T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

KENTSEL ALANLARDA YAYA DİNAMİKLERİNİN MODELLENMESİ

Özge ÖZTÜRK HACAR

DOKTORA TEZİ
Harita Mühendisliği Anabilim Dalı
Uzaktan Algılama ve CBS Programı

Danışman
Prof. Dr. Fatih GÜLGEN

Temmuz, 2025

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

KENTSEL ALANLARDA YAYA DİNAMİKLERİNİN MODELLENMESİ

Özge ÖZTÜRK HACAR tarafından hazırlanan tez çalışması 01.07.2025 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Harita Mühendisliği Anabilim Dalı Uzaktan Algılama ve CBS Programı **DOKTORA TEZİ** olarak kabul edilmiştir.

Prof. Dr. Fatih GÜLGEN
Yıldız Teknik Üniversitesi
Danışman

Jüri Üyeleri

Prof. Dr. Fatih GÜLGEN, Danışman
Yıldız Teknik Üniversitesi _____

Prof. Dr. Ali Melih BAŞARANER, Üye
Yıldız Teknik Üniversitesi _____

Prof. Dr. Ahmet Özgür DOĞRU, Üye
İstanbul Teknik Üniversitesi _____

Prof. Dr. Türkay GÖKGÖZ, Üye
Yıldız Teknik Üniversitesi _____

Dr. Öğr.Üyesi Ayşe Giz GÜLNERMAN GENGEÇ, Üye
Ankara Hacı Bayram Veli Üniversitesi _____

Danışmanım Prof. Dr. Fatih GÜLGEN sorumluluğunda tarafımca hazırlanan Kentsel Alanlarda Yaya Dinamiklerinin Modellenmesi başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Özge ÖZTÜRK HACAR

İmza

Bu çalışma, “TÜBİTAK (Türkiye Bilimsel ve Teknolojik Araştırma Kurumu) 2214-A Yurt Dışı Doktora Sırası Araştırma Bursu (No: 1059B142200486)” projesi ile desteklenmiştir.

Aileme

TEŞEKKÜR

Öncelikle, bilgi birikimi, vizyonu ve sabrı ile her aşamada yol gösteren danışmanım **Prof. Dr. Fatih GÜLGEN** 'e en derin şükranlarımı sunarım. Değerli görüşleriyle çalışmayı zenginleştiren tez izleme komitesi üyeleri **Prof. Dr. Ali Melih BAŞARANER**'e ve **Prof. Dr. Ahmet Özgür DOĞRU** 'ya teşekkür ederim.

Tezin yurt dışı araştırmasını **ISTI-CNR** bünyesinde gerçekleştirmemi mümkün kılan Türkiye Bilimsel ve Teknolojik Araştırma Kurumu'na (TÜBİTAK) ve araştırma sürecim boyunca desteklerini esirgemeyen **Dr. Luca Pappalardo**, **Dr. Mirco Nanni** ve tüm *KDD-Lab* ekibine teşekkür ederim.

Veri paylaşımında bulunan Melbourne Belediyesi **Open Data Platformu** ekibine; moral ve motivasyon desteği sağlayan çalışma arkadaşlarım **Güldane**, **Özge** ve **Zehra**'ya; bir tek mesajıyla bile günümü güzelleştiren **Aynur Hocam**'a; beni fiziksel ve zihinsel olarak zinde tutan yoga eğitmenlerim **Handan** ve **Özge**'ye ve pilates eğitmenim **Saime Hocam**'a; akademik yolculuğumun en başından beri beni en iyi şekilde yönlendiren **Doç. Dr. Serdar BİLGİ** ve **Dr. Öğr. Üyesi Ayşe Giz GÜLNERMAN GENGEÇ**'e en içten teşekkürlerimi sunarım.

Çocukluğumdan bu yana beni koşulsuz destekleyen aileme; sabrı, sevgisi ve bana olan inancıyla bu yolculuğu paylaşan biricik eşim **Müslüm**'e; minicik kalbi ve sevgi dolu kocaman gözleriyle yaşadığım her zorlukta bana güç veren, sayesinde zaman yönetimini öğrendiğim biricik kızım **Jülide Liv**'e sonsuz teşekkür ederim.

Adlarını tek tek anamadığım, doğrudan ya da dolaylı katkı sunan herkese teşekkür ederim.

Özge ÖZTÜRK HACAR

İÇİNDEKİLER

SİMGE LİSTESİ viii

KISALTMA LİSTESİ x

ŞEKİL LİSTESİ xi

TABLO LİSTESİ xiii

ÖZET xiv

ABSTRACT xvi

1 GİRİŞ 1

1.1 Araştırmanın Arka Planı ve Motivasyonu . . . 3
1.2 Literatür Özeti . . . 3
1.3 Tezin Amacı . . . 7
1.4 Hipotezler . . . 7

2 İNSAN HAREKETLİLİĞİ: KURAMSAL YAKLAŞIMLAR VE MODELLEME YÖNTEMLERİ 8

2.1 Tarihsel Gelişim ve Öncü Modeller . . . 8
2.2 Makine Öğrenmesine Dayalı Hareketlilik Modelleri . . . 14
2.3 Mekansal Ağ Modelleri ve Hareketlilik . . . 14
2.4 Hareketlilik Modellerinin Karşılaştırılması . . . 16

3 İNSAN HAREKETLİLİĞİ VE DİJİTAL AYAK İZİ 21

3.1 Veri Kaynakları . . . 23
3.1.1 Google Maps verileri . . . 24
3.1.2 CoM-OD portal verileri . . . 26
3.1.3 OSM verileri . . . 29
3.2 Veri Ön İşleme . . . 30
3.3 Veri Entegrasyonu . . . 33
3.4 Bulgular ve Değerlendirme . . . 36
3.5 Tartışma . . . 41

4 GELİŞTİRİLEN N-ADIM (N-STEP) AKIŞ MODELİNİN TASARIMI VE UYGULAMASI **44**
4.1 Hareketlilik Modelinin Geliştirilmesinde İlk Yaklaşımlar 45
4.2 N-Adım Modeli 47
4.3 Akış Miktarının Hesaplanması 48
4.4 Çalışma Bölgesi ve Veri Kaynağı 49
4.5 Mekansal Mozaikleme 49
4.6 Sonuçlar 52
4.7 Tartışma 60

5 SONUÇ **63**

KAYNAKÇA **68**

A PYTHON KODLARI-1 **80**

B PYTHON KODLARI-2 **86**

TEZDEN ÜRETİLMİŞ YAYINLAR **92**

SİMGE LİSTESİ

n	Adım numarası
N	Ağdaki toplam düğüm sayısı
$C_B(i)$	Arasındalık (betweenness) merkeziliği
T_{ij}	Başlangıç noktası i'den varış noktası j'ye yönelen toplam hareket (akış) miktarı
T_i	Başlangıç bölgesi i'den çıkan toplam yolculuk (gözlenen ya da tahmin edilen)
M_i	Başlangıç noktası i'nin "kütle"si (nüfus, istihdam veya çekim gücünü temsil eden değişken)
m_i	Başlangıç bölgesi i'nin nüfusu
$\sigma_{st}(i)$	Bu yollardan düğüm i üzerinden geçenlerin sayısı
$C_D(i)$	Derece (degree) merkeziliği
k_i	Düğüm i'nin derece (bağlantı) sayısı
d_{ij}	Düğüm i ile j arasındaki en kısa yol mesafesi
x_i	Düğüm i'nin özvektör bileşeni
k_j^{out}	Düğüm j'nin giden (çıkış) kenar sayısı
λ	En büyük özdeğer
$C_H(i)$	Harmonik yakınlık merkeziliği
s_{ij}	i–j yarıçapında, i ve j hariç tüm ara bölgelerin toplam nüfusu
$C_K(i)$	Katz merkeziliği
α	Katz sönüm katsayısı ($0 < \alpha < 1/\lambda$)
κ	Katz merkeziliği için başlangıç sabiti (genellikle 1)
a_{ij}	Komşuluk matrisi elemanı; i–j arasında kenar varsa 1, yoksa 0
β	Mesafe duyarlılık katsayısı

d_{ij}	Noktalar arası mesafe
$C_E(i)$	Özvektör (eigenvector) merkeziliği
$PR(i)$	PageRank değeri
d	PageRank sönüm faktörü (genelde 0.85)
$\ell_{st}(i)$	s ve t birim akışının düğüm i üzerinden geçen payı
σ_{st}	s–t arasındaki en kısa yol sayısı
M_j	Varış noktası j'nin "kütle"si
n_j	Varış bölgesi j'nin nüfusu
$C_C(i)$	Yakınlık (closeness) merkeziliği
P_{new}	Yeni yer seçme olasılığı (EPR)
$L(i)$	Yük (load) merkeziliği

KISALTMA LİSTESİ

API	Application Programming Interface
ATM	Ajan Tabanlı Model
CPC	Common Part of Commuters
CV	Coefficient of Variation
EDO	Eating Drinking Out
EPR	Exploration and Preferential Return
GIS	Geographic Information System
GPS	Global Positioning System
IDW	Inverse Distance Weighting
IoT	Internet of Things
OD	Origin-Destination
OSM	OpenStreetMap
ÖS	Özellik Seti
RO	Rastgele Orman
STS-EPR	Spatial–Temporal–Social EPR

ŞEKİL LİSTESİ

Şekil 2.1 Hareketlilik Modelleri: Tarihçe ve Öncü Çalışmalar 8
Şekil 3.1 Melbourne belediye sınırı (siyah) ve çalışma alanı (kırmızı). . . . 23
Şekil 3.2 Çalışma alanında EDO hizmeti sunan yerler. 25
Şekil 3.3 Çalışma alanında binaların hane sayısına göre dağılımı. 26
Şekil 3.4 Melbourne'ün merkezi iş noktalarından biri olan William caddesindeki (a) yaya sayım sensörü (b) [142] 27
Şekil 3.5 Yıllara göre kurulan sensör sayıları. 28
Şekil 3.6 Yıllara göre değişen toplam sensör sayıları. 28
Şekil 3.7 Çalışma alanındaki sensörlerin yerleşimi. 29
Şekil 3.8 Melbourne'e ait OSM yol ağı verisi. 30
Şekil 3.9 Çalışma alanında yer alan 71 sensörün tümünün her saat diliminde kaydettiği toplam yaya sayısının saat bazlı dağılımı. . . 31
Şekil 3.10 Özellik setlerinin üretim süreci. 34
Şekil 3.11 EDO konumları (sarı noktalar) ve Voronoi hücreleri. 35
Şekil 3.12 Çalışma alanında (a) konut ve (b) yaya yoğunluğunun mekansal dağılımı. 37
Şekil 3.13 OSM yol ağından hesaplanan merkezilik ölçüleri. 38
Şekil 3.14 Yorum sayısı (a) ve ortalama ziyaretçi puanı (b) tahminlerine ilişkin model performanslarının, farklı özellik seti ÖS-(FS) kombinasyonları ve mekan türleri (barlar, kafeler ve restoranlar) bazında karşılaştırılması. 39
Şekil 3.15 (a) Yorum hacmi ve (b) ziyaretçi puanı tahminlerinde en iyi sonuç veren öznitelik seti kombinasyonları için öznitelik önem düzeylerinin görselleştirilmesi. 40
Şekil 4.1 D8 tabanlı akış yönleri. 45
Şekil 4.2 Akışın başladığı numaralandırılmış (beyaz) hücreler, onların komşuları (kırmızı) ve erişilemeyen (gri) hücreler. 46
Şekil 4.3 Varsayımsal bir şehir üzerindeki N-Adım akış modelinin basit bir gösterimi. 48
Şekil 4.4 Kare ve altıgen hücrelerin Melbourne şehri için OSM altlığı kullanılarak görselleştirilmesi. 51
Şekil 4.5 Kare ve altıgen hücreler içerisinde sensörlerin dağılımı. 52

Şekil 4.6 Yaya Sayımlarının Haftalık Standart Sapma Değerleri (Yüksek standart sapma: kırmızı; orta: mavi ve düşük: yeşil). 52
Şekil 4.7 Test haftaları için hücrelerdeki yaya sayımları. 54
Şekil 4.8 Karesel yapı için adım adım akış haritaları. 56
Şekil 4.9 Altıgen yapı için adım adım akış haritaları. 57
Şekil 4.10 Kare ve altıgen mozaikler üzerindeki yerçekimi akışları. 58
Şekil 4.11 Kare mozaik (sol) ve altıgen (sağ) için Düşük, Orta ve Yüksek Haftalara ait CPC Değerlerindeki Değişimler. 59
Şekil 4.12 Düşük, orta ve yüksek haftalara ait kare mozaiklerin dağılım grafikleri. 59
Şekil 4.13 Düşük, orta ve yüksek haftalara ait altıgen mozaiklemenin dağılım grafikleri. 60
Şekil 4.14 Modellerin pratik kullanım durumunda kıyaslaması. 62

TABLO LİSTESİ

Tablo 2.1 İnsan hareketliliği üzerine yapılmış çalışmalar. 17
Tablo 3.1 Melbourne'de Google Places API'den elde edilen temsili veriler. 25
Tablo 3.2 Örnek yaya sayım verisi (kısaltılmış). 27
Tablo 3.4 Bu çalışmada kullanılan merkezilik ölçüleri ve formülleri 33
Tablo 3.6 Özellik Setlerinin İçerdiği Temel Özellikler 35
Tablo 4.1 Seçili haftalar için sensörlerden toplanan saatlik yaya sayımı verilerinin standart sapma ve ortalama değerleri. 53

ÖZET

KENTSEL ALANLARDA YAYA DİNAMİKLERİNİN MODELLENMESİ

Özge ÖZTÜRK HACAR

Harita Mühendisliği Anabilim Dalı
Doktora Tezi

Danışman: Prof. Dr. Fatih GÜLGEN

Bu doktora tezi, kentsel alanda yaya hareketliliğini dijital ayak izleri ve sentetik akış modelleri aracılığıyla incelemektedir. İlk olarak, Google Maps platformunda yiyecek-içecek işletmelerine ait kullanıcı yorum sayıları ve ziyaretçi puanları, Rastgele Orman algoritmasıyla modellenmiştir. Bu tahmin modeline, OSM yol ağından türetilen merkezilik ölçüleri, sensör tabanlı yaya yoğunlukları ve hane sayıları gibi mekansal değişkenler entegre edilmiştir. Sonuçlar, yaya yoğunluğunun dijital etkileşimleri açıklamada en güçlü belirleyici olduğunu ve dijital izler ile kentsel mekansal yapı arasında anlamlı ilişkiler bulunduğunu göstermiştir.

İkinci aşamada, ayrıntılı akış örüntülerini üretmek amacıyla özgün bir "N-Adım Akış Algoritması" geliştirilmiştir. Melbourne şehrindeki sensör ağından saatlik olarak toplanan yaya sayımları, kare ve altıgen yapıda mozaiklenmiş hücrelere aktarılmış ve sayımlar dört adımda komşu hücrelere dağıtılarak sentetik akış verileri oluşturulmuştur. Elde edilen matrisler, klasik yerçekimi modeline karşı "Common Part of Commuters (CPC)" ölçüsüyle değerlendirilmiş ve önerilen yaklaşımın daha ayrıntılı ve yaya hareketlerinin doğasına daha uygun akış desenleri sunduğu gösterilmiştir.

Bu çalışma, çok kaynaklı verilerin birlikte kullanımının dijital tayak izleri ve yaya hareketliliğini anlamada yüksek açıklayıcılığa sahip olduğunu ortaya koymaktadır. Bununla birlikte, gerçek akış verilerinin eksikliği ve modeldeki adımlar arası ağırlıkların sabit tutulması önemli sınırlılıklar oluşturmaktadır. Gelecek araştırmalarda, telekomünikasyon verileriyle çok kaynaklı doğrulama ve

gerçek zamanlı kalibrasyon yaklaşımlarının geliştirilmesi önerilmektedir.

Anahtar Kelimeler: Yaya hareketliliği, mekansal analiz, OD matris üretimi, dijital ayak izi.

ABSTRACT

MODELLING PEDESTRIAN DYNAMICS IN URBAN AREAS

Özge ÖZTÜRK HACAR

Department of Geomatic Engineering
Doctor of Philosophy Thesis

Supervisor: Prof. Dr. Fatih GÜLGEN

This doctoral thesis introduces a novel "N-Step Flow Algorithm" developed to conduct detailed and precise analyses of pedestrian mobility in urban areas. The algorithm primarily relies on pedestrian count data collected from physical sensors. Hourly pedestrian count data collected from Melbourne, Australia's sensor network, were transferred to square and hexagonal grid cells covering the study area. The counts within each cell were redistributed across neighboring cells through a four-step process, generating synthetic flow data.

These synthetic origin-destination (OD) matrices were compared with matrices derived from the traditional gravity model using the "Common Part of Commuters (CPC)" metric. The comparison revealed step-by-step similarities, demonstrating that the proposed algorithm is more innovative and effective than conventional methods.

In another phase of the thesis, the significance of pedestrian mobility was further illustrated by modeling user reviews and visitor ratings of eating drinking out places establishments on the Google Maps platform using the Random Forest algorithm. Spatial features, such as centrality measures calculated from the OpenStreetMap (OSM) road network, pedestrian density, and the number of residential dwellings in the area, were incorporated into the model. The analysis concluded that pedestrian density was a more influential determinant compared to other spatial variables.

The findings of the research indicated that the developed multi-step model

represents pedestrian movements more realistically and precisely compared to traditional single-step models. However, the study's primary limitations include the absence of real OD matrices and the static nature of the step weights used in the model. Therefore, future research is recommended to include multi-source validation methods using telecommunication data and implement real-time calibration practices.

Keywords: Pedestrian mobility, spatial analysis, OD matrix generation, digital footprint.

1
GİRİŞ

Yürümek, bir başlangıçtır, çıkış noktasıdır. İnsan, yürümek için yaratılmıştır ve hayatın büyük küçük tüm olayları, diğer insanların arasında yürüdüğümüzde gelişir. Hayat, tüm çeşitliliğiyle, yürüdüğümüzde gözlerimizin önünde açılır. Canlı, güvenli, sürdürülebilir ve sağlıklı şehirlerde yaşam kalitesi iyi yürüme olanaklarının sağlanmasıyla artar [1]. Kentlerin büyümesi tarih boyunca ulaşım sistemlerinin gelişmesine paralel hareket etmiş ve insan hareketliliği kentlerin sosyal ve ekonomik yapısını şekillendiren en önemli unsurlardan biri olmuştur [2].

Bilim tarihinde insan hareketliliğinin temel ilkeleri ilk olarak büyük düşünürler tarafından ele alınmıştır. Leonardo da Vinci, Newton'dan yaklaşık iki yüzyıl önce hareketin sürekliliğini ve dış etkenler tarafından yönlendirildiğini gözlemlemiştir [3]. Da Vinci, yaptığı deneylerde "Hiçbir şey kendiliğinden hareket etmez, bir başka şey onu harekete geçirir. Her türlü hareket sürme eğilimindedir." ifadesiyle, hareketin sürekliliğini açıklayan önemli bir sezgi ortaya koymuştur [3]. Newton'un birinci hareket yasası, yani "Bir cisim üzerine bir kuvvet etki etmediğinde duruyorsa durmaya, hareket ediyorsa sabit hızla hareketine devam eder" prensibi [4], aslında Da Vinci'nin notlarında yer alan gözlemlerle büyük ölçüde paralellik göstermektedir. Tıpkı fiziksel hareketin çevresel faktörlerden etkilendiği gibi, insan hareketliliği de şehirlerin altyapısı, yolların düzeni ve mekansal etkileşimler tarafından şekillenir.

Uzun yıllar boyunca yaya hareketliliği, esas olarak trafik planlamasının bir alt dalı olarak değerlendirildi. Bu süreçte, şehir hayatının sunduğu zenginlik ve olanaklar büyük ölçüde göz ardı edildi ya da unutuldu. Kullanılan terimler; "yaya trafiği", "yaya akışları", "kaldırım kapasitesi" ve "güvenli bir şekilde karşıdan karşıya geçmek" gibi kavramlarla sınırlı kaldı. Ancak şehirlerde yürümek, yalnızca yürümekten çok daha fazlasıdır. Yürümek, insanlarla ve çevremizdeki toplulukla doğrudan temas kurmaktır. Temiz havayı solumak, açık havada vakit geçirmek, hayatın sunduğu zevkleri deneyimlemek, yeni bilgiler ve deneyimler edinmektir.

Özellikle sanayi devrimi sonrası ulaşım sistemleri köklü bir dönüşüm geçirmiş, yayalar, at arabaları ve tramvaylarla şekillenen şehirler, otomobil ve metro gibi yeni ulaşım araçlarıyla bambaşka bir düzene girmiştir.

20. yüzyılın ikinci yarısından itibaren, şehir planlamacıları motorlu araçlara öncelik veren sistemleri yaygınlaştırırken, yaya hareketliliği kimi zaman geri planda kalmıştır. Ancak, 21. yüzyılda sürdürülebilir şehircilik anlayışıyla birlikte, yaya hareketliliğinin önemi tekrar gündeme gelmiştir. Jan Gehl'in "İyi şehirler, insanlar için yapılmış şehirlerdir" anlayışı, insan merkezli şehir planlamasının önemini vurgulamaktadır [5]. Günümüz akıllı şehir anlayışında sensörler, GPS (Global Positioning System) verileri ve dijital platformlardan elde edilen bilgiler, insan hareketliliğini anlamak için yeni bakış açıları sunmaktadır. Bu kapsamda hareketliliği en doğru şekilde modellemek ve şehir planlamasında etkin olarak kullanmak için geliştirilen yaklaşımlar, bilim dünyasının önemli araştırma konuları arasındaki varlığını sürdürmektedir.

Bu tez çalışması, şehirlerde yaşayan insanların hareketlilik örüntülerini anlamayı ve insanların mekansal alanlarla olan etkileşimini vurgulayarak yaya hareketlerinin önemini ortaya koymaktadır. Bu kapsamda geliştirilen model ve yapılan analizler, yerçekimi modeli gibi geleneksel yaklaşımlardan farklı olarak, mekansal bağlamın ve komşu alanlarla olan etkileşimin önemini vurgulayarak yaya hareketliliğini ortaya koymaktadır.

Bu tez beş bölümden oluşmaktadır. Birinci bölümde çalışma motivasyonu, araştırmanın amacı, hipotezleri ve literatür özeti sunulmaktadır. İkinci bölümde insan hareketliliği kuramları ve modelleri, mekansal ağ tabanlı modelleme yaklaşımları sistematik olarak tartışılarak kavramsal çerçeve tanıtılmaktadır. Üçüncü bölümde Google Maps yorum-puan verileri, yaya sensör yoğunlukları ve OSM tabanlı ağ göstergeleri bütünleştirilerek kentsel mekanın gördüğü talep niceliksel olarak analiz edilir. Bu bölümden elde edilen bulgular, 4.bölümde yaya akışlarını modellemek amacıyla için geliştirilen modelde kullanılır. Dördüncü bölüm, aynı sensör verilerinden türetilen sentetik akış desenlerini geliştirilen N-Adım Akış Algoritması aracılığıyla üretir ve bu desenleri yerçekimi modeliyle karşılaştırır. Beşinci bölümde elde edilen sonuçlar bir arada tartışılır ve çalışmanın katkıları özetlenir. Gelecekteki araştırmalara yönelik öneriler sunulur. Böylece tez, önce talep odaklı bir kestirim yapıp ardından bu talebi mekana nasıl dağıtacağımızı gösteren akış modelini ortaya koyarak makro ölçekli insan hareketliliğini iki aşamalı kapsamlı bir çerçeve içinde ele almaktadır.

1.1 Araştırmanın Arka Planı ve Motivasyonu

Kentleşme sürecinin hızlanması ve şehirlerin giderek daha karmaşık bir yapıya bürünmesi, şehir içi hareketlilik dinamiklerini anlamanın önemini arttırmaktadır. Bu hareketliliğin temel bileşeni olan yaya hareketliliği, sürdürülebilir ulaşım politikaları ve akıllı şehir uygulamalarının geliştirilmesinde kilit bir faktördür. Geleneksel ulaşım planlaması, genellikle motorlu taşıtlara odaklanırken, yaya hareketliliğinin detaylı analizi uzun yıllar göz ardı edilmiştir. Akıllı şehir teknolojileri ve büyük veri analitiğinin gelişimiyle birlikte, şehir içi insan hareketliliğini anlamaya yönelik çabalar daha fazla ön plana çıkmıştır. Bu tez çalışması, dijital ayak izleri ve insan hareketliliği verilerini birleştirerek, yaya hareketliliğinin mekansal özelliklerle nasıl ilişkili olduğunu ortaya koyarak yeni bir hareketlilik modeli geliştirmeyi amaçlamaktadır.

1.2 Literatür Özeti

Kent nüfusunun artışı ve kentsel ulaşım ağlarının karmaşıklığı, yaya dinamiklerinin modellenmesini kentsel planlama ve ulaşım yönetimi için kritik bir görev haline getirmektedir [6]. İnsan hareketliliği üzerine yapılan mekansal ve zamansal analizler, kentleşme süreçlerinin anlaşılmasında önemli bir rol oynamaktadır. Bu hareketlilikten doğan ulaşım taleplerinin yönetilmesi, trafik yoğunluğunun optimize edilmesi ve tıkanıklıkların azaltılması gibi ulaşımı ve trafik yönetimini konu alan çalışmalarda olduğu gibi yaya hareketliliğini inceleyen birçok araştırma da başlangıç ve hedef konumlar arasındaki akış ilişkisine dayanır [7–9].

Akış verisi, geleneksel veri toplama yöntemi olan seyahat anketleri ya da mobil cihazlardan elde edilen GPS izleri analiz edilerek yolculukların sayısal dağılımlarının modellenmesi ile tahmin edilir [10–12]. Ancak geleneksel veri toplama yaklaşımları yüksek maliyetlidir ve bilgi gizliliği ile güvenlik sorunları nedeniyle her zaman etkin şekilde kullanılamaz. Buna karşın, akıllı şehircilik çalışmaları kapsamında kullanılan Internet of Things (IoT) teknolojileri, sensör verileri ve toplu taşıma kartlarından elde edilen büyük veriler, hareketliliği açıklayan akış verisinin daha güvenilir ve hızlı şekilde temin edilmesini sağlar [13–15].

İnsan hareketliliğinin tahmini için farklı veri kaynaklarına bağlı olarak çok sayıda modelleme yaklaşımı geliştirilmiştir. Bu yaklaşımlar bireysel ve kolektif insan hareketliliği modelleri olmak üzere iki temel grupta ele alınır. Bireysel hareketlilik modelleme yaklaşımları tek bir bireyin davranışı, kişisel tercihleri ve bunu etkileyen çevresel faktörler ile geçmiş seyahatleri gibi etkenlerle şekillenen benzersiz hareket

desenlerine odaklanmıştır [16–19].Kolektif hareketlilik modelleme yaklaşımları geniş popülasyonları analiz ederek bölgeler veya şehirler genelindeki daha geniş hareket örüntülerine dair içgörüler sunar. Toplu insan hareketliliği örüntüleri, şehir trafiği veya hastalık yayılımı gibi büyük ölçekli olgular kolektif yaklaşımlar kullanılarak modellenmektedir [20–24]. Zipf [25], "en az çaba" (principle of least effort) ilkesini kentler arası etkileşime uyarlayarak, bireylerin seyahat mesafesini en aza indirmeye eğilimli olduklarını ve iki yerleşim birimi arasındaki etkileşim hacminin mesafe ile ters orantılı biçimde azaldığını savunmuştur. Bu görüş, daha sonra geliştirilen yerçekimi ve radyasyon modellerine kuramsal temel oluşturmuştur. Yerçekimi ve radyasyon modelleri, insan hareketliliğinin tahmin edilmesinde yaygın olarak kullanılan kolektif yaklaşım araçlarıdır. Yerçekimi modeli, başlangıç ve varış noktaları arasındaki akışı mesafeye dayalı olarak üretmektedir [26–29].Bu model, nüfuslar arasındaki mal ve hizmet talebinin analiz etmek ya da insan hastalıklarının yayılımını incelemek gibi farklı alanlardaki araştırma çalışmalarında kullanılmıştır [30–32]. Buna karşın Anderson [31] çalışmasında, yer çekimi modelinin teorik temellerden yoksun olduğunu ileri sürmüştür. Yer çekimine benzer şekilde işleyen bir diğer model olan radyasyon modeli de hücreler arasındaki mesafeye dayalı olarak çalışır. Bu model, akışı mikro düzeyde ve fırsat temelli olarak ele alır [33–36]. Radyasyon modelinin tahmin doğruluğu insan hareketliliğini açıklamada başarılıdır [35]. Ancak nüfus dağılımının homojen olmadığı ya da çalışma alanının ölçeğinin kapsamı genişlediğinde modelin tahmin doğruluğu azalmaktadır [34, 37].

Son yıllarda insan hareketliliğini modelleme konusunda derin öğrenme yaklaşımlarının kullanımı ön plana çıkmaktadır [19, 38]. Yüksek hesaplama maliyeti, büyük miktarda veriye olan ihtiyaç, eğitim verilerinin kalitesindeki eksikler, veri gizliliği endişeleri ve etik kaygılar derin öğrenme modellerinin kullanımı önündeki temel zorluklardır [39–41]. Yaya hareketlerini inceleyen derin öğrenmeye dayalı yaklaşımlar genellikle kolektif sistemler çerçevesinde değerlendirilmektedir. Son yıllarda, yaya hareketliliğini kolektif davranış örüntüleri üzerinden inceleyen çok sayıda çalışma literatürde yer bulmuştur. Bu çalışmalar hem bireyler arası etkileşimleri hem de çevresel faktörleri dikkate alarak yaya davranışlarını daha gerçekçi biçimde modellemeyi amaçlamaktadır. Rutherford [27], yer çekimi modelinin yaya hareketlerini tahmin etmede etkili olduğunu vurgulamaktadır. Helbing [42], yaya yollarındaki kalabalık dinamiklerini ve tıkanıklıkları inceleyen kolektif davranış tanıma modelini geliştirmiştir. Schadschneider ve diğ.,[43]yaya etkileşimlerini karınca davranışına benzeterek kapı girişlerinde kalabalık tıkanıklığını ve düzenli şerit oluşumunu açıklayan iki boyutlu hücresel otomat modelini önermiştir. Bauer [44], otomatik yaya sayım

teknolojilerini kullanarak zaman içindeki yaya hareketlerini analiz etmiştir. Vogt ve diğ.,[45] şehir merkezlerinde yaya hareketliliğini açıklamak için yaya yollarını simüle eden mekan dizimi tabanlı bir model geliştirmiştir. Fang ve diğ.,[46] acil çıkış durumlarında yayaların kuyruk oluşturma ve kolektif hareket davranışlarını açıklayan bir lider takipçi modeli önermiştir. Khoshkhah ve Hadachi [47], IoT sensörlerinden elde edilen sınırlı verileri kullanarak gerçek zamanlı saatlik başlangıç-varış matrisleri(Origin Destination Matrix)-OD matrisleri üreterek ağ tabanlı rota seçimine dayalı yaya hareketlerini simüle etmiştir. Chan ve diğ.,[48] yaya OD matrisini ve aktivite-destinasyon seçim modeli parametrelerini eşzamanlı olarak tahmin eden iki seviyeli bir programlama modeli önermiştir. Friedrich ve diğ,[49] mobil telefon sinyallerinden yararlanarak hareketli cihazların başlangıç ve varış noktalarını belirlemeye çalışmıştır. Qin ve diğ.,[50] çift yönlü yaya akışını simüle etmek için iki katmanlı bir ilişki mekanizması kullanarak kolektif bir hareket modeli geliştirmiştir. Li ve diğ.,[51] düşük ışıklı acil durum ortamlarında yayaların izleyeceği güzergahları tahmin etmek için RGB-D kameralarından elde ettikleri verilerini kullanmıştır. Diğer taraftan kolektif yaklaşımlar ile bireysel yaklaşımları birlikte kullanan çalışmalar da mevcuttur [52–58].Vanky [59], mobil cihazlardan elde edilen 2.2 milyon yürüyüş yolculuğunun analizini yaparak, kentsel çevrenin yaya hareketliliği üzerindeki etkisini değerlendirmiştir. Jiang [60], Twitter ve Google hareketlilik verilerini kullanarak, COVID-19 pandemisi sırasında insan hareketliliğinin farklı arazi kullanımı türlerine göre değişimini incelemiş ve afetler sırasında tahliye edilen kişilerin varış noktalarını tahmin etmek için yerçekimi modelini sosyal bağlantılarla ilişkilendirmiştir. Chávez-Hernández ve diğ., [61] toplu taşıma kullanıcılarının güzergah tercihlerini analiz ederek OD matrislerini optimize eden bir model önermiştir. Yoongsomporn ve diğ.,[62] Tokyo şehri sınırları içindeki insan hareketliliğini incelemiş, hareketliliğin hafta içi ve hafta sonu farklılıklarını ortaya koymuş, kamu altyapıları ile insan hareketliliği arasındaki ilişkiyi analiz ederek hareketlilik desenlerini belirlemiştir.

İnsan hareketliliği üzerine yapılan çalışmalar, mekansal ve zamansal dinamiklerin anlaşılması açısından büyük önem taşımaktadır. Şehirlerdeki insan hareketliliği, kentsel altyapının planlanması, toplu taşıma sistemlerinin etkinliği ve kamusal alanların kullanılabilirliği açısından önemli bir belirleyicidir. He ve diğ.[63], nüfus büyüklüğü ve mesafeye dayalı hareketlilik modellerinin dezavantajlı grupların seyahat alışkanlıklarını yeterince temsil edilemediğini saptamış, ulaşım politikalarının daha adil ve kapsayıcı olması için modellerin yeniden değerlendirilmesi gerektiğini vurgulamıştır. Sadeghian ve Mojarrad [64], İsveç'in Falun kentinde gerçekleştirdikleri araştırmada, insan hareketliliğinin zamansal ve cinsiyet temelli farklılıklarını analiz etmiş ve kadınların hareketliliğinin genellikle

konut ve ticari alanlarla ilişkili olduğunu, erkeklerin ise daha geniş alanlara yayılan bir hareketlilik sergilediğini tespit etmiştir.

Kentsel alanlarda, bireylerin şehir deneyimlerini dijital ortamda paylaşmaları, önemli bir veri kaynağı olarak ortaya çıkmaktadır. Bu tür paylaşımlar, sosyal medya platformlarında yapılan yorumlar, puanlamalar ve konum bazlı etkileşimler aracılığıyla şekillenmekte ve 'dijital ayak izleri' olarak tanımlanmaktadır. Dijital ayak izleri, insanların şehir içinde bıraktıkları veri noktalarını ifade etmekte olup, Google Maps, Yelp ve TripAdvisor gibi platformlarda bırakılan yorumlar ve puanlamalar, bireylerin mekansal tercihlerine dair önemli bilgiler sunmaktadır. Bu verilerin şehir içi hareketlilik ile nasıl ilişkilendirilebileceğini inceleyen çalışmalar, dijital ayak izlerinin yaya yoğunluğu, cadde merkeziyeti ve kamusal alan kullanımı gibi mekansal faktörler üzerindeki etkilerini ortaya koymaktadır [65]. Özellikle bireylerin belirli bir mekanı tercih etme nedenleri, sosyal medya platformlarındaki değerlendirmeleri ve kentsel yapı ile olan ilişkileri göz önünde bulundurulduğunda, dijital ayak izlerinin hareketlilik tahminlerinde değerli bir veri kaynağı olduğu görülmektedir [60]. Literatürde şehir içi hareketlilik modelleri ve dijital ayak izleri ayrı ayrı incelenmiş olsa da, bu iki alanı bütüncül bir yaklaşımla ele alan çalışmaların sınırlı olduğu görülmektedir. Ayrıca yaya hareketliliği çalışmaları genellikle mahalleler ve sokaklar gibi küçük kentsel bölümlere odaklanmaktadır. Bu nedenle, şehir merkezlerindeki toplulukların hareketlerini esnek ve ölçeklenebilir bir şekilde ortaya koyan makro düzeyde çalışmaların artırılmasına önemli bir ihtiyaç duyulmaktadır. Kameralar, sensörler ve IoT teknolojileri, kolektif hareketleri makro ölçekte modellemek için kullanılabilecek nokta bazlı yaya sayım verilerini sağlamaktadır. Bu veriler yaya dinamiklerini yansıtsa da hareketliliği açıklayan akışları içermemektedir.

Bu literatür özeti, insan hareketliliğini modellemeye yönelik çok sayıda yöntem ve veri türü geliştirildiğini göstermektedir. Bununla birlikte, özellikle yaya hareketliliğinin şehir içi sensör verileriyle modellenmesi, mekansal bağlamda komşuluk etkilerinin dahil edilmesi ve dijital ayak izlerinin mekansal örüntülerle bütünleştirilmesi gibi konularda literatürde boşluklar bulunmaktadır. Bu boşluklar, veri kaynaklarının doğası, modelleme yaklaşımlarının ölçek sınırlılıkları ve bireysel tercihleri açıklamada yaşanan güçlükler nedeniyle tam olarak giderilememiştir. Mevcut çalışmalarda yaya sayım verilerinin akışa dayalı modellere entegrasyonu sınırlı kalırken, dijital etkileşimlerin mekansal özelliklerle bütüncül olarak değerlendirilmesi de ele alınmamıştır. Bu çerçevede, bu tez çalışması söz konusu boşluklara katkı sunmayı hedeflemektedir.

1.3 Tezin Amacı

Bu tez çalışması, şehirlerdeki yaya dinamiklerini ortaya koyan etkili bir hareketlilik modeli geliştirmeye odaklanmaktadır. Geleneksel hareketlilik modellerinin sınırlamalarını aşarak, mekansal bağlamı ve dijital ayak izleri gibi modern veri kaynaklarını içeren kapsamlı bir yaklaşım modeli geliştirmek tez çalışmasının temel amacıdır. Bu doğrultuda, çalışmanın hedefleri aşağıdaki şekilde belirlenmiştir:

- Yaya yoğunluğu ve dijital etkileşim verilerinden elde edilen mekansal örüntüleri birlikte analiz etmek.
- Geleneksel modellerin ötesine geçen yeni bir akış modelleme yöntemi geliştirmek.
- Elde edilen bulgular üzerinden şehir planlamacılarına ve karar vericilere veri odaklı öneriler sunmak.

1.4 Hipotezler

Çalışmada test edilecek ana hipotezler şunlardır:

- **Hipotez 1:** Yaya yoğunluğu, hareket akış desenlerinin öngörülmesinde birincil göstergedir.
- **Hipotez 2:** Şehirde en çok kullanılan cadde ve kavşaklar, dijital platformlardaki yorum ve puanların da en yoğun olduğu noktalardır.
- **Hipotez 3:** Basamak basamak ilerleyen yeni akış modelimiz, yaya geçişlerini tek adımda dağıtan yerçekimi gibi klasik modellere göre daha ayrıntılı hareket akışları üretir.

2
İNSAN HAREKETLİLİĞİ: KURAMSAL YAKLAŞIMLAR VE MODELLEME YÖNTEMLERİ

Şehir içi hareketlilik, bireylerin mekansal karar alma süreçlerini ve hareket modellerini anlamaya yönelik yaklaşımlar üzerinden analiz edilir [16]. 20. yüzyılın başlarından itibaren geliştirilen geleneksel modellerden günümüzün yeni nesil veri odaklı hareketlilik modellerine kadar tasarlanan tüm modeller kişilerin ya da toplulukların bireysel ve kolektif hareketlerini anlamaya odaklanmaktadır (Şekil 2.1).

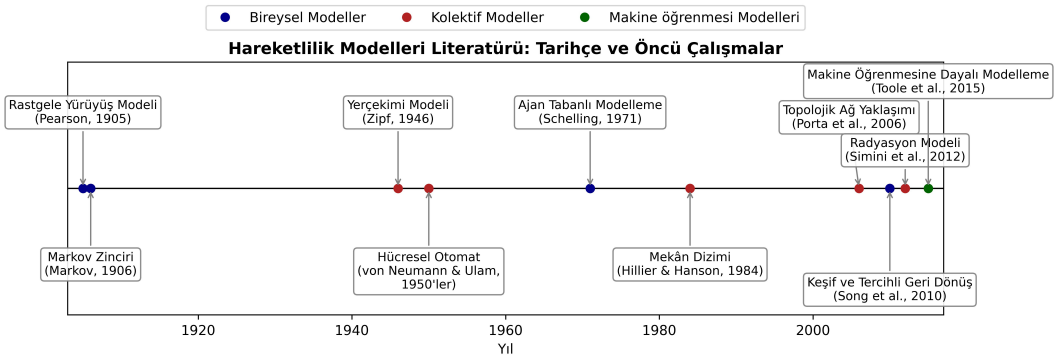

Şekil 2.1 Hareketlilik Modelleri: Tarihçe ve Öncü Çalışmalar

2.1 Tarihsel Gelişim ve Öncü Modeller

Pearson'ın [66] rastgele yürüyüş modeli ve Markov'un [67] geçiş olasılıklarına dayalı yaklaşımı, hareketlilik modellemesinin bilinen ilk örnekleri arasında sayılmaktadır. Zipf'in [25] yerçekimi modeli, mekansal etkileşimi analitik biçimde ele alan ilk model olarak kabul edilmektedir. Schelling'in [68] geliştirdiği ajan tabanlı modelleme yaklaşımı bireysel kararların sistemsel sonuçlarını göstermeyi hedeflemiştir. 1980'lerden sonra ise mekansal morfolojiye odaklanan modeller öne çıkmaya başlamıştır. Bunlar arasında Hillier ve Hanson'ın [69] mekan dizimi ve

Porta ve diğ., [70] ile Simini ve diğ.,[71] gibi araştırmacılar tarafından geliştirilen ağ temelli analiz yaklaşımları hareketlilik modellemesi yaklaşımlarına yeni boyutlar kazandırmıştır. Bunlar arasında öne çıkan yaklaşımlar aşağıda ayrıntılı olarak açıklanmaktadır.

Yerçekimi Modeli

Hareketliliği tahmin etmede kullanılan birçok modelleme yaklaşımı arasında yerçekimi modeli, kuramsal olarak basit olması ve sezgisel bir yapıya sahip olması nedeniyle en yaygın kullanılan mekansal etkileşim modeli olmuştur. Yerçekimi modeli, insan hareketliliğini tahmin etmek için geliştirilen en eski ve en yaygın kullanılan modellerden biridir. Bölgesel çekim gücü,örneğin nüfus, ile iki yer arasındaki mesafe ilişkisini esas alarak akışları tahmin eder. Bu model, basit yapısı, düşük veri gereksinimi ve aynı zamanda büyük çaplı verisetlerinde kullanılabilirliğiyle öne çıkmaktadır [25]. Başlangıç noktası i ile varış noktası j arasındaki akışın,

$$T_{ij} = k \frac{M_i^{\alpha} M_j^{\gamma}}{d_{ij}^{\beta}} \tag{2.1}$$

mesafe ile ters orantılı olduğunu varsayar. Burada T_{ij}, başlangıç noktası i'den varış noktası j'ye beklenen akış miktarını; M_i ve M_j sırasıyla başlangıç ve varış bölgelerindeki "kütle" değerlerini (ör. nüfus ya da istihdam büyüklüğü); d_{ij}, iki bölge arasındaki mesafeyi; k, modelin ölçekleme katsayısını; α ve γ, kütle değişkenlerinin elastisite katsayılarını; β ise mesafeye duyarlılık katsayısını ifade eder. Yerçekimi modeli, büyük merkezlerin daha fazla insanı ve ticari faaliyeti çektiğini ve coğrafi olarak daha uzak yerler arasındaki etkileşimin daha düşük olduğunu öngörmektedir. Göç topluluklarının hareket yönünü ve yoğunluğunu tahmin etmek ya da hava, kara ve demiryolu ulaşımı ve seyahat planlamasında yolcu hareketliliğini ve talebi belirlemek için yerçekimi modeli sıklıkla kullanılmaktadır [2, 32]. Şehirler ve ülkeler arasındaki ticaret hacminin belirlenmesi gibi iktisadi çalışmalarda da bu modelin sıkça kullanıldığı bilinmektedir [72–74]. Bölgesel planlama süreçleri ile kent merkezleri arasındaki etkileşimlerin incelenmesi üzerine yapılan yoğunluk modelleme ve ulaşım altyapısının geliştirilmesine yönelik stratejik karar destek süreçlerinde de yerçekimi modeli yaklaşımından yararlanılmaktadır [75, 76]. Buna karşın, bireysel karar mekanizmaları ve mekansal faktörler açısından daha karmaşık etkileri dikkate almaması yerçekimi modelinin en önemli eksikliğidir [31, 77, 78]. Bireylerin davranışsal tercihlerini ve zaman içindeki değişimleri yeterince yansıtamaması önemli bir sınırlılık olarak öne çıkmaktadır [79–81].

Radyasyon Modeli

Simini ve diğ.,[71] tarafından geliştirilen radyasyon modeli, insan hareketliliğini açıklamak üzere önerilmiş, kalibrasyon gerektirmeyen ve yalnızca nüfus dağılımı verilerini kullanan parametrik olmayan bir mekansal etkileşim modelidir. Modelin kuramsal temeli, "araya giren fırsatlar" (intervening opportunities) ilkesine dayanır. Bu yaklaşıma göre, bir bireyin belirli bir hedefe ulaşmadan önce karşılaştığı daha yakın ve yeterli sayıdaki fırsatlar, hareketin o noktada sonlanmasına neden olabilir. Bu varsayım, bireylerin karar alma süreçlerinde yalnızca hedefe olan uzaklığın değil, aynı zamanda bu yol üzerinde karşılaşılan fırsatların da belirleyici olduğunu öne sürer.

$$T_{ij} \;=\; T_i \,\frac{m_i\, n_j}{(m_i + s_{ij})(m_i + n_j + s_{ij})} \tag{2.2}$$

Burada:

- T_{ij} : i bölgesinden j bölgesine tahmin edilen yolculuk sayısı,
- T_i : i bölgesinden çıkan toplam yolculuk (gözlenen veya tahmin edilen),
- m_i : i bölgesinin nüfusu,
- n_j : j bölgesinin nüfusu,
- s_{ij} : i–j yarıçapı içinde, i ve j hariç tüm bölgelerin nüfuslarının toplamını gösterir.

Bu modele göre bireylerin hareket kararları, başlangıç noktalarının bölgesel yoğunluğu ve yolculuk esnasındaki fırsatların dağılımına bağlı olarak değişir. Başlangıç ve varış noktalarının bulunduğu bölgelerin nüfusları ile seyahat sırasında temas edilen bölgelerin nüfus değerleri üzerinden akış miktarı ve hareketlilik hesaplanır. Bu noktalar arasında kalan bölgelerin nüfusunun fazla olması bireylerin varış noktasına ulaşma olasılığını azaltır. Temas edilen bölge nüfusunun yüksek olması durumunda radyasyon modeli bireylerin varış noktasına ulaşmadan önce daha iyi fırsatlar yakaladığını kabul eder ve hareketi o bölgede sonlandırır.

Radyasyon modelinin en yaygın kullanım alanlarından biri kentleşme ve bölgesel planlamadır [35, 82, 83]. Ulaşım ağlarının planlanması, özellikle karayolu, demiryolu ve hava yolu taşımacılığı talebinin modellenmesi açısından radyasyon modeli önemli bir araçtır [84]. Aynı zamanda, salgın hastalık yayılımı çalışmalarında bireylerin hareketliliğini analiz etmek ve hastalık yayılım hızını tahmin etmek için kullanılır [85, 86].

Hücresel Otomat Yaklaşımı

Hücresel otomat modeli, şehir içinde bireylerin hareketlerini belirlemek için grid tabanlı bir sistem kullanır [87]. Bu model, bireylerin belirli kurallar çerçevesinde komşu hücrelerle olan etkileşimine dayalı olarak hareket ettiğini varsayar. Coğrafya alanında hücresel otomat modelleri, arazi kullanım değişimi ve kentsel gelişim süreçlerinin mekansal simülasyonunda önemli bir yer tutar [88]. İki boyutlu bir ızgara üzerindeki her hücre, tarım arazisi, ormanlık alan veya kentsel bölge gibi farklı arazi kullanım türlerini temsil edecek şekilde tanımlanır ve her hücrenin yeni kullanımı, komşuluk ilişkilerine göre belirlenir. Ulaşım bilimlerinde trafik akışı ve yaya hareketi simülasyonlarında yaygın olarak tercih edilen bu model, araçların yol şeritlerinde ilerleme, frenleme veya çarpışmayı önleme davranışlarını ayrık hücreler ve yerel güncelleme kuralları üzerinden modelleyerek trafik sıkışıklığı, kuyruk oluşumu ve gecikme süreleri gibi makro ölçekli olguların incelenmesine olanak tanır. Yaya akışı çalışmalarında ise her hücre belirli bir alandaki bir bireyi temsil edecek şekilde düzenlenir ve bireylerin komşuluk ilişkileri, örneğin daha az kalabalık yöne hareket etme eğilimleri, yerel karar kurallarıyla tanımlanarak acil tahliye senaryoları veya kalabalık yönetimi analizleri yürütülebilir. Modelin doğruluğu açısından komşuluk tanımları, hücre boyutu ve zaman adımı gibi parametrelerin seçimi dikkat edilmesi gereken noktalardır. Ayrıca, raster verilere uygun bir çerçeve sunar. Sistemin mikro düzeydeki kurallarından makro ölçekte kendiliğinden örgütlenmiş (self-organization) karmaşık davranışların ortaya çıkmasına olanak tanıyan bir yapıya sahiptir. Ancak, sürekli mekansal süreçleri ayrık hücrelere bölerek temsil etmesi, gerçek dünyadaki akıcı hareketleri basitleştirilmiş hale getirebilir ve bazı süreçlerin fazla indirgenmesine neden olabilir [89].

Keşif ve Tercihli Geri Dönüş (Exploration and Preferential Return)-EPR Modeli

Song ve diğ. [90] bireylerin hareketliliğini açıklamak için Keşif ve Tercihli Geri Dönüş (Exploration and Preferential Return – EPR) modelini geliştirmiştir. Bu model, insan hareketliliğini açıklamak için iki temel mekanizma tanımlar: keşif (exploration) ve tercihli geri dönüş (preferential return). Keşif, bireyin yeni bir konuma gitme eğilimi olup, kesikli güç yasası sıçrama boyutu dağılımına sahip bir rastgele yürüyüş süreci ile belirlenir. Tercihli geri dönüş ise bireylerin geçmişte sık ziyaret ettikleri konumlara dönme eğilimidir. Geri dönülecek konumun seçimi, daha önce o konumu ziyaret etme sıklığıyla orantılı olarak gerçekleşir. Modelin işleyişi şu şekildedir: $P_{\text{new}} = S$ olasılığıyla birey yeni bir konuma hareket eder. Burada S, ajanın ziyaret ettiği konumların sayısını ifade eder. Yeni konumun

mevcut konuma olan uzaklığı, güç yasası dağılımına göre belirlenir. $1 - P_{\text{new}}$ olasılığıyla birey daha önce ziyaret ettiği konumlardan birine geri döner [90]. Bu geri dönüş tercihi, ziyaret sıklığına göre belirlenir. Bu iki mekanizmanın etkileşimi, seyrek ancak sistemli şekilde yeni yerlerin devreye girmesini ve giderek artan bir biçimde daha sık gidilen yerlerin tekrar ziyaret edilmesini sağlar. Dolayısıyla, EPR modeli gözlemlenen birçok insan hareket kalıbında rastlanan ağır kuyruklu adım uzunlukları, sabit merkezlere geri dönüş ve kısa dönem bellek etkileri gibi olguları doğal bir biçimde üretir [91].

Rastgele Yürüyüş Modeli

Rastgele yürüyüş modeli, belirli bir olgunun, bireylerin veya insan topluluklarının, rastgele yön ve mesafe seçimlerine dayalı olarak konum değiştirmesini açıklayan olasılıksal bir yaklaşımdır [66]. Rastgele yürüyüş modelinin temel prensibi, her adımda bir sonraki konumun belirli bir olasılık dağılımına göre seçilmesine dayanır. Modelin temel bileşenleri adım yönü ve adım büyüklüğüdür. En basit haliyle, basit rastgele yürüyüş modelinde her adım rastgele seçilen sabit bir mesafeye ve yön değişimine sahiptir. Ancak insan hareketliliğini daha gerçekçi şekilde modellemek için kullanılan Lévy uçuşu (Lévy flight) gibi varyantlar, adım uzunluklarının ağır kuyruklu bir dağılıma sahip olmasını öngörmektedir. Bu tür modeller, bireylerin belirli bir konumda uzun süre vakit geçirdikten sonra ani ve uzun mesafeli bir sıçrama yapma eğilimini açıklamak açısından daha uygun bir yaklaşım sunar [16]. İlk olarak fizik ve matematik alanlarında, özellikle Brown hareketi [92] gibi stokastik süreçleri modellemek için geliştirilmiş olan bu model, zamanla sosyal bilimler, mekansal analizler ve insan hareketliliği çalışmalarında da yaygın olarak kullanılmaya başlanmıştır [93]. İnsan hareketliliği bağlamında, rastgele yürüyüş modelleri bireylerin zaman içerisindeki konum değişimlerini istatistiksel bir çerçevede analiz etme olanağı sunar. Büyük ölçekli veri kaynakları, örneğin cep telefonu sinyalleri veya GPS verileri, ile birleştirildiğinde, kent planlaması, ulaşım analizi ve salgın hastalık yayılımı gibi konular için simülasyon ve tahmin modelleri geliştirmek mümkün hale gelmektedir. Rastgele yürüyüş modelinin uygulanabilirliği ve doğruluğu, kullanılan veri setinin doğasına bağlı olarak değişkenlik gösterebilir. Ayrıca modelin zamansal ölçeği veya veri setindeki örnekleme periyodu, bireylerin hareket örüntülerini en iyi şekilde yansıtacak şekilde belirlenmelidir. Bu nedenlerden dolayı rastgele yürüyüş modelleri, insan hareketliliğini belirleyen tüm faktörleri kapsayan bir yaklaşım sunmamaktadır. Gerçek dünyadaki hareketler rastgele olmaktan çok, bireylerin sosyal, bilişsel ve kültürel faktörlere dayalı karar mekanizmalarına göre şekillenmektedir. Dolayısıyla, rastgele yürüyüş modelleri mekansal çekicilik

unsurlarını ve bireylerin tercihlerini doğrudan içermediğinden, insan hareketliliğini daha iyi modellemek için ek metodolojik yaklaşımlar ve veriye dayalı iyileştirmeler gerekmektedir.

Markov Zinciri Modeli

Markov zinciri yaklaşımı, insan hareketliliğini modelleme sürecinde özellikle konum geçişlerinin zaman içindeki olasılıksal dağılımını ele almak amacıyla kullanılan bir yöntemdir [67]. Bir bireyin veya grubun bir sonraki adımda hangi konuma gideceğine dair olasılık, büyük ölçüde güncel konumundan ve zamanın getirdiği koşullardan etkilenir. Geçmişteki bütün hareketlerin uzun bir bellek oluşturması yerine, esas belirleyici olan mevcut konumdaki duruma dayalı geçiş olasılıklarıdır. Bu yaklaşıma göre, insan hareketliliği bir dizi ayrık durum veya konum olarak, örneğin; şehirler, ilçeler veya belirli alanlar şeklinde tanımlanır ve geçiş olasılık matrisi aracılığıyla bireylerin bu durumlar arasındaki mekansal hareketleri modeller. Her durum, bir kişinin bulunabileceği bir konumu veya konum kategorisini temsil eder. Bir sonraki adımda başka bir konuma geçmenin ya da aynı konumda kalmanın ihtimali, Markov zincirinin geçiş matrisiyle belirlenir [94]. Bu çerçevede, insan hareketliliğinin Markov zinciriyle modellenmesi sürecinde öncelikle temsil edilecek düzey önemlidir. Modelin düzeyini belirlerken, konumlar arasındaki uzaklık, seyahat maliyeti ve ulaşım ağının yapısı gibi etkenler dikkate alınır. Veri entegrasyonunda cep telefonu sinyali, GPS, anket ve toplu taşıma kart verileri gibi farklı kaynaklardan elde edilen bilgiler, geçiş olasılıklarını tahmin etmek ve geçiş matrisi kalibrasyonunu sağlamak üzere kullanılır. Bununla birlikte, Markov zincirlerinin temel özelliği olan belleksizlik, insan davranışları her zaman tam anlamıyla belleksiz olmadığı için pratikte genişletilebilir. Bu nedenle, kimi durumlarda Markov zinciri modeli zamansal örüntüleri, haftanın günleri, sosyo-ekonomik faktörler gibi bağlamsal verileri de dikkate alır [95].

Ajan Tabanlı Modeller

Ajan tabanlı modelleme (ATM), karmaşık sistemleri, sistem içinde yer alan ve belirli kurallar çerçevesinde kendi kararlarını alabilen, çevresini algılayarak diğer ajanlarla ve ortamla etkileşime geçebilen özerk birimler olan "ajanların" davranışlarına dayanarak simüle etme yaklaşımıdır [87]. Bu ajanlar birey, araç, kurum ya da herhangi bir karar verici birim olarak modellenebilir ve sistemin genel dinamikleri, bu ajanların mikro düzeydeki etkileşimleri üzerinden türetilir. Bu mikro ölçekteki bireysel etkileşimlerin toplamı ise makro seviyede "kendiliğinden düzen" olarak nitelenen karmaşık dokuların ortaya çıkmasına neden

olur. İnsan hareketliliği çalışmaları bağlamında ajan tabanlı modeller, bireylerin seyahat kararlarını, ulaşım araçlarını seçme eğilimlerini veya belirli mekanlara yönelimlerini son derece ayrıntılı bir biçimde modellemeyi mümkün kılar. Örneğin, bir şehir içi hareketliliği senaryosunda her ajan yani birey, kişisel zaman kısıtları, ekonomik imkanlar, sosyo-kültürel yönelimler, trafik yoğunluğu gibi faktörlere göre hareket planını belirleyebilir [96]. ATM'lerin avantajlarından biri, insan davranışlarının esnek ve dinamik bir biçimde temsil edilebilmesidir. Heterojenlik, her bireyin farklı gelir, alışkanlık ya da tercih yapısı olmasıdır. Böylece ATM'ler adaptif tepki, trafik sıkıştığında rota değiştirme gibi gerçekçi unsurları modele dahil ederek, sonuçların doğruluğunu ve karar vericilere sağladığı faydayı artırır [97].

2.2 Makine Öğrenmesine Dayalı Hareketlilik Modelleri

Makine öğrenmesi yöntemleri, GPS verileri, sensör ölçümleri, sosyal medya verileri ve mobil ağ kayıtları gibi çeşitli veri kaynaklarından elde edilen büyük ölçekli hareketlilik verilerini işleyerek yaya veya araç hareketlerini yüksek doğrulukla tahmin etme potansiyeline sahiptir. Geleneksel regresyon ve istatistiksel modellerinin yerine, rastgele orman (Random Forest), destek vektör makineleri ve derin sinir ağları, mekansal-zamansal örüntüleri daha esnek bir çerçevede yakalayabilir [98, 99]. Bu sayede şehir içi yolculuk talebinin yoğunlaştığı noktalar, yaya trafiğindeki dalgalanmalar veya gerçek zamanlı trafik akışları gibi faktörler tahmin edilebilir. Makine öğrenmesi tabanlı modellerin en önemli avantajlarından biri, veriyle güncellenerek zaman içindeki değişikliklere hızla uyum sağlayabilmeleridir. Böylece, demografik yapı değişimleri, ekonomik faktörler veya altyapı projeleri gibi makro değişkenler kadar; günün belirli saatlerindeki anlık tıkanıklıklar veya olağanüstü haller (afet, konser, spor etkinliği vb.) gibi beklenmeyen durumlar da modele dahil edilerek daha gerçekçi senaryolar oluşturulabilir [100]. Bununla birlikte, veri kalitesi, temsil gücü ve gizlilik gibi konular kritik önem taşır. Veri ön işleme, özellik mühendisliği ve model kalibrasyonu süreçleriyle, hareketlilik tahminlerinde tutarlılık ve yüksek doğruluk sağlanabilmektedir. Şehir içi ulaşım planlaması, kalabalık yönetimi ve akıllı şehir uygulamaları gibi alanlarda, makine öğrenmesi tabanlı hareketlilik tahmin modelleri giderek daha yaygın hale gelmektedir [38].

2.3 Mekansal Ağ Modelleri ve Hareketlilik

Mekansal ağ modelleri, karmaşık kent sistemlerindeki insan hareketliliğini açıklamak için hem mekanın yapısal özelliklerini hem de bireylerin davranışsal tercihlerini kapsamlı bir şekilde ele alır. Bu alt bölümde, kentsel hareketliliği

tahmin etmek amacıyla geliştirilen iki temel ağ-temelli yaklaşımı karşılaştırmalı olarak incelemektedir. Her iki yöntem de kentsel tasarım ve ulaşım planlamasında tamamlayıcı bilgiler sunar.

Mekan Dizimi Yaklaşımı

Mekan Dizimi mekansal organizasyonun insan hareketliliği üzerindeki etkisini analiz etmeye yönelik bir teorik çerçevedir. İlk olarak Hillier ve Hanson [69] tarafından geliştirilen bu yaklaşım, mekansal erişilebilirlik ve bağlantısallık gibi kavramları kullanarak şehir içindeki yaya akışlarını anlamayı amaçlamaktadır. Özellikle kentsel planlama, mimarlık, ulaşım ve kamusal alan kullanımı gibi alanlarda yaygın olarak kullanılan bu yöntem, bireylerin şehir içindeki hareketliliğini mekansal yapı üzerinden açıklamaktadır. Mekan dizimi analizleri, yaya hareketliliğini doğrudan gözlemleme yerine, mekansal erişilebilirlik üzerinden tahmin etme yaklaşımına dayanır. Literatürde yapılan çeşitli çalışmalar, mekansal ağ yapılarının bireylerin günlük hareket örüntülerini etkilediğini göstermektedir [101–105]. Bu model, özellikle şehir içi mekansal bağlantıların hareketlilik ile ilişkisini inceleyen araştırmalarda sıkça kullanılmaktadır. Mekan dizimi şehir içindeki mekansal konfigürasyonun yaya hareketleri üzerindeki etkisini analiz eder. Bu yöntem, şehir planlamasında yayaların hangi yolları tercih ettiğini anlamada etkili bir yaklaşım olarak görülmektedir. Mekan dizimi, yerçekimi ve radyasyon modellerine alternatif olarak değil, tamamlayıcı bir çerçeve olarak değerlendirilebilir. Literatürdeki çeşitli çalışmalar, mekansal konfigürasyonların yaya hareketliliğini nasıl şekillendirdiğini ve şehir içi hareketlilik tahminlerinde nasıl kullanılabileceğini ortaya koymaktadır [106]. Özellikle kamusal alanların erişilebilirliği, ticari bölgelerin yaya trafiği ve ulaşım ağı analizleri gibi konular için önemli bir araçtır.

Topolojik Ağ Yaklaşımı ile Hareketlilik Analizi

Topolojik ağ analizi, şehir içi hareketliliği, ulaşım hatları ve mekansal erişilebilirlik bağlamında ele alan bir yaklaşımdır. Mekan dizimi ile benzer şekilde ağ teorisi temellidir, ancak daha çok ulaşım ağlarının organizasyonu ve yol bağlantıları odaklanır. Topolojik ağ analizi, şehirlerde düğümler (istasyonlar, kavşaklar, merkezler) ve kenarlar (yollar, ulaşım hatları, bağlantılar) üzerinden hareketlilik akışlarını inceler. Bu model, şehir içindeki ulaşım altyapısının etkilerini değerlendirmek için kullanılır ve genellikle trafik akışları, toplu taşıma erişilebilirliği ve yol ağlarının etkinliği gibi konulara odaklanır. Bu yöntemle şehirlerin ulaşım ağları, transit sistemleri ve yaya hareketlilik modelleri

incelenmiştir [70, 107]. Topolojik ağ analizi, küresel (global) ve yerel (local) ağ ölçümleri ile şehir içi hareketliliği değerlendirir. Bu model, şehrin mekansal organizasyonunu anlamada, yol ağlarını iyileştirmede ve ulaşım planlamasında önemli bir araçtır. Özellikle toplu taşıma ağlarının optimizasyonu, alternatif ulaşım yollarının belirlenmesi ve yaya hareketlilik akışlarının analizinde kullanılmaktadır.

2.4 Hareketlilik Modellerinin Karşılaştırılması

Hareketliliği modellemek için kullanılan yöntemler, farklı veri gereksinimleri, hesaplama kompleksiteleri ve uygulama alanlarıyla birbirlerinden ayrılır. Tüm modeller için ortak sınırlılık, gerçek dünyadaki dinamiklerin tam olarak yakalanmasını zorlaştıran kuramsal kabuller ve hesaplama yüküdür.

Yer çekimi ve radyasyon modelleri, nüfus ve mesafe temelli formülleri sayesinde kolay yorumlanabilir ve düşük hesaplama yükü sunar [33]. Bununla birlikte, bireysel tercihleri, sosyo ekonomik heterojenliği ve kısa zamanda oluşabilecek dalgalanmaları kapsam dışı bırakmaları, özellikle karmaşık kentsel dinamiklerin analizi söz konusu olduğunda belirgin bir eksiklik oluşturmaktadır [71]. Rastgele Yürüyüş ve Markov Zinciri modelleri, matematiksel izlenebilirlikleri ve parametrik sadelikleri, bu yaklaşımları karşılaştırmalı deneyler için elverişli kılar [90]. Geçiş olasılık matrisleri yoluyla veriye duyarlı kalibrasyon yapılabilmesine rağmen belleksizlik varsayımı çok adımlı bağımlılıkları ve amaç güdümlü seyahatleri açıklamakta yetersiz kalır. Ayrıca geniş ağlarda matris boyutlarının hızla büyümesi, hesaplama ve veri gereksinimlerini artırır [108]. Hücresel otomatlar, komşuluk kuralları üzerinden mikro ölçekte kalabalık davranışlarını simüle edebilme kabiliyetiyle öne çıkar [89, 109]. Yerel etkileşimlerin makro ölçekte nasıl örüntülere evrildiğini görselleştirmek açısından etkilidir. Ancak geniş alan uygulamalarında veya uzun süreli senaryolarda hücre sayısının ve kural çeşitliliğinin artması, işlem maliyetini önemli ölçüde yükseltmektedir. Ajan bazlı yaklaşımlar, karar süreçlerini ve karşılıklı etkileşimleri ayrıntılı biçimde modelleyerek gerçekçi senaryolar üretebildikleri için özellikle acil tahliye ve kalabalık yönetimi uygulamalarında tercih edilir. Yüksek veri gereksinimi, parametrelerin belirsizliği ve uzun kalibrasyon süreçleri, modelin genellenebilirliğini ve kullanım alanlarını sınırlar [110]. EPR ve Makine Öğrenmesi modelleri, geniş hacimli GPS, sensör ve sosyal medya verileriyle beslenerek tahmin üretirken, ani talep değişimlerine hızlı tepki verebilme avantajına sahiptir [38, 90]. Buna karşın, çıktıların veri kalitesine duyarlı olması ve mahremiyet konusunda etik sorunları gibi sınırlılıkları mevcuttur [111]. Model türleri karşılaştırıldığında, hesaplama kolaylığı ile gerçekçilik, gereken veri miktarı ile zaman-mekan çözünürlüğü arasında belirgin farklar vardır [38,

110]. Makro ölçekli kestirim ve politika analizi için parametrik yaklaşımlar tercih edilirken, mikro davranışların irdelenmesi veya gerçek zamanlı adaptasyon gerektiren durumlarda hücresel, ajan tabanlı ya da makine öğrenmesi temelli yöntemler üstünlük sağlamaktadır. Çalışma alanının büyüklüğüne bağlı olan uyumsuzluklar, parametrik belirsizlikler, veri gizliliği sorunları ve işlem yükü hemen tüm modeller için ortak sınırlılık alanlarıdır.

Bu çalışmada önerilen modelin başarısını değerlendirmek amacıyla, insan hareketliliği literatüründe köklü bir yere sahip olan yerçekimi modeliyle karşılaştırma yapılmıştır. Kuramsal sadeliği, düşük veri gereksinimi ve yaygın kullanımı nedeniyle literatürde çoğu yeni model çalışmasında karşılaştırmalı analizlerde de referans model olarak tercih edilmektedir [33, 71, 81, 112, 113]. Örneğin, Simini ve arkadaşları tarafından önerilen radyasyon modeli dahil olmak üzere, birçok modern yaklaşım yerçekimi modelinin sunduğu varsayımlara alternatif üretme amacıyla geliştirilmiştir. Bu bağlamda, çalışmamızda önerilen modelin performansı, yerleşik bir karşılaştırma noktası olan yerçekimi modeliyle değerlendirilmiş; böylece modelin literatürdeki konumunun daha etkili biçimde yorumlanması hedeflenmiştir. Bu yöntemlerden geliştirilen ya da farklı yöntemleri içeren çalışmalar Tablo 2.1'de çalışma bölgelerine ve çeşitli veri türlerine göre verilmiştir. Aşağıdaki tablo, bu çalışmalardan seçilen bazı örnekleri özetlemektedir.

Tablo 2.1 İnsan hareketliliği üzerine yapılmış çalışmalar.

Makale	Veri Türü	Model Türü	Çalışma Konusu	Çalışma Bölgesi
Kwon ve diğ.[114]	Seyahat verileri	Mesafeye duyarlı yerçekimi modeli	Mesafe etkisi	ABD'nin 12 büyük şehri
Xing ve diğ.[115]	Taksi seyahat verileri	Grafik sinir ağı, LSTM ve çoklu regresyon	OD matrisi tahmini	New York, Tokyo
Chávez-Hernández ve diğ.[61]	Toplu taşıma seyahat verileri	OD matrisi tahmini, bağlantı analizi	OD matris güncelle	Meksika

Tablo 2.1: İnsan hareketliliği üzerine yapılmış çalışmalar (devamı)

Makale	Veri Türü	Model Türü	Çalışma Konusu	Çalışma Bölgesi
Hou ve diğ.[116]	Metro seyahat verileri	Derin öğrenme	Kısa vadeli OD tahmini, çevresel etki analizi	Çin
Liu ve diğ.[117]	Taksi ve bisiklet seyahat verileri	Derin öğrenme	Mekansal benzerliğe dayalı transfer öğrenmesi	New York, Chicago
Yoongsomporn ve diğ.[62]	Mobil ağ verisi	K ortalama dayalı mekansal sınıflama	COVID19 öncesi ve sonrası hareketlilik, altyapı analizi	Tokyo, Japonya
Sadeghian ve Mojarrad[64]	GPS temelli OD verisi, OSM arazi kullanımı	KDE, hotspot, nokta yoğunluğu analizi	Cinsiyet ve zamana dayalı hareketlilik farkları	İsveç – Falun
Ek ve Wennerberg[118]	Sosyal medya verileri	Bireysel hareketlilik modeli EPR	Twitter verisini seyahat talebi tahminine uyarlama	İsveç, Hollanda, São Paulo

Tablo 2.1: İnsan hareketliliği üzerine yapılmış çalışmalar (devamı)

Makale	Veri Türü	Model Türü	Çalışma Konusu	Çalışma Bölgesi
Bao ve diğ.[119]	Sosyal medya verileri	Derin öğrenme	Bir sonraki konumun alan bazlı tahmini	Wuhan, Çin
Li ve diğ.[120]	GPS araç verisi	Makine öğrenme	Uzun vadeli bireysel hareketlilik tahmini	Çin
Pappalardo ve diğ.[91]	GSM kule verisi	d-EPR	Yerçekimi ve kişisel tercihlerle mobilite modeli	Avrupa
Ren ve diğ.[121]	Taksi GPS, hava durumu verileri	Derin öğrenme	Şehir genelinde akış hacmi tahmini	Pekin, Çin
Cornacchia ve Pappalardo[122]	Sosyal medya verileri	STS-EPR (sosyal, zamansal ve mekansal)	Sosyal etki, bireysel hareketlilik	New York, İstanbul
Demšar ve diğ.[123]	GPS ve sensör verileri	Lagrangian, Eulerian birleşik çerçeve	Hayvan ve insan hareketliliği kavramsal modeli	Kuramsal, yerden bağımsız
Teixeira ve diğ.[124]	GPS ve arama kayıtları	Entropi tabanlı tahmin	Rutin davranışın öngörülebilirliğe katkısı	Brezilya, Çin

Tablo 2.1: İnsan hareketliliği üzerine yapılmış çalışmalar (devamı)

Makale	Veri Türü	Model Türü	Çalışma Konusu	Çalışma Bölgesi
Cornacchia ve diğ.[125]	Sosyal medya verileri	Gelişmiş STS EPR	Gerçekçi hareketlilik sentezi	New York
Wang ve diğ.[126]	Sensör verisi	ARIMA, SVR, MLR zaman serisi	Şehir içi yaya trafiği tahmini	Melbourne, Avustralya
Simini ve diğ.[71]	OSM ve nüfus verileri	Derin öğrenme	Coğrafi verilerle desteklenen derin yerçekimi modeli	İngiltere, İtalya, New York
Krishnakumari[12]	Zaman serisi verileri	Veri odaklı OD matrisi	OD matrisi tahmini	İspanya

3
İNSAN HAREKETLİLİĞİ VE DİJİTAL AYAK İZİ

Dijital ayak izi, bireylerin veya işletmelerin interneti kullanarak gerçekleştirdikleri etkileşimlerin dijital yansımasıdır ve bunların bir araya gelmesiyle dijital ayak izi oluşur [127]. İnternet ortamında kullanıcıların bilinçli olarak bırakılan izler aktif ayak izleri olarak adlandırılır. Bireylerin farkında olmadan gerçekleştirdiği eylemler sonucu sistem tarafından kaydedilen izler pasif ayak izleridir [128]. Tarayıcı geçmişindeki tıklama kayıtları ve içerik üretimi gibi çeşitli veri türlerini kapsayan bu izler zaman damgalı sayısal verilerin yanı sıra bu etkileşimlerin gerçekleştiği coğrafi konum verilerini de kapsar. Konum temelli dijital ayak izleri genellikle navigasyon uygulamaları üzerinden bırakılan aktif ayak izleridir. Bunun yanında sosyal medya etkileşimleri, mobil cihaz GPS kayıtları ve çevrimiçi inceleme platformlarından elde edilen veriler konum temelli servislerle ilişkilendirilebilir. Bu sayede konum temelli servisler hem aktif hem pasif izleri içeren karma bir sistematikte toplanır. Bu veri seti bireylerin kent içi seyahat biçimlerini, ziyaret noktalarını ve zaman aralıklarını dolaylı yoldan ortaya koyarak bireysel hareket örüntülerinin ve toplumsal hareketlilik eğilimlerinin analizine olanak tanır [122, 129, 130]. Konum temelli dijital ayak izlerinin toplanması ve işlenmesi önemli etik ve yasal sorumlulukları beraberinde getirir. Özellikle bireysel düzeyde hassas konum bilgilerinin kullanımı, kullanıcı mahremiyetinin ve kişisel veri güvenliğinin korunmasını gerektirir. Avrupa Birliği'nin Genel Veri Koruma Yönetmeliği benzeri düzenlemeler, veri sahiplerinin rızası ve şeffaflık gibi ilkeleri öne çıkararak konum verilerinin erişim ve işlenme koşullarını sıkı şekilde sınırlandırmaktadır [131]. Bireylerin bıraktığı dijital ayak izlerine Google Maps, Yelp Fusion, TripAdvisor gibi global platformların konum temelli servisleri üzerinden erişmek mümkündür. Bu platformların kullanıcıları, etik ve yasal sorumluluklar ile bırakacakları dijital ayak izlerinin dağıtımı ve işlenmesi hususunda önceden bilgilendirilmiştir. Örneğin platforma üye olan bir kullanıcı:

- Ziyaret ettiği kafe, restoran, otel gibi kentsel donatılar hakkında yapacağı değerlendirmelerin diğer kullanıcılarla paylaşılacağını bilir,

- Farklı donatılar için verdiği puanların, yorumların ve diğer bilgilendirmelerin belirli sınırlar dahilinde araştırmacılar tarafından kullanılabileceğinin bilincindedir.

Araştırmacılar, platformların sağladığı uygulama programlama arayüzlerini (Application Programming Interface - API) kullanarak bu dijital ayak izlerine (açık veri) toplu olarak erişebilir. Ayrıca API'ler, geliştiricilere ve araştırmacılara belirli sorgular aracılığıyla konum temelli olarak kullanıcı etkileşimlerini analiz etme imkanı sunar. Böylece kullanıcıların hangi mekanları ne sıklıkta ziyaret ettikleri, bu mekanlar hakkında ne tür geri bildirimlerde bulundukları ve mekansal deneyimlerine dair ipuçları yasal çerçevede toplanabilir. Elde edilen veriler, mekansal algının, tüketici tercihlerinin ve kentsel hareketliliğin analizi açısından oldukça önemli bir kaynaktır [132–134]. Diğer taraftan, global platformların açık veri statüsünde, kentsel donatılarla bağlantılı olarak sunduğu dijital ayak izlerinin insan hareketliliğini inceleme bağlamında ele alındığı araştırmalar henüz sınırlı sayıdadır [135–137]. Bu tez kapsamında, Öztürk Hacar ve diğ. [138], dijital ayak izleri ile mekansal yapı ilişkisini kapsamlı şekilde ele almak adına, dijital etkileşimlerin mekansal dağılımı etkileyen yapısal faktörleri belirlemiş ve bunların kentsel bağlam içinde nasıl şekillendiğini Avustralya'nın Melbourne şehri özelinde incelemiştir. İnsan odaklı kent planlama politikalarının geliştirilmesinde öne çıkan kentlerden biri olan Melbourne, 1980'li yıllar sonrası kentleşme programlarıyla öne çıkan yaklaşık 5,4 milyon nüfuslu bir metropoldür [139]. 1985'te başlatılan iyileştirme projeleri sonucunda kent merkezi, mesai saatleri dışında terk edilmiş bir kent olmaktan çıkmış ve canlı bir şehir merkezi kimliğine evrilmiştir (Şekil 3.1). 1992–2002 arasında merkez nüfusun 1.000'den 10.000'e çıkması [5] ve konut stoğunun on kat artması bu gelişimin önemli bir göstergesidir. Melbourne'nin kentleşme dönüşümünün en önemli bileşenlerinden biri, yaya dostu politikaların benimsenmesidir. Bu kapsamda kaldırımlar genişletilmiş, yaya yolları güçlendirilmiş, kent mobilyaları ve kamusal sanat projeleriyle kent estetiği zenginleştirilmiştir. Düzenli ağaçlandırmalar ve gece aydınlatmaları gibi sürdürülebilirlik odaklı müdahaleler sayesinde şehir, 24 saat yaşanabilir duruma dönüşmüştür. Bu özellikleriyle Melbourne, insan merkezli kent planlaması anlayışına ve yaya hareketliliğine öncelik veren kamusal alan politikalarını temsil eden özgün bir örnek sunmaktadır. Melbourne, açık veri ve dijitalleşme konusunda da oldukça gelişmiş bir şehirdir. Bu kapsamda oluşturulan City of Melbourne (CoM) Open Data (OD) portalı isimli çatı altında herkese açık veri kaynakları sunulmaktadır. Kent yönetimi, şehrin önemli noktalarında yaya hareketliliklerini ortaya koyan sayım verileri toplamakta ve bunları 2009 yılından itibaren bir saatlik aralıklarla düzenli şekilde tüm kullanıcılarla paylaşmaktadır.

Bu veri altyapısı, mekansal analizler ve modelleme yaklaşımları için güvenilir ve tekrarlanabilir temel bir kaynaktır [140]. Veri akışının sürekli ve şeffaf oluşu kent kapsamında geliştirilen uygulamaların geçerliliğini ve elde edilen bulguların güvenilirliğini güçlendirmektedir. Tez çalışmasının bu bölümünde, Melbourne

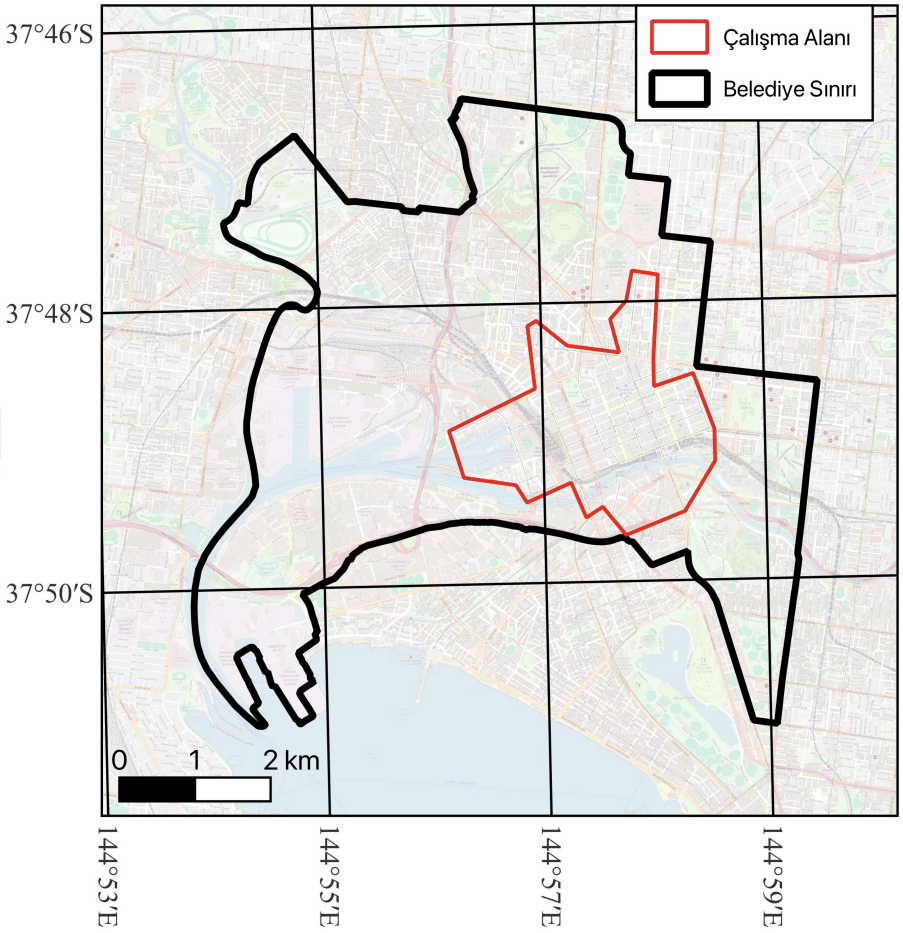

Şekil 3.1 Melbourne belediye sınırı (siyah) ve çalışma alanı (kırmızı).

özelinde konum temelli dijital ayak izleri kullanılarak türetilen veriler ile noktasal yaya sayım verileri ve bazı kentsel morfolojik veriler (bina hane sayısı, yol ağından çıkarılabilen metrik ve topolojik ölçüler) bir arada değerlendirilerek yaya hareketliliği araştırılmış; bu kapsamda veri ölçeği ve model tutarlılığı konularındaki boşlukların doldurulması hedeflenmiştir. Ayrıca, dijital ayak izlerinin mekansal entegrasyonu ve yaya hareketliliğini kestirmede, tekil veri kümelerine dayalı modellere kıyasla daha yüksek tahmin doğruluğu oluşturma potansiyeli test edilmiştir.

3.1 Veri Kaynakları

Çalışmada kullanılan veriler, birbirleriyle ilişkili üç farklı veri kaynağından elde edilmiştir:

- Google Maps
- City of Melbourne Open Data (CoM-OD) portalı
- OpenStreetMap (OSM)

3.1.1 Google Maps verileri

Melbourne şehir merkezinde yeme-içme (eating drinking out-EDO) hizmeti sunan çok sayıda işletme bulunmaktadır. Bunlar gün içinde birçok ziyaretçiye hizmet vermekte ve hizmet kaliteleri hakkında global platformlarda puanlamalar ve yorumlar yapılmaktadır. Bu etkileşimleri dünya genelindeki mekansal katmanlarla interaktif bir arayüz üzerinden açık erişimle kullanıcılarına sunan en kapsamlı çevrimiçi harita servislerinden biri Google Maps'tir [141]. Yüksek çözünürlüklü uydu görüntüleri, sokak görünümleri, rota planlama olanakları ve gerçek zamanlı trafik bilgileri gibi çok çeşitli özellikleri bünyesinde barındıran bu platform, hem bireysel kullanıcılar hem de araştırmacılar için güçlü bir coğrafi bilgi kaynağı niteliği taşımaktadır. Web tabanlı yapısı ve sağladığı API'ler sayesinde erişilebilirliği yüksek olan Google Maps, araştırmacılar tarafından mekansal analiz ve karar destek süreçlerinde sıklıkla kullanılmaktadır. Google Maps Places API aracı, mekanlar hakkında platform kullanıcı değerlendirmelerinin, araştırmacıların erişimine açılmasını sağlar. Bu çalışma kapsamında, Melbourne kent merkezinde, EDO hizmeti sunan 1.582 adet işletme hakkında, platform kullanıcılarının puanlamaları ve yaptıkları yorumlar, Google Maps Places API aracı kullanılarak elde edilmiştir (Şekil 3.2).

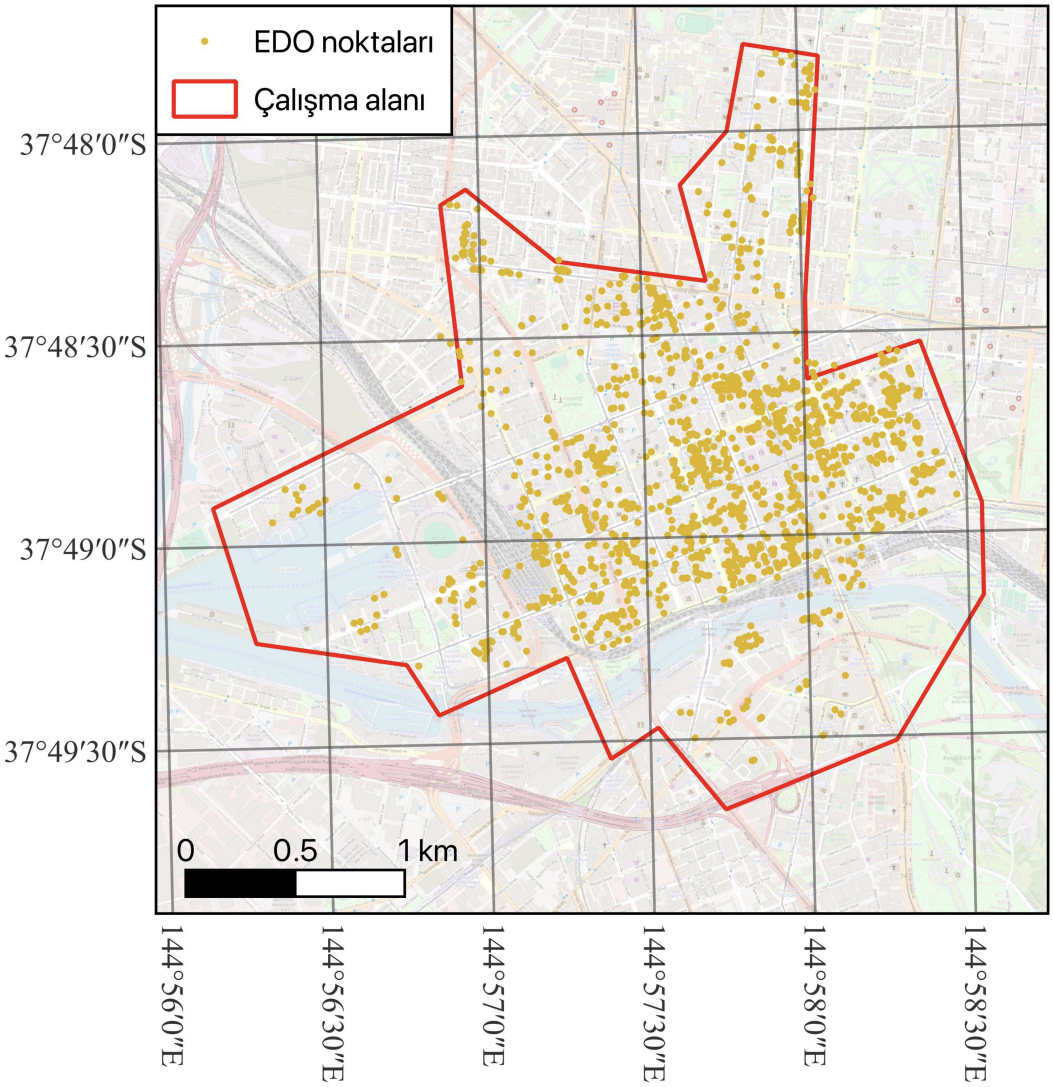

Şekil 3.2 Çalışma alanında EDO hizmeti sunan yerler.

Bu verinin bir örneği aşağıdaki Tablo 3.1'te verilmiştir.

Tablo 3.1 Melbourne'de Google Places API'den elde edilen temsili veriler.

Yer_ID	Yerin Adı	Puan	Yorum	Tür	Enlem	Boylam
1	Pellegrini's Espresso Bar	4,5	2 660	kafe	−37.8109	144.9701
2	Brother Baba Budan	4,6	3 039	kafe	−37.8127	144.9628
3	Seven Seeds Coffee	4,4	3 501	kafe	−37.8005	144.9577
4	Market Lane Coffee (QV)	4,3	1208	kafe	−37.8100	144.9646
5	St Ali Coffee Roasters	4,2	3 601	kafe	−37.8420	144.9934

3.1.2 CoM-OD portal verileri

Bu tez çalışmasında kullanılmak üzere CoM-OD portalı açık veri kaynağından iki adet veri seti elde edilmiştir. Bunlardan birincisi, Melbourne Belediyesi emlak veri tabanından CoM-OD portalına aktarılan her bir binaya bağlı hane sayısını içeren verilerdir (Şekil 3.3).

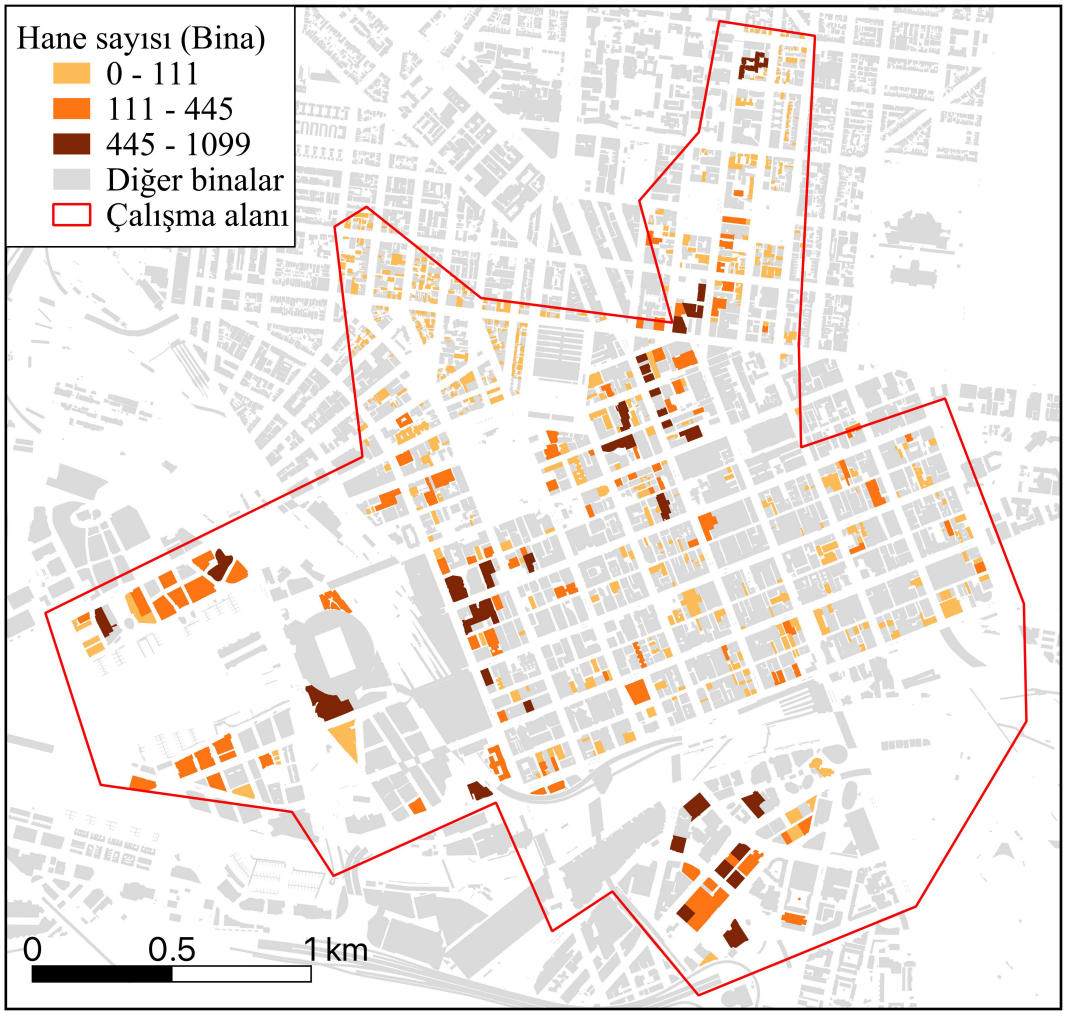

Şekil 3.3 Çalışma alanında binaların hane sayısına göre dağılımı.

İkinci veri seti, Melbourne Belediyesi tarafından kentin kritik konumlarına yerleştirilen sensörler aracılığıyla toplanan yaya sayım verileridir. Sensörler, ilgili konumdan geçen yayaları 7 gün, 24 saat boyunca çift yönlü olarak saymaktadır. 2009 yılından itibaren toplanan bu bilgiler, bir saatlik aralıklarla açık veri şeklinde CoM-OD portalı üzerinden sunulmaktadır. Sensörler, kent içi yaya trafiğinin yoğun olduğu cadde, meydan ve ticari akslarda bulunan restoran, kafe, büyük alışveriş merkezi gibi yüksek etkileşime sahip donatıların bulunduğu noktalara yerleştirilmiştir (Şekil 3.4a). Genellikle bir tente altına ya da sokak direklerine monte edilen sensörler altındaki kaldırım üzerinde bir sayım alanı oluşturmaktadır (Şekil 3.4b) [142].



(a) (b)

Şekil 3.4 Melbourne'ün merkezi iş noktalarından biri olan William caddesindeki (a) yaya sayım sensörü (b) [142]

Tablo 3.2'de gösterilen sayım verisi, her bir yaya sensörü ölçümünü dokuz sütun altında özetlemektedir: *ID* benzersiz kayıt anahtarını, *Location_ID* belediye envanterindeki sensör kimliğini, *Sensing_Date* ölçümün yapıldığı tarihi, *Hour* o gün içindeki saati (0–23), *Dir1* ve *Dir2* sensörde tanımlı iki zıt yönden gelen yaya sayılarını, *Total* bu iki değerin toplamını, *Sensor_Name* cihazın sokak/bina kısaltmasıyla verilen adını ve *Location* sütunu da sensör konumunun enlem-boylam koordinatlarını içermektedir.

Tablo 3.2 Örnek yaya sayım verisi (kısaltılmış).

ID	LID	Tarih	Hr	D1	D2	Tot	Sensör	Lat	Lon
1	20	23-07-22	04	9	11	20	LtB170_T	−37.8117	144.9682
2	18	23-07-20	17	556	104	660	Col12_T	−37.8134	144.9731
3	108	23-07-27	18	590	190	780	261Will_T	−37.8130	144.9568
4	72	23-07-17	19	206	183	389	ACMI_T	−37.8173	144.9687
5	8	23-07-22	11	140	209	349	WebBN_T	−37.8229	144.9472

Melbourne yaya sayım sistemindeki sensörler kentin gelişimine ve altyapı çalışmalarına bağlı ihtiyaçlar doğrultusunda zaman içinde birçok kez güncellenmiştir. Bu süreçte bazı sensörlere olan ihtiyaç azalmış ve bunlar kaldırılmış ya da farklı konumlara taşınmıştır. Veri toplama sisteminin kapsamını genişletme hedefi doğrultusunda her yıl yeni sensör kurulumlarıyla sensör sayıları arttırılmaktadır (Şekil 3.5). 2009 yılından itibaren her yıl eklenen sensör sayılarına bağlı olarak artan toplam sensör sayısındaki değişim, sistemin kapasitesinin artırılması ve kentsel yaya hareketliliğine yönelik veri toplama çabalarının önemini işaret etmektedir.Yaya sayım sensörlerinin ilk olarak kurulduğu 2009 yılından 2025 yılına gelene kadar Melbourne belediye sınırları içinde kalan toplam sensör sayılarına ilişkin yıllık grafik Şekil 3.6 görülmektedir.

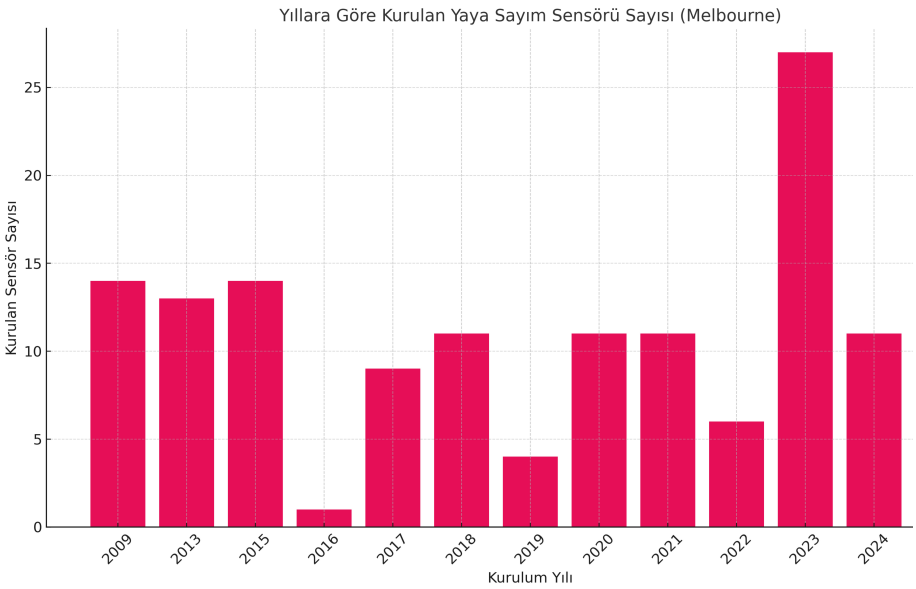

Şekil 3.5 Yıllara göre kurulan sensör sayıları.

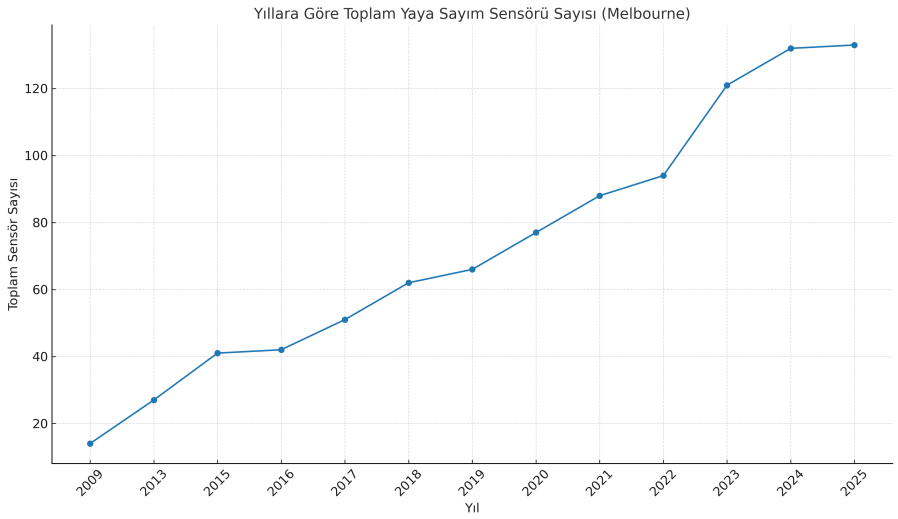

Şekil 3.6 Yıllara göre değişen toplam sensör sayıları.

2024 yılı sonu itibariyle Melbourne belediye sınırları içinde toplam 133 adet sensör tesis edilmiştir. Bu sensörlerden 71 adedi şehir merkezinde yer almaktadır (Şekil 3.7).

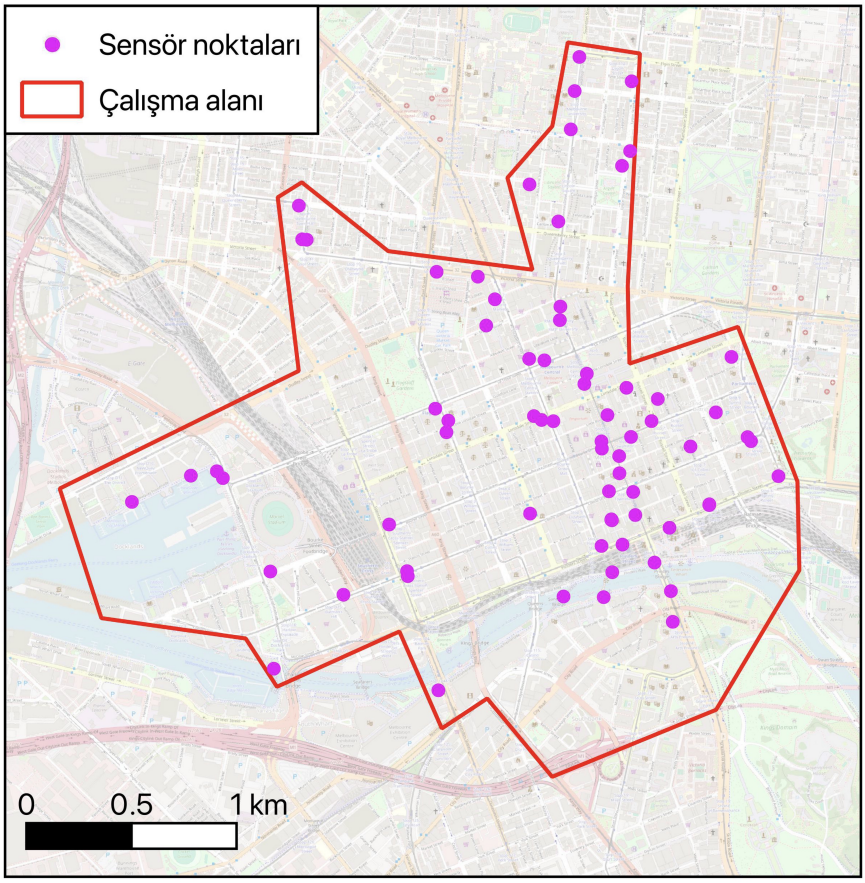

Şekil 3.7 Çalışma alanındaki sensörlerin yerleşimi.

3.1.3 OSM verileri

OSM, kullanıcı katkısına dayalı açık kaynaklı bir harita platformudur. Dünya genelinde coğrafi bilgilerin serbestçe oluşturulmasını, düzenlenmesini ve paylaşılmasını hedeflemektedir. Katılımcıların gönüllü olarak sağladığı verilerle sürekli güncellenen OSM, ticari harita servislerinin kullanıcılara açık veri olarak sunmadığı bazı verileri kullanıcılara yüksek doğrulukta ve ayrıntı düzeyinde sunar. Bu çalışmada ihtiyaç duyulan Melbourne yol ağına ilişkin geometrik verileri BBBike web servisi [143] OSM üzerinden elde edilmiştir (Şekil 3.8).

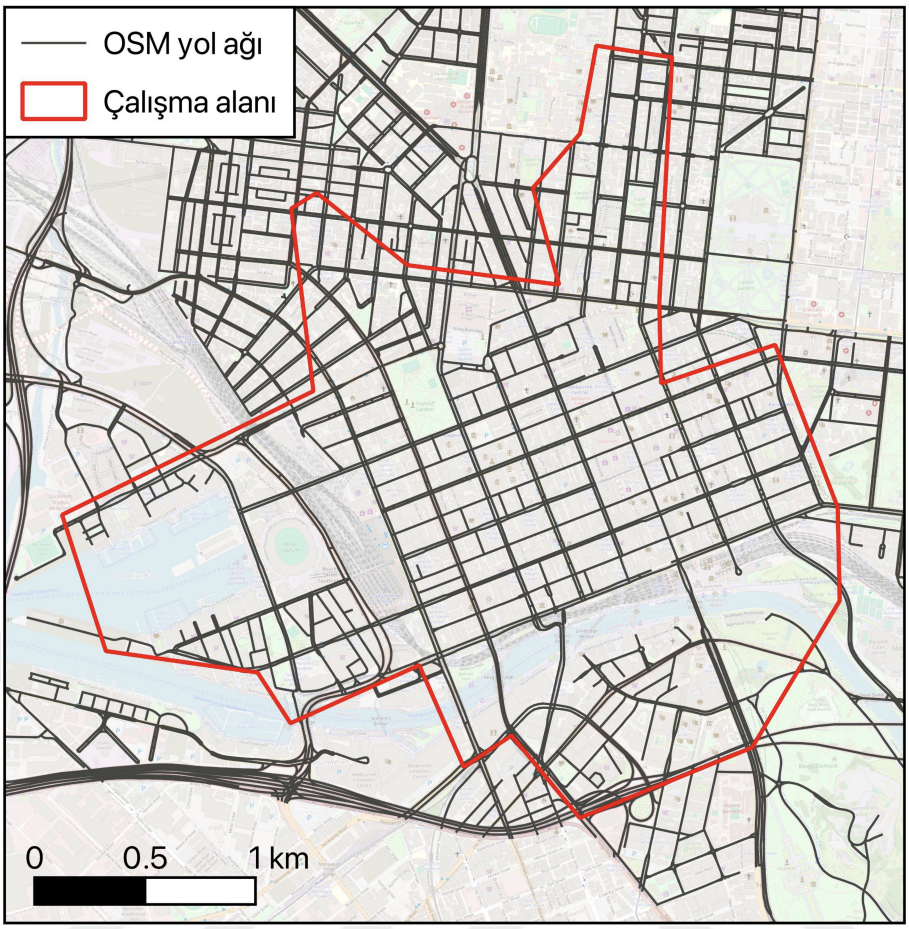

Şekil 3.8 Melbourne'e ait OSM yol ağı verisi.

OSM, geometrik verilerin yanında semantik öznitelik bilgilerini kapsayan zengin bir veri modeli yapısına sahiptir. Bu yapı sayesinde yollar, binalar, doğal unsurlar ve altyapı öğeleri gibi mekansal nesnelere ait öznitelikler OSM veri tabanında etiket (tag) sistemiyle depolanır. OSM'de yol ağına ait *highway* etiketi yol detaylarının kullanım türlerine göre bir sınıflandırma sistemi sunar [144]. Bu etiket tahmin modelinin oluşturulmasında kullanılan veri kaynaklarından biridir.

3.2 Veri Ön İşleme

Google Maps, CoM-OD portal ve OSM veri kaynaklarından elde edilen veri setleri işlenerek bu çalışmada önerilen tahmin modeli için girdi veriler oluşturulmuştur. Google Maps Place API kullanılarak elde edilen EDO hizmeti sunan mekanlara ilişkin veriler hakkında yapılan puanlamalar ve yorumların sayısı ilgili işletmenin etkileşim miktarını açıklar. Bu çalışmada ilk olarak çevrimiçi etkileşimi ondan düşük EDO'lar kapsam dışına çıkarılmıştır. Daha sonra, her bir EDO için işletme türü (kafe, restoran ve bar), toplam yorum sayısı ve ortalama puan öznitelikleri bir veri tablosuna konumla ilişkili olarak eklenmiştir. Son aşamada, sürekli değişkenler

olan yorum sayısı ve ortalama puan "yüksek" ve "düşük" olmak üzere eşit öğeli (quantile) iki sınıfa ayrılmıştır. CoM-OD portalından elde edilen sensör yaya sayım verileri yıllık veri setleri olarak gruplandırılmış ve her bir yıl için günün bir saatinde sayılan yaya miktarının ortalamaları hesaplanmıştır. 2022 ve 2023 yıllarının hesaplanan ortalama değerleri geliştirilen tahmin modelinin girdilerinden ikisini oluşturmuştur. Diğer taraftan, her bir saatte sensörler tarafından sayılan yaya miktarı günün zamanına bağlı olarak anlamlı değişimler göstermektedir (Şekil 3.9). 2022 ve 2023 yıllarının ortalamasına bağlı olarak oluşturulan grafiğe göre günün ilk saatinden sabah 06.00'a kadar yaya hareketliliği oldukça düşüktür. Sabah 07.00 itibarıyla yaya sayılarında hızlı bir artış gözlenmekte ve yaya yoğunluğu öğle saatlerinde zirveye ulaşmaktadır. Özellikle 12.00–18.00 saatleri arası, ticari ve kamusal alanlardaki yaya sirkülasyonu en yoğun seviyededir. Bu aralıkta saat 17.00'de, yaya hareketliliği en yüksek sayıya ulaşır. Bu kapsamda saat 17.00 için her bir sensörün saydığı yaya miktarının ortalama değeri geliştirilen tahmin modelinin diğer iki (2022 ve 2023) girdisini oluşturmuştur.

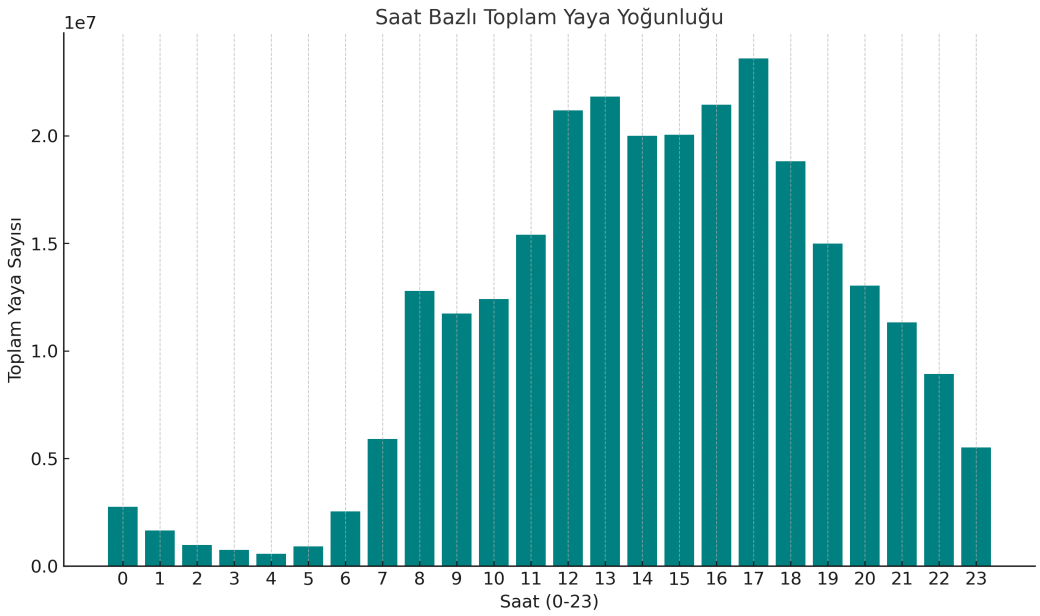

Şekil 3.9 Çalışma alanında yer alan 71 sensörün tümünün her saat diliminde kaydettiği toplam yaya sayısının saat bazlı dağılımı.

OSM'den elde edilen yol ağı veri seti ile birlikte kullanılan *highway* etiketi çok sayıda farklı yol türünü tanımlar. Melbourne'ün OSM yol etiketleri genel olarak eksiksizdir. Ancak gönüllü kullanıcılar tarafından kesintisiz şekilde sayısallaştırılan yol ağı düğüm noktaları dikkate alınmadığından topolojik olarak sorunludur. Bu nedenle sorunlu yol detayları topolojik olarak yeniden yapılandırılmıştır [145]. Ardından, topolojik olarak tutarlı hale getirilen yol ağından merkezilik ölçüleri

hesaplanmıştır [146]. Merkezilik ölçüleri birincil ağ [70] ve dual ağ [147] yaklaşımı ile iki farklı şekilde hesaplanabilir. Bu çalışmada her iki yaklaşım da kullanılarak sekizer merkezilik ölçüsü için hesaplamalar yapılmıştır. Bu ölçüler, birincil ve dual ağlardaki her bir düğüm noktasının topolojik yapıdaki diğer düğüm noktalarıyla bütünleşme ya da ayrışma durumunu ortaya koyar. Derece (Degree), yakınlık (closeness), arasındalık (betweenness), özvektör (eigenvector), harmonik yakınlık (harmonic closeness), katz, yük (load) ve pagerank merkezilikleri bu çalışmada kullanılan sekiz merkezilik ölçüsüdür. Derece, ağdaki bir düğüm noktasına doğrudan bağlanan düğümlerin sayısını ölçer. Bu ölçü yerel düzeydeki erişilebilirliğin temel bir göstergesi olarak kabul edilir. Yakınlık, her bir düğüm noktasının ağdaki diğer düğümlere olan ortalama en kısa yol uzaklığının tersidir. Ele alınan düğüm noktasının ağdaki genel erişilebilirliğini açıklar. Arasındalık, herhangi iki düğüm noktası arasındaki en kısa yolun ele alınan düğüm noktası üzerinden geçme durumunu inceler. Ağdaki bir düğüm noktasının diğer düğüm noktaları arasındaki erişimde köprü oluşturma durumunu ortaya koyar. Özvektör merkeziliği, bir düğüm noktasının merkezilik değerini ona bağlı diğer düğümlerin merkezilik dereceleriyle orantılı olarak değerlendirir. Harmonik yakınlık, bir düğümün merkeziliğini ağdaki tüm diğer düğümlere olan ters en-kısa-yol mesafelerinin toplamı olarak hesaplar. Katz merkeziliği, düğüm noktaları arasındaki farklı topolojik uzunluktaki yolların etkilerini ağırlıklandırarak düğümlerin uzak ve yakın bağlantılardan aldığı toplam etkiyi açıklar. Yük merkeziliği, arasındalık ölçüsünün akış odaklı uyarlamasıdır. Akış, düğüm noktaları arasına varsayılan yolculuklar gerçekleştirildiğinde her düğümde birikecek olan olası trafik miktarıdır. PageRank merkeziliği, rastgele yürüyüş modelini (Bknz 2.2) kullanarak bir düğüm noktasından geçilebilme olasılığını ölçer. Yüksek PageRank değerine sahip düğüm noktalarının bağlantıları daha yüksek ağırlıklarla değerlendirilir. Bu çalışmada sunulan tüm merkezilik ölçüleri, Python 3 ortamında `networkx` (v3.3) kütüphanesi kullanılarak hesaplanmıştır [148].Tablo 3.4'de formüller ve sembol açıklamaları özetlenmiştir.

Tablo 3.4 Bu çalışmada kullanılan merkezilik ölçüleri ve formülleri

Ölçü	**Formül**	**Formül açıklaması / değişkenler**
Derece C_D	$C_D(i) = \sum_j a_{ij}$	a_{ij} = 1 ise i–j arasında kenar vardır.
Yakınlık C_C	$C_C(i) = \frac{N-1}{\sum_{j \neq i} d_{ij}}$	d_{ij} en kısa yol mesafesi.
Arasındalık C_B	$C_B(i) = \sum_{s \neq i \neq t} \frac{\sigma_{st}(i)}{\sigma_{st}}$	$\sigma_{st}(i)$: i'den geçen en-kısa yollar.
Özvektör C_E	$\lambda x_i = \sum_j a_{ij} x_j$	x_i en büyük özdeğer λ'ya ait bileşen.
Harmonik C_H	$C_H(i) = \sum_{j \neq i} \frac{1}{d_{ij}}$	Ters mesafe toplamı.
Katz C_K	$C_K(i) = \alpha \sum_j a_{ij} C_K(j) + \kappa$	α sönüm, κ başlangıç sabiti.
Yük L	$L(i) = \sum_{s \neq i \neq t} \frac{\ell_{st}(i)}{\sigma_{st}}$	Akışın i üzerindeki payı.
PageRank PR	$PR(i) = \frac{1-d}{N} + d \sum_j \frac{a_{ji}}{k_j^{\text{out}}} PR(j)$	d sönüm (0.85).

Topolojik ölçülerin yanında bu çalışmada ayrıca yol ağının geometrisine bağlı olarak hesaplanan iki adet ölçü daha tahmin modeline eklenmiştir. Bunlar kıvrımlılık ve mesafe ölçüleridir. Kıvrımlılık, bir yol çizgisinin uzunluğunun, başlangıç ve bitiş noktaları arasındaki Öklid mesafesine oranı şeklinde hesaplanır [149]. Mesafe, bir EDO konumunun ek yakın yol ağı detayına olan uzaklığıdır.

3.3 Veri Entegrasyonu

Yukarıda bahsedilen farklı kaynaklardan derlenen veriler RO algoritması kullanılarak modellenmiştir. RO, sınıflandırma işlemleri ve regresyon analizinde yaygın olarak kullanılan bir makine öğrenmesi algoritmasıdır [98, 150, 151]. Bu çalışmada RO, bağımlı ve bağımsız olarak tanımlanan çeşitli değişkenler arasındaki ilişkileri modelleyerek bir sınıflandırma sistematiği oluşturmak için kullanılmıştır. RO yöntemi, birden fazla karar ağacının çıktısını birleştirerek tek bir sonuca ulaşmayı hedefler. Kullanım kolaylığı ve esnekliği, algoritmanın farklı veri türleriyle geniş bir uygulama alanında kullanılabilmesini sağlar. Ayrıca çok boyutlu ve çok değişkenli veri yapılarında diğer sınıflandırma yaklaşımlarına göre daha başarılı performans göstermesiyle öne çıkar [152]. Makine öğrenmesine dayalı geleneksel birçok sınıflandırma algoritması eğitim verisiyle uyumlu verilerle çalıştırıldığında oldukça başarılıyken, farklı veriler sınıflandırmanın başarısını düşürür. RO algoritması, aşırı öğrenme sorunu olarak bilinen bu riski azaltmasının yanında, değişkenler arasındaki doğrusal olmayan ilişkileri

etkili biçimde modellemesi nedeniyle diğer modellere göre önemli bir avantaj sunmaktadır. Bu çalışmada RO algoritmasının bağımlı değişkeni olan girdiler, EDO'lara ilişkin puan ve yorumlardan türetilen yüksek ve düşük olarak adlandırılan iki sınıflı verilerdir. Bağımsız değişken girdileri ise CoM-OD portalından türetilen saatlik ortalama yaya sayısı ile hane sayısı bilgileri ve OSM yol ağından türetilen sekiz adet topolojik ve iki adet geometrik ölçü ile *highway* etiket bilgileridir. Bağımsız değişkenler aşağıda açıklanan altı ayrı özellik seti(feature set)-ÖS içinde gruplandırılmıştır (Şekil 3.10):

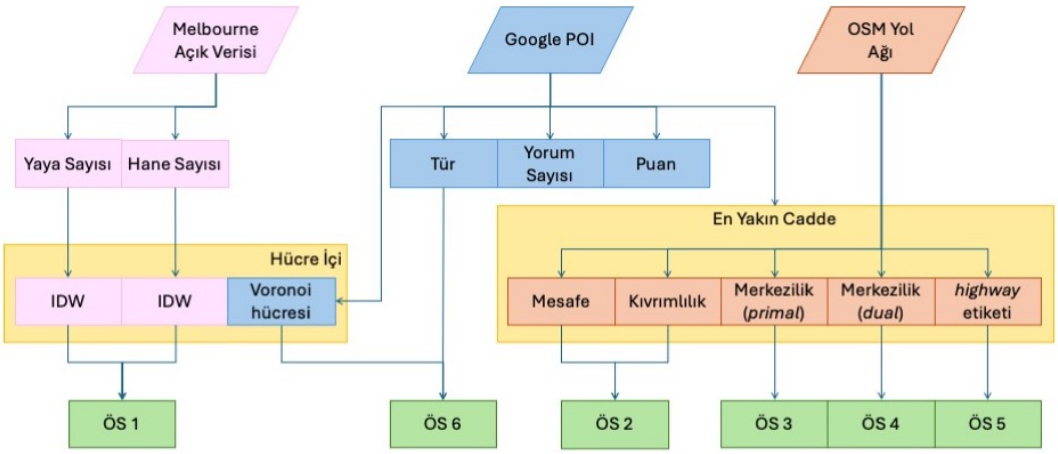

Şekil 3.10 Özellik setlerinin üretim süreci.

- **ÖS1:** Bu grupta; (1) sensörlerin saydığı yıllık ortalama saatlik yaya sayısı ve (2) en yoğun saat olan 17:00'deki yaya sayısı ile (3) hane sayısı verileri yer almaktadır. Bunların her biri mekansal dağılımı yansıtmak için birer raster veri setine dönüştürülmüştür. Noktasal verilerin raster verisetine dönüştürülmesinde ters mesafe ağırlıklandırma (Inverse Distance Weighting - IDW) enterpolasyon yöntemi kullanılmıştır. Bağımsız değişken olan ÖS1'in raster verisetleri EDO noktalarından türetilen Voronoi poligonları ile ilişkilendirilmiş ve her bir Voronoi hücresi içine düşen ortalama yaya ve konut yoğunlukları hesaplanmıştır (Şekil 3.11).

- **ÖS2:** Bu grupta, yol ağı geometrisi ve EDO konumları kullanılarak türetilen (1) kıvrımlılık ve (2) mesafe verileri yer almaktadır. ÖS2 verisetini oluşturan iki geometrik ölçüden türetilen sayısal değerler EDO noktalarıyla yakınlığa bağlı olarak doğrudan ilişkilidir.

- **ÖS3–ÖS4:** Bu iki grup birincil ve dual ağ üzerinden türetilen merkezilik ölçülerine dayalı verisetlerinden oluşur. Birincil ağ yaklaşımından türetilen ölçüler ÖS3, dual ağ yaklaşımından türetilen ölçüler ÖS4 içinde

tanımlanmıştır. Buradan türetilen sayısal değerler EDO noktalarıyla yakınlığa bağlı olarak ilişkilendirilmiştir.

- **ÖS5:** Bu grup altında, OSM yol ağının *highway* özniteliği ile ilişkilendirilen EDO noktasına ait en yakın yolun bilgileri yer almaktadır.
- **ÖS6:** Bu grup her bir EDO'nun kullanım türü ve ÖS1 için oluşturulan ilgili EDO'ya ait Voronoi hücresinin alan bilgisi yer almaktadır.

ÖS gruplarının içerdiği değişkenler, Tablo 3.6'de özetlenmiştir.

Tablo 3.6 Özellik Setlerinin İçerdiği Temel Özellikler

ÖS	**Değişkenler**
ÖS1	Yıllık ortalama saatlik yaya sayısı; 17:00'deki yaya sayısı; hane sayısı
ÖS2	Yol ağı kıvrımlılığı; yol ağı mesafesi
ÖS3	Birincil ağdan türetilen merkezilik ölçüleri
ÖS4	Dual ağdan türetilen merkezilik ölçüleri
ÖS5	En yakın yolun *highway* özniteliği
ÖS6	EDO kullanım türü; Voronoi hücresi alanı

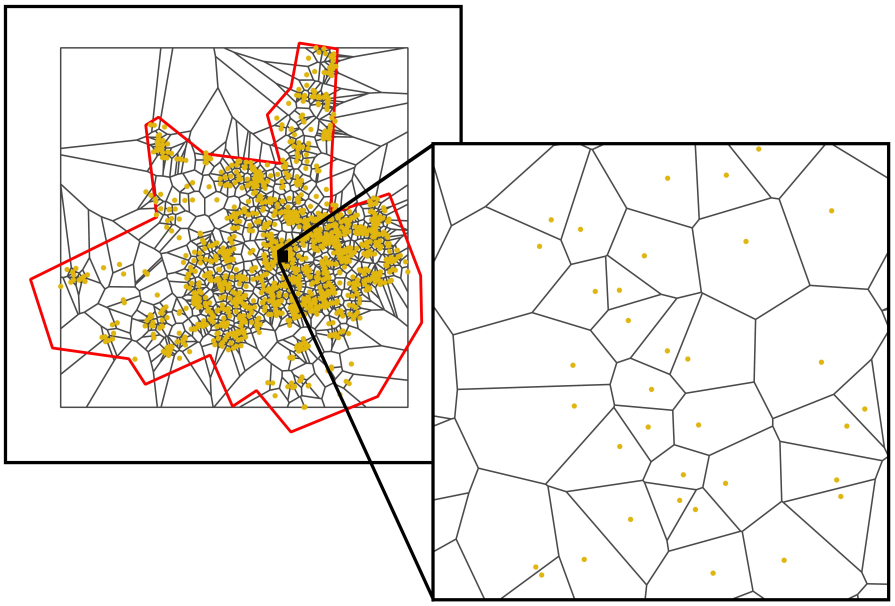

Şekil 3.11 EDO konumları (sarı noktalar) ve Voronoi hücreleri.

Bu çalışmada önerilen RO'ya dayalı tahmin modeli için dört adet parametre tanımlanmıştır. Bu parametreler, `scikit-learn` kütüphanesinde RO için kullanılan varsayılan (default) parametrelerdir [153]. Oluşturulan modelin yeniden üretilebilirliğini sağlamak amacıyla `random_state` parametresi 42

olarak alınmıştır. Bu parametre, modelin her çalıştırıldığında aynı sonuçları üretmesine olanak tanır ve böylece modelin tutarlılığını sağlar. Ağaç sayısı, `n_estimators=100` olarak belirlenmiştir. Bu değer, tahmin performansı ile işlem süresi arasında uygun bir denge sağlar ve birçok çalışmada yaygın bir tercih olarak öne çıkmaktadır [153]. Gini safsızlık kriteri, veri setindeki homojenliği temel alarak modelin daha iyi sınıflandırmalar yapmasını sağlar. Modelin performansını değerlendirmek için, girdi olarak tanımlanan 1.582 EDO'nun %80'i (1.265 örnek) eğitim, %20'si (317 örnek) test kümesi olarak ayrılmıştır. Bu 80/20 bölüşümü, parametrelerin optimizasyonuna yeterli veri sağlarken, modelin henüz görmediği veriler üzerindeki tahmin yeteneğinin güvenilir şekilde ölçülmesini sağlar.Modelin Python ortamında uygulanmasına ilişkin ayrıntılı kod listeleri Ek-A'da sunulmuştur.

3.4 Bulgular ve Değerlendirme

Bu bölümde, kentsel yapı, yaya ve konut yoğunluğu desenlerinin, Melbourne kentindeki EDO mekanlarıyla olan etkileşimini nasıl etkilediği ortaya konmaktadır. Şekil 3.12, hane sayısı verisetinden hesaplanan ÖS1 hane yoğunluk haritasıdır. Burada kırmızıya yaklaşan sıcak renkler daha yüksek nüfus yoğunluğunu göstermektedir. Tahmin modelinde bu katman, nüfusun potansiyel insan etkileşimi üzerindeki durumunu anlamaya katkı sağlamaktadır.

Şekil 3.13, ortalama saatlik yaya sayısı ve saat 17:00'deki en yüksek yaya yoğunluğunu göstermektedir. Kırmızı tonlar daha yoğun alanları belirtmektedir. Bu veriler, kentsel tasarım, bağlantısallık ve işlevsel arazi kullanımıyla ilişkili olan yaya hareketlilik odaklarını ortaya koymaktadır.

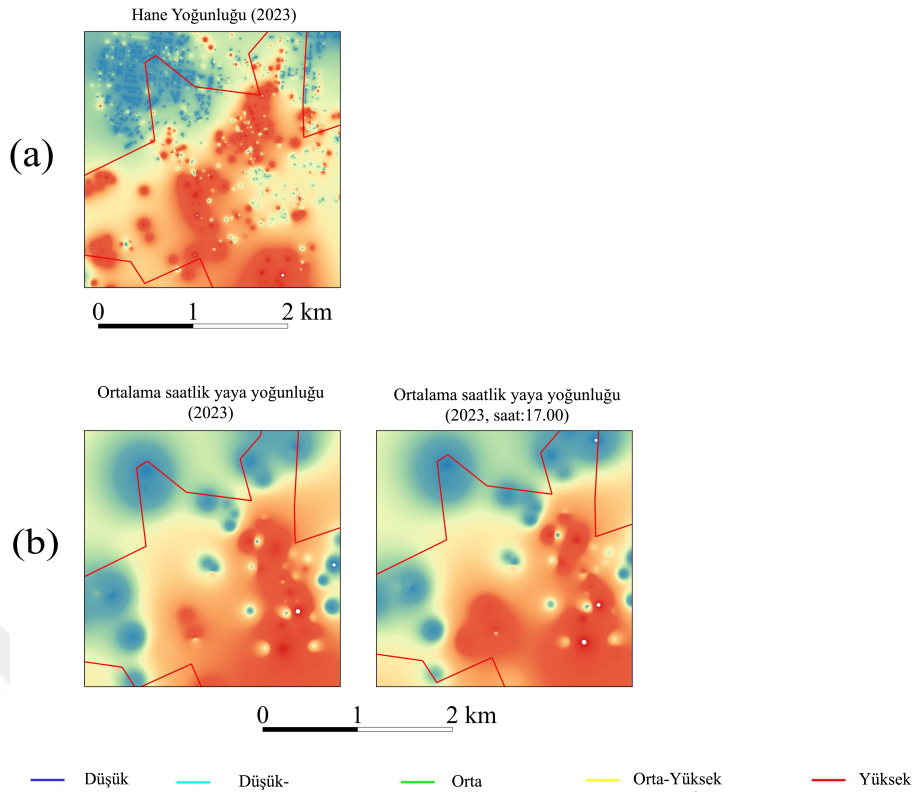

Şekil 3.12 Çalışma alanında (a) konut ve (b) yaya yoğunluğunun mekansal dağılımı.

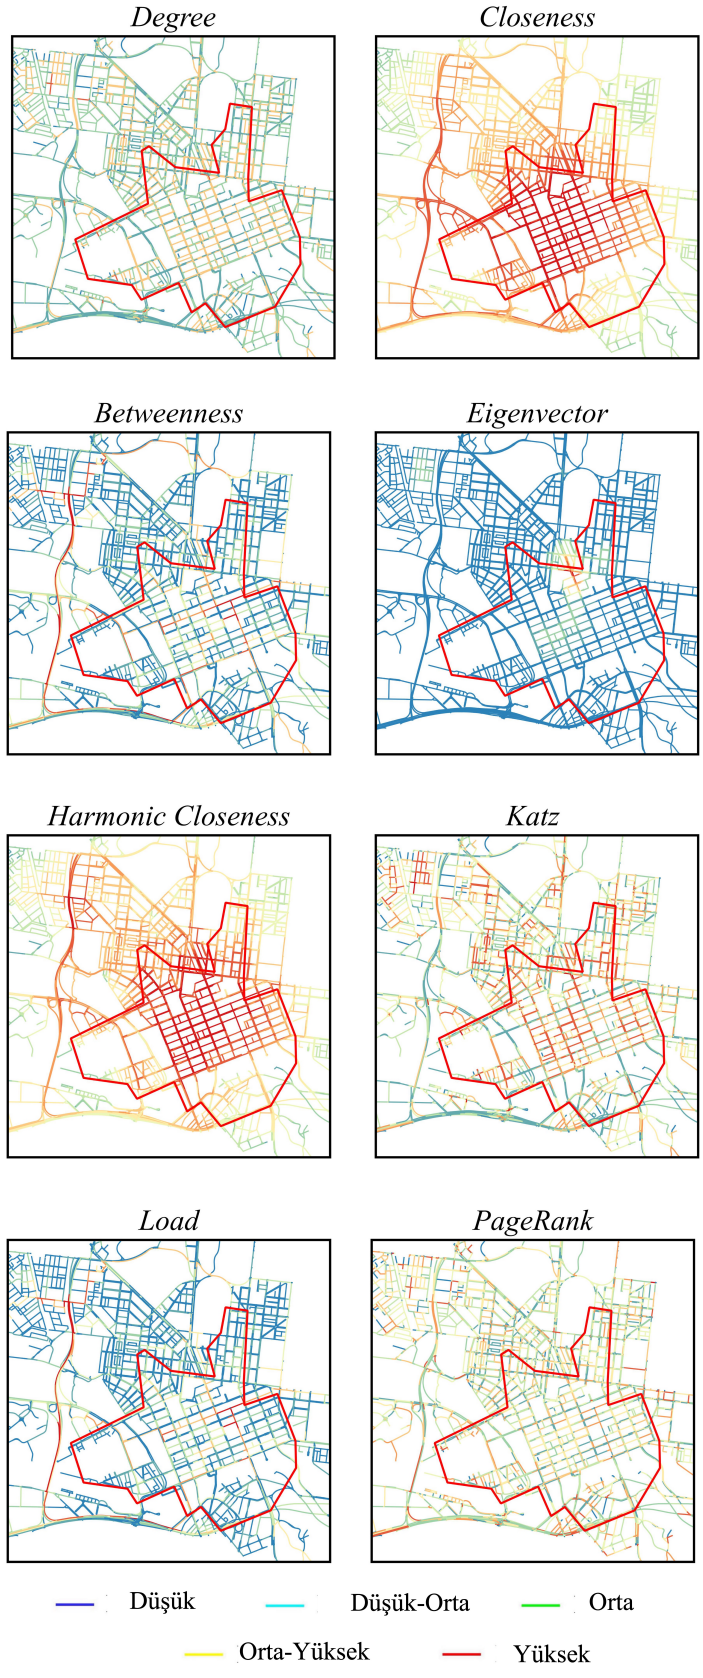

Şekil 3.13 OSM yol ağından hesaplanan merkezilik ölçüleri.

RO modelinin başarısının incelenmesinde kullanılan en etkili yaklaşım F1 skor değerlendirmesidir. F1 skor, modelin doğru tahmin oranını (precision) ve gerçek olumlu örnekleri yakalama yeteneğini (recall) tek bir dengeli ölçüte indirger. F1 Skor değeri 1'e ne kadar yaklaşırsa model o kadar başarılı, 0'a yaklaştıkça da başarısız sayılır. Bu nedenle RO modelinin performansını özetlemek için F1 skoru en pratik göstergedir. Şekil 3.14, Melbourne'deki EDO mekanlarına uygulanan farklı ÖS kombinasyonları ile yorum sayısı ve ortalama puan bağımlı değişkenleri için hesaplanan F1 skor bilgilerini göstermektedir. Altı adet ÖS ile birlikte modelin bar, kafe ve restoranlar için ayrı ayrı eğitilmesi durumunda elde edilen F1 skorları Şekil 3.14'teki bar grafiklerinin son üç çubuğunda verilmiştir.

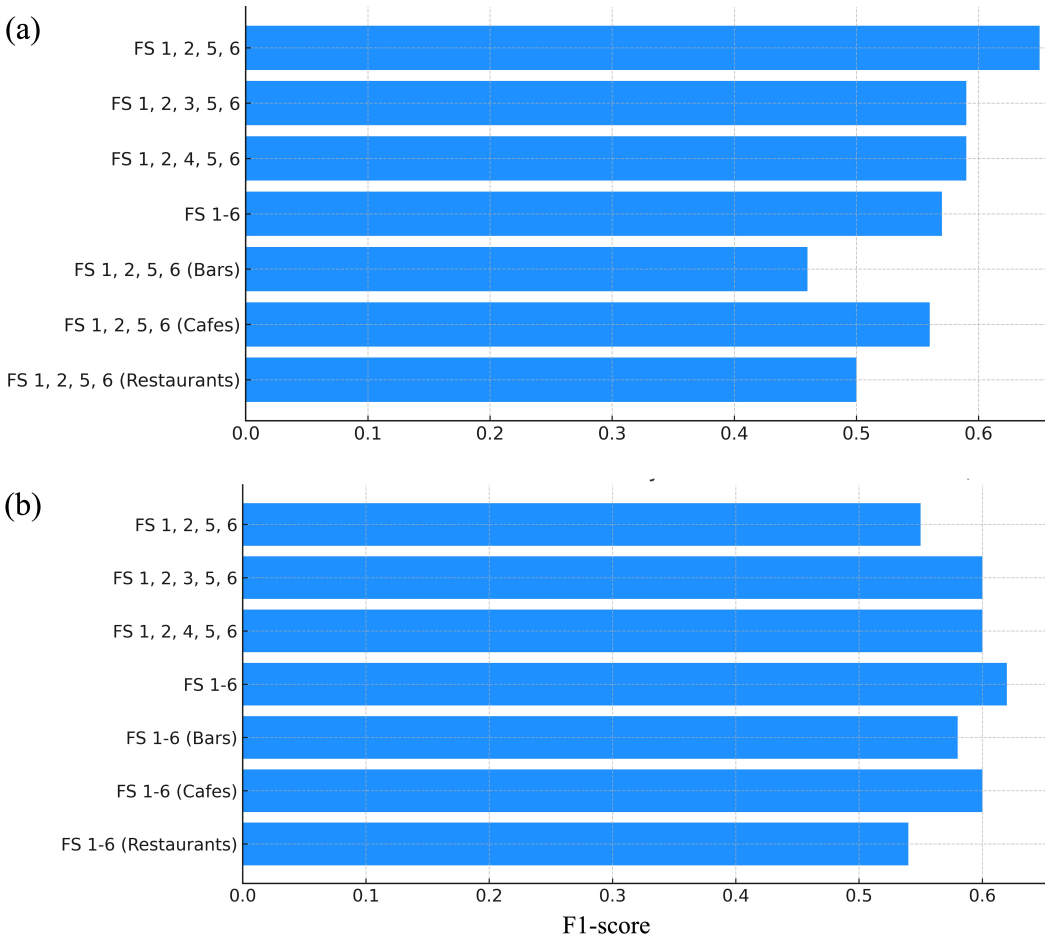

Şekil 3.14 Yorum sayısı (a) ve ortalama ziyaretçi puanı (b) tahminlerine ilişkin model performanslarının, farklı özellik seti ÖS-(FS) kombinasyonları ve mekan türleri (barlar, kafeler ve restoranlar) bazında karşılaştırılması.

Şekil 3.14(a)'da görüldüğü üzere; ÖS1, ÖS2, ÖS5 ve ÖS6 kombinasyonunun en yüksek F1 skoru olan 0.65 ile genel yorum hacmini en iyi şekilde tahmin ettiğini göstermektedir. Bunlara ÖS3 ve ÖS4 eklendiğinde en düşük F1 skor elde edilmiştir. Bu bulgu, birincil ve dual merkezilik ölçülerinin modelin yorum sayısı

tahmin performansını olumsuz etkilediğini göstermektedir. Aynı kombinasyon kafe öznitelik bilgisiyle birlikte ele alındığında model 0,56 F1 skoru değerine sahip olmuştur. Bu durumda orta düzeyde bir başarıdan söz edilebilir. Barlar ve restoranlar için bu öznitelik kombinasyonun tahmin başarısı daha düşüktür. Ziyaretçi puanlarını tahmin etmek için tüm ÖS'lerin birlikte kullanımı, modelin F1 skor değerini en yüksek seviyeye getirmiştir (Şekil 3.14(b)). Bar, kafe ve restoran gruplarına yönelik bilgiler modele dahil edildiğinde F1 skor başarı oranları azalmaktadır. Yorum sayısı ve ziyaretçi puan ortalamalarının tahmin edilmesinde başarılı olan ÖS bileşenlerinin bireysel etkilerini ortaya koymak için önem parametresi kullanılmıştır. Bu parametre, her bir özelliğin (ÖS bileşeninin) tahmin sırasında modele yaptığı katkıyı sayısal olarak özetler. Modelde o özellik kullanıldığında hata ne kadar azalırsa önem değeri de o ölçüde yükselir. Bu değer büyüdükçe ilgili bileşenin yorum sayısı ve ziyaretçi puanı tahminlerinde belirleyici rolü artar. Şekil 3.15a, yorum sayısını tahmin etmede başarılı olan model kombinasyonu bileşenlerinin (ÖS1, ÖS2, ÖS5 ve ÖS6) kendi içindeki önemlerini göstermektedir. Şekil 3.15(b) ise ziyaretçi ortalama puanlarını tahmin etmede kullanılan tüm bileşenler için önemleri göstermektedir.

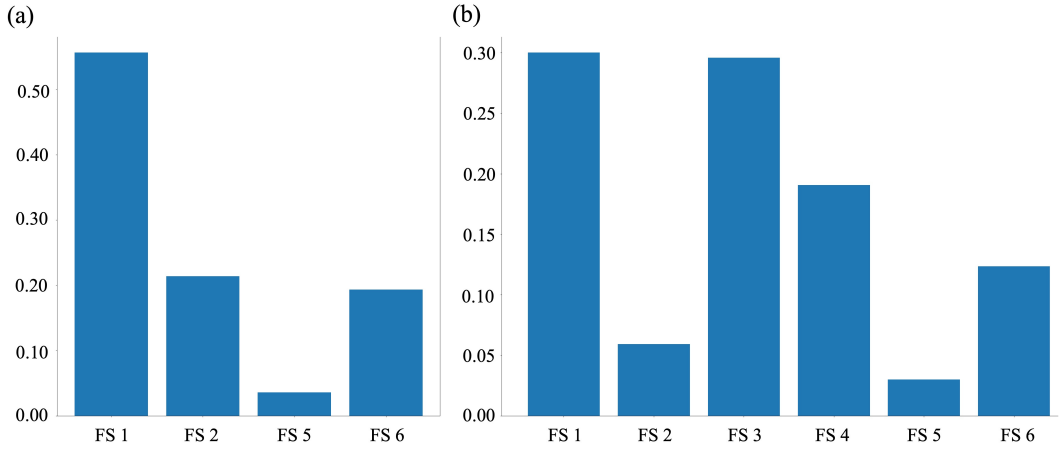

Şekil 3.15 (a) Yorum hacmi ve (b) ziyaretçi puanı tahminlerinde en iyi sonuç veren öznitelik seti kombinasyonları için öznitelik önem düzeylerinin görselleştirilmesi.

Bileşenlerin bireysel değerlendirmesinde her iki modelde de ÖS1 öne çıkmaktadır. ÖS5 ise en düşük etkiye sahip bileşendir. Bu sonuçlar yaya sayısı ve hane sayısının EDO değerlendirmelerinde etkili olduğunu göstermiştir. Diğer taraftan, yollara dair yapısal verilerin tek başına anlamlı bir öngörü gücü sunmadığını göstermektedir. Kıvrımlılık, mesafe, EDO sınıfı yorum sayısı için oluşturulan modelde etkiliyken ziyaretçi puanı modelinde kıvrımlılık ve mesafe etkileri azalmıştır. Birincil ağdan türetilen merkezilik ölçüleri ziyaretçi puanı tahmininde ÖS1'e yakın düzeyde etkili olmuştur. Bu bulgu, yüksek merkeziliğe sahip alanlarda konumlanan mekanların

erişilebilirlik avantajıyla daha yüksek memnuniyet düzeyine ulaşabileceğini göstermektedir. Dolayısıyla, merkezilik yalnızca yerel hareketliliği değil, aynı zamanda mekanın daha geniş kentsel ağ içindeki stratejik konumunu da ziyaretçi algıları üzerinde etkili kılmaktadır.

3.5 Tartışma

Bu bölüm, dijital ayak izlerinin yalnızca içerik temelli değil, aynı zamanda mekansal yapı, bağlantısallık ve yaya hareketliliği gibi fiziksel değişkenlerle nasıl ilişkili olduğunu analiz etmektedir. Bu çalışma, Melbourne kent merkezindeki yaya sensörlerinden türetilen ortalama saatlik yoğunluk değerleri, Google Maps API üzerinden elde edilen EDO konumlarına ilişkin yorum sayısı ve ortalama puan verileri ile OSM yol ağı üzerinde hesaplanan betweenness, closeness ve eigenvektör merkeziliği gibi mekansal ağ ölçülerini bütünleştirerek mekansal analizleri ve dijital ayak izi verilerini bir araya getiren özgün bir metodolojik çerçeve sunmaktadır. Elde edilen bulgular, farklı türdeki EDO'lar (barlar, kafeler, restoranlar) açısından değerlendirildiğinde, model başarısının hem yorum sayısının hem de ziyaretçi puanı açısından farklılıklar gösterdiğini ortaya koymaktadır. Tek bir EDO türünde, model başarısı düşerken; tüm EDO türleri birlikte modellendiğinde, modelin başarısı artmıştır. Bu tür paylaşılan nitelikler, tüm EDO türleri tek bir modelde işlendiğinde daha doğru şekilde yakalanmakta ve modelin genelleme yeteneğini artırmaktadır. EDO türleri ayrı ayrı modellendiğinde, veri çeşitliliğinin azalması, modelin genel örüntüleri öğrenme yetisini sınırlandırabilmektedir. Kafeler, hem yorum hacmi hem de ziyaretçi puanı tahmininde en yüksek başarıyı göstermiştir. Bu durum, tüketici davranışlarının bu mekan türlerinde daha öngörülebilir olabileceğini düşündürmektedir. Bu başarı, kafelerin genellikle yüksek yoğunluklu ve merkezi konumlarda yer almasından kaynaklanabilir. Bu tür lokasyonlar, modelin kilit öznitelikleriyle (yaya yoğunluğu, merkezilik vb.) güçlü korelasyon göstermektedir. Yorum hacmi açısından, restoranlar, barlara kıyasla daha yüksek tahmin başarısı göstermiştir; bu durum, restoranlardaki yorum kalıplarının daha tutarlı olmasından kaynaklanabilir. Diğer yandan, ziyaretçi puanı tahmininde barlar, restoranlardan daha başarılı sonuç vermiştir. Bu durum farklı mekan türlerinde tüketici memnuniyetini etkileyen faktörlerin değişebileceğini göstermektedir.

Batty [154] çalışmasında karmaşık kent sistemleri yaklaşımı, kentsel ağlarda yüksek yoğunluk ve erişilebilirlik noktalarının ticari çekim merkezleri haline gelmesiyle ekonomik faaliyetlerle etkileşimi arttırdığını öne sürer. Bu çalışmada da merkezi yerlerde konumlanan EDO'ların, hem daha fazla erişime sahip olup hem de daha yüksek etkileşim sunduğu gösterilmiştir. Yüksek nüfus yoğunluğu,

daha fazla potansiyel müşteri anlamına gelmekte, bu da hem yorum hem de memnuniyet puanı sayısını artırmaktadır. Dolayısıyla, yaya yoğunluğu, işletmelerin başarısını belirleyen temel faktörleri doğrudan etkilediği için önemli bir değişken olarak değerlendirilebilir. ÖS3 (veya ÖS3+ÖS4)'ün ÖS1'e yakın düzeyde önemli olması, ziyaretçi puanlarının tahmininde yalnızca yerel çevresel etkenlerden değil, aynı zamanda mekanın kentsel ağ içindeki stratejik konumundan da etkilendiğini göstermektedir. Merkezi bir noktada konumlanan bir mekan, artan erişilebilirliğinin sağladığı avantajlardan faydalanarak daha yüksek tüketici memnuniyetine katkı sağlayabilir.

Araştırmamızda, yaya yoğunluğunun hem yorum sayısı hem de ziyaretçi puanı üzerinde belirleyici bir rol oynadığı ortaya çıkmıştır. Benzer şekilde Tang ve diğ.[155]'nin, Şanghay'daki 16.794 restoran verisini kullanarak sokak görüntülerinden çıkardıkları çevresel göstergeler ile Dianping yorum/puanlarını ve dinamik yaya akışını OLS modellerinde analiz etmiş; yaya trafiğinin hem yorum sayısını hem de tat, ortam ve hizmet puanları üzerinde en etkili değişkenler olduğunu ortaya koymuştur. Ancak, bu tez çalışması kapsamında en yoğun saat hareketliliği gibi dinamik yaya verilerini ve merkezilik ölçülerini de dahil ederek, tüketici davranışlarını daha ayrıntılı biçimde modellemiştir. Merkezilik ölçülerine ilişkin daha derinlemesine analizler, tahmin çıktıları üzerindeki etkilerinin oldukça farklılaştığını ortaya koymuştur. Özellikle, birincil merkezilik ölçüleri, ağdaki iyi bağlantılı düğümleri vurgulayarak ziyaretçi puanı tahminlerinde iyileşme sağlamıştır. Bu ölçüler, bir mekanın daha geniş kentsel ağ içindeki entegrasyon seviyesini yansıtmaktadır. Diğer yandan, dual merkezilik ölçüleri, yorum hacmini tahmin etmede sınırlı etki göstermiştir. Bu durum, ağ düzeyindeki bütünleşmenin insanları etkilediğini, ancak yorum bırakma davranışının daha çok yerel düzeydeki unsurlar (örneğin yaya yoğunluğu, sokak geometrisi, vb.) tarafından şekillendirildiğini göstermektedir. Gavilan ve diğ. [156], otel rezervasyonları üzerine yaptıkları deneysel çalışmada yüksek puanların yalnızca çok sayıda yorumla desteklendiğinde güven oluşturduğunu; düşük puanların ise yorum hacminden bağımsız olarak mekana duyulan güveni azalttığını göstermiştir. Bizim çalışmamızın sonuçlarına göre de yoğun yaya trafiğine sahip bölgelerde yer alan ve hem yüksek puana hem de çok sayıda yoruma sahip EDO'ların kullanıcılar tarafından daha güvenilir algılanması beklenebilir. Çalışmamızdaki merkezilik ölçülerinin ortalama puanları tahmin etmede önemli bir bileşen olduğunu gösteren bulgular ile, Hacar ve diğ. [65], Matera'da betweenness ile Google Maps'teki mekanların yorum sayısı ve puanları arasındaki pozitif korelasyonu gösteren sonuçlar açısından uyumludur. Bulgular, tüketici davranışının kentsel ölçekli özellikler olan merkezilik ile yaya akışı kadar yerel çevresel etmenler olan

kıvrımlılık ve ana yola yakınlık tarafından da şekillendiğini göstermektedir. Bu nedenle mekan yönetimi stratejileri, ağ düzeyindeki makro faktörleri ve mikro düzeydeki bağlamsal unsurları birlikte değerlendirmelidir. Özellikle, kıvrımlılık ve yola yakınlık gibi geometrik öznitelikler de anlamlıdır. Düşük kıvrımlılığa sahip sokaklara yakın konumlanan yerler daha fazla yorum almış, bu da kolay erişilebilirliğin tüketici etkileşimini arttırdığını göstermektedir. Ancak, ziyaretçi puanı tahmininde bu etki daha az belirgindir. Bu durum deneyimsel faktörlerin puanlamada daha karmaşık rol oynadığını düşündürmektedir.

Bu çalışmanın dikkat edilmesi gereken bir sınırlılığı, Google Maps API verilerinin yalnızca en az 10 yoruma sahip EDO mekanlarını içermesi nedeniyle, daha küçük veya yeni açılmış mekanların dahil edilmemiş olmasıdır. Ayrıca, dijital ayak izlerinin yapay ya da yanıltıcı yorumlar içerebileceği göz önünde bulundurulmalıdır. Google Maps'te yer alabilecek sahte yorumları filtreleme algoritmalarına rağmen bu içeriklerin tamamen elimine edilemeyeceği belirtilmelidir.

4
GELİŞTİRİLEN N-ADIM (N-STEP) AKIŞ MODELİNİN TASARIMI VE UYGULAMASI

Yaya hareketliliğini konu alan birçok araştırma başlangıç ve hedef konumlar arasındaki akış verisine dayanır. Şehir içi hareketliliğin ve talep dağılımının ortaya konulması, seyahat taleplerinin yönetilmesi ve yaya yoğunluğunun optimize edilmesi gibi farklı sorunların çözümünde kullanılan akış hareketlerini makro ölçekte, esnek ve ölçeklenebilir şekilde ortaya koymak gerekir. Sensör ve kamera teknolojilerindeki hızlı gelişmeler ve akıllı şehir uygulamalarında kullanılan IoT sistemleri, yaya sayım verilerinin noktasal bazda elde edilmesini kolaylaştırmıştır. Geniş kentsel alanlarda yol üstü kameralardan ve sensörlerden sağlanan veriler anında işlenerek yüksek duyarlılıkta noktasal yaya sayım verisi elde edilir. Bu cihazların çalışma sahasındaki dağılımı ve sıklığı arttıkça kentsel yaya yoğunluğu daha duyarlı olarak belirlenir. Makro ölçekli bir çalışma sahasına yerleştirilmiş yaya sayım araçları, kollektif hareketlerin modellenmesine katkı sağlayan dokuları üretir. Buna karşın elde edilen sayım verileri noktasaldır ve yaya hareketlerinin başlangıç-hedef noktaları ile hareket doğrultuları yani akış hakkında bir fikir vermez. Yaya sayım verilerinden başlangıç ve hedef konumlar arasındaki akış hareketlerini modelleyerek bir OD matris oluşturmak için genellikle sentetik çözümler kullanılır. Bu çalışmada, sayım verilerinden yaya hareketlerini sentetik olarak üreten çok adımlı bir akış modeli önerilmektedir. Bu model mekansal bağlantılılık ve akış modelleri temelinde geliştirilmiş bir topluluk hareket modelidir. N-adımlı akış yaklaşımı olarak adlandırılan bu model, yaya sayımlarına dayalı olarak OD matris oluşturur. Modelin geliştirilme sürecinde ilk olarak tek adımda işleyen model sonrasında farklı çözümler ile çok adımlı hale dönüştürülmüştür. Aşağıda modelin ilkel versiyonundan son aşamasına kadar olan dönüşüm süreci açıklanmıştır.

4.1 Hareketlilik Modelinin Geliştirilmesinde İlk Yaklaşımlar

Yaya hareketliliğini oluşturan temel unsur, insanların bir konumdan başka bir konuma yürüyerek konum değiştirme eğilimidir. Yaya dolaşımına uygun bir yerleşim bölgesinin coğrafi hücrelerden oluşan bir yapı ile tanımlandığı durumda, yayalar için konum değiştirme bir hücreden diğer bir hücreye akış ile ifade edilir. Hücrelerin düzenli şekilde oluşturulduğu grid yapıda, bir hücrenin çevresinde akışın oluşabileceği sekiz komşu hücre mevcuttur. Şekil 4.1'te görünen yapıda, merkezde bulunan hücreden sekiz komşu hücreye olabilecek yaya hareket doğrultuları gösterilmiştir. Bu yapıda, merkez hücre dışındaki diğer sekiz hücre de kendi komşularına yaya akışı sağlar. Yaya hareketleri, herhangi bir hücreden başlar ve komşu hücrelere doğru devam eder.

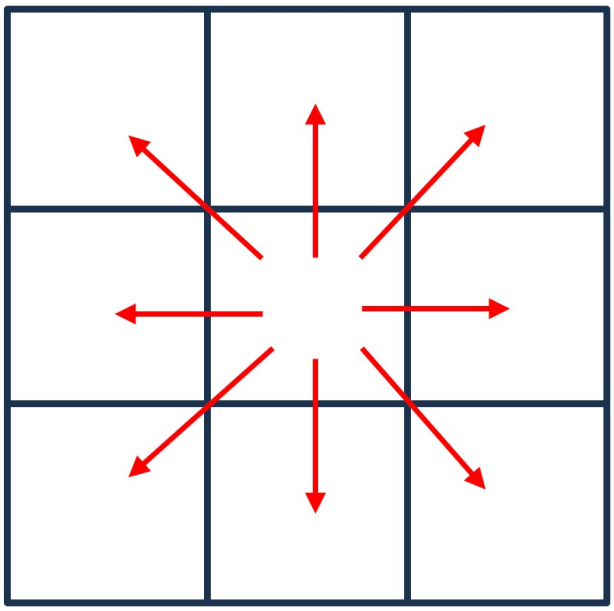

Şekil 4.1 D8 tabanlı akış yönleri.

Yaya hareketlerinin dışında akışın modellendiği farklı uygulama örneklerinde benzer dokuz hücreli yapı sıklıkla kullanılmaktadır. Örneğin gayrimeskûn arazilerde suyun biriktiği yerlerin, drenaj ağı yapısının, havzaların vb. birçok hidrolojik parametrenin hesaplanmasında etkin olarak kullanılan D8 yaklaşımında akış eğime göre modellenmektedir [157]. Bu çalışmada ilk versiyonu D8 akış algoritmasından esinlenerek geliştirilen yaya akış modeli, bir hücreden başlayan yaya hareketini kendisinden daha yüksek yaya hareketlerine sahip komşu hücreler arasından hareketin en düşük olduğu hücreye yönlendirmektedir. Bu yinelemeli süreç, sekiz komşu hücrenin her birindeki hareketin merkezdeki hücreden daha düşük olması durumunda sonlanmaktadır. Bu yaklaşım yayaları komşu hücreler arasından sadece birine yönlendirmekte ve son aşamada yaya hareketlerinin tek bir

hücrede yoğunlaşmasına sebep olmaktadır. N-step modelinin ikinci versiyonu tıpkı birinci versiyonunda olduğu gibi tek adımlı bir strateji izlemiştir. Bu versiyonda yaya akışı, merkezdeki hücreden tüm komşu hücrelere, ilgili komşu hücredeki hareket miktarına bağlı olarak doğru orantılı dağıtılmaktadır. Buna göre, Şekil 4.2'te beyaz ile gösterilen numaralandırılmış hücrelerden kırmızı ile gösterilen hücrelere doğru yaya akışı gerçekleşir. Beyaz hücreler ile gri hücreler arasında komşuluk ilişkisi olmadığından akış olamaz. Yani 1, 3, 7 ve 9 numaralı hücrelerden beş hücreye; 2, 4, 6 ve 8 numaralı hücrelerden 3 hücreye akış gerçekleşmez. Yaya akışının başladığı bir hücreden akışın olmadığı hücrelere ulaşmanın yolu komşu hücrelerden geçmektedir. Komşu hücreler (kırmızı) köprü olarak kullanıldığı takdirde ikinci adımda gri hücrelere erişilebilir.

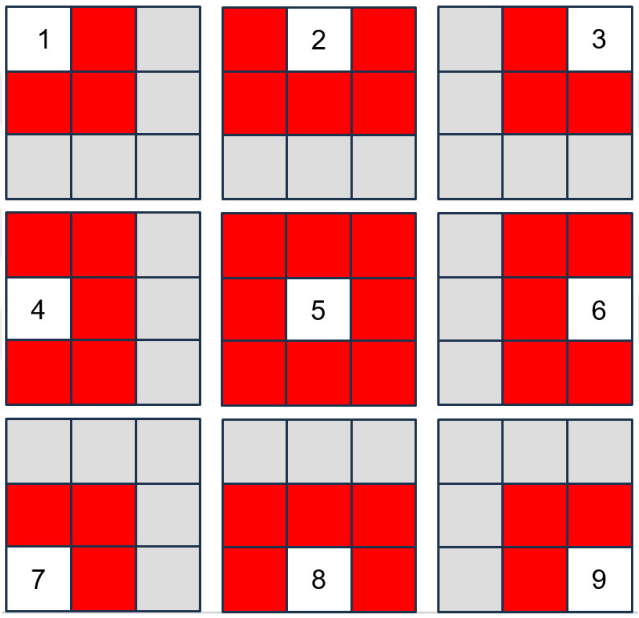

Şekil 4.2 Akışın başladığı numaralandırılmış (beyaz) hücreler, onların komşuları (kırmızı) ve erişilemeyen (gri) hücreler.

Buna göre yukarıda tanımlı dokuz hücreden kırmızı ile gösterilen toplam 40 adet komşu hücreye yaya akışı tanımlanır. Fakat akışın başladığı dokuz hücre gerçekte dokuz hücreli bu yapıda yer alan diğer tüm hücrelere yaya akışı sağlayabilir. Bu durumda toplam 9 x 8 = 72 adet akış gerçekleşmesi beklenirken 32 hücreye akış oluşamaz. Sonuç olarak hareketin sadece yakın komşular ile sınırlı kalması; ikinci ya da üçüncü komşulara akış dokularının üretilmemesi modelin en belirgin eksikliğidir.

4.2 N-Adım Modeli

Yukarıda bahsedilen sorunu ortadan kaldırmak için ikinci versiyonda tasarlanan tek adımlı model, her bir hücreden diğer tüm hücrelere ulaşacak şekilde çok adımlı hale getirilmiştir. Şekil 4.3, sol üst köşede bulunan 1 numaralı hücreden diğer sekiz hücreye iki adımda gerçekleşebilecek hareketleri göstermektedir. 1 numaralı hücreden 2 numaralı hücreye **1** $\rightarrow$ **2** rotası ile birinci adımda ulaşılabilirken, aynı hücreye iki adımda **1** $\rightarrow$ **4** $\rightarrow$ **2** ve **1** $\rightarrow$ **5** $\rightarrow$ **2** rotaları üzerinden gidilerek toplam üç farklı rota (mavi ok) kullanılarak erişilebilir.

İkinci adım, alternatif iki rotanın daha oluşmasını sağlar. Benzer şekilde, 1 numaralı hücreden 4 ve 5 numaralı hücrelere iki adımlı üçer adet alternatifli rota kullanılarak erişilebilir (kahverengi ve mor oklar). 1 numaralı hücreden 3 numaralı hücreye birinci adım sonunda erişme imkânı yoktur. Bu hücreler arası erişim ikinci adım sonunda **1** $\rightarrow$ **2** $\rightarrow$ **3** ve **1** $\rightarrow$ **5** $\rightarrow$ **3** rotaları üzerinden iki şekilde yapılır (yeşil oklar).

1 numaralı hücreden 6, 7 ve 8 numaralı hücrelere erişim yine sadece ikinci adım sonunda iki farklı rota üzerinden gerçekleşir. Son olarak, 1 numaralı hücreden 9 numaralı hücreye erişim için iki adımda sadece **1** $\rightarrow$ **5** $\rightarrow$ **9** rotası kullanılarak erişilebilir (mor).

Böylece dokuz hücreli grid yapıda, 1 numaralı hücreden diğer sekiz hücreye en fazla iki adımda toplam 18 rota üzerinden erişim sağlanabilir. Bu yapıda, 1 numaralı hücre gibi 3, 7 ve 9 numaralı hücreler de köşe hücrelerdir. Bu nedenle ilgili hücrelerden başlayan akış, diğer hücrelere 18 farklı rota üzerinden gerçekleşir. 2, 4, 6 ve 8 numaralı hücreler birbirine göre simetrik konumdadır ve bu hücrelerden başlayan akışlar iki adımda 24'er adet rota üzerinden yapılır. 5 numaralı hücre modelin merkezindedir. Bu hücreden iki adımda diğer hücrelere 32 adet rota kullanılarak ulaşılır. İki adımda modelin tamamı için toplam 200 rota hesaplanır.

Bu rotalar, tüm hücreler arasında olması beklenen 72 akışı gerçekleştirir. Dokuz hücre için beklenen akış sayısına iki adımda ulaşıldığı için, önerilen akış modeli "iki adımlı" olarak adlandırılır. Modelin hücre sayısına bağlı olarak oluşacak toplam akış sayısı Eşitlik 4.1 ile verilmiştir:

$$F_{num} = t_{num} \times (t_{num} - 1) \tag{4.1}$$

Burada F_{num} gerçekleşmesi beklenen akış sayısını, t_{num} ise modeldeki hücre sayısını ifade etmektedir. Beklenen akış sayısına ulaşılabilmesi için hesaplanması

gereken rota sayısı, hücrelerin komşuluk ilişkilerine bağlı olarak değişmektedir. Her bir hücreden modeldeki diğer hücrelere erişim için gereken adım sayısı, önerilen akış modelinin n temel parametre değeridir.

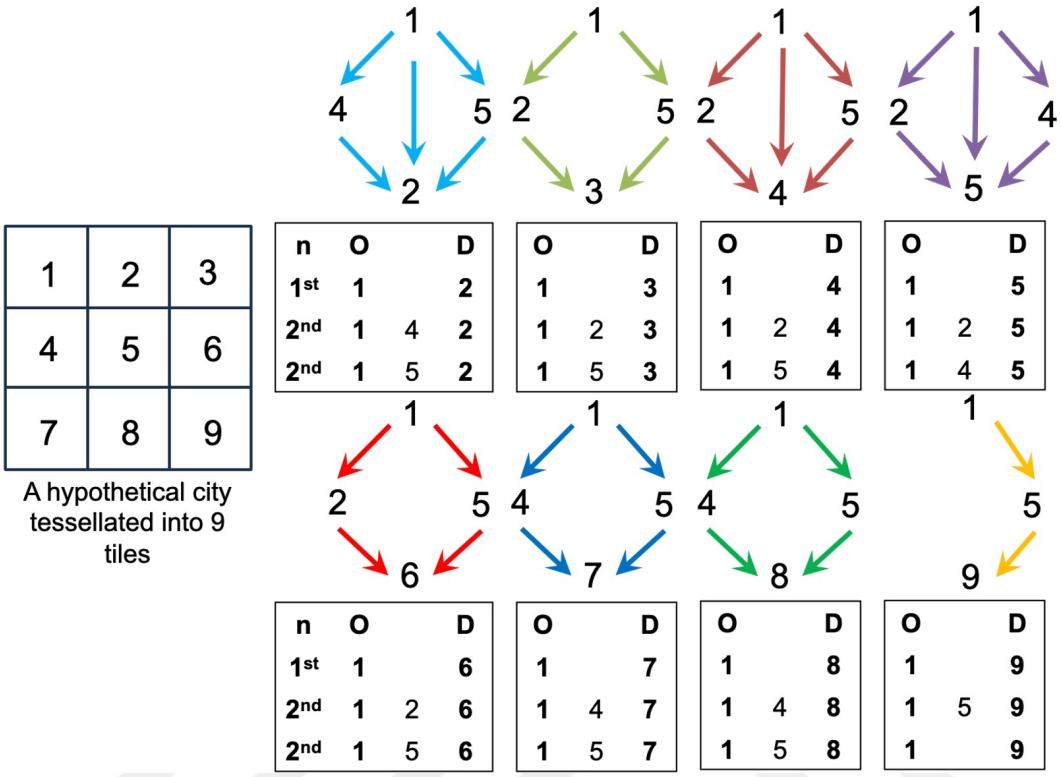

Şekil 4.3 Varsayımsal bir şehir üzerindeki N-Adım akış modelinin basit bir gösterimi.

4.3 Akış Miktarının Hesaplanması

Önerilen yaklaşıma göre her bir hücrede sayılan yayalar komşu hücrelere akış rotaları kullanılarak dağıtılır. Bir hücre için başlangıçtaki yaya sayısı komşu yaya sayılarına bağlı olarak orantılı şekilde paylaştırılır. Komşu hücrelerin bir köprü görevi gördüğü durumda bu hücreye gelen yaya sayısı komşu hücrelere ikinci adımda orantılı şekilde tekrar dağıtılır. Adım sayısı arttıkça köprü görevi gören hücrelere gelen yayalar diğer komşu hücrelere dağıtılır. Bir önceki aşamada açıklanan dokuz hücreli modelde birinci adımda 1 numaralı hücredeki yaya sayısı 2, 4 ve 5 numaralı hücrelere orantılı şekilde dağıtılır. Bu yayalardan 2 numaralı hücreye gelenler ikinci adımda 3, 4, 5 ve 6 numaralı hücrelere dağıtılır. Akışa 1 numaralı hücre olduğu için 2 numaralı hücreden 1 numaralı hücreye ikinci adımda dağıtım yapılmaz. Benzer şekilde ikinci adım için 4 ve 5 numaralı hücrelerin köprü görevi gördüğü durumlarda yayalar ilgili komşularına dağıtılır. Toplam 200 rota için bu dağıtım tekrar eder. Her bir hücreye aynı başlangıç noktasından farklı rotalar kullanılarak gelen tüm akış miktarları toplanır. Böylece başlangıç ve bitiş noktaları

arasında toplam akış miktarı hesaplanır.Modelin Python ile yazılmış uygulama kodu **Ek B**'de sunulmuş, ayrıca GitHub deposunda paylaşılmıştır.

N-Step akış modeli ile hücreler arası akışın ve akış miktarlarının hesaplanması için geliştirilen algoritmanın işleyişini açıklayan 'pseudo-code' yapısı aşağıda verilmektedir. Buna göre akış miktarları OD matris yapısında elde edilir.

Algorithm 1: N-Step Flow Algorithm

Input: Graph $G = (V, E)$, hourly counts $\mathbf{C}$, maximum steps n
Output: OD matrices $\{F^{(s)}\}$
Initialise $R_i^{(0)} \leftarrow C_i$ and $F_{ij}^{(s)} \leftarrow 0$;
for $s \leftarrow 1$ **to** n **do**
  foreach $i \in V$ *with* $R_i^{(s-1)} > 0$ **do**
    $Z \leftarrow \sum_{k \in \mathcal{N}(i)} C_k$;
    foreach $j \in \mathcal{N}(i)$ **do**
      if $Z > 0$ ***and*** (i, j) *unused in previous steps* **then**
        $F_{ij}^{(s)} \leftarrow R_i^{(s-1)} \, C_j / Z$;
        $R_j^{(s)} \leftarrow R_j^{(s)} + F_{ij}^{(s)}$;
    $R_i^{(s-1)} \leftarrow 0$;
return $\{F^{(s)}\}_{s=1}^{n}$

4.4 Çalışma Bölgesi ve Veri Kaynağı

Sosyal olanaklar bakımından dünyanın en yaşanabilir şehirleri listesinde ön sıralarda yer alan Melbourne, yol ağlarının yaya erişimi için düzenlendiği ve yürüme alanlarının sürekli olarak sensörler tarafından izlendiği dünyanın yaya erişimine odaklı şehirlerinden en önemlisidir. Bu çalışmada, Bölüm 3'te ayrıntıları verilen Melbourne'ün sensör sayım verileri kullanılarak, şehir merkezinde bir saatlik zaman aralığında herhangi iki lokasyon arasındaki hareketliliğin sentetik olarak üretilmesi hedeflenmiştir. Test işlemleri, 2023 yılına ait haftalık kayıtlar üzerinden standart sapmanın düşük, orta ve yüksek olduğu üç ayrı hafta için gerçekleştirilmiştir. Bu haftalara ait çalışmaya girdi oluşturan bir saatlik ortalama sayım verileri, aritmetik ortalama ile hesaplanmıştır.

4.5 Mekansal Mozaikleme

Bir lokasyondan başka bir lokasyona olan hareketliliğin modellendiği çalışmalarda hareketin başladığı ve bittiği yerler bir nokta ya da noktayı temsil eden bir bölge ile tanımlanır. Kentsel hareketliliğin tanımlandığı geniş ve büyük sahalarda yaya hareketlerini modellemek için bölge çeşitli faktörlere göre bölünerek

analiz edilir. Mekansal bölümlendirme, kentsel planlama, toplu taşıma ve hareketlilik altyapısı optimizasyonunda sıklıkla kullanılan bir tekniktir. Batty [112], kentsel alanlarda veri modeli oluşturmak için bu tekniğin kullanışlı olduğunu vurgulamıştır. Cheng ve Masser [158], hücresel otomatlar yardımıyla kentsel büyüme modellerinin oluşturulmasında ve karmaşık sistemlerin analizinde mekansal bölümlendirmeyi kullanmıştır. Mekansal bölümlendirme toplu taşıma sistemlerinin rota optimizasyonu ve seyahat talebi belirleme çalışmalarında kritik bir öneme sahiptir [159]. Mekansal mozaikleme çevresel değişimleri izleme ve acil durum müdahaleleri için coğrafi alanların yönetilebilir birimlere ayrılmasında kullanılan güçlü bir araçtır [160]. Sensör verilerinin sıklıkla kullanıldığı akıllı şehir projelerinde şehirlerdeki alanların verimli bir şekilde izlenmesini sağlayarak karar almayı kolaylaştırmaktadır [161, 162]. Mozaikleme, idari sınırlara bağlı kalınarak oluşturulabildiği gibi gerçekleştirilen çalışmaların amacına göre şekillenen farklı geometrik düzenlerde ve çözünürlüklerde oluşturulabilir. Bu çalışmada Melbourne şehri karesel ve altıgen mozaiklere ayrılarak hücreler arasındaki yaya akışı analiz edilmiştir. Şehri parçalara ayıran bu iki düzenli geometrik yapı için hücre çözünürlüğü yayaların ortalama yürüme hızına bağlı olarak belirlenmiştir. Bir yayanın ortalama yürüme hızı bireyin yaşına, cinsiyetine, fiziksel kondisyonuna, çevre koşullarına ve yürüyüş amacına bağlı olarak değişebilir [163]. El-Geneidy [164], beş dakikada bir yayanın ortalama 400 metre yol alabileceğini belirtmiştir. Moreno ve diğ.[165] ve Allam ve diğ.[166] hareketlilik çalışmaları kapsamında rahatlık ve yaşam kalitesini arttırmak için 15 dakikalık şehir konseptini ortaya atmıştır. Bu konsept, şehrin dört bir yanındaki sokakları ve kamusal alanları, yerel halkın yararına olacak şekilde yeniden tasarlamayı vadetmektedir. Yayalar için 15 dk 1.200 metre seyahat mesafesine karşılık gelir. Levinson ve El-Geneidy [167], seyahat mesafesi ile en kısa doğrusal mesafe olan Öklid mesafesi arasındaki oranı circuity factor olarak adlandırmıştır. Newell [168], kentsel alanlarda minimum circuity factorünün yol ağının kuş uçuşu mesafesinden %20 daha uzun olduğunu ifade etmiştir. Buna göre bu çalışmada kullanılan karesel ve altıgen mozaiklemeler için hücre büyüklüğü 1.000 m Öklid mesafesi olarak kabul edilmiştir. Şekil 4.4 ve 4.5, bu çalışmada Melbourne şehir merkezi için oluşturulan hücreleri göstermektedir. Yaya hareketlerinin yoğun olduğu hücrelerin birçoğunda birden fazla sensör bulunmaktadır. Bu hücrelerin yaya sayıları, ilgili hücre içine düşen tüm sensörlerin kaydettiği saatlik ortalamalar toplanarak belirlenmiştir. Buna karşın Şekil 4.5'de gri ile gösterilen hücrelerde sensör mevcut değildir ve bu hücreler içinde sensör bulunan birer hücreyi diğerlerinden ayırmaktadır. Bu çalışmada akışlar içinde sensör bulunan kenar bağlantılı 16 adet karesel ve 12 adet altıgen hücre grubu için oluşturulmuştur. İçinde sensör bulunmayan ve hücre grubundan ayrı kalan hücreler değerlendirme dışında bırakılmıştır.

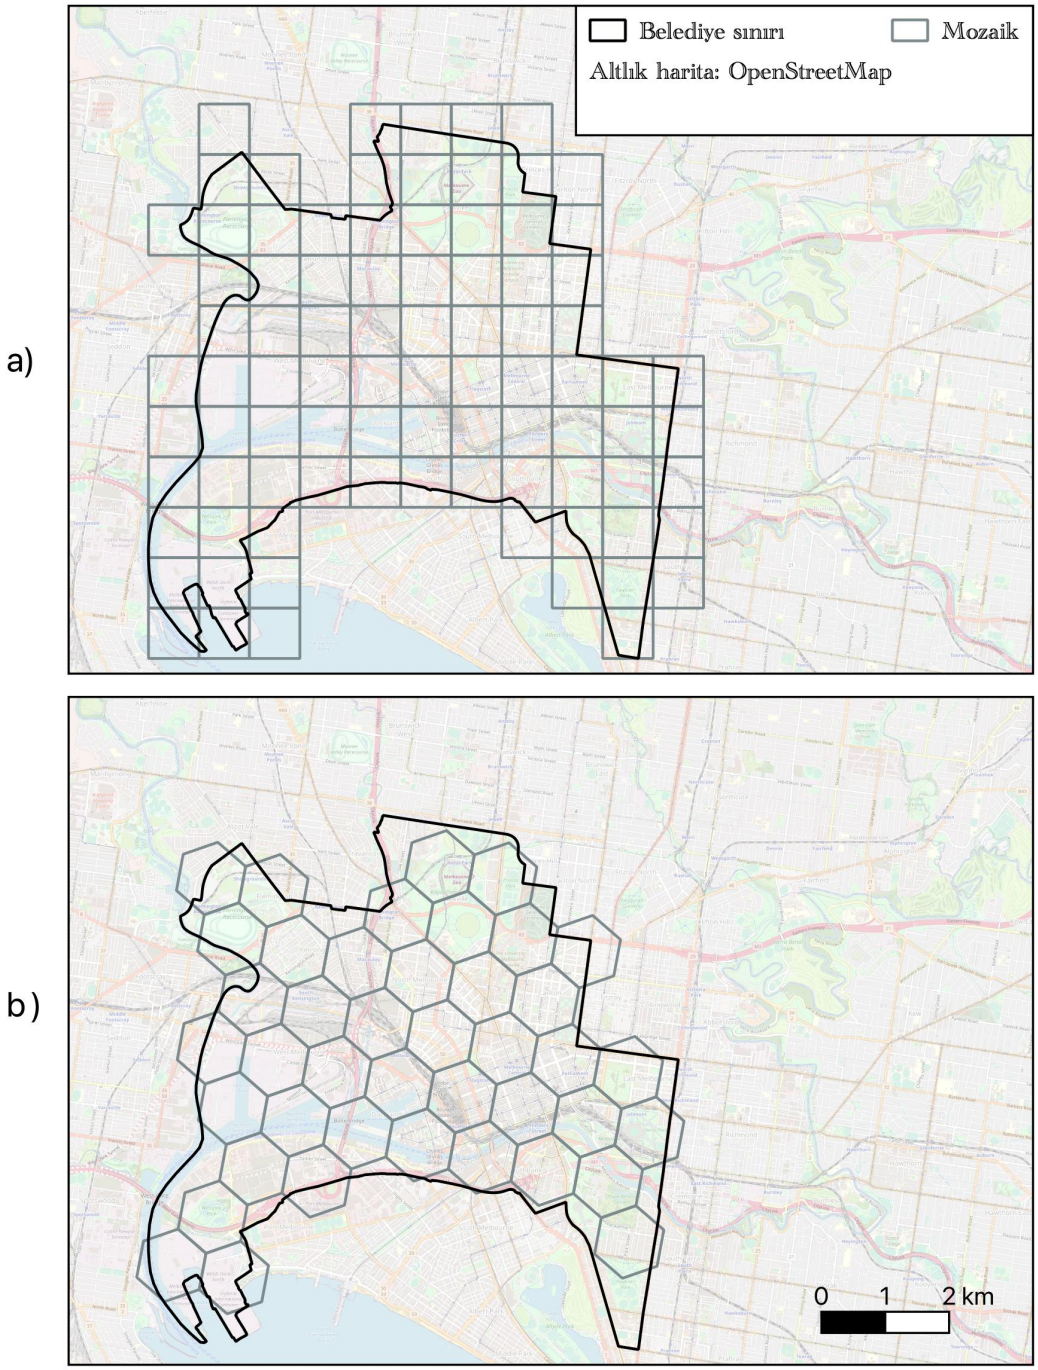

Şekil 4.4 Kare ve altıgen hücrelerin Melbourne şehri için OSM altlığı kullanılarak görselleştirilmesi.

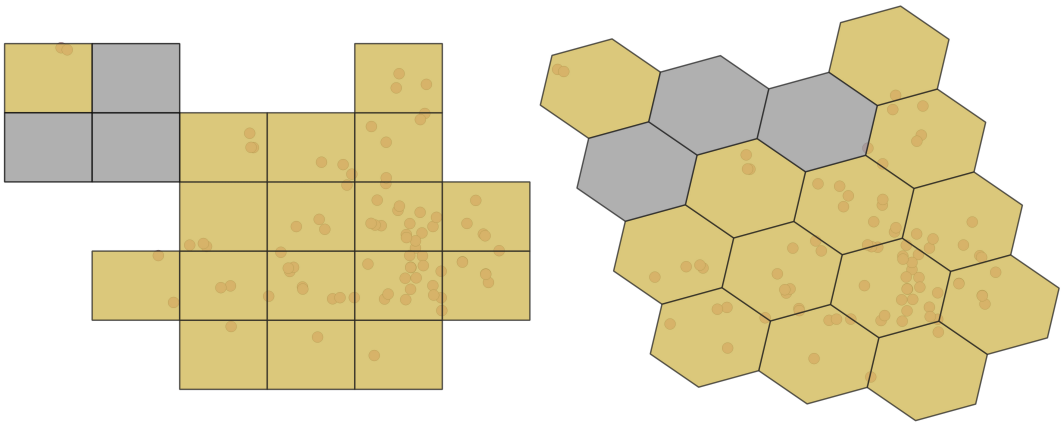

Şekil 4.5 Kare ve altıgen hücreler içerisinde sensörlerin dağılımı.

4.6 Sonuçlar

Bu çalışmada, Melbourne şehrine ait sensörlerden elde edilen yaya sayım verilerine dayanarak hücreler arasındaki akışlar üretilmiştir. 1 Eylül 2023 ile 1 Eylül 2024 tarihleri arasında kentteki yaklaşık 85 adet yaya sayım sensöründen saatlik olarak toplanan veriler haftalık periyotlarda gruplanmıştır. Ardından, seçilen haftalar için saatlik ortalama yaya sayıları ve standart sapmaları hesaplanmıştır (Şekil 4.6).

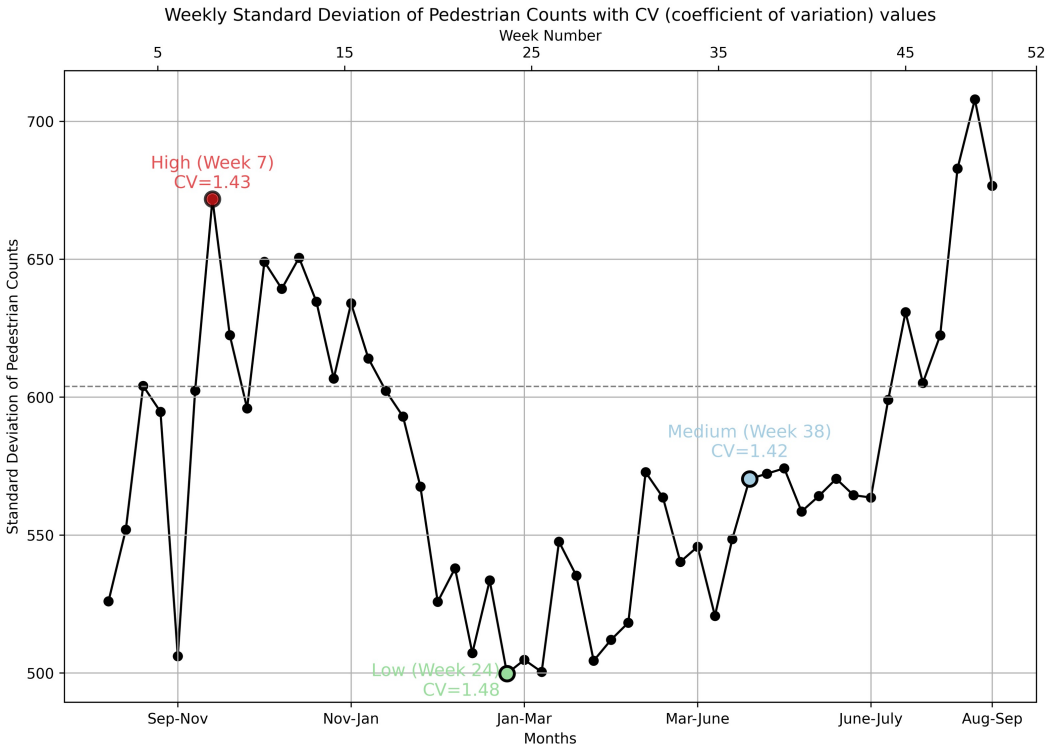

Şekil 4.6 Yaya Sayımlarının Haftalık Standart Sapma Değerleri (Yüksek standart sapma: kırmızı; orta: mavi ve düşük: yeşil).

Şekil 4.6'de çalışma alanındaki yaya sayımlarının haftalık standart sapmaları ve

bunlara karşılık gelen değişim katsayısı (CV) değerleri gösterilmektedir. Değişim katsayısı, standart sapmayı ortalamaya oranlayarak göreli değişkenliği ölçer. Görüldüğü gibi, yaya sayıları haftadan haftaya önemli ölçüde dalgalanabilmektedir. Bu değişkenliği yakalamak amacıyla, düşük, orta ve yüksek standart sapma değerlerine karşılık gelen üç temsili hafta seçilmiştir. Seçilen her haftanın, çalışma alanındaki tüm sensörlerden eksiksiz veriye sahip olması zorunluluğu getirilmiş; herhangi bir sensörden veri kaybı olan hafta değerlendirmeye alınmamıştır. Test için seçilen üç haftanın ortalama yaya sayıları ve standart sapmaları Tablo 4.1'de verilmiştir.

Tablo 4.1 Seçili haftalar için sensörlerden toplanan saatlik yaya sayımı verilerinin standart sapma ve ortalama değerleri.

Haftalar	Ortalama	Standart sapma
Düşük	338	499.785
Orta	401	570.397
Yüksek	470	671.782

Çalışma alanı, sırasıyla 16 kare ve 12 altıgen hücreye bölünmüştür. Bu mozaikleme işlemi scikit-mobility kütüphanesi kullanılarak gerçekleştirilmiştir [169]. Seçilen üç haftada, her hücredeki sensörlerden elde edilen günlük ortalama yaya sayılarının toplamı Şekil 4.7'da gösterilmiştir.

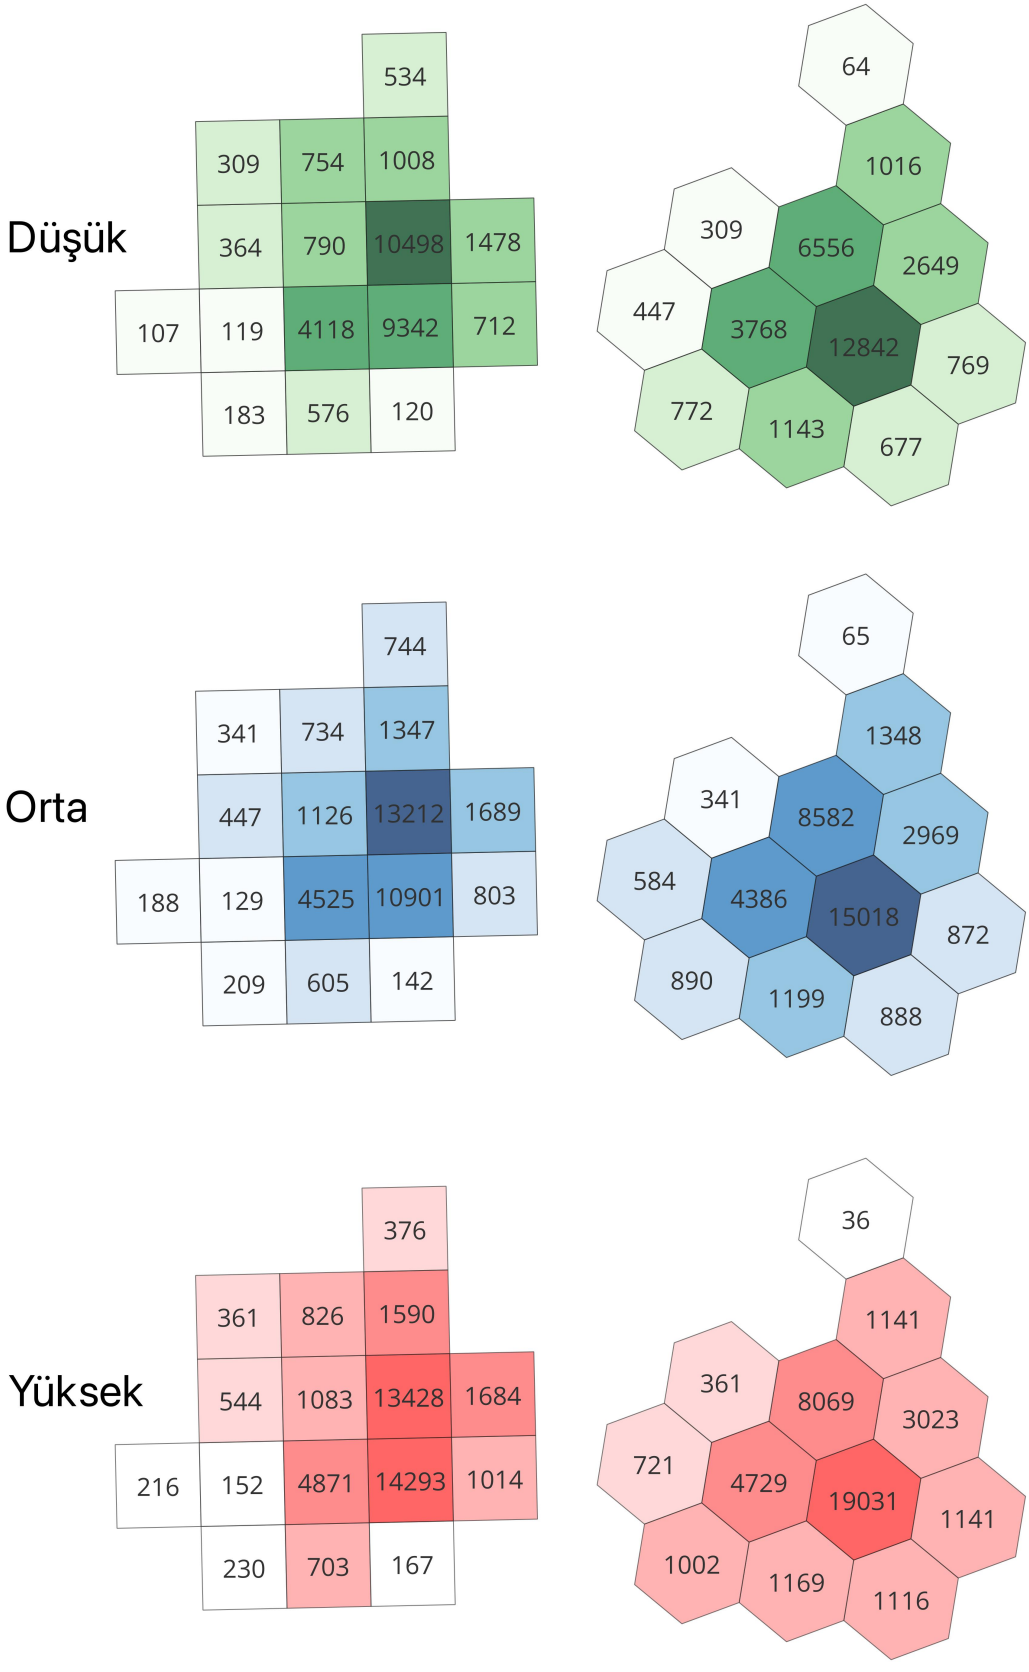

Şekil 4.7 Test haftaları için hücrelerdeki yaya sayımları.

Her hücre için elde edilen yaya sayıları, *N-Adım Akış* (N-Step Flow) modeli ile komşu hücrelere paylaştırılmış ve hücreler arasındaki akışlar sentetik olarak üretilmiştir. Oluşturulan akış haritaları, yaya hareketlerinin mekansal yoğunluğunu ve yönünü görselleştirmek amacıyla çizilmiştir. Bu haritalarda akış hacmi; çizgi kalınlığı ve renk tonuyla kodlanmış, yüksek akışlar kalın çizgi ve koyu tonla, düşük akışlar ise ince çizgi ve açık tonla vurgulanmıştır (Şekil 4.8 ve Şekil 4.9).

Kare ve altıgen hücrelerden oluşan çalışma bölgesinde, hücre sayısına göre beklenen toplam akış sayısı sırasıyla 240 ve 132 olarak hesaplanmıştır (Eşitlik 4.1). *N-Adım Akış* modeli, her iki mozaikleme türü için de dört adımda beklenen akış sayısına ulaşmıştır. Üç temsili haftanın kare mozaiklemeye göre üretilen yaya akış haritaları Şekil 4.8'da, altıgen mozaiklemeye göre üretilenler ise Şekil 4.9'de gösterilmektedir.

Kare yapıda birinci adım sonunda beklenen 240 akışın 82'si, ikinci adım sonunda 178'i, üçüncü ve dördüncü adımların sonunda sırasıyla 230 ve 240'ı elde edilmiştir. Kare yapıya göre oransal dağılımlar sırasıyla %34, %74, %95 ve %100'dür.

Altıgen yapıda ise birinci adım sonunda 132 akışın 44'ü, ikinci adımda 92'si, üçüncü ve dördüncü adımlarda sırasıyla 123 ve 132'si gerçekleştirilmiştir. Altıgen yapının oransal dağılımları ise %33, %70, %93 ve %100'dür.

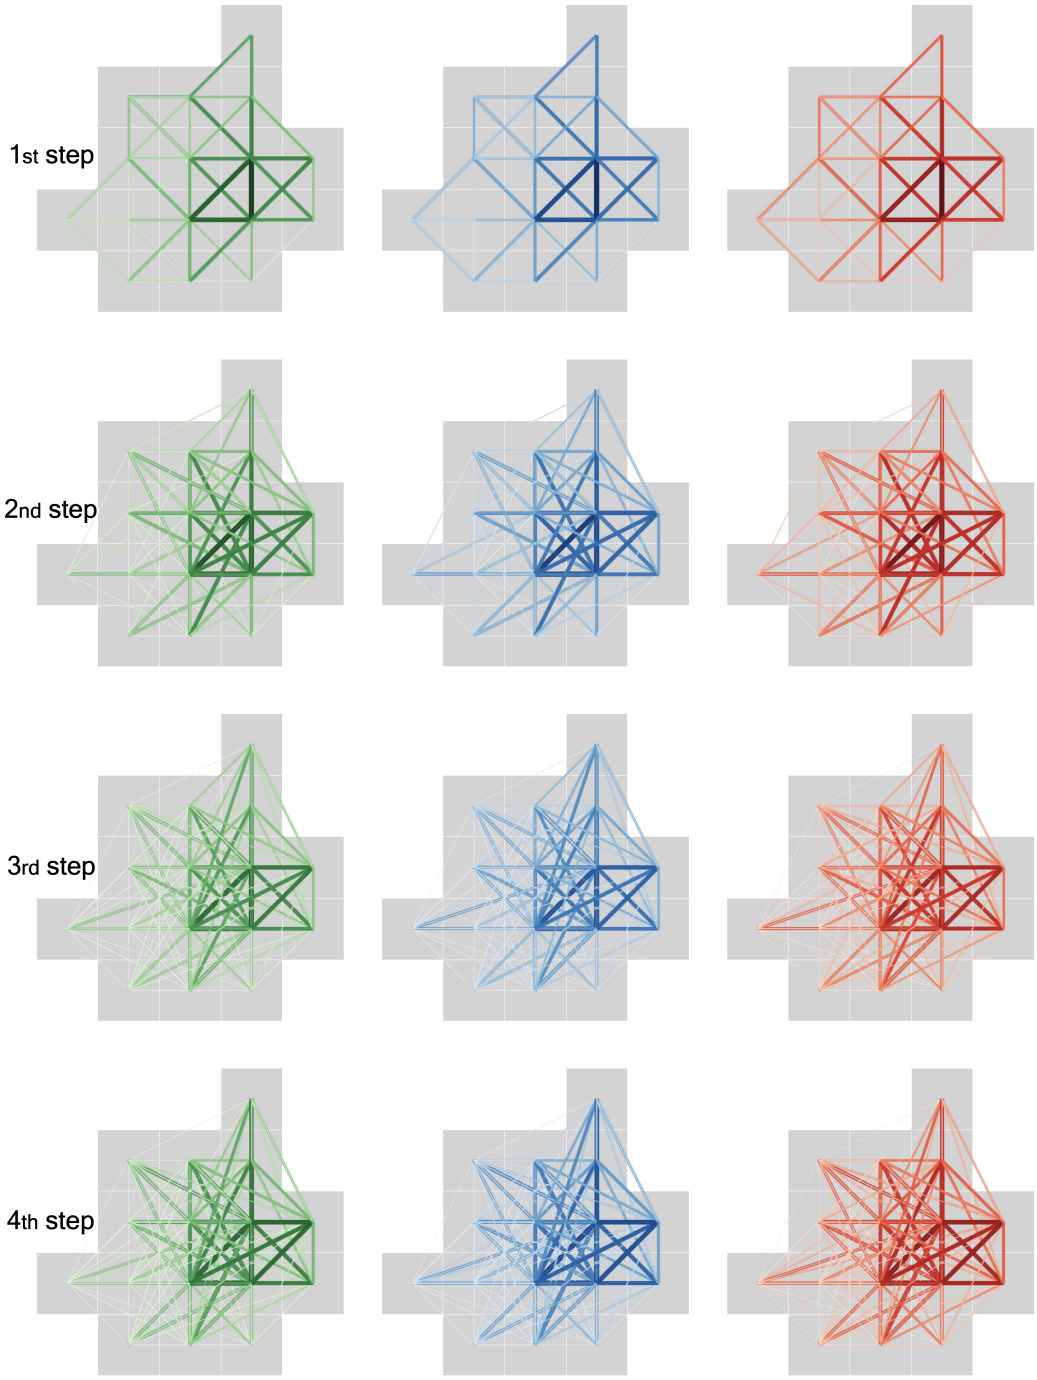

Şekil 4.8 Karesel yapı için adım adım akış haritaları.

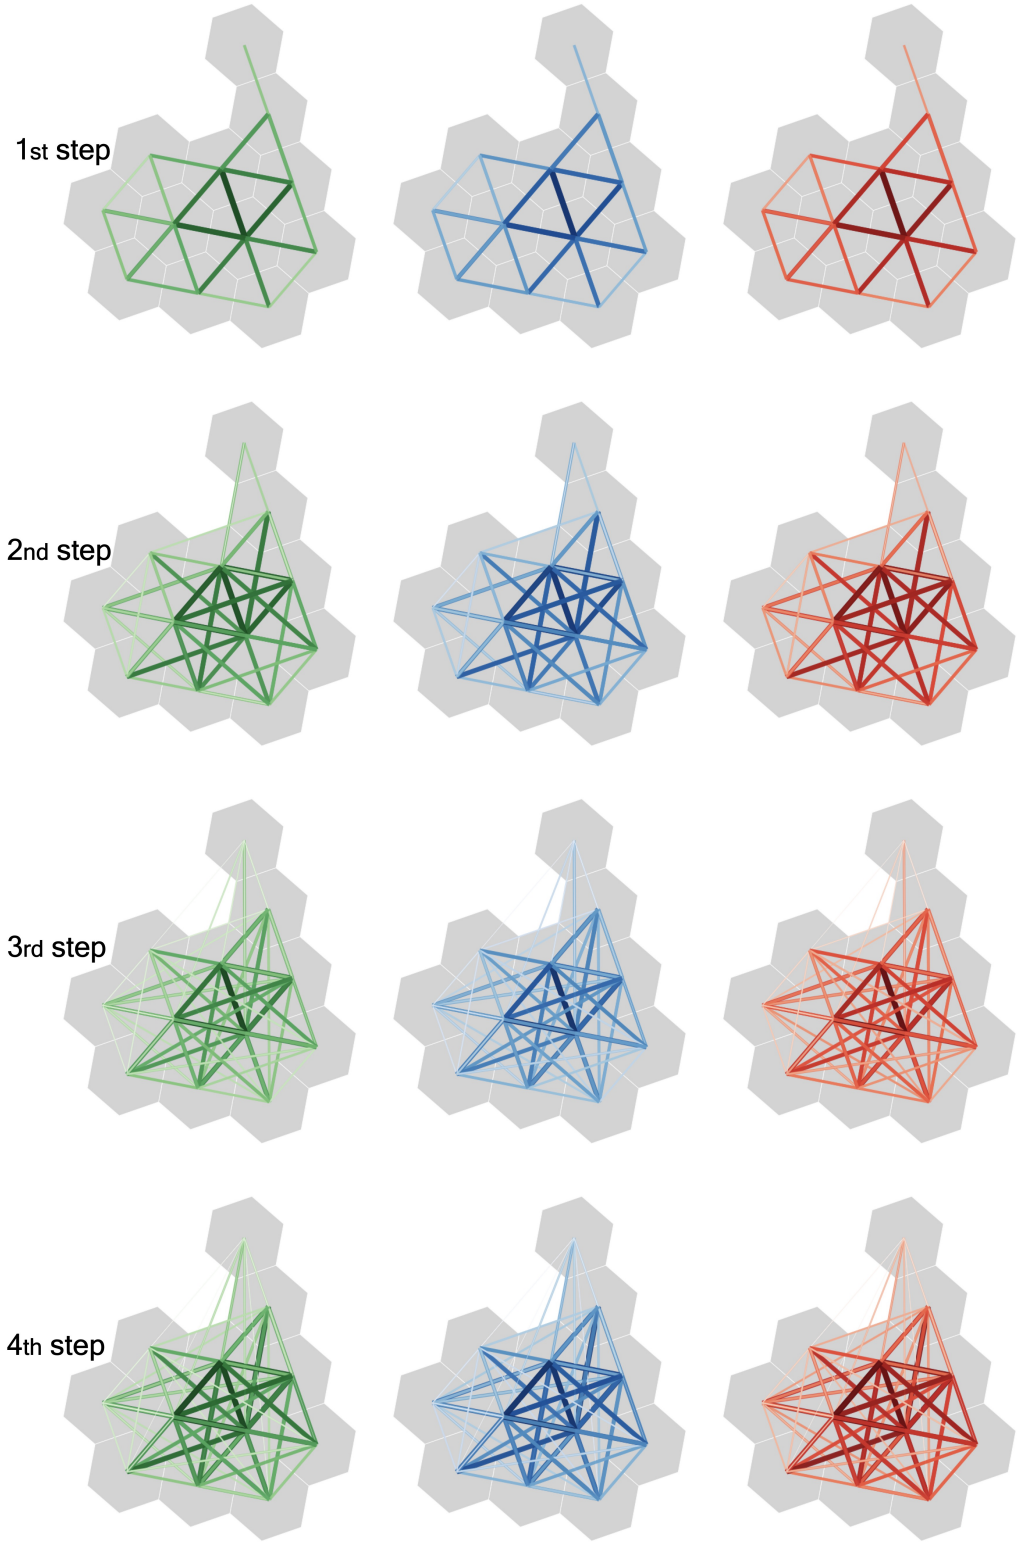

Şekil 4.9 Altıgen yapı için adım adım akış haritaları.

Bu çalışmada önerilen N-Adım Akış modeline benzer bir görevi yerine getiren en önemli yaklaşım, yaya sayımlarından sentetik akışlar üretebilen yerçekimi modelidir. Yerçekimi modelinde iki hücre arasındaki akış, her iki hücredeki

yaya sayısıyla orantılı; aralarındaki mesafe ile ters orantılı olarak hesaplanır. Bu sayede yoğun nüfuslu ve birbirine yakın hücreler arasında akış yüksek, seyrek nüfuslu ve uzak hücreler arasında akış düşük olur. Melbourne'deki kare ve altıgen mozaikleme yapıları için yerçekimi modelinin üç haftalık akış haritaları Şekil 4.10'de sunulmaktadır. Yerçekimi modeli, Python 3.11 ortamında `scikit-mobility` kütüphanesinin ilgili modülleri kullanılarak uygulanmıştır.

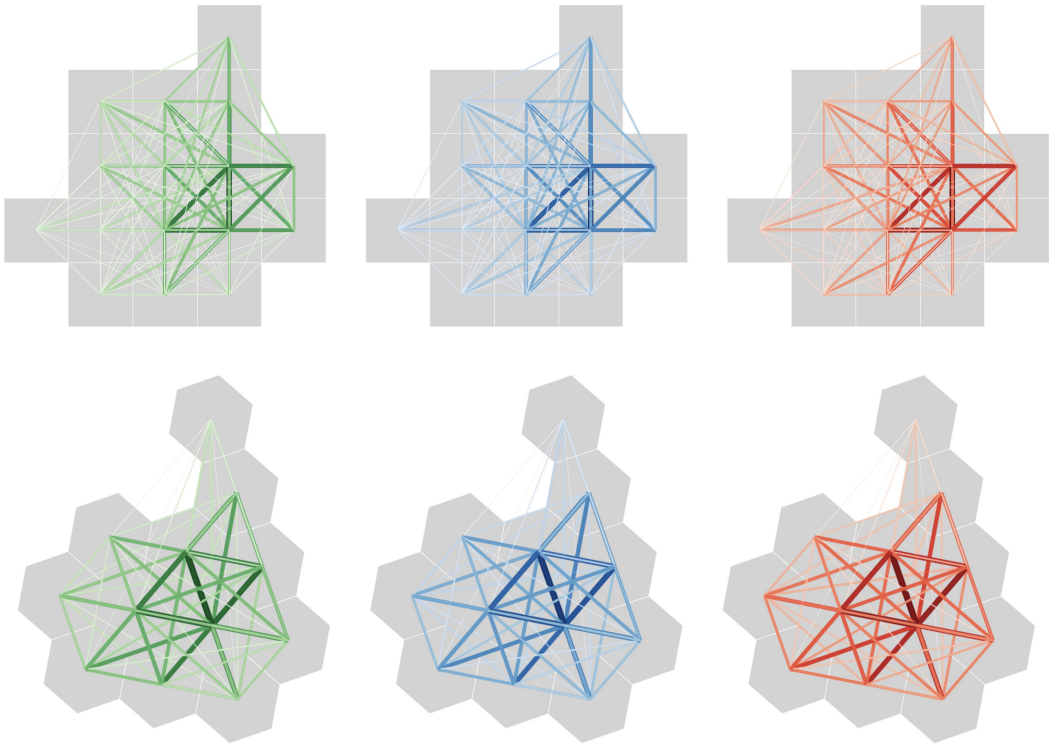

Şekil 4.10 Kare ve altıgen mozaikler üzerindeki yerçekimi akışları.

Önerilen N-Adım Akış modeli ile yer çekimi modeli arasındaki benzerlik ve farklılıklar, Common Part of Commuters (CPC) ölçüsüyle analiz edilmiştir. CPC metriği 0 ile 1 arasında değer alır; 1 mükemmel örtüşme, 0 ise akışlar arasında ilişkisizlik anlamına gelir. Bu çalışmada, N-Adım Akış modelinin her adım sonuçları ayrı ayrı çekim modeli ile karşılaştırılmıştır (Şekil 4.11).

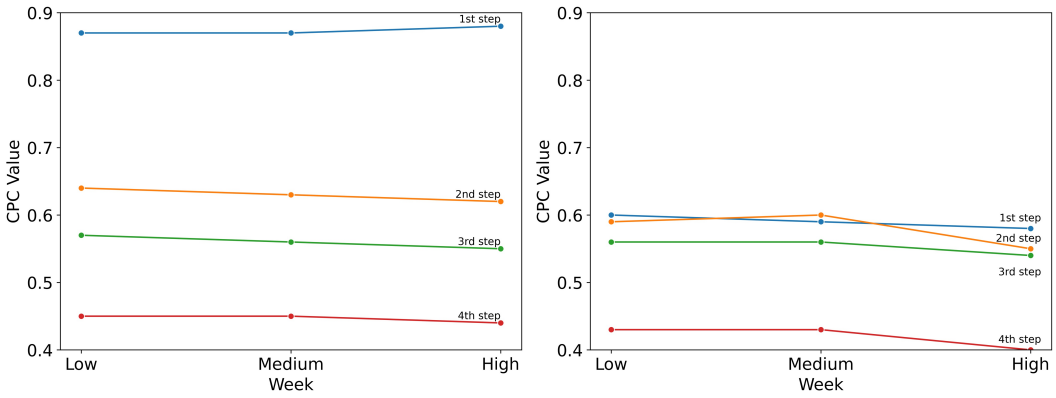

Şekil 4.11 Kare mozaik (sol) ve altıgen (sağ) için Düşük, Orta ve Yüksek Haftalara ait CPC Değerlerindeki Değişimler.

Kare yapıda modelin birinci adım sonuçları çekim modeliyle oldukça yakın iken, benzerlik değerleri adım sayısı arttıkça kademeli olarak azalmış; son adımda ilk adıma göre yaklaşık %50 düşüş gözlenmiştir. Altıgen yapıda ilk üç adımda yüksek benzerlik sürerken, dördüncü adımda benzerlik önemli ölçüde azalmıştır. Ayrıca, haftalar arası benzerlik örüntülerini görselleştirmek üzere kare ve altıgen yapılar için 12 adet saçılım grafiği (scatter plot) oluşturulmuştur (Şekil 4.12 ve Şekil 4.13).

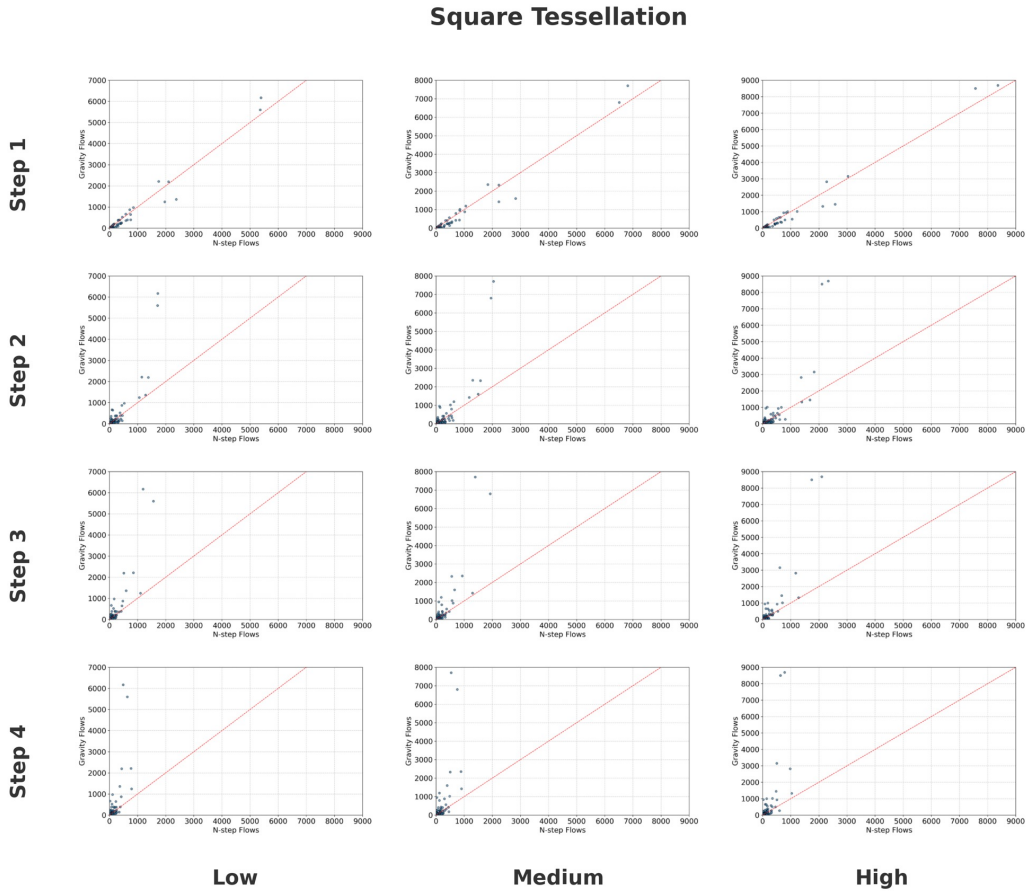

Şekil 4.12 Düşük, orta ve yüksek haftalara ait kare mozaiklerin dağılım grafikleri.

Bu grafikler, N-Adım Akış algoritmasının her adımında oluşturulan akış yoğunluklarını çekim modelinin tahminleriyle karşılaştırır. Şekil 4.13'de kare yapıda "Adım 1"den "Adım 4"e kadar, Şekil 4.13'te ise altıgen yapıda aynı adımlar altında "Düşük", "Orta" ve "Yüksek" haftalara ait dağılımlar görülmektedir. Grafikte x eksenindeki N-Adım Akış modelinden, y eksenindeki ise yer çekimi modelinden elde edilen akış hacimleri okunur; kırmızı çizgi ise ideal 1:1 eşleşmeyi gösterir. Noktalar çizgiye ne kadar yakınsa, modeller arasındaki benzerlik o kadar yüksektir.

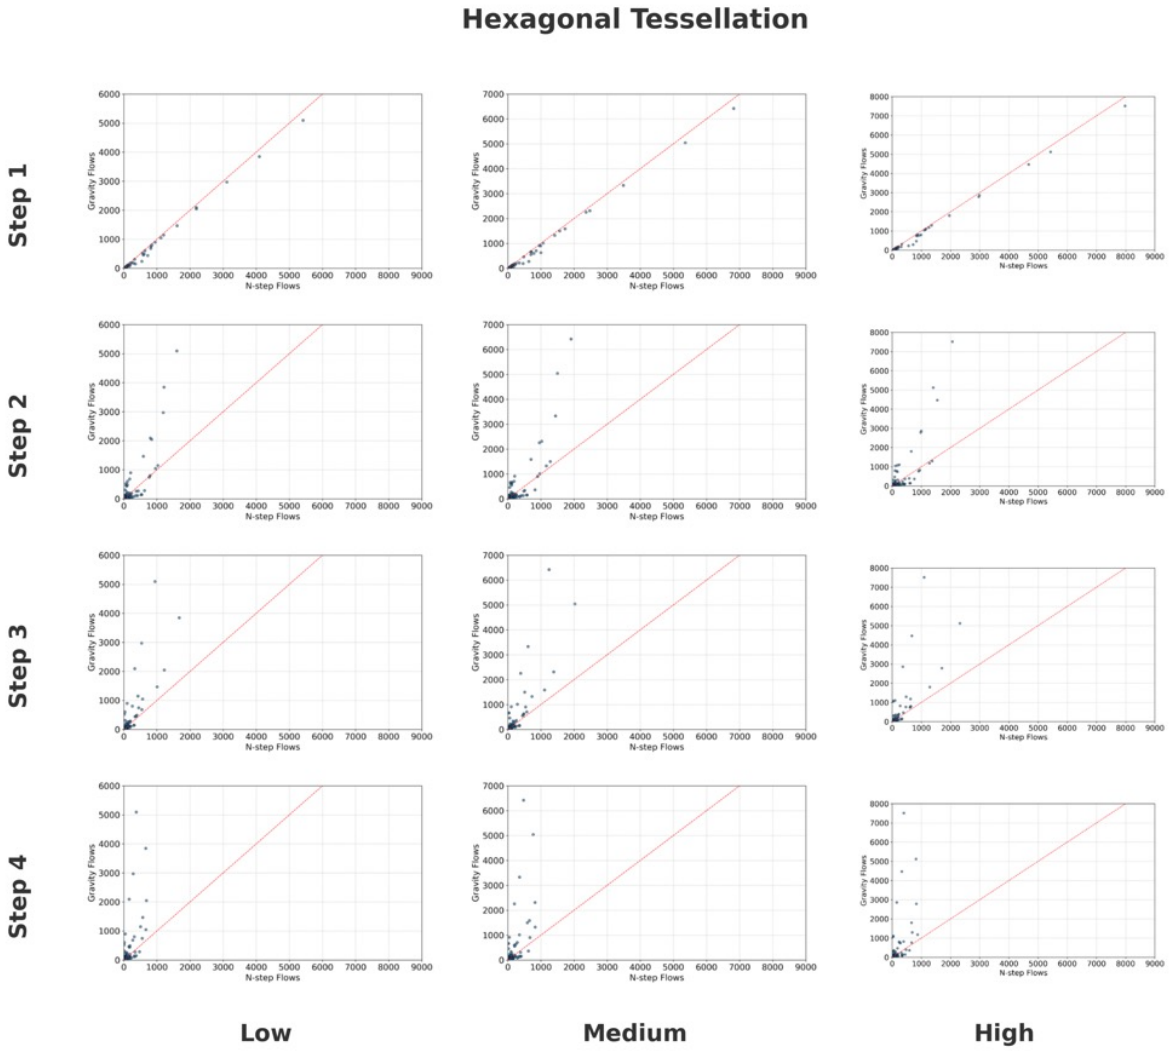

Şekil 4.13 Düşük, orta ve yüksek haftalara ait altıgen mozaiklemenin dağılım grafikleri.

4.7 Tartışma

Bu bölümde tanıtılan N-Step Akış modeli, sensör sayımı verilerinden sentetik yaya akışları üretmek üzere geliştirilen yeni bir yaklaşımdır. Başlangıçta hidrolojik analizlerde kullanılan D8 algoritmasından esinlenilerek tasarlanan bu model, yaya

akışlarını tek bir komşuya yönlendirmek yerine, çevredeki tüm komşulara orantılı olarak dağıtır. Model, ilk olarak birinci dereceden komşulara yapılan dağıtımı daha sonra onların komşularına aktararak devam ettirir. Son adımda, tüm yayaların hedef hücrelere ulaştığı bir yapı oluşur. Model, yayaların hareketini gerçekçi bir zaman penceresi içerisinde ele alarak sonsuz yayılımı engeller. Böylece, kentsel hareketliliğin gerçekçi sınırlamalarıyla uyumlu olur. Ayrıca, model tüm adımlar boyunca başlangıç yoğunluğunu sabit tutar. Bu durum, hesaplama tutarlılığı sağlarken, yeniden dağıtım sürecinde ortaya çıkabilecek dinamik etkileşimleri (örneğin sıkışıklık etkisi) dışarıda bırakır. Modelin değerlendirilmesindeki en büyük sınırlama, oluşturulan yaya akışlarının gerçek verilere doğrudan karşılaştırılamamasıdır. Bu nedenle, doğruluk yerine yerçekimi modeli ile göreli karşılaştırmalar yapılmıştır. Yerçekimi modeli nüfus ve mesafeye dayalı öngörülerde bulunurken, N-Adım akış modeli, geçişler arası adımları hesaba katar. Özellikle şehir içi yol ağları, fiziksel engeller (nehirler, otobanlar) ve yaya tercihleri düşünüldüğünde bu fark önem kazanmaktadır.

Bu durum Şekil 4.14'de kentsel bir senaryo üzerinden görselleştirilmiştir. N-Adım akış modeli (kırmızı kesikli oklar), yayanın A noktasından B noktasına giderken aradaki nehir engelini geçmek için köprü işlevi gören bir düğümden geçmesini varsayar. Oysa yerçekimi modeli, yalnızca mesafe ve nüfus büyüklüğüne dayalı doğrudan bir akış önerir.

Üç farklı zaman periyodunda ve iki mozaikleme yapısında yapılan CPC analizleri, benzerliğin ilk adımlarda yüksek, son adımlarda ise %40 civarına düştüğünü ortaya koymuştur. Bu, modelin yalnızca yer çekimi tahminlerini taklit etmediğini, kendi özgün dinamiklerini ürettiğini gösterir. N-Step Akış modeli, basitliği ve hesaplama verimliliğinin yanı sıra, kentsel hareketliliği adım adım izleyebilme kapasitesiyle yer çekimi ve radyasyon modellerine kıyasla daha ayrıntılı bir analiz aracı sunmaktadır. Yüksek yoğunluklu alanlarda altyapı planlaması, yaya ağı optimizasyonu ve yürüme yollarının iyileştirilmesi gibi amaçlarla karar destek aracı olarak kullanılabilir. Makro ölçekte yaya dinamiklerini incelemek için pratik bir çerçeve sağlar. Modelin gelecekte farklı şehirlerde, farklı zaman periyotlarında ve alternatif mekansal çözünürlüklerde test edilmesi; ayrıca dinamik etkileri içerecek şekilde genişletilmesi önerilmektedir. Bunun yanı sıra, yalnızca kare ve altıgen yapılarda değil, graf tabanlı mekansal ağlar üzerinde de uygulanabilirliği mümkündür.

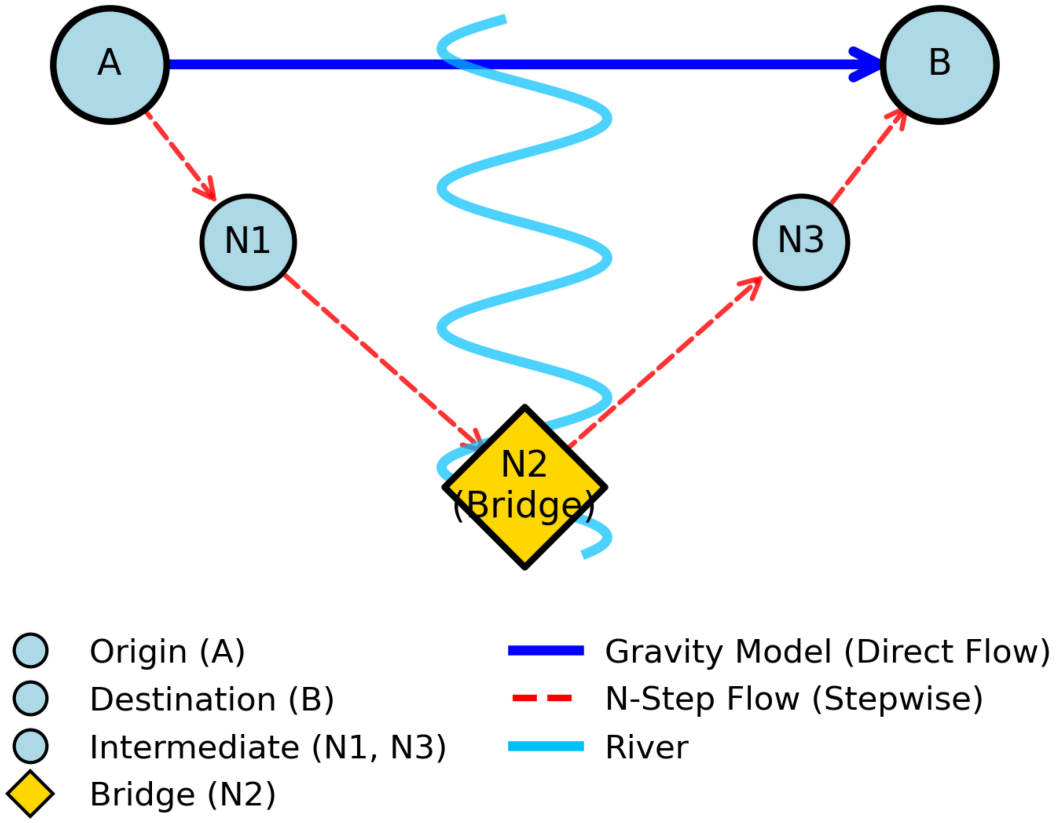

Şekil 4.14 Modellerin pratik kullanım durumunda kıyaslaması.

5
SONUÇ

Bu tez, dijital ayak izleriyle sensör tabanlı yaya sayım verisini bütünleştirerek kentsel yaya ulaşım talebini ve akışını modellemek için yeni bir model geliştirmiştir. Geliştirilen N-Adım Akış Modeli, tek adımlı parametrik yaklaşımlara kıyasla daha ayrıntılı hareket akışları üreterek, özellikle yoğun akış koridorlarının ve darboğazların belirlenmesinde anlamlı bir model sağlamıştır. Yaya yoğunluğu ile hane sayısının talebi belirleyen değişkenler olduğunu ortaya koyan bulgular, mikro ölçekli kent müdahalelerinin hangi sokaklarda önceliklendirilmesi gerektiğini somut biçimde işaret etmektedir. Model çıktıları, karar vericilerin harita tabanlı bir pano üzerinden anlık senaryo analizi yapmasına imkan tanıyarak, veri temelli yaya planlaması için uygulanabilir bir yol haritası sunmaktadır. Böylece tez, akademik literatüre yeni bir akış modelleme yaklaşımı kazandırırken kent yöneticileri için de eyleme geçirilebilir bir karar destek aracı ortaya koymaktadır.

İnternet üzerinden elde edilen konumla bağlantılı dijital ayak izleri ve coğrafi analizlere temel oluşturan konuma ait geometrik, topolojik ve semantik veriler arasında kurulan tahmin modeli, semantik dokuların geometrik ve topolojik özelliklere göre daha etkili olduğunu göstermiştir. Sensörler aracılığıyla toplanan yaya sayıları üzerinden hesaplanan yaya yoğunluğu ve hane sayısı gibi EDO konumlarıyla ilişkilendirilen sayısal bilgiler, tahmin modeli üzerinde etkili olan temel semantik verilerdir. Yaya yoğunluğunu açıklayan bu özellikler EDO mekanlarının insanlar tarafından tercih edilme durumunu ortaya koyar. Aynı zamanda EDO türü tahmin modellerinin başarısında yaya yoğunluğu özelliklerinden daha düşük olsa da önemli bir etkiye sahiptir. Diğer taraftan, OSM yol ağı sınıfları yaya erişimi üzerinde etkili bir parametre olmasına karşın tahmin modelleri üzerindeki etkisi düşüktür. Aynı yol ağından çıkarılan mekansal erişilebilirlik göstergeleri gibi topolojik özellikler ise EDO mekanlarının ortalama beğeni puanlarını kestirmede daha etkilidir. Bu durum merkezi ve kolay erişilebilir yerlerde hizmet veren EDO mekanlarının insanların bireysel tercihlerine yön verdiğini göstermektedir. EDO mekanlarının geometrik özellikleri tahmin

modellerine eklendiğinde başarı olumlu yönde etkilenmektedir. Mesafe analiz parametreleri olarak modellere dahil edilen geometrik özellikler, insanların yakın çevresiyle daha fazla etkileşimli olduğunu ortaya koymaktadır.

Coğrafi bölgede etkileşime neden olan mekanların yukarıda bahsedilen temel özellikleri topluluk hareketliliği üzerinde etkilidir. Fakat topluluğunu oluşturan bireylerin hareket yönlerinin belirlenmesinde bu özelliklerin farklı bir bakış açısıyla modellenmesi gerekir. EDO mekanları üzerine gerçekleştirilen çalışmada öne çıkan, topluluk hareketliliği ile bağlantılı en etkin parametreler yaya yoğunluğu ve hane sayısıdır. Bu kapsamda yaya hareket yönlerinin oluşturulması için geliştirilen N-adımlı akış modelinin temel veri kaynağı sensörlerden elde edilen yaya sayıları olarak seçilmiştir. Melbourne yaya sayım sensörlerinin konumlarıyla ilişkili olarak mozaiklenen çalışma bölgesinde, her bir hücre arasındaki yaya hareketleri N-adımlı akış modeli kullanılarak OD matris yapısında sunulmuştur. N-Adım Akış Modelinin çok adımlı yayılım stratejisi hareketlilik akışlarını oldukça gerçekçi bir şekilde modellemektedir. Her bir hücredeki yayaların komşularına adım sistematiğiyle ve onların yaya sayılarıyla orantılı şekilde dağıtılması böylece yolculukların zincirler halinde simüle edilmesi modelin en güçlü tarafıdır. Ayrıca, modelin etkileşimi yakından uzağa doğru yayması sayesinde uygulama bölgesinde dört adım sonunda beklenen tüm OD bağlantıları üretilmiş olur. Model sayesinde yüksek akış olan hücrelerdeki yollar ve kaldırımlar belirlenebilir ve kritik noktalara çeşitli yol aksesuarları yerleştirilerek mikro-ölçekte sokak iyileştirmeleri yapılabilir. Bu kapsamda, yöneticilere yalnızca kalabalık alanların kapasitesini artırma değil, aynı zamanda erişimi kısıtlı koridorlarda hizmet kalitesini iyileştirme gereğini de göstermektedir. Modelin işaret ettiği köprüler, yaya geçitleri ve kamusal meydanlar gibi ara geçiş düğümlerinde yapılacak tasarım geliştirmeleri ile yol ağı yapısı iyileştirilerek yaya memnuniyeti arttırılabilir. Büyük ölçekli etkinlik kapanışları gibi sıra dışı senaryolar için çalıştırılan model üzerinden yaya hareketliliği ve tahliye süreleri gerçekçi biçimde planlanabilir ve acil durum planlarının doğruluğu güçlendirilebilir. Geliştirilen N-adımlı akış modelinin temel girdisi olan yaya sayım verileri yerine farklı amaçlar için türetilmiş başka veriler modele entegre edilebilir. Modelin veriye duyarlı esnek yapısı sayesinde yaya akışının dışında kentsel bölgelere ilişkin farklı akış senaryoları oluşturulabilir.

Bu tez çalışmasının sonuçları kapsamlı bir şekilde değerlendirildiğinde, yaya yoğunluğu, mekansal erişilebilirlik, dijital ayak izi ve çok adımlı akış simülasyonlarının kent içi yaya hareketliliği ve tüketici etkileşimlerini açıklamada birlikte yol gösterici olduğunu ortaya koyarak kentsel alanlarda yaya hareketlerinin yönetimi için yol gösterir. Veriye dayalı modelleme ve etkin yönetim arasındaki bağlantı şu adımlar üzerinden somutlaşmaktadır. Öncelikle, kapsamlı sensör

sayımları ve dijital ayak izi verileri, kentsel alanlardaki yaya hareketlerinin nerede, ne zaman ve hangi yoğunlukta gerçekleştiğini ayrıntılı biçimde ortaya koyar. Ardından, bu veriler rastgele orman sınıflandırması ile N-Adım akış simülasyonları gibi ileri analitik yöntemlerle işlenerek, hem talep yoğunluk noktaları hem de yaya akış koridorları nesnel ölçütlerle belirlenir. Son olarak, elde edilen tahminlere göre; dar boğazların tespiti, altyapı kapasitesinin planlanması, kaldırım ve aydınlatma gibi mikro ölçekli iyileştirmelerin yönlendirilmesi ile acil tahliye senaryolarının senaryo temelli analizine dayalı somut karar destek malzemesi sağlar. Bu akış —"veri toplama $\rightarrow$ modelleme $\rightarrow$ politika tasarımı $\rightarrow$ uygulama"— karar vericilerin müdahalelerini öngörüye dayalı, hızlı ve hedef odaklı kılarken, kentsel yaya altyapısının verimliliğini ve kullanıcı memnuniyetini birlikte yükseltir.

Tezde geliştirilen yöntem ve bulgular, yalnızca kentsel planlama disiplinine değil, çok sayıda mesleki alana doğrudan katkı sağlar. Ulaşım mühendisleri ve trafik operatörleri model çıktılarından yararlanarak kavşak düzenlemelerini, yaya–araç etkileşim noktalarını ve toplu taşıma durak konumlarını optimize edebilir. Afet ve acil durum yöneticileri, senaryo temelli N-Adım akış modelini kullanıp tahliye sürelerini öngörebilir, kalabalık yönetimi planlarını test edebilir. Perakende konum analistleri ile gayrimenkul geliştirme uzmanları, yaya yoğunluğu ve talep sıcak noktalarını okuyarak mağaza yeri veya kiralama stratejilerini veri temelli kurgulayabilir. Kamu sağlığı ekipleri, nüfus hareketliliğine dayalı bulaş riski tahminlerini hassaslaştırmak için modelin ürettiği OD matrislerini giriş verisi olarak kullanabilir. Turizm planlamacıları ve kültürel etkinlik organizatörleri yüksek akış koridorlarını göz önünde bulundurarak yaya yönlendirme, bilgi panosu ve hizmet noktasını doğru yerlere konumlayabilir. Son olarak akıllı kent yazılım geliştiricileri ve CBS analistleri, sensör verisi ile dijital ayak izini bir arayüzde birleştiren bu çerçeveyi doğrudan karar-destek modüllerine entegre edebilir. Bu çok yönlü uygulanabilirlik, tezi kuramsal ve pratik açıdan yüksek katma değerli olduğunu göstermektedir.

Uygulamaya yönelik çıkarımlar doğrultusunda, yüksek konut yoğunluğuna rağmen erişilebilirliği zayıf bölgelerde kaldırım genişletme ve aydınlatma yatırımlarının önceliklendirilmesi, yaya odaklı altyapının güçlendirilmesine katkı sağlayacaktır. Google Maps benzeri açık platformlardan elde edilen dijital izler mahalle ölçeğinde canlılık göstergesi olarak kullanılabilir. Düşük puan veya yorum yoğunluğu sergileyen odak alanlar kentsel tasarım iyileştirmeleri için hedeflenebilir. Bu çalışmanın çıktıları, göç hareketlerinin tahmin edilmesinde ve ulaşım planlamasında da kullanılabilir.

Bu çalışmanın başlıca sınırlılığı gerçek OD matrislerinin yokluğu olmakla birlikte,

gelecekte telekom verileriyle bu eksiklerin giderilmesi mümkün olabilir.Gerçek OD matrislerinin yokluğunu gidermek amacıyla, öncelikle telekom operatörleriyle yapılacak veri paylaşım protokolleri sayesinde anonimleştirilmiş sinyal izleri temin edilebilir. Bu veriler, sensör sayımlarıyla senkronize edilerek hareket akışlarının dinamik güncellenmesine olanak tanır. Ayrıca, metro turnike geçişleri ve toplu taşıma kart basımlarından elde edilecek yolculuk kayıtlarıyla çapraz doğrulama yapılması önerilir. Kamera tabanlı sayım sistemleri ve Wi-Fi/Bluetooth tarayıcıları da, veri yoğunluğunu artırmak için düşük maliyetli tamamlayıcı kaynaklar sunabilir. Verinin hala az olduğu noktalarda sentetik örnekleme (data augmentation) ve transfer öğrenme yaklaşımlarının kullanılmasıyla, az sayıda etiketli akışlar ile model parametrik bir modele dönüştürülebilir.

Bu çerçevede kent yöneticileri, sunulan çok-verili ve çok-düzeyli modelleri stratejik altyapı yatırımları ve anlık akış yönlendirme kararlarında rehber olarak kullanabilir. Akademik ve pratik planda sürdürülebilir, esnek ve kanıta dayalı bir yaya yönetimi yaklaşımı benimseyebilirler. Ayrıca dijitalleşmenin en üst seviyelerde olduğu bu zamanlarda kentsel yaya hareketliliğini anlamak için disiplinler arası veri birleşimi ve yenilikçi akış modellemesinin birlikte kullanılmasının avantajları fazladır. Tezde sunulan yöntemler, kentsel politika yapıcıları için güçlü bir karar destek temeli sağlamaktadır. Gelecekte yürütülecek çalışmalar açısından, araştırma programının öncelikle gerçek zamanlı verilere yönelmesi önerilmektedir. Böylece modelin akışlarının adım sayısı veya ağırlık fonksiyonunun yoğunluk artışlarına göre dinamik biçimde ayarlanması sağlanabilir. Benzer şekilde, telekom kayıtları gibi farklı kaynaklardan türetilecek gerçek OD matrislerinin kullanılması, model doğrulamasını çok-kaynaklı bir temele oturtacaktır. Derin öğrenme yaklaşımlarının entegrasyonu da bir diğer araştırma konusudur. Özellikle grafik sinir ağlarıyla N-Adım algoritmasındaki yeniden dağıtım katsayılarının veri-güdümlü olarak öğrenilmesi, yeni modellerin geliştirilmesine olanak sağlayacaktır. Modelin genellenebilirliğini sınamak amacıyla, farklı morfolojiye ve veri yoğunluğuna sahip kentlerde çapraz uygulamalar yapılması önem taşımaktadır. Ayrıca model, "ya sokak araç trafiğine kapatılırsa, yeni bir köprü eklenirse ya da büyük bir etkinlik düzenlenirse ne olur?" sorularını simülasyonla yanıtlayarak yöneticilerin bu tür müdahalelerin olası etkilerini önceden görmesine olanak tanır; böylece karar verme sürecindeki destek gücünü önemli ölçüde artırır.

Melbourne verisiyle geliştirilen yaklaşım, veri kaynakları ve ölçek uyarlaması doğru yapıldığında Türkiye'deki büyük ve orta ölçekli kentlere somut fayda sağlayabilir. İstanbul, Ankara ve İzmir'de halihazırda İBB Cep Trafik, EGO CEP, İzmirKart gibi akıllı ulaşım altyapıları üzerinden toplanan turnike ve sensör verileri, modelin N-Adım akış bileşenine ham veri sağlayacak niteliktedir. Ayrıca,

Çevre Şehircilik ve İklim Değişikliği Bakanlığı'nın CBS Portalı ile belediyelerin açık veri kataloglarındaki nüfus-yoğunluk ızgaraları, hane sayısı katmanları ve OSM tabanlı yol ağları, dijital ayak izi verileriyle entegre edilebilir. Böyle bir entegrasyon; tarihi merkezlerde (Kapalıçarşı, Kaleiçi, Kemeraltı) yaya akışının dar sokaklardan ana koridorlara yönlendirilmesi, turistik sahil kentlerinde sezonluk talep artışının senaryo-temelli yönetimi, deprem toplanma alanlarının erişilebilirlik ve tahliye sürelerinin gerçeğe yakın simülasyonu gibi kritik uygulamalarda karar vericilere veriye dayalı önlem alma imkanı sunar. Modelin sensör verisi yerine toplu taşıma biletleme veya GSM hareket verisiyle beslenmesi de olasıdır. Böylece ülkemizde henüz yaygın olmayan yaya sensör altyapısı kısıtı aşılır ve yöntemin uygulanabilirliği genişler. Bu bakış açısıyla tez, ülkemizdeki kentlerin yaya odaklı ulaşım, afet yönetimi ve kamusal mekan iyileştirme çalışmalarına doğrudan aktarılabilecek esnek bir analitik çerçeve sunmaktadır.

Bu tez, kentlerin nabzını tutan yeni bir dil sunmaktadır. İnsan akışları artık tuğlalar kadar kentsel planlamanın temel bileşenidir. Geliştirdiğimiz model, bu bileşenleri sağlam ve görünür bir çerçeveye oturtarak akademik ve pratik anlamda katkı sağlamaktadır.

KAYNAKÇA

[1] World Health Organization, *WHO Manifesto: Build healthy, liveable cities*, https://www.who.int/teams/environment-climate-change-and-health/climate-change-and-health/advocacy-partnerships/manifesto/cities, Son erişim 2 Şubat 2025, World Health Organization, 2021.

[2] J.-P. Rodrigue, *The geography of transport systems*. Routledge, 2020.

[3] M. Gharib, C. Roh F. Noca, "Leonardo da Vinci's Visualization of Gravity as a Form of Acceleration," *Leonardo*, c. 56, no. 1, ss. 28–35, 2023. doi: 10.1162/leon_a_02322.

[4] I. Newton, *Philosophiae naturalis principia mathematica*. G. Brookman, 1833, c. 1.

[5] J. Gehl, *Cities for people*. Island press, 2013.

[6] D. Harney, "Pedestrian modelling: current methods and future directions," *Road & Transport Research*, c. 11, no. 4, s. 38, 2002.

[7] M. S. Daskin, *Urban transportation networks: Equilibrium analysis with mathematical programming methods*, 1985.

[8] T. Aoki, S. Fujishima N. Fujiwara, "Urban spatial structures from human flow by Hodge–Kodaira decomposition," *Scientific reports*, c. 12, no. 1, s. 11 258, 2022.

[9] J. de Dios Ortúzar L. G. Willumsen, *Modelling transport*. John wiley & sons, 2024.

[10] N. S. Dhakar S. Srinivasan, "Route choice modeling using GPS-based travel surveys," *Transportation Research Record*, c. 2413, no. 1, ss. 65–73, 2014.

[11] Q. Ge D. Fukuda, "Updating origin–destination matrices with aggregated data of GPS traces," *Transportation Research Part C: Emerging Technologies*, c. 69, ss. 291–312, 2016.

[12] P. Krishnakumari, H. Van Lint, T. Djukic O. Cats, "A data driven method for OD matrix estimation," *Transportation Research Part C: Emerging Technologies*, c. 113, ss. 38–56, 2020.

[13] M. L. Hazelton, "Statistical inference for time varying origin–destination matrices," *Transportation Research Part B: Methodological*, c. 42, no. 6, ss. 542–552, 2008.

[14] G. E. Sánchez-Martínez, "Inference of public transportation trip destinations by using fare transaction and vehicle location data: Dynamic programming approach," *Transportation Research Record*, c. 2652, no. 1, ss. 1–7, 2017.

[15] M. Rostami Nasab Y. Shafahi, "Estimation of origin–destination matrices using link counts and partial path data," *Transportation*, c. 47, no. 6, ss. 2923–2950, 2020.

[16] M. C. Gonzalez, C. A. Hidalgo A.-L. Barabasi, "Understanding individual human mobility patterns," *nature*, c. 453, no. 7196, ss. 779–782, 2008.

[17] J. Ren Q. Xie, "Efficient od trip matrix prediction based on tensor decomposition," *2017 18th IEEE International Conference on Mobile Data Management (MDM)*, IEEE, 2017, ss. 180–185.

[18] C. Jin, A. Nara, J.-A. Yang M.-H. Tsou, "Similarity measurement on human mobility data with spatially weighted structural similarity index (SpSSIM)," *Transactions in GIS*, c. 24, no. 1, ss. 104–122, 2020.

[19] I. Goodfellow ve diğ., "Generative adversarial nets," *Advances in neural information processing systems*, c. 27, 2014.

[20] L. B. Chi J. Wang, "Transit OD Generation Based on Information Technology," *Advanced Engineering Forum*, Trans Tech Publ, c. 5, 2012, ss. 50–55.

[21] J. Tang, F. Liu, Y. Wang H. Wang, "Uncovering urban human mobility from large scale taxi GPS data," *Physica A: Statistical Mechanics and its Applications*, c. 438, ss. 140–153, 2015.

[22] H. Barbosa ve diğ., "Human mobility: Models and applications," *Physics Reports*, c. 734, ss. 1–74, 2018.

[23] E. Graells-Garrido, D. Caro D. Parra, *Inferring modes of transportation using mobile phone data. EPJ Data Sci 7 (1): 49*, 2018.

[24] S. Cerqueira, E. Arsenio R. Henriques, "Inference of dynamic origin–destination matrices with trip and transfer status from individual smart card data," *European Transport Research Review*, c. 14, no. 1, s. 42, 2022.

[25] G. K. Zipf, "The P 1 P 2/D hypothesis: on the intercity movement of persons," *American sociological review*, c. 11, no. 6, ss. 677–686, 1946.

[26] A. J. Scott, "A theoretical model of pedestrian flow," *Socio-Economic Planning Sciences*, c. 8, no. 6, ss. 317–322, 1974.

[27] G. S. Rutherford, "Use of the gravity model for pedestrian travel distribution," *Transportation research record*, c. 728, ss. 53–59, 1979.

[28] T. Tsekeris A. Stathopoulos, "Gravity models for dynamic transport planning: Development and implementation in urban networks," *Journal of Transport Geography*, c. 14, no. 2, ss. 152–160, 2006.

[29] Y. Luan J. Tang, "An improved gravity model for passenger flow distribution prediction of new urban rail transit lines," *2020 5th International Conference on Electromechanical Control Technology and Transportation (ICECTT)*, IEEE, 2020, ss. 487–491.

[30] D. Balcan, V. Colizza, B. Gonçalves, H. Hu, J. J. Ramasco A. Vespignani, "Multiscale mobility networks and the spatial spreading of infectious diseases," *Proceedings of the national academy of sciences*, c. 106, no. 51, ss. 21 484–21 489, 2009.

[31] J. E. Anderson, “The gravity model,” *Annu. Rev. Econ.*, c. 3, no. 1, ss. 133–160, 2011.

[32] K. E. Haynes A. S. Fotheringham, “Gravity and spatial interaction models,” 2020.

[33] F. Simini, M. C. González, A. Maritan A.-L. Barabási, “A universal model for mobility and migration patterns,” *Nature*, c. 484, no. 7392, ss. 96–100, 2012.

[34] A. P. Masucci, J. Serras, A. Johansson M. Batty, “Gravity versus radiation models: On the importance of scale and heterogeneity in commuting flows,” *Physical Review E–Statistical, Nonlinear, and Soft Matter Physics*, c. 88, no. 2, s. 022 812, 2013.

[35] C. Kang, Y. Liu, D. Guo K. Qin, “A generalized radiation model for human mobility: spatial scale, searching direction and trip constraint,” *PloS one*, c. 10, no. 11, e0143500, 2015.

[36] L. Kluge J. Schewe, “Evaluation and extension of the radiation model for internal migration,” *Physical Review E*, c. 104, no. 5, s. 054 311, 2021.

[37] B. Hilton, A. P. Sood T. S. Evans, “Predictive limitations of spatial interaction models: a non-Gaussian analysis,” *Scientific reports*, c. 10, no. 1, s. 17 474, 2020.

[38] M. Luca, G. Barlacchi, B. Lepri L. Pappalardo, “Deep learning for human mobility: a survey on data and models,” *arXiv preprint arXiv:2012.02825*, 2020.

[39] E. Strubell, A. Ganesh A. McCallum, “Energy and policy considerations for modern deep learning research,” *Proceedings of the AAAI conference on artificial intelligence*, c. 34, 2020, ss. 13 693–13 696.

[40] B. D. Mittelstadt, P. Allo, M. Taddeo, S. Wachter L. Floridi, “The ethics of algorithms: Mapping the debate,” *Big Data & Society*, c. 3, no. 2, s. 2 053 951 716 679 679, 2016.

[41] C. Sun, A. Shrivastava, S. Singh A. Gupta, “Revisiting unreasonable effectiveness of data in deep learning era,” *Proceedings of the IEEE international conference on computer vision*, 2017, ss. 843–852.

[42] D. Helbing, “A fluid dynamic model for the movement of pedestrians,” *arXiv preprint cond-mat/9805213*, 1998.

[43] A. Schadschneider, A. Kirchner K. Nishinari, “CA approach to collective phenomena in pedestrian dynamics,” *International Conference on Cellular Automata*, Springer, 2002, ss. 239–248.

[44] D. Bauer, “Estimating origin–destination-matrices depending on the time of the day from high frequent pedestrian entry and exit counts,” *IET Intelligent Transport Systems*, c. 6, no. 4, ss. 463–473, 2012.

[45] R. Vogt, I. Nikolaidis P. Gburzynski, “A realistic outdoor urban pedestrian mobility model,” *Simulation Modelling Practice and Theory*, c. 26, ss. 113–134, 2012.

[46] J. Fang, S. El-Tawil B. Aguirre, "Leader–follower model for agent based simulation of social collective behavior during egress," *Safety Science*, c. 83, ss. 40–47, 2016.

[47] K. Khoshkhah, M. Pourmoradnasseri A. Hadachi, "A real-time model for pedestrian flow estimation in urban areas based on IoT sensors," *2022 IEEE 25th International Conference on Intelligent Transportation Systems (ITSC)*, IEEE, 2022, ss. 4124–4130.

[48] K. S. Chan, W. H. Lam, L. Ouyang S. Wong, "Simultaneous estimation of the pedestrian origin-destination matrix and parameter of the activity/destination choice model," *Journal of the Eastern Asia Society for Transportation Studies*, c. 7, ss. 1760–1773, 2007.

[49] M. Friedrich, K. Immisch, P. Jehlicka, T. Otterstätter J. Schlaich, "Generating origin–destination matrices from mobile phone trajectories," *Transportation research record*, c. 2196, no. 1, ss. 93–101, 2010.

[50] X. Qin, H. Liu, H. Zhang B. Liu, "A collective motion model based on two-layer relationship mechanism for bi-direction pedestrian flow simulation," *Simulation Modelling Practice and Theory*, c. 84, ss. 268–285, 2018.

[51] Y. Li, M. Sarvi K. Khoshelham, "Pedestrian origin-destination estimation in emergency scenarios," *2019 9th International Conference on Fire Science and Fire Protection Engineering (ICFSFPE)*, IEEE, 2019, ss. 1–5.

[52] L. Moreira-Matias, J. Gama, M. Ferreira, J. Mendes-Moreira L. Damas, "Time-evolving OD matrix estimation using high-speed GPS data streams," *Expert systems with Applications*, c. 44, ss. 275–288, 2016.

[53] M. Batran, M. G. Mejia, H. Kanasugi, Y. Sekimoto R. Shibasaki, "Inferencing human spatiotemporal mobility in greater Maputo via mobile phone big data mining," *ISPRS International Journal of Geo-Information*, c. 7, no. 7, s. 259, 2018.

[54] P. Krishnakumari, O. Cats H. van Lint, "Estimation of metro network passenger delay from individual trajectories," *Transportation Research Part C: Emerging Technologies*, c. 117, s. 102 704, 2020, issn: 0968-090X. doi: https://doi.org/10.1016/j.trc.2020.102704. erişim adresi: https://www.sciencedirect.com/science/article/pii/S0968090X20306197.

[55] N. Tsanakas, D. Gundlegård C. Rydergren, "O–D matrix estimation based on data-driven network assignment," *Transportmetrica B: Transport Dynamics*, c. 11, no. 1, ss. 376–407, 2023.

[56] D. S. Sobrino, J. Andión, J. C. Dueñas, J. M. Del Álamo F. Cuadrado, "Model Generation and Origin-Destination (OD) Matrix Forecasting for metro systems," *2023 7th International Young Engineers Forum (YEF-ECE)*, IEEE, 2023, ss. 112–117.

[57] B. Huang, K. Ruan, W. Yu, J. Xiao, R. Xie J. Huang, "ODformer: spatial–temporal transformers for long sequence Origin–Destination matrix forecasting against cross application scenario," *Expert Systems with Applications*, c. 222, s. 119 835, 2023.

[58] K. Zhang, Y. Pang, Y. Zhang Y. Sekimoto, "MobGLM: A Large Language Model for Synthetic Human Mobility Generation," *Proceedings of the 32nd ACM International Conference on Advances in Geographic Information Systems*, 2024, ss. 629–632.

[59] A. P. Vanky, "To and fro: digital data-driven analyses of pedestrian mobility in urban spaces," dok. tezi, Massachusetts Institute of Technology, 2017.

[60] Y. Jiang, "Quantifying Human Mobility Patterns during Disruptive Events with Geospatial Big Data," dok. tezi, University of South Carolina, 2022.

[61] M. V. Chávez-Hernández, Y. Á. Ríos-Solís, L. H. Juárez Valencia R. Z. Ríos-Mercado, "Updating origin–destination matrices and link probabilities in public transportation networks," *Public Transport*, ss. 1–27, 2025.

[62] T. Yoongsomporn, A. C. G. Varquez, S. Choi, M. Okumura, S. Hanaoka M. Kanda, "Spatiotemporal Analysis of Human Mobility in Greater Tokyo Area Using Hourly 500 m Mobile Spatial Statistics from 2019 to 2021," *Urban Science*, c. 9, no. 2, s. 50, 2025.

[63] J. He ve diğ., "A Framework for Measuring and Benchmarking Fairness of Generative Crowd-Flow Models," *ACM Journal on Computing and Sustainable Societies*, 2025.

[64] P. Sadeghian B. B. Mojarrad, "Analysing Gender and Temporal Dynamics in Human Mobility Patterns in Central Sweden," *Geographies*, c. 5, no. 1, s. 7, 2025.

[65] M. Hacar, Ö. Ö. Hacar, D. Altafini, L. Pappalardo, F. Gülgen V. Cutini, "From streets to screens: A deep dive into urban configuration and Google reviews," *Proceedings of the 14th International Space Syntax Symposium (SSS14)*, University of Cyprus, Nicosia, Cyprus, Haz. 2024, ss. 3201–3223.

[66] K. Pearson, "The problem of the random walk," *Nature*, c. 72, no. 1867, ss. 342–342, 1905.

[67] A. A. Markov, "Rasprostranenie zakona bol'shih chisel na velichiny, zavisyaschie drug ot druga," *Izvestiya Fiziko-matematicheskogo obschestva pri Kazanskom universitete*, c. 15, no. 135-156, s. 18, 1906.

[68] T. C. Schelling, "Dynamic models of segregation," *Journal of mathematical sociology*, c. 1, no. 2, ss. 143–186, 1971.

[69] B. Hillier J. Hanson, *The social logic of space*. Cambridge university press, 1989.

[70] S. Porta, P. Crucitti V. Latora, "The network analysis of urban streets: A dual approach," *Physica A: Statistical Mechanics and its Applications*, c. 369, no. 2, ss. 853–866, 2006.

[71] F. Simini, G. Barlacchi, M. Luca L. Pappalardo, "A deep gravity model for mobility flows generation," *Nature communications*, c. 12, no. 1, s. 6576, 2021.

[72] J. E. Anderson E. Van Wincoop, "Gravity with gravitas: A solution to the border puzzle," *American economic review*, c. 93, no. 1, ss. 170–192, 2003.

[73] K. Kepaptsoglou, M. G. Karlaftis D. Tsamboulas, "The gravity model specification for modeling international trade flows and free trade agreement effects: a 10-year review of empirical studies," *The open economics journal*, c. 3, ss. 1–13, 2010.

[74] Y. V. Yotov, "On the role of domestic trade flows for estimating the gravity model of trade," *Contemporary Economic Policy*, c. 40, no. 3, ss. 526–540, 2022.

[75] N. Davidich ve diğ., "Intelligent decision support system for modeling transport and passenger flows in human-centric urban transport systems," *Energies*, c. 15, no. 7, s. 2495, 2022.

[76] C.-H. Wang, N. Chen ve diğ., "A gravity model integrating land-use and transportation policies for sustainable development: Case study of Fresno, California," Mineta Transportation Institute, tek. rap., 2023.

[77] C. Hsu, C. Fan A. Mostafavi, "Limitations of gravity models in predicting fine-scale spatial-temporal urban mobility networks," *arXiv preprint arXiv:2109.03873*, 2021.

[78] R. M. Beyer, J. Schewe H. Lotze-Campen, "Gravity models do not explain, and cannot predict, international migration dynamics," *Humanities and Social Sciences Communications*, c. 9, no. 1, ss. 1–10, 2022.

[79] X. Zhang N. Li, "An activity space-based gravity model for intracity human mobility flows," *Sustainable Cities and Society*, c. 101, s. 105 073, 2024.

[80] W. Yu, H. Wen, W. Wang, D. Zhao X. Hua, "On the calibration and improvement of human mobility models in intercity transportation system," *Physica A: Statistical Mechanics and its Applications*, c. 653, s. 130 116, 2024.

[81] O. Cabanas-Tirapu, L. Danús, E. Moro, M. Sales-Pardo R. Guimerà, "Human mobility is well described by closed-form gravity-like models learned automatically from data," *Nature Communications*, c. 16, no. 1, s. 1336, 2025.

[82] C. Alis, E. F. Legara C. Monterola, "Generalized radiation model for human migration," *Scientific reports*, c. 11, no. 1, s. 22 707, 2021.

[83] L. Pappalardo, E. Manley, V. Sekara L. Alessandretti, "Future directions in human mobility science," *Nature computational science*, c. 3, no. 7, ss. 588–600, 2023.

[84] H. Thomas, "Applying the radiation model to long-distance trip patterns in Western Australia," *Australasian Transport Research Forum (ATRF), 44th, 2023, Perth, Western Australia, Australia*, 2023.

[85] V. Belik, T. Geisel D. Brockmann, "Natural human mobility patterns and spatial spread of infectious diseases," *Physical Review X*, c. 1, no. 1, s. 011 001, 2011.

[86] M. Tizzoni ve diğ., "On the use of human mobility proxies for modeling epidemics," *PLoS computational biology*, c. 10, no. 7, e1003716, 2014.

[87] J. Von Neumann, A. W. Burks ve diğ., "Theory of self-reproducing automata," *IEEE Transactions on Neural Networks*, c. 5, no. 1, ss. 3–14, 1966.

[88] Q. Xu, A.-X. Zhu J. Liu, "Land-use change modeling with cellular automata using land natural evolution unit," *Catena*, c. 224, s. 106 998, 2023.

[89] V. J. Blue J. L. Adler, "Cellular automata microsimulation of bidirectional pedestrian flows," *Transportation Research Record*, c. 1678, no. 1, ss. 135–141, 1999.

[90] C. Song, T. Koren, P. Wang A.-L. Barabási, "Modelling the scaling properties of human mobility," *Nature physics*, c. 6, no. 10, ss. 818–823, 2010.

[91] L. Pappalardo, S. Rinzivillo F. Simini, "Human mobility modelling: exploration and preferential return meet the gravity model," *Procedia Computer Science*, c. 83, ss. 934–939, 2016.

[92] G. E. Uhlenbeck L. S. Ornstein, "On the theory of the Brownian motion," *Physical review*, c. 36, no. 5, s. 823, 1930.

[93] G. H. Weiss R. J. Rubin, "Random walks: theory and selected applications," *Adv. Chem. Phys*, c. 52, ss. 363–505, 1983.

[94] M. Yan, S. Li, C. A. Chan, Y. Shen Y. Yu, "Mobility prediction using a weighted Markov model based on mobile user classification," *Sensors*, c. 21, no. 5, s. 1740, 2021.

[95] J. Jiang, C. Pan, H. Liu G. Yang, "Predicting human mobility based on location data modeled by Markov chains," *2016 Fourth International Conference on Ubiquitous Positioning, Indoor Navigation and Location Based Services (UPINLBS)*, IEEE, 2016, ss. 145–151.

[96] C. M. Macal M. J. North, "Agent-based modeling and simulation," *Proceedings of the 2009 winter simulation conference (WSC)*, IEEE, 2009, ss. 86–98.

[97] S. Abar, G. K. Theodoropoulos, P. Lemarinier G. M. O'Hare, "Agent Based Modelling and Simulation tools: A review of the state-of-art software," *Computer Science Review*, c. 24, ss. 13–33, 2017.

[98] L. Breiman, "Random forests," *Machine learning*, c. 45, ss. 5–32, 2001.

[99] S. Suthaharan, "Support vector machine," içinde *Machine learning models and algorithms for big data classification: thinking with examples for effective learning*, Springer, 2016, ss. 207–235.

[100] J. Gunkel, M. Mühlhäuser A. Tundis, "Machine learning for human mobility during disasters: A systematic literature review," *Progress in Disaster Science*, s. 100 405, 2025.

[101] B. Hillier, "Cities as movement economies," içinde *Intelligent environments*, Elsevier, 1997, ss. 295–344.

[102] A. Penn, B. Hillier, D. Banister J. Xu, "Configurational modelling of urban movement networks," *Environment and Planning B: planning and design*, c. 25, no. 1, ss. 59–84, 1998.

[103] K. Al-Sayed, A. Turner, B. Hillier, S. Iida A. Penn, "Space syntax methodology," *Bartlett School of Architecture, UCL: London, UK*, 2014.

[104] Ö. Öztürk, "Mekan dizimi yöntemiyle mekansal değişimin incelenmesi Yıldız Teknik Üniversitesi Davutpaşa Kampüsü örneği," yük. lis. tezi, Fen Bilimleri Enstitüsü, 2018.

[105] Ö. Ö. Hacar, F. Gülgen S. Bilgi, "Evaluation of the space syntax measures affecting pedestrian density through ordinal logistic regression analysis," *ISPRS International Journal of Geo-Information*, c. 9, no. 10, s. 589, 2020.

[106] B. Hillier, A. Penn, J. Hanson, T. Grajewski J. Xu, "Natural movement: or, configuration and attraction in urban pedestrian movement," *Environment and Planning B: planning and design*, c. 20, no. 1, ss. 29–66, 1993.

[107] M. Barthélemy, "Spatial networks," *Physics reports*, c. 499, no. 1-3, ss. 1–101, 2011.

[108] X. Lu, E. Wetter, N. Bharti, A. J. Tatem L. Bengtsson, "Approaching the limit of predictability in human mobility," *Scientific reports*, c. 3, no. 1, s. 2923, 2013.

[109] D. Helbing P. Molnar, "Social force model for pedestrian dynamics," *Physical review E*, c. 51, no. 5, s. 4282, 1995.

[110] G. P. Senanayake, M. Kieu, Y. Zou K. Dirks, "Agent-based simulation for pedestrian evacuation: A systematic literature review," *International Journal of Disaster Risk Reduction*, s. 104 705, 2024.

[111] N. Kohli, E. Aiken J. E. Blumenstock, "Privacy guarantees for personal mobility data in humanitarian response," *Scientific Reports*, c. 14, no. 1, s. 28 565, 2024.

[112] M. Batty, *The new science of cities*. MIT press, 2013.

[113] J. Liu, L. Xu, L. Ma N. Chen, "Modeling Population Mobility Flows: A Hybrid Approach Integrating a Gravity Model and Machine Learning," *ISPRS International Journal of Geo-Information*, c. 13, no. 11, s. 379, 2024.

[114] O.-H. Kwon, I. Hong, W.-S. Jung H.-H. Jo, "Multiple gravity laws for human mobility within cities," *EPJ Data Science*, c. 12, no. 1, s. 57, 2023.

[115] Z. Xing, E. Chung, Y. Wang, A. Toriumi, T. Oguchi Y. Wu, "Origin–destination prediction via knowledge-enhanced hybrid learning," *Computer-Aided Civil and Infrastructure Engineering*, 2025.

[116] Z. Hou, J. Han G. Yang, "Analysis of Passenger Flow Characteristics and Origin–Destination Passenger Flow Prediction in Urban Rail Transit Based on Deep Learning," *Applied Sciences*, c. 15, no. 5, s. 2853, 2025.

[117] Y. Liu, G. Shen, Y. Fu, Z. Feng, Z. Zhao X. Kong, "Spatial homogeneity-aware transfer learning for urban flow prediction," *Knowledge and Information Systems*, ss. 1–23, 2025.

[118] K. EK E. WENNERBERG, "Estimating travel demand from twitter using an individual mobility model: in Sweden, the Netherlands and São paulo," 2020.

[119] Y. Bao, Z. Huang, L. Li, Y. Wang Y. Liu, "A BiLSTM-CNN model for predicting users' next locations based on geotagged social media," *International Journal of Geographical Information Science*, c. 35, no. 4, ss. 639–660, 2021.

[120] F. Li ve diğ., "A hierarchical temporal attention-based LSTM encoder-decoder model for individual mobility prediction," *Neurocomputing*, c. 403, ss. 153–166, 2020.

[121] Y. Ren, H. Chen, Y. Han, T. Cheng, Y. Zhang G. Chen, "A hybrid integrated deep learning model for the prediction of citywide spatio-temporal flow volumes," *International Journal of Geographical Information Science*, c. 34, no. 4, ss. 802–823, 2020.

[122] G. Cornacchia L. Pappalardo, "A mechanistic data-driven approach to synthesize human mobility considering the spatial, temporal, and social dimensions together," *ISPRS International Journal of Geo-Information*, c. 10, no. 9, s. 599, 2021.

[123] U. Demšar ve diğ., "Establishing the integrated science of movement: bringing together concepts and methods from animal and human movement analysis," *International Journal of Geographical Information Science*, c. 35, no. 7, ss. 1273–1308, 2021.

[124] D. do Couto Teixeira, J. M. Almeida A. C. Viana, "On estimating the predictability of human mobility: the role of routine," *EPJ Data Science*, c. 10, no. 1, s. 49, 2021.

[125] G. Cornacchia, G. Rossetti L. Pappalardo, "Modelling Human Mobility considering Spatial, Temporal and Social Dimensions. arXiv 2020," *arXiv preprint arXiv:2007.02371*,

[126] X. Wang, J. Liono, W. Mcintosh F. D. Salim, "Predicting the city foot traffic with pedestrian sensor data," *Proceedings of the 14th EAI International Conference on Mobile and Ubiquitous Systems: Computing, Networking and Services*, 2017, ss. 1–10.

[127] IBM, *What is a digital footprint?* `https://www.ibm.com/think/topics/digital-footprint`, Erişim tarihi: 2024-04-26, 2024.

[128] S. A. Golder M. W. Macy, "Digital footprints: Opportunities and challenges for online social research," *Annual review of sociology*, c. 40, no. 1, ss. 129–152, 2014.

[129] Y. Zheng, L. Capra, O. Wolfson H. Yang, "Urban computing: concepts, methodologies, and applications," *ACM Transactions on Intelligent Systems and Technology (TIST)*, c. 5, no. 3, ss. 1–55, 2014.

[130] I. A. T. Hashem, I. Yaqoob, N. B. Anuar, S. Mokhtar, A. Gani S. U. Khan, "The rise of "big data" on cloud computing: Review and open research issues," *Information systems*, c. 47, ss. 98–115, 2015.

[131] P. Regulation, "Regulation (EU) 2016/679 of the European Parliament and of the Council," *Regulation (eu)*, c. 679, s. 2016, 2016.

[132] A. Noulas, "Human urban mobility in location-based social networks: analysis, models and applications," dok. tezi, Citeseer, 2013.

[133] S. Rahimi, S. Mottahedi X. Liu, "The geography of taste: using yelp to study urban culture," *ISPRS International Journal of Geo-Information*, c. 7, no. 9, s. 376, 2018.

[134] A. Bendeck C. Andris, "Text mining and spatial analysis of Yelp data to support socially vibrant cities," *2022 UrbComp*, 2022.

[135] M. Chukwu, X. Huang, S. Wang, X. Li H. Wei, "Urban park accessibility assessment using human mobility data: a systematic review," *Annals of GIS*, c. 30, no. 2, ss. 181–198, 2024.

[136] S. Kamel Basmenj S. Li, "a Review of Urban Human Mobility Research Based on Crowd-Sourced Data and Space-Time and Semantic Analysis," *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, c. 43, ss. 247–252, 2022.

[137] S. Heroy, I. Loaiza, A. Pentland N. O'Clery, "Are neighbourhood amenities associated with more walking and less driving? Yes, but predominantly for the wealthy," *Environment and Planning B: Urban Analytics and City Science*, c. 50, no. 4, ss. 958–982, 2023.

[138] Ö. Öztürk Hacar, M. Hacar, F. Gülgen L. Pappalardo, "Where We Rate: The Impact of Urban Characteristics on Digital Reviews and Ratings," *Applied Sciences*, c. 15, no. 2, s. 931, 2025.

[139] World Population Review, *Melbourne Population 2024*, https://worldpopulationreview.com/cities/australia/melbourne, Erişim tarihi: 19 Nisan 2025, 2024.

[140] City of Melbourne, *City of Melbourne Open Data Portal*, https://data.melbourne.vic.gov.au/pages/home/, Accessed: 2025-04-22, 2023.

[141] Google LLC. "Google Maps API." Accessed: 15 November 2024. (2024), erişim adresi: https://developers.google.com/maps.

[142] M. Wong, *City of Melbourne pedestrian counters*, Accessed: 2025-05-12, 2012. erişim adresi: https://wongm.com/2012/10/city-of-melbourne-pedestrian-counters/.

[143] BBBike Project, *BBBike – Index of OSM Downloads*, https://download.bbbike.org/osm/bbbike/, Accessed: 15 November 2024, 2024.

[144] OpenStreetMap Wiki, *Map Features*, https://wiki.openstreetmap.org/wiki/Map_Features, Accessed: 15 November 2024, 2024.

[145] M. Hacar, F. Mara, D. Altafini V. Cutini, "Preprocessing open data for optimizing estimation times in urban network analysis: Extracting, filtering, geoprocessing, and simplifying the road-center lines," *International Conference on Innovation in Urban and Regional Planning*, Springer, 2023, ss. 551–562.

[146] G. Boeing, "OSMnx: New methods for acquiring, constructing, analyzing, and visualizing complex street networks," *Computers, environment and urban systems*, c. 65, ss. 126–139, 2017.

[147] S. Porta, P. Crucitti V. Latora, "The network analysis of urban streets: A dual approach," *Physica A: Statistical Mechanics and its Applications*, c. 369, no. 2, ss. 853–866, 2006.

[148] A. A. Hagberg, D. A. Schult P. J. Swart, "Exploring Network Structure, Dynamics, and Function using NetworkX," *Proceedings of the 7th Python in Science Conference (SciPy2008)*, G. Varoquaux, T. Vaught J. Millman, ed., Pasadena, CA, USA, 2008, ss. 11–15.

[149] J. E. Mueller, "An introduction to the hydraulic and topographic sinuosity indexes," *Annals of the association of american geographers*, c. 58, no. 2, ss. 371–385, 1968.

[150] T. K. Ho, "Random decision forests," *Proceedings of 3rd international conference on document analysis and recognition*, IEEE, c. 1, 1995, ss. 278–282.

[151] Y. Amit D. Geman, "Shape quantization and recognition with randomized trees," *Neural computation*, c. 9, no. 7, ss. 1545–1588, 1997.

[152] A. Liaw, M. Wiener ve diğ., "Classification and regression by randomForest," *R news*, c. 2, no. 3, ss. 18–22, 2002.

[153] F. Pedregosa ve diğ., "Scikit-learn: Machine learning in Python," *the Journal of machine Learning research*, c. 12, ss. 2825–2830, 2011.

[154] M. Batty, "Big data, smart cities and city planning," *Dialogues in human geography*, c. 3, no. 3, ss. 274–279, 2013.

[155] Y. Tang, J. Zhang, R. Liu Y. Li, "Exploring the impact of built environment attributes on social followings using social media data and deep learning," *ISPRS International Journal of Geo-Information*, c. 11, no. 6, s. 325, 2022.

[156] D. Gavilan, M. Avