirlik	1	Sosyal Etki	0,25	1,25	0,80	0,44
Maliyet	3	Maliyet	0,20	1,20	0,67	0,27
Kalite	4	Kalite	0,15	1,15	0,58	0,28
Çevreye Duyarlılık	5	Çevreye Duyarlılık	0,50	1,50	0,39	0,24
Kapasite	6	Kapasite	0,05	1,05	0,37	0,28

Akabinde, her bir uzmanın belirlediği kriter ağırlıkları geometrik ortalama ile birleştirilmiştir. Tablo 4.58., birleştirilmiş kriter ağırlıklarını göstermektedir.

Tablo 4.58. Birleştirilmiş kriter ağırlıkları

Birleştirilmiş Kriter Ağırlıkları	w _j
Güvenilirlik	0,604
Sosyal Etki	0,498
Maliyet	0,433
Kapasite	0,293
Çevreye Duyarlılık	0,260
Kalite	0,256

SWARA yöntemi ile elde edilen sonuçlar, ana kriter olan güvenilirliğin, sefer sıklığı optimizasyonu açısından en önemli kriter olduğunu ortaya koymaktadır (Tablo 4.58.).

4.2.3. Problemin TOPSİS yöntemi ile çözümü

Bu bölümde, sefer sıklığı optimizasyonundaki ana kriterlerin öncelik düzeylerini ortaya koymak için TOPSİS yöntemi kullanılmıştır.

Uygulamada, öncelikle başlangıç karar matrisi oluşturulmuştur (Tablo 4.59.). Başlangıç karar matrisi oluşturulduktan sonra normalleştirilmiş karar matrisi Denklem 3.31’de belirtildiği gibi oluşturulur (Tablo 4.60.).

Tablo 4.59. Başlangıç karar matrisi

Ağırlık	0,25	0,06	0,23	0,11	0,07	0,27
	Sosyal Etki	Kalite	Maliyet	Kapasite	Çevreye Duyarlılık	Güvenilirlik
Hat Karakteristikleri	1,00	2,00	2,00	7,00	3,00	7,00
Çalışma Kuralları	0,50	1,00	3,00	5,00	2,00	5,00
Araçlar	0,50	0,33	1,00	3,00	0,50	0,25
İşletme Faktörleri	0,14	0,20	0,33	1,00	1,00	0,33
Yolcu Akımı	0,33	0,50	2,00	1,00	1,00	1,00
Servis Standartları	0,14	0,20	4,00	3,00	1,00	1,00

Tablo 4.60. Normalleştirilmiş karar matrisi

	Sosyal Etki	Kalite	Maliyet	Kapasite	Çevreye Duyarlılık	Güvenilirlik
Hat						
Karakteristikleri	0,778044643	0,857405368	0,34244	0,72199	0,744208408	0,802039519
Çalışma Kuralları	0,389022321	0,428702684	0,51366	0,51571	0,496138938	0,572885371
Araçlar	0,389022321	0,142900895	0,17122	0,30943	0,124034735	0,028644269
İşletme Faktörleri	0,111149235	0,085740537	0,05707	0,10314	0,248069469	0,038192358
Yolcu Akımı	0,259348214	0,214351342	0,34244	0,10314	0,248069469	0,114577074
Servis Standartları	0,111149235	0,085740537	0,68488	0,30943	0,248069469	0,114577074

İkinci adımda ağırlıklı normalleştirilmiş karar matrisi Denklem 3.32’de belirtildiği gibi oluşturulmuştur (Tablo 4.61.); bu aşamada, AHP ile elde edilen ağırlıklar kullanılmıştır.

Tablo 4.61. Ağırlıklı normalleştirilmiş karar matrisi

	Sosyal Etki	Kalite	Maliyet	Kapasite	Çevreye Duyarlılık	Güvenilirlik
Hat						
Karakteristikleri	0,194511161	0,051444322	0,07876	0,07942	0,052094589	0,21655067
Çalışma Kuralları	0,09725558	0,025722161	0,11814	0,05673	0,034729726	0,15467905
Araçlar	0,09725558	0,008574054	0,03938	0,03404	0,008682431	0,007733953
İşletme Faktörleri	0,027787309	0,005144432	0,01313	0,01135	0,017364863	0,010311937
Yolcu Akımı	0,064837054	0,012861081	0,07876	0,01135	0,017364863	0,03093581
Servis Standartları	0,027787309	0,005144432	0,15752	0,03404	0,017364863	0,03093581

İkini adımın akabinde, Denklem 3.33'te belirtildiği gibi pozitif ideal çözüm hesaplanır; daha sonra Denklem 3.34'te belirtildiği gibi negatif ideal çözüm hesaplanır (Tablo 4.62.):

Tablo 4.62. Pozitif ideal ve negatif ideal çözüm değerleri

V_j^*	0,027787309	0,051444322	0,15752	0,07942	0,052094589	0,21655067
V_j^*	0,194511161	0,005144432	0,01313	0,01135	0,008682431	0,007733953

Daha sonra, her alternative için ayrılma ölçüleri hesaplanmıştır. Pozitif ideal alternatiften ayrılma Denklem 3.35'teki gibi hesaplanırken; negatif ideal alternatiften ayrılma Denklem 3.36'daki gibi hesaplanmıştır. Ayrıca, son olarak, çalışmada ideal çözüm C_i^* 'ye göreceli yakınlık Denklem 3.37'de belirtildiği gibi hesaplanmıştır. 1'e en yakın C_i^* ile alternatif seçilmiştir (Tablo 4.63.):

Tablo 4.63. Ayrılma ölçüleri ve ideal çözüm C_i^* değeri

S_i^*	S_i^*	C_i^*	Sıralama
0,184391161	0,237854	0,563308	2
0,108087067	0,212699	0,663056	1
0,261093166	0,103318	0,28352	6
0,26714814	0,16697	0,384618	5
0,222165884	0,147636	0,39923	4
0,199655414	0,223104	0,527733	3

TOPSİS yöntemi ile elde edilen sonuçlar, karar alternatifi olan çalışma kurallarının sefer sıklığı optimizasyonu açısından en önemli faktörler olduğunu ortaya koymuştur (Tablo 4.63.).

BÖLÜM 5. TARTIŞMA VE SONUÇ

Çalışma iki bölümden oluşmaktadır. Çalışmanın ilk bölümünde, raylı ulaşım sistemlerinde Yenikapı – Kirazlı hattındaki geçmiş dönem verileri kullanılarak yolcu talep tahmini yapılmıştır. Ayrıca, talep tahmini çalışması hat ve istasyon bazlı olmak üzere iki aşamada yapılmıştır. Hat bazlı talep tahmini yapılırken istatistiksel tekniklerden basit ortalama yöntemi ve regresyon analiz tekniği uygulanmıştır. İstasyon bazlı talep tahmini yapılırken ise, yapay sinir ağı ve makine öğrenme algoritmaları kullanılmıştır.

Ayrıca, ikinci bir çalışma olarak raylı ulaşım sistemlerinde sefer sıklığı belirlemede kritik başarı faktörlerinin önceliklendirilmesi ele alınmıştır. Bu önceliklendirme, kantitatif karar verme tekniklerinden AHP, SWARA ve TOPSİS yöntemleri ile değerlendirilmiştir. Bu çalışmada 6 ana kriter ve 6 alternatif ele alınmıştır.

Birinci çalışma talep tahmin yöntemlerinin sonuçları başlığı altında detaylaştırılırken; ikinci çalışma ÇKKV yöntem sonuçları başlığı altında detaylandırılmıştır.

5.1. Talep Tahmin Yöntemlerinin Sonuçları

İstanbul gibi büyük şehirlerde ulaşım çok büyük bir problemdir. Bu sorun toplu taşıma ile çözülebilmektedir. Demiryolu taşımacılığı bu sorun için adeta bir çaredir. Toplu taşımanın stratejik ve ayrıntılı planlamasının başarısı, büyük ölçüde doğru talep bilgisi verilerine bağlıdır. Yolcu talep tahmini, demiryolu ulaşım sistemlerinde doğru sefer sıklığı çizelgelemeleri açısından oldukça önemlidir. Yolcu talebi doğru tahmin edilirse, sefer sıklığı optimize edilerek yolcu memnuniyeti artırılır ve işletme maliyetleri düşürülür.

Yolcu talep tahmininin önemi göz önünde bulundurularak yapılan bu çalışmada; yapay sinir ağları, makine öğrenmesi algoritmaları, regresyon analizi tekniği ve basit ortalama yöntemi gibi teknikler kullanılmıştır. Bu teknikler aracılığıyla elde edilen tahmin sonuçlarının, ortalama mutlak hata (MAE), BIAS, ortalama karesel hata (MSE), ortalama mutlak yüzde hata (MAPE) ve ortalama karesel hata (RMSE) hesaplanarak performansları değerlendirilmiştir. Yolcu talep tahminin kritik önemi dikkate alındığında; doğru tahminin sefer sıklığı optimizasyon çalışmalarına önemli bir girdi oluşturacağı bilinciyle çalışma birden fazla teknikle ele alınmıştır. Yolcu talep tahmini çalışmasında 8 farklı yöntem kullanılarak çalışma iki aşamada ele alınmıştır.

Çalışmanın ilk aşamasında geçmiş dönem verileri kullanılarak Yenikapı M1 - Kirazlı M1 hattı için talep tahmini yapılmıştır. Bu aşamada talep tahmini için basit ortalama yöntemi ve regresyon analizi yapılır; regresyon analizi SPSS Statistics 21.0 programı ile yapılmıştır. Sonuç olarak bu iki tekniğin MAPE değerleri karşılaştırılmıştır (Tablo 4.30.). Basit ortalama yönteminin daha doğru sonuçlar verdiği gözlemlenmiştir. Basit ortalama yöntemi ile yapılan talep tahmini MAPE değeri; hafta içi için 0,001 bulunurken, bu değer haftasonu için 0,002 olarak bulunmuştur.

Çalışmanın ikinci aşamasında ise, Yenikapı M1 - Kirazlı M1 hattındaki tüm istasyonlar için istasyon bazlı talep tahminleri yapılmıştır. Bu tahmin yapılırken yapay sinir ağları ve makine öğrenmesi algoritmalarından karar ağacı, doğrusal regresyon, rassal orman, polinom regresyon ve destek vektör makine yöntemleri kullanılmıştır. BIAS, MAE, MSE, MAPE ve RMSE hata oranları karşılaştırılmış; bu veri seti için en düşük hata oranları (%0,03 MAPE) karar ağacı, (%0,54) rassal orman ve (%0,57) destek vektör makinesi olarak bulunmuştur. Sonuçlardan da anlaşılacağı üzere en doğru tahmin makine öğrenmesi algoritmaları ile elde edilmektedir.

Bu çalışma, demiryolu ulaşım sistemlerinin gelecekteki sefer sıklığı çizelgeleme çalışmalarına girdi sağlayacağı için önemlidir. Ayrıca, literatürdeki çalışmalardan farklı olarak bu çalışma talep tahmini için iki aşama içermektedir. Çalışmanın ilk aşamasında hafta içi ve hafta sonu için hat bazında talep tahmini yapılırken; çalışmanın ikinci aşamasında istasyon bazında tahmin yapılmaktadır. Çalışmanın hem hat bazında

hem de istasyon bazında yapılması literatüre önemli katkı sağlayacaktır. Öyle ki bu çalışmada; literatürdeki diğer çalışmalardan farklı olarak hat yoğunluğu ve istasyon yoğunluğu dikkate alınarak tek bir çalışmada ayrı ayrı talep tahmini yapılmıştır. Böylece hat yoğunluğu dikkate alınarak durakların yoğunluğuna göre dönüş istasyonları belirlenebilir; bu nedenle trenin tüm hattı tamamlaması gerekmeyebilir. Hat yoğunluğuna bağlı olarak her seferinde son istasyona gidilmeyerek maliyet karı elde edilebilir.

Ayrıca, içinde bulunduğumuz pandemi döneminde (COVID-19) özellikle İstanbul gibi büyük şehirlerde toplu ulaşımaya yönelik yolcu talep tahmini daha önemli hale gelmiştir. Demiryolu ulaşımını talep eden yolcu sayısı önceden bilindiği ve sosyal mesafe sağlandığı için; talep tahmini bulaşıcı hastalıkların ve salgın hastalıkların önlenmesi için ayrıca önemli yer tutmaktadır.

5.2. ÇKKV Yöntem Sonuçları

Yolcu talep tahmini çalışmasına ek olarak bu çalışmada, raylı ulaşım sistemlerinde sefer sıklığı optimizasyonunda kritik başarı faktörleri tartışılmış ve bu faktörlerin önceliklendirilmesi kantitatif tekniklerden SWARA, AHP ve TOPSİS yöntemleri ile araştırılmıştır.

Çok kriterli karar verme yöntemleri ile sefer sıklığı optimizasyonundaki altı kritik başarı faktörü arasında önceliklendirme sorunu için oluşturulan AHP ve TOPSİS modeli sonucunda, çalışma kuralları alternatifinin ağırlığı 0,197 olarak bulunmuştur. Diğer kritik başarı faktörlerinin ağırlıkları göz önüne alındığında, çalışma kuralları, optimizasyonda birincil öncelikli kritik başarı faktörü olarak seçilmelidir. Bunu takiben hat karakteristikleri alternatifi ikinci (0,192); servis standartları üçüncü (0,177); yolcu akımı dördüncü (0,159); işletme faktörleri beşinci (0,145); araçlar altıncı sırada yer almıştır (0,130). Sonuçlar göz önüne alındığında, Tablo 5.1. elde edilir:

Tablo 5.1. Kritik Başarı Faktörü Seçim Probleminde Alternatiflerin Öncelik Değerleri

ÖNCELİK DÜZEYLERİ	ALTERNATİFLER	ÖNEM DÜZEYLERİ
Birinci Öncelik	Çalışma Kuralları	0,197
İkinci Öncelik	Hat Karakteristikleri	0,192
Üçüncü Öncelik	Servis Standartları	0,177
Dördüncü Öncelik	Yolcu Akımı	0,159
Beşinci Öncelik	İşletme Faktörleri	0,145
Altıncı Öncelik	Araçlar	0,130
TOPLAM		1

Bununla birlikte, bu çalışmada üçüncü bir yöntem olarak SWARA yöntemi kullanılmıştır. Ana kriterler SWARA yöntemi ile önceliklendirilmiş ve güvenilirlik kriterinin birinci öncelikli ana kriter olduğu görülmüştür. Benzer şekilde, birinci öncelikli ana kriter AHP yöntemiyle de güvenilirlik olarak bulunmuştur. Çalışmada, sefer sıklığı optimizasyonunda kritik başarı faktörlerini önceliklendirmek için üç farklı yöntem birlikte kullanılarak literatüre katkıda bulunulması amaçlanmıştır.

Raylı ulaşım sistemlerinde yolcu talep tahmini ve sefer sıklığı optimizasyonundaki kritik başarı faktörlerinin önceliklendirilmesi üzerine yapılan bu çalışma, raylı ulaşım sistemlerinin gelecekte yapılması planlanan sefer sıklığı çizelgeleme çalışmalarına girdi sağlayacağı için önemlidir.

Raylı ulaşım sistemlerinde yolcu talep tahmini çalışması literatürdeki çalışmalardan farklı olarak talep tahmini için iki aşama içermektedir. Çalışmanın ilk aşamasında hafta içi ve hafta sonu için istasyon bazında talep tahmini yapılırken; çalışmanın ikinci aşamasında hat bazında tahmin yapılmaktadır. Bu çalışmada literatürdeki diğer çalışmalardan farklı olarak hat yoğunluğu ve istasyon yoğunluğu dikkate alınarak tek bir çalışmada ayrı ayrı talep tahmini yapılmıştır. Böylece hat yoğunluğu dikkate alınarak durakların yoğunluğuna göre dönüş istasyonları belirlenebilir; bu nedenle trenin tüm hattı tamamlaması gerekmebilir. Hat yoğunluğuna bağlı olarak her seferinde son istasyona gidilmeyerek maliyet karı elde edilebilir. Bu araştırma genetik algoritma gibi sezgisel yöntemlerle desteklenerek gelecekteki çalışmalar için farklı bir bakış açısı oluşturabilir. Ayrıca, içinde bulunduğumuz pandemi döneminde (COVID-19) özellikle İstanbul gibi büyükşehirlerde toplu ulaşımaya yönelik yolcu talep tahmini daha önemli hale gelmiş; raylı ulaşımı talep eden yolcu sayısı önceden bilindiği ve sosyal mesafe sağlandığı için; talep tahmini bulaşıcı hastalıkların ve salgın

hastalıkların önlenmesi için ayrıca önemli hale gelmektedir. İlerideki çalışmalarda karar destek sistemleri de araştırmaya dahil edilerek bu çalışma diğer toplu ulaşım uygulanabilir.

Sefer sıklığı optimizasyonundaki kritik başarı faktörlerinin önceliklendirilmesi çalışması ise, gelecekte raylı ulaşım tercih eden yolculara anket uygulanarak genişletilebilir. Bu anket SPSS programı ile analiz edilerek çalışma daha kapsamlı hale getirilebilir.



KAYNAKLAR

- Abdul, D., Wenqi, J., & Tanveer, A. (2022). Prioritization of renewable energy source for electricity generation through AHP-VIKOR integrated methodology. *Renewable Energy*, 184, 1018-1032.
- Adalı, E. A., & Ayşegül, T. U. Ş. (2017). Bir Tedarikçi Seçim Problemi İçin Swara Ve Waspas Yöntemlerine Dayanan Karar Verme Yaklaşımı. *International Review of Economics and Management*, 5(4), 56-77.
- Adel, S., Mansour, Z., & Ardeshtir, H. (2021). Geochemical behavior investigation based on k-means and artificial neural network prediction for titanium and zinc, Kivi region, Iran. *Известия Томского политехнического университета. Инжиниринг георесурсов*, 332(3), 113-125.
- Agatonovic-Kustrin, S., & Beresford, R. (2000). Basic concepts of artificial neural network (ANN) modeling and its application in pharmaceutical research. *Journal of pharmaceutical and biomedical analysis*, 22(5), 717-727.
- Ahmad, S., Ouenniche, J., Kolosz, B. W., Greening, P., Andresen, J. M., Maroto-Valer, M. M., & Xu, B. (2021). A stakeholders' participatory approach to multi-criteria assessment of sustainable aviation fuels production pathways. *International Journal of Production Economics*, 238, 108156.
- Ahmed, M. N., Yas, A. H., & Hussein, I. G. (2022). Evaluation of construction companies performance by using stepwise weight assessment ratio analysis. *Periodicals of Engineering and Natural Sciences*, 10(1), 253-267.
- Akçay, M. T., & Kocaarslan, İ. (2019). Matlab/simulink yardımıyla çok-araçlı sinyalizasyon sisteminin simülasyonu ve tren zaman çizelgesinin tasarımı. *El-Cezeri Journal of Science and Engineering*, 6(3), 799-807.
- Akinyelu, A. A., & Adewumi, A. O. (2014). Classification of phishing email using random forest machine learning technique. *Journal of Applied Mathematics*, 2014.
- Alahgholi, S., Shirazy, A., & Shirazi, A. (2018). Geostatistical studies and anomalous elements detection, Bardaskan Area, Iran. *Open Journal of Geology*, 8(7), 697-710.
- Alekseev, K. P. G., & Seixas, J. M. (2002). Forecasting the air transport demand for passengers with neural modelling. In *VII Brazilian Symposium on Neural Networks*, 2002. SBRN 2002. Proceedings. (pp. 86-91). IEEE.

- Allen, M. P. (2004). *Understanding regression analysis*. Springer Science & Business Media.
- Al-Saegh, A., Dawwd, S. A., & Abdul-Jabbar, J. M. (2021). Deep learning for motor imagery EEG-based classification: A review. *Biomedical Signal Processing and Control*, 63, 102172.
- Andreolli, F., Bragolusi, P., D'Alpaos, C., Faleschini, F., & Zanini, M. A. (2022). An AHP model for multiple-criteria prioritization of seismic retrofit solutions in gravity-designed industrial buildings. *Journal of Building Engineering*, 45, 103493.
- Arcanjo, G. S., Costa, F. C., Ricci, B. C., Mounteer, A. H., de Melo, E. N., Cavalcante, B. F., ... & Amaral, M. C. (2020). Draw solution solute selection for a hybrid forward osmosis-membrane distillation module: Effects on trace organic compound rejection, water flux and polarization. *Chemical Engineering Journal*, 400, 125857.
- Arsu, V. Ö. T. (2013). Lojistik Servis Sağlayıcısı Seçiminde Ahp Uygulaması. *Sosyal ve Beşeri Bilimler Dergisi*, 5(1).
- Asakereh, A., Soleymani, M., & Sheikhdavoodi, M. J. (2017). A GIS-based Fuzzy-AHP method for the evaluation of solar farms locations: Case study in Khuzestan province, Iran. *Solar Energy*, 155, 342-353.
- Asra, S., & Arpi, N. (2022). Alternative location determination of frozen tuna industry using analytical hierarchy process (AHP). In *IOP Conference Series: Earth and Environmental Science* (Vol. 951, No. 1, p. 012082). IOP Publishing.
- Atanasova-Pacemska, T., Lapevski, M., & Timovski, R. (2014). Analytical Hierarchical Process (AHP) method application in the process of selection and evaluation.
- Awad, J., & Jung, C. (2022). Extracting the Planning Elements for Sustainable Urban Regeneration in Dubai with AHP (Analytic Hierarchy Process). *Sustainable Cities and Society*, 76, 103496.
- Azadnia, A. H., Saman, M. Z. M., & Wong, K. Y. (2015). Sustainable supplier selection and order lot-sizing: an integrated multi-objective decision-making process. *International Journal of Production Research*, 53(2), 383-408.
- Bai, L., Yao, L., Kanhere, S., Wang, X., & Sheng, Q. (2019). Stg2seq: Spatial-temporal graph to sequence model for multi-step passenger demand forecasting. *ArXiv preprint arXiv: 1905.10069*.
- Bai, L., Yao, L., Wang, X., Li, C., & Zhang, X. (2021). Deep spatial-temporal sequence modeling for multi-step passenger demand prediction. *Future Generation Computer Systems*, 121, 25-34.

- Bakar, N. M. A., & Tahir, I. M. (2009). Applying multiple linear regression and neural network to predict bank performance. *International Business Research*, 2(4), 176-183.
- Ballı, M. T. 2014. Yapay Sinir Ağları ile Talep Tahmini ve Gıda Sektöründe Uygulanması. Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Bölümü, Yüksek Lisans Tezi.
- Bao-yu, L. I., Jing, L. I., Lei, H. U. A. N. G., Xin, Z. H. U., Xue-yan, L. I., Zi-yang, X. I. A., & Hai-feng, H. U. A. N. G. (2021, January). Research on Prediction of Short-term Passenger Flow of Urban Rail Transit Based on Deep Neural Network. In 2021 2nd International Conference on Urban Engineering and Management Science (ICUEMS) (pp. 111-116). IEEE.
- Basheer, I. A., & Hajmeer, M. (2000). Artificial neural networks: fundamentals, computing, design, and application. *Journal of microbiological methods*, 43(1), 3-31.
- Begić, F., & Afgan, N. H. (2007). Sustainability assessment tool for the decision making in selection of energy system—Bosnian case. *Energy*, 32(10), 1979-1985.
- Behzadian, M., Otaghsara, S. K., Yazdani, M., & Ignatius, J. (2012). A state-of the-art survey of TOPSIS applications. *Expert Systems with applications*, 39(17), 13051-13069.
- Bera, D., Chatterjee, N. D., & Bera, S. (2021). Comparative performance of linear regression, polynomial regression and generalized additive model for canopy cover estimation in the dry deciduous forest of West Bengal. *Remote Sensing Applications: Society and Environment*, 22, 100502.
- Bilgiç, E. M. R. A. H., Türkmenoğlu, M. A., & Bati, G. B. (2019). İş analitiği ve değer zinciri: Detaylı ve sistematik bir literatür taraması. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, (54), 1-24.
- Bishop, C. M. (2006). Pattern recognition. *Machine learning*, 128(9).
- Bradley, R. A., & Srivastava, S. S. (1979). Correlation in polynomial regression. *The American Statistician*, 33(1), 11-14.
- Breiman, L., & Cutler, A. (2007). "Random forests-classification description," Department of Statistics Homepage, http://www.stat.berkeley.edu/~breiman/RandomForests/cc_home.htm.
- Canci M. & Onden I. (2013), Determining Success Criteria for Creating a Sustainable Bus System, Okan University, International Logistics Department, Tuzla, Istanbul, Conference Paper: December
- Cao, W., Sun, S., & Li, H. (2021). A new forecasting system for high-speed railway passenger demand based on residual component disposing. *Measurement*, 183, 109762.

- Chatterjee, S., & Hadi, A. S. (2013). Regression analysis by example. John Wiley & Sons.
- Chen, S. J., & Hwang, C. L. (1992). Fuzzy multiple attribute decision making: Methods and applications. Berlin: Springer-Verlag.
- Cheng, Z., Trépanier, M., & Sun, L. (2021). Incorporating travel behavior regularity into passenger flow forecasting. *Transportation Research Part C: Emerging Technologies*, 128, 103200.
- Choi, R. Y., Coyner, A. S., Kalpathy-Cramer, J., Chiang, M. F., & Campbell, J. P. (2020). Introduction to machine learning, neural networks, and deep learning. *Translational Vision Science & Technology*, 9(2), 14-14.
- Chopra, S., & Meindl, P. (2015). *Supply Chain Management: Strategy, Planning, and Operation*, Pearson-Prentice Hall, Upper Saddle River, NJ, USA, 6th edition, 2015.
- Cinelli, M., Kadziński, M., Gonzalez, M., & Słowiński, R. (2020). How to support the application of multiple criteria decision analysis? Let us start with a comprehensive taxonomy. *Omega*, 96, 102261.
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine learning*, 20(3), 273-297.
- Cruz, P. P. (2011). *Inteligencia artificial con aplicaciones a la ingeniería*. Alfaomega.
- Cyril, A., Mulangi, R. H., & George, V. (2018). Modelling and forecasting bus passenger demand using time series method. In 2018 7th International Conference on Reliability, Infocom Technologies and Optimization (Trends and Future Directions) (ICRITO) (pp. 460-466). IEEE.
- Çağlar, T. 2007. Talep Tahmininde Kullanılan Yöntemler ve Fens Teli Üretimi Yapan Bir İşletmede Uygulanması. Kırıkkale Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Bölümü, Yüksek Lisans Tezi.
- Çelebi, D., Bolat, B., & Bayraktar, D. (2009). Light rail passenger demand forecasting by artificial neural networks. In 2009 International Conference on Computers & Industrial Engineering (pp. 239-243). IEEE.
- Da Silva, I. N., Spatti, D. H., Flauzino, R. A., Liboni, L. H. B., & dos Reis Alves, S. F. (2017). In *Artificial neural networks* (pp. 39). Springer, Cham.
- Dashtian, A., Rouhani, A., & Dashtian, A. (2022). Municipal Solid Waste Disposal Site Selection Using Remote Sensing Technology and AHP Process (Case Study: Khesht city, Fars Province, Iran). *Journal of Brilliant Engineering*, 2, 4535.

- Dehnavi, A., Aghdam, I. N., Pradhan, B., & Varzandeh, M. H. M. (2015). A new hybrid model using step-wise weight assessment ratio analysis (SWARA) technique and adaptive neuro-fuzzy inference system (ANFIS) for regional landslide hazard assessment in Iran. *Catena*, 135, 122-148.
- Demirbaş, F. P. 2011. Kombi Üretiminde Talep Tahmin Yöntemlerinin Uygulanması. Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Bölümü, Yüksek Lisans Tezi.
- Dou, F., Xu, J., Wang, L., & Jia, L. (2013). A train dispatching model based on fuzzy passenger demand forecasting during holidays. *Journal of Industrial Engineering and Management*, 6(1), 320-335.
- Draper, N. R., & Smith, H. (1998). *Applied regression analysis* (Vol. 326). John Wiley & Sons.
- EFENDİGİL, T., & EMİNLER, Ö. E. (2017). Havacılık sektöründe talep tahminin önemi: Yolcu talebi üzerine bir tahmin modeli. *Journal of Yaşar University*, 12, 14-30.
- Fares, N., & Lloret, J. (2022). An integrated SWOT-AHP-fuzzy TOPSIS approach for maturity management following the COVID-19 outbreak: lessons learned from fast fashion. *Journal of Global Operations and Strategic Sourcing*.
- Forouzandeh, S., Rostami, M., & Berahmand, K. (2022). A Hybrid Method for Recommendation Systems based on Tourism with an Evolutionary Algorithm and Topsis Model. *Fuzzy Information and Engineering*, 1-25.
- Freund, R. J., Wilson, W. J., & Sa, P. (2006). *Regression analysis*. Elsevier.
- Fuloria, S. (2020). Passenger Demand Forecasting in the Ridesharing Context: A Comparison of Statistical and Deep Learning Approaches. *IUP Journal of Applied Economics*, 19(1).
- Galik, A., Baki, M., Bałandynowicz-Panfil, K., & Cirella, G. T. (2022). Evaluating Labour Market Flexibility Using the TOPSIS Method: Sustainable Industrial Relations. *Sustainability* 2022, 14, 526.
- Ghenai, C., Albawab, M., & Bettayeb, M. (2020). Sustainability indicators for renewable energy systems using multi-criteria decision-making model and extended SWARA/ARAS hybrid method. *Renewable Energy*, 146, 580-597.
- Gong, W. (2010). ARMA-GRNN for passenger demand forecasting. In 2010 Sixth International Conference on Natural Computation (Vol. 3, pp. 1577-1581). IEEE.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT press.
- Gunn SR. Support vector machines for classification and regression. *ISIS Tech Rep*. 1988;14(1):5-16.

- Guo, J., Huang, W., & Williams, B. M. (2014). Adaptive Kalman filter approach for stochastic short-term traffic flow rate prediction and uncertainty quantification. *Transportation Research Part C: Emerging Technologies*, 43, 50-64.
- Hamurcu, M., & Eren, T. (2017). Decision Making for Rail System Projects with AHP-GP and ANP-GP. *Gazi J. Eng. Sci*, 3, 1-13.
- Han, Y., Peng, T., Wang, C., Zhang, Z., & Chen, G. (2021). A Hybrid GLM Model for Predicting Citywide Spatio-Temporal Metro Passenger Flow. *ISPRS International Journal of Geo-Information*, 10(4), 222.
- Hashemi, A., Dowlatshahi, M. B., & Nezamabadi-pour, H. (2022). Ensemble of feature selection algorithms: A multi-criteria decision-making approach. *International Journal of Machine Learning and Cybernetics*, 13(1), 49-69.
- Hopfield, J. J. (1982). Neural networks and physical systems with emergent collective computational abilities. *Proceedings of the national academy of sciences*, 79(8), 2554-2558.
- Hsu, C. W., & Lin, C. J. (2002). A comparison of methods for multiclass support vector machines. *IEEE transactions on Neural Networks*, 13(2), 415-425.
- Huang, X., Wang, Y., Lin, P., Yu, H., & Luo, Y. (2021). Forecasting the All-Weather Short-Term Metro Passenger Flow Based on Seasonal and Nonlinear LSSVM. *Promet-Traffic&Transportation*, 33(2), 217-231.
- Hwang, C. L., & Yoon, K. (1981). Methods for multiple attribute decision making. In *Multiple attribute decision making* (pp. 58-191). Springer, Berlin, Heidelberg.
- Hwang, C. L., Paidy, S. R., Yoon, K., & Masud, A. S. M. (1980). Mathematical programming with multiple objectives: A tutorial. *Computers & Operations Research*, 7(1-2), 5-31.
- Ibrić, S., Djuriš, J., Parojčić, J., & Djurić, Z. (2012). Artificial neural networks in evaluation and optimization of modified release solid dosage forms. *Pharmaceutics*, 4(4), 531-550.
- Jafari, S. A., Mashohor, S., Ramli, A. R., & Marhaban, M. H. (2012, March). Expert pruning based on genetic algorithm in regression problems. In *Asian Conference on Intelligent Information and Database Systems* (pp. 79-88). Springer, Berlin, Heidelberg.
- Jain, A. K., Mao, J., & Mohiuddin, K. M. (1996). Artificial neural networks: A tutorial. *Computer*, 29(3), 31-44.
- Jang, J., Park, C., Kim, B., & Choi, N. (2011). Modeling of time headway distribution on suburban arterial: Case study from South Korea. *Procedia-social and behavioral sciences*, 16, 240-247.

- Javapoint, (2020), <https://www.javatpoint.com/machine-learning-polynomial-regression>, Erişim Tarihi: 2020-11-01
- Jin, F., Li, Y., Sun, S., & Li, H. (2020). Forecasting air passenger demand with a new hybrid ensemble approach. *Journal of Air Transport Management*, 83, 101744.
- Kacprzak, D. (2019). A doubly extended TOPSIS method for group decision making based on ordered fuzzy numbers. *Expert Systems with Applications*, 116, 243-254.
- Kalifa, M., Özdemir, A., Özkan, A., & Banar, M. (2022). Application of Multi-Criteria Decision analysis including sustainable indicators for prioritization of public transport system. *Integrated Environmental Assessment and Management*, 18(1), 25-38.
- Karaatlı, M., Helvacıoğlu, Ö. C., Ömürbek, N., & Tokgöz, G. (2012). Yapay Sinir Ağları Yöntemi ile Otomobil Satış Tahmini. *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 8(17), 87-100.
- Karabasevic, D., Stanujkic, D., Urosevic, S., & Maksimovic, M. (2015a). Selection of candidates in the mining industry based on the application of the SWARA and the MULTIMOORA methods. *Acta Montanistica Slovaca*, 20(2).
- Karabašević, D., Stanujkić, D., & Urošević, S. (2015b). The MCDM Model for Personnel Selection Based on SWARA and ARAS Methods. *Management (1820-0222)*, 20(77).
- Karabašević, D., Stanujkić, D., Urošević, S., & Maksimović, M. (2016). An approach to personnel selection based on SWARA and WASPAS methods. *Bizinfo (Blace) Journal of Economics, Management and Informatics*, 7(1), 1-11.
- Karabasevic, D., Stanujkic, D., Urosevic, S., Popovic, G., & Maksimovic, M. (2017). An approach to criteria weights determination by integrating the Delphi and the adapted SWARA methods. *Management: Journal of Sustainable Business and Management Solutions in Emerging Economies*, 22(3), 15-25.
- Karahan, M. 2011. İstatistiksel Tahin Yöntemleri: Yapay Sinir Ağları Metodu ile Ürün Talep Tahmini Uygulaması. Selçuk Üniversitesi, Sosyal Bilimler Enstitüsü, Üretim Yönetimi ve Pazarlama Bölümü, Doktora Tezi.
- Kavitha, S., Varuna, S., & Ramya, R. (2016). A comparative analysis on linear regression and support vector regression. In 2016 online international conference on green engineering and technologies (IC-GET) (pp. 1-5). IEEE.
- Ke, J., Zheng, H., Yang, H., & Chen, X. M. (2017). Short-term forecasting of passenger demand under on-demand ride services: A spatio-temporal deep learning approach. *Transportation Research Part C: Emerging Technologies*, 85, 591-608.

- Keršulienė, V., & Turskis, Z. (2011). Integrated fuzzy multiple criteria decision making model for architect selection. *Technological and economic development of economy*, 17(4), 645-666.
- Keršulienė, V., & Turskis, Z. (2014). An integrated multi-criteria group decision making process: selection of the chief accountant. *Procedia-Social and Behavioral Sciences*, 110, 897-904.
- Keršulienė, V., Zavadskas, E. K., & Turskis, Z. (2010). Selection of rational dispute resolution method by applying new step-wise weight assessment ratio analysis (SWARA). *Journal of business economics and management*, 11(2), 243-258.
- Kim, K., & Kim, J. H. (2020). Polynomial Regression Predistortion for Phase Error Calibration in X-Band SAR. *IEEE Geoscience and Remote Sensing Letters*.
- Kim, S. (2016). Forecasting short-term air passenger demand using big data from search engine queries. *Automation in Construction*, 70, 98-108.
- Ko, Y. D., & Shang, H. (2011). A neural network-based soft sensor for particle size distribution using image analysis. *Powder Technology*, 212(2), 359-366.
- Kondratenko, Y. P., Klymenko, L. P., & Al Zu'bi, E. Y. M. (2013). Structural optimization of fuzzy systems' rules base and aggregation models. *Kybernetes*.
- Kondratenko, Y., Kondratenko, G., & Sidenko, I. (2018, May). Multi-criteria decision making for selecting a rational IoT platform. In *2018 IEEE 9th International Conference on Dependable Systems, Services and Technologies (DESSERT)* (pp. 147-152). IEEE.
- Lazcano-Herrera, A. G., Fuentes-Aguilar, R. Q., & Alfaro-Ponce, M. (2021, November). EEG motor/imagery signal classification comparative using machine learning algorithms. In *2021 18th International Conference on Electrical Engineering, Computing Science and Automatic Control (CCE)* (pp. 1-6). IEEE.
- Li, C., Bai, L., Liu, W., Yao, L., & Waller, S. T. (2021). A multi-task memory network with knowledge adaptation for multimodal demand forecasting. *Transportation Research Part C: Emerging Technologies*, 131, 103352.
- Li, P., Wu, J., & Qian, H. (2012). Groundwater quality assessment based on rough sets attribute reduction and TOPSIS method in a semi-arid area, China. *Environmental Monitoring and Assessment*, 184(8), 4841-4854.
- Li, W., Sui, L., Zhou, M., & Dong, H. (2021). Short-term passenger flow forecast for urban rail transit based on multi-source data. *EURASIP Journal on Wireless Communications and Networking*, 2021(1), 1-13.
- Li, X., Zhang, Y., Du, M., & Yang, J. (2020). The forecasting of passenger demand under hybrid ridesharing service modes: A combined model based on WT-FCBF-LSTM. *Sustainable Cities and Society*, 62, 102419.

- Li, Y., Yin, M., & Zhu, K. (2021, May). Short Term Passenger Flow Forecast of Metro Based on Inbound Passenger Plow and Deep Learning. In 2021 International Conference on Communications, Information System and Computer Engineering (CISCE) (pp. 777-780). IEEE.
- Li, Z. C., & Sheng, D. (2016). Forecasting passenger travel demand for air and high-speed rail integration service: A case study of Beijing-Guangzhou corridor, China. *Transportation Research Part A: Policy and Practice*, 94, 397-410.
- Li, Z., Luo, Z., Wang, Y., Fan, G., & Zhang, J. (2022). Suitability evaluation system for the shallow geothermal energy implementation in region by Entropy Weight Method and TOPSIS method. *Renewable Energy*, 184, 564-576.
- Liang, J. (2020, November). Multivariate linear regression method based on SPSS analysis of influencing factors of CPI during epidemic situation. In 2020 2nd International Conference on Economic Management and Model Engineering (ICEMME) (pp. 294-297). IEEE.
- Lolli, F., Coruzzolo, A. M., & Balugani, E. (2022). The Indoor Environmental Quality: A TOPSIS-based approach with indirect elicitation of criteria weights. *Safety Science*, 148, 105652.
- Luo, H., Cai, J., Zhang, K., Xie, R., & Zheng, L. (2021). A multi-task deep learning model for short-term taxi demand forecasting considering spatiotemporal dependences. *Journal of Traffic and Transportation Engineering (English Edition)*, 8(1), 83-94.
- Mamakou, X. J., & Roumeliotou, K. P. (2022). Evaluating the Electronic Service Quality of E-Shops Using AHP-TOPSIS: The Case of Greek Coffee Chains During the COVID-19 Lockdown. *Journal of Electronic Commerce in Organizations (JECO)*, 20(1), 1-17.
- Mardani, A., Zavadskas, E. K., Khalifah, Z., Jusoh, A., & Nor, K. M. (2016). Multiple criteria decision-making techniques in transportation systems: A systematic review of the state of the art literature. *Transport*, 31(3), 359-385.
- Mavi, R. K., Goh, M., & Zarbakhshnia, N. (2017). Sustainable third-party reverse logistic provider selection with fuzzy SWARA and fuzzy MOORA in plastic industry. *The International Journal of Advanced Manufacturing Technology*, 91(5), 2401-2418.
- Meydan, Y. A. 2007. Talep Tahmin Yöntemleri ve Orta Ölçekli Bir İşletmede Uygulanması. İstanbul Ticaret Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Bölümü, Yüksek Lisans Tezi.
- Mittal, K., Chandra Tewari, P., Khanduja, D., & Kaushik, P. (2016). Application of Fuzzy TOPSIS MADM approach in ranking & underlining the problems of plywood industry in India. *Cogent Engineering*, 3(1), 1155839.

- Mojaver, M., Hasanzadeh, R., Azdast, T., & Park, C. B. (2022). Comparative study on air gasification of plastic waste and conventional biomass based on coupling of AHP/TOPSIS multi-criteria decision analysis. *Chemosphere*, 286, 131867.
- Montgomery, D. C., Peck, E. A., & Vining, G. G. (2015). "Introduction to linear regression analysis", Wiley Series in Probability and Statistics, 2015.
- Nahmias, S. (2008). *Production and Operations Analysis*, McGraw-Hill, Irwin, CA, USA, 6th edition, 2008.
- Nakamura, H. (1998). Analysis of minimum train headway on a moving block system by genetic algorithm. *WIT Transactions on the Built Environment*, 37.
- Nar, M. 2018. İş sürekliliği yönetiminde (BCM) kritik başarı faktörlerinin belirlenmesi ve önceliklendirilmesi. Çukurova Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Bölümü, Yüksek Lisans Tezi.
- Navada, A., Ansari, A. N., Patil, S., & Sonkamble, B. A. (2011). Overview of use of decision tree algorithms in machine learning. In 2011 IEEE control and system graduate research colloquium (pp. 37-42). IEEE.
- Nazerian, H., Shirazy, A., Shirazi, A., & Hezarkhani, A. (2021). Predict the Amount of Cu Using the Four Ca, Al, P, S Elements by Multiple Linear Regression Method. *International Journal for Research in Applied Science and Engineering Technology (IJRASET)*, 9, 1088-1092.
- Noviantoro, T., & Huang, J. P. (2021). Investigating airline passenger satisfaction: Data mining method. *Research in Transportation Business & Management*, 100726.
- 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.
- Ostertagová, E. (2012). Modelling using polynomial regression. *Procedia Engineering*, 48, 500-506.
- Pacheco, F. A. L., Pires, L. M. G. R., Santos, R. M. B., & Fernandes, L. S. (2015). Factor weighting in DRASTIC modeling. *Science of the Total Environment*, 505, 474-486.
- Padfield, N., Zabalza, J., Zhao, H., Masero, V., & Ren, J. (2019). EEG-based brain-computer interfaces using motor-imagery: Techniques and challenges. *Sensors*, 19(6), 1423.
- Pandas.Pydata, (2020), <https://pandas.pydata.org>, Erişim Tarihi: 2020-11-01
- Patel, J., & Patel, A. (2016). Artificial neural networking in controlled drug delivery. In *Artificial Neural Network for Drug Design, Delivery and Disposition* (pp. 195-218). Academic Press.

- Pavlov, Y. L. (2019). Random forests. *Random Forests*, 1–122.
- Picano, B., Chiti, F., Fantacci, R., & Han, Z. (2019, May). Passengers Demand Forecasting Based on Chaos Theory. In *ICC 2019-2019 IEEE International Conference on Communications (ICC)* (pp. 1-6). IEEE.
- Picano, B., Fantacci, R., & Han, Z. (2019). Nonlinear Dynamic Chaos Theory Framework for Passenger Demand Forecasting in Smart City. *IEEE Transactions on Vehicular Technology*, 68(9), 8533-8545.
- Prabowo, A. S. (2021). Forecasting System For Passenger, Airplane, Luggage And Cargo, Using Artificial Intelligence Method-Backpropagation Neural Network At Juanda International Airport. *Warta Ardha*, 45(2), 99-110.
- Radović, D., & Stević, Ž. (2018). Evaluation and selection of KPI in transport using Swara method. *Transport & Logistics: The International Journal*, 8(44), 60-68.
- Rajendran, S., Srinivas, S., & Grimshaw, T. (2021). Predicting demand for air taxi urban aviation services using machine learning algorithms. *Journal of Air Transport Management*, 92, 102043.
- Rathi, R., Khanduja, D., & Sharma, S. (2015). Six Sigma project selection using fuzzy TOPSIS decision making approach. *Management Science Letters*, 5(5), 447-456.
- Raubitzek, S., & Neubauer, T. (2021). Taming the Chaos in Neural Network Time Series Predictions. *Entropy*, 23(11), 1424.
- Ravindran, A., & Warsing, D. P. (2013). *Supply Chain Engineering: Models and Applications*, CRC Press, Boca Raton, FL, USA, 2013.
- Ray, S. (2019, February). A quick review of machine learning algorithms. In *2019 International conference on machine learning, big data, cloud and parallel computing (COMITCon)* (pp. 35-39). IEEE.
- Rechy-Ramirez, E. J., & Hu, H. (2015). Bio-signal based control in assistive robots: a survey. *Digital Communications and networks*, 1(2), 85-101.
- Riccardo, R., & Massimiliano, G. (2012). An empirical analysis of vehicle time headways on rural two-lane two-way roads. *Procedia-Social and Behavioral Sciences*, 54, 865-874.
- Rosenblatt, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, 65(6), 386.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *nature*, 323(6088), 533-536.
- Saarikoski, H., Barton, D. N., Mustajoki, J., Keune, H., Baggethun, E. N. G., & Langemeyer, J. (2015). Multi-criteria decision analysis (MCDA) in ecosystem service valuation. In *OpenNESS Ecosystem Service Reference Book*.

- Saaty, R. W. (1987). The analytic hierarchy process—what it is and how it is used. *Mathematical modelling*, 9(3-5), 161-176.
- Saaty, T. L. (1980). *The analytic hierarchy process* McGraw-Hill. New York, 324.
- Saaty, T. L. (1990). How to make a decision: the analytic hierarchy process. *European journal of operational research*, 48(1), 9-26.
- Saaty, T. L. (2004). Decision making—the analytic hierarchy and network processes (AHP/ANP). *Journal of systems science and systems engineering*, 13(1), 1-35.
- Saaty, T. L. (2008). Decision making with the analytic hierarchy process. *International journal of services sciences*, 1(1), 83-98.
- Saaty, T. L., & Sodenkamp, M. (2010). The analytic hierarchy and analytic network measurement processes: the measurement of intangibles. In *Handbook of multicriteria analysis* (pp. 91-166). Springer, Berlin, Heidelberg.
- Salcedo-Sanz, S., Rojo-Álvarez, J. L., Martínez-Ramón, M., & Camps-Valls, G. (2014). Support vector machines in engineering: an overview. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 4(3), 234-267.
- Saxe, A., Nelli, S., & Summerfield, C. (2021). If deep learning is the answer, what is the question?. *Nature Reviews Neuroscience*, 22(1), 55-67.
- Scikit-Learn, (2020), <https://scikit-learn.org/stable/modules>, Erişim Tarihi: 2020-11-01
- Seber, G. A. F., & Lee, A. J. (2012a). "Linear regression analysis", *Wiley Series in Probability and Statistics*, 2012.
- Seber, G. A., & Lee, A. J. (2012b). *Linear regression analysis* (Vol. 329). John Wiley & Sons.
- Sener, E., & Davraz, A. (2013). Assessment of groundwater vulnerability based on a modified DRASTIC model, GIS and an analytic hierarchy process (AHP) method: the case of Egirdir Lake basin (Isparta, Turkey). *Hydrogeology Journal*, 21(3), 701-714.
- Sexton, R. S., Johnson, R. A., & Hignite, M. A. (2002). Predicting Internet/e-commerce use. *Internet research*.
- Shih, H., & Rajendran, S. (2019). Comparison of time series methods and machine learning algorithms for forecasting Taiwan Blood Services Foundation's blood supply. *Journal of healthcare engineering*, 2019.

- Shirazi, A., Hezarkhani, A., Shirazy, A., & Shahrood, I. R. A. N. (2018). Exploration Geochemistry Data-Application for Cu Anomaly Separation Based On Classical and Modern Statistical Methods in South Khorasan, Iran. *International Journal of Science and Engineering Applications*, 7, 39-44.
- Shirazi, A., Shirazy, A., Saki, S., & Hezarkhani, A. (2018). Geostatistics studies and geochemical modeling based on core data, sheytoor iron deposit, Iran. *Journal of Geological Resource and Engineering*, 6, 124-133.
- Shirazy, A., Shirazi, A., Ferdossi, M. H., & Ziaii, M. (2019). Geochemical and geostatistical studies for estimating gold grade in tarq prospect area by k-means clustering method. *Open Journal of Geology*, 9(6), 306-326.
- Shirazy, A., Ziaii, M., & Hezarkhani, A. (2020). Geochemical Behavior Investigation Based on K-means and Artificial Neural Network Prediction for Copper, in Kivi region, Ardabil province, IRAN. *Iranian Journal of Mining Engineering*, 14(45), 96-112.
- Shirazy, A., Ziaii, M., Hezarkhani, A., & Timkin, T. (2020). Geostatistical and remote sensing studies to identify high metallogenic potential regions in the Kivi area of Iran. *Minerals*, 10(10), 869.
- Shohda, A., Ali, M. A., Ren, G., Kim, J. G., & Mohamed, M. A. E. H. (2022). Application of Cascade Forward Backpropagation Neural Networks for Selecting Mining Methods. *Sustainability*, 14(2), 635.
- Sindhu, S., Nehra, V., & Luthra, S. (2017). Solar energy deployment for sustainable future of India: Hybrid SWOC-AHP analysis. *Renewable and Sustainable Energy Reviews*, 72, 1138-1151.
- Singh, A. K., & Mukherjee, K. (2022). PRIORITIZATION OF PROJECT STAKEHOLDERS: AN AHP BASED APPROACH. *International Journal of Business and Economics*, 6(2), 299-314.
- Singh, B. (2021). Predicting airline passengers' loyalty using artificial neural network theory. *Journal of Air Transport Management*, 94, 102080.
- Singh, R. K., & Modgil, S. (2020). Supplier selection using SWARA and WASPAS—a case study of Indian cement industry. *Measuring Business Excellence*.
- Smola AJ, Schölkopf B. A tutorial on support vector regression. *Stat Comput*. 2004;14(3):199–222.
- Stanujkic, D., Karabasevic, D., & Zavadskas, E. K. (2015). A framework for the selection of a packaging design based on the SWARA method. *Engineering Economics*, 26(2), 181-187.
- Sun, Y., Peng, Y., Chen, Y., & Shukla, A. J. (2003). Application of artificial neural networks in the design of controlled release drug delivery systems. *Advanced Drug Delivery Reviews*, 55(9), 1201-1215.

- Suweda, I. W. (2016). Time headway analysis to determine the road capacity. *Jurnal Spektran* Vol, 4(2).
- Svetnik, V., Liaw, A., Tong, C., Culberson, J. C., Sheridan, R. P., & Feuston, B. P. (2003). Random forest: a classification and regression tool for compound classification and QSAR modeling. *Journal of chemical information and computer sciences*, 43(6), 1947-1958.
- Tahri, M., Maanan, M., Tahri, H., Kašpar, J., Purwestri, R. C., Mohammadi, Z., & Marušák, R. (2022). New Fuzzy-AHP Matlab based graphical user interface (GUI) for a broad range of users: Sample applications in the environmental field. *Computers & Geosciences*, 158, 104951.
- Tang, J., Liang, J., Liu, F., Hao, J., & Wang, Y. (2021). Multi-community passenger demand prediction at region level based on spatio-temporal graph convolutional network. *Transportation Research Part C: Emerging Technologies*, 124, 102951.
- Tang, T., Fonzone, A., Liu, R., & Choudhury, C. (2021). Multi-stage deep learning approaches to predict boarding behaviour of bus passengers. *Sustainable Cities and Society*, 103111.
- Torkashvand, M., Neshat, A., Javadi, S., & Pradhan, B. (2021). New hybrid evolutionary algorithm for optimizing index-based groundwater vulnerability assessment method. *Journal of Hydrology*, 598, 126446.
- TRANSPORT, (2022), <https://tourismteacher.com/advantages-of-rail-transport/>, Erişim Tarihi: 2022-01-16
- Tzeng, G. H., & Huang, J. J. (2011). Multiple attribute decision making: methods and applications. CRC press.
- UITP, (2022), <https://www.uitp.org/topics/metro/>, Erişim Tarihi: 2022-01-16
- Ulutaş, A. (2019). SWARA ve MAIRCA Yöntemleri ile Catering Firması Seçimi. *Business & Management Studies: An International Journal*, 7(4), 1467-1479.
- Urosevic, S., Karabasevic, D., Stanujkic, D., & Maksimovic, M. (2017). AN APPROACH TO PERSONNEL SELECTION IN THE TOURISM INDUSTRY BASED ON THE SWARA AND THE WASPAS METHODS. *Economic Computation & Economic Cybernetics Studies & Research*, 51(1).
- Vásquez, J. A., Escobar, J. W., & Manotas, D. F. (2022). AHP–TOPSIS Methodology for Stock Portfolio Investments. *Risks*, 10(1), 4.
- Vesković, S., Stević, Ž., Stojić, G., Vasiljević, M., & Milinković, S. (2018). Evaluation of the railway management model by using a new integrated model DELPHI-SWARA-MABAC. *Decision Making: Applications in Management and Engineering*, 1(2), 34-50.

- Wahyono, I. D., Fadlika, I., Asfani, K., Putranto, H., & Hammad, J. (2019, October). New Adaptive Intelligence Method for Personalized Adaptive Laboratories. In 2019 International Conference on Electrical, Electronics and Information Engineering (ICEEIE) (Vol. 6, pp. 196-200). IEEE.
- Wahyuni, D. S., Agustini, K., & Ariadi, G. (2022). An AHP-Based Evaluation Method for Vocational Teacher's Competency Standard. *International Journal of Information and Education Technology*, 12(2).
- Wallenius, J., Dyer, J. S., Fishburn, P. C., Steuer, R. E., Zionts, S., & Deb, K. (2008). Multiple criteria decision making, multiattribute utility theory: Recent accomplishments and what lies ahead. *Management science*, 54(7), 1336-1349.
- Wang, J., Zhang, Y., Wei, Y., Hu, Y., Piao, X., & Yin, B. (2021). Metro Passenger Flow Prediction via Dynamic Hypergraph Convolution Networks. *IEEE Transactions on Intelligent Transportation Systems*.
- Wang, S., Di, J., Wang, D., Dai, X., Hua, Y., Gao, X., ... & Gao, J. (2022). State-of-the-Art Review of Artificial Neural Networks to Predict, Characterize and Optimize Pharmaceutical Formulation. *Pharmaceutics*, 14(1), 183.
- Wang, Y., Hong, H., Chen, W., Li, S., Panahi, M., Khosravi, K., ... & Costache, R. (2019). Flood susceptibility mapping in Dingnan County (China) using adaptive neuro-fuzzy inference system with biogeography based optimization and imperialistic competitive algorithm. *Journal of environmental management*, 247, 712-729.
- Wei, X., Zhang, Y., Wei, Y., Hu, Y., Tong, S., Huang, W., & Cao, J. (2021). Metro passenger-flow representation via dynamic mode decomposition and its application. *IEEE Transactions on Neural Networks and Learning Systems*.
- Xie, C., Li, X., Chen, B., Lin, F., Lin, Y., & Huang, H. (2021). Subway Sudden Passenger Flow Prediction Method Based on Two Factors: Case Study of the Dongsishitiao Station in Beijing. *Journal of Advanced Transportation*, 2021.
- Yalcin, A. S., Kilic, H. S., & Delen, D. (2022). The use of multi-criteria decision-making methods in business analytics: A comprehensive literature review. *Technological Forecasting and Social Change*, 174, 121193.
- Yang, X., Xue, Q., Ding, M., Wu, J., & Gao, Z. (2021). Short-term prediction of passenger volume for urban rail systems: A deep learning approach based on smart-card data. *International Journal of Production Economics*, 231, 107920.
- Yang, X., Xue, Q., Yang, X., Yin, H., Qu, Y., Li, X., & Wu, J. (2021). A novel prediction model for the inbound passenger flow of urban rail transit. *Information Sciences*, 566, 347-363.
- Yoon, K. P., & Hwang, C. L. (1995). Multiple attribute decision making: an introduction. Sage publications.

- Yu, H., Fu, J., Dang, L., Cheong, Y., Tan, H., & Wei, H. (2015). Prediction of the particle size distribution parameters in a high shear granulation process using a key parameter definition combined artificial neural network model. *Industrial & Engineering Chemistry Research*, 54(43), 10825-10834.
- Yücenur, G. N., & Ipekçi, A. (2021). SWARA/WASPAS methods for a marine current energy plant location selection problem. *Renewable Energy*, 163, 1287-1298.
- Zahedi, F. (1986). The analytic hierarchy process—a survey of the method and its applications. *interfaces*, 16(4), 96-108.
- Zhang, Z. (2020, June). From Artificial Neural Networks to Deep Learning: A Research Survey. In *Journal of Physics: Conference Series* (Vol. 1576, No. 1, p. 012030). IOP Publishing.
- Zhao, S., & Mi, X. (2019). A novel hybrid model for short-term high-speed railway passenger demand forecasting. *IEEE Access*, 7, 175681-175692.
- Zheng, Z. H., Ling, X. M., Wang, P., Xiao, J., & Zhang, F. (2021). Hybrid model for predicting anomalous large passenger flow in urban metros. *IET Intelligent Transport Systems*, 14(14), 1987-1996.
- Zolfani, S. H., & Saparauskas, J. (2013). New application of SWARA method in prioritizing sustainability assessment indicators of energy system. *Engineering Economics*, 24(5), 408-414.
- Zuo, Y., Fu, X., Liu, Z., & Huang, D. (2021). Short-term forecasts on individual accessibility in bus system based on neural network model. *Journal of Transport Geography*, 93, 103075.
- Zyoud, S. H., & Fuchs-Hanusch, D. (2017). A bibliometric-based survey on AHP and TOPSIS techniques. *Expert systems with applications*, 78, 158-181.

EKLER

EK 1: Python programının 'pandas' kütüphanesinde kullanılan kodlar (PANDAS.PYDATA, 2020; SCİKİT-LEARN, 2020)

```
import pandas as pd
```

```
# csv dosyaları okutulur.
```

```
aksaray = pd.read_csv('data/aksaray.csv')
```

```
bagcilar = pd.read_csv('data/bagcilar.csv')
```

```
bayrampasa = pd.read_csv('data/bayrampasa.csv')
```

```
emniyet = pd.read_csv('data/emniyet.csv')
```

```
esenler = pd.read_csv('data/esenler.csv')
```

```
kirazli = pd.read_csv('data/kirazli.csv')
```

```
kocatepe = pd.read_csv('data/kocatepe.csv')
```

```
menderes = pd.read_csv('data/menderes.csv')
```

```
otogar = pd.read_csv('data/otogar.csv')
```

```
sagmancilar = pd.read_csv('data/sagmancilar.csv')
```

```
ucyuzlu = pd.read_csv('data/ucyuzlu.csv')
```

```
ulubatli = pd.read_csv('data/ulubatli.csv')
```

```
yenikapi = pd.read_csv('data/yenikapi.csv')
```

```
data = kirazli
```

```
newData = pd.read_csv('new.csv')
```

```
subData = data.iloc[:, 0:-1].values
```

```
newSubData = newData.iloc[:,].values
```

```

totalPassengers = data.iloc[:, -1:].values

# ----- Decision Tree (Karar Ağacı) -----
from sklearn.tree import DecisionTreeRegressor
dtr = DecisionTreeRegressor(random_state=0)

# Makine eğitilir.
dtr.fit(subData, totalPassengers)

# Tahmin yaptırılır
result = dtr.predict(newSubData)

sum = 0
for i in result:
    sum = sum + i
print('Decision',sum)

# # ----- Linear Regression (Doğrusal Regresyon) -----
from sklearn.linear_model import LinearRegression

lr = LinearRegression()

# Makine eğitilir.
lr.fit(subData, totalPassengers)

# Tahmin yaptırılır.
result = lr.predict(newSubData)
sum = 0
for i in result:
    sum = sum + i
print('Linear',sum)

# # ----- Random Forest (Rassal Orman) -----

```



```
from sklearn.ensemble import RandomForestRegressor
```

random_state modelin çıkışını çoğaltılamaz hale getirir yani random_state değeri belli olduğunda aynı parametreler

ve aynı eğitim verisi verilmişse, aynı sonuçları üretecektir. n_estimators = oluşturulacak decision tree (karar ağacı) sayısını gösterir:

```
rfg = RandomForestRegressor(n_estimators=10, random_state=0)
```

Makine eğitilir.

```
rfg.fit(subData, totalPassengers)
```

Random Forest (Rassal Orman) algoritmasını kullanarak eğitilen makinenin verilen verilere göre bir tahmin yapması sağlanır:

```
result = rfg.predict(newSubData)
```

```
sum = 0
```

```
for i in result:
```

```
    sum = sum + i
```

```
print('Random',sum)
```

----- Polynomial Regression (Polinom Regresyon) -----

```
from sklearn.preprocessing import PolynomialFeatures
```

```
lr2 = LinearRegression()
```

Buradaki degree (derece) parametresi polinomun derecesidir.

degree (derece) ne kadar arttırılırsa o kadar sağlıklı bir sonuç elde edilebilir.

```
poly = PolynomialFeatures(degree=4)
```

Makine eğitilmeden önce eğitim kolonundaki değerler PolynomialFeatures ile

dönüşüm yaptırılır.

```
subData_poly = poly.fit_transform(subData)
newSubData_poly = poly.fit_transform(newSubData)
```

Makine eğitilir.

```
lr2.fit(subData_poly, totalPassengers)
```

Makine eğitildikten sonra bir tahmin yaptırılır.

```
result = lr2.predict(newSubData_poly)
```

```
sum = 0
```

```
for i in result:
```

```
    sum = sum + i
```

```
print('Polynomial',sum)
```

----- Support Vector Regression (Destek Vektör Regresyonu) -----

```
from sklearn.preprocessing import StandardScaler
```

```
sc_subData = StandardScaler()
```

```
sc_newSubData = StandardScaler()
```

```
subData_scale = sc_subData.fit_transform(subData)
```

```
newSubData_scale = sc_newSubData.fit_transform(newSubData)
```

```
sc_totalPassengers = StandardScaler()
```

```
totalPassengers_scale = sc_totalPassengers.fit_transform(totalPassengers)
```

```
from sklearn.svm import SVR
```

```
svr_reg = SVR(kernel='rbf')
```

Makine eğitilir.

```
svr_reg.fit(subData_scale, totalPassengers_scale)
```

Ölçeklenmiş veriye göre tahmin yaptırılır.

```
result = svr_reg.predict(newSubData_scale)
```

```
sum = 0
```

```
for i in result:
```

```
    sum = sum + i
```

```
print('Support',sum)
```



ÖZGEÇMİŞ

Adı Soyadı : Melek NAR

ÖĞRENİM DURUMU

Derece	Eğitim Birimi	Mezuniyet Yılı
Doktora	Sakarya Üniversitesi / Fen Bilimleri Enstitüsü / Endüstri Mühendisliği	Devam ediyor
Yüksek Lisans	Çukurova Üniversitesi / Fen Bilimleri Enstitüsü / Endüstri Mühendisliği	2018
Lisans (Çiftanadal)	Çukurova Üniversitesi / Fen Bilimleri Enstitüsü / İstatistik	2012
Lisans	Çukurova Üniversitesi / Mühendislik Fakültesi / Endüstri Mühendisliği	2011
Lise	Adana Ticaret Odası Anadolu Lisesi	2007

İŞ DENEYİMİ

Yıl	Yer	Görev
2021-Halen	TÜBİTAK RUTE- Sinyalizasyon Sistemleri Birimi	Uzman Araştırmacı
2017-2021	TÜBİTAK BİLGEM- Raylı Ulaşım Sistemleri Birimi	Araştırmacı/Uzman
2016-2016	Alpro Endüstriyel Gıda Ürünleri – Hakan YURDACAN	Araştırmacı Dış Ticaret Uzmanı
2016-2016	INIGO Ecza Deposu İth. İhr. San. Ve Tic Ltd. Şti	Dış Ticaret Uzmanı
2014-2015	Makser PVC Makine San. Tic. Ltd. Şti.	Dış Ticaret Uzmanı

YABANCI DİL

İngilizce

ESERLER (makale, bildiri, proje vb.)

1. Nar, M. & Arslankaya, S. (2022). Passenger demand forecasting for railway systems. Open Chemistry, 20(1), 105-119. <https://doi.org/10.1515/chem-2022-0124>
2. MALIDARRE, R. B., ARSLANKAYA, S., NAR, M., KIRELLI, Y., IMAMOGLU, M. Y., KARPUZ, N., OVALIOGLU, H., & MALIDARREH, P. B. (2022). Deep Learning Prediction for gamma ray attenuation behavior of the KNN-LMN based lead free ceramics. Emerging Materials Research.
3. Melek, N. A. R., & YÜREGİR, O. H. İş Sürekliliği Yönetiminde Kritik Başarı Faktörlerinin AHP Yöntemi ile Önceliklendirilmesi. Çukurova Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi, 33(4), 241-254.
4. Nar, M., & Yüreğir, O. H. (2017). PRIORITIZATION OF CRITICAL SUCCESS FACTORS IN BUSINESS CONTINUITY MANAGEMENT WITH AHP METHOD. In International Conference on Economic Research, Alanya, Turkey, 20-21 October 2017. Proceedings (pp. 116-127). Alanya Alaaddin Keykubat University.

HOBİLER

Yüzme, Binicilik, Resim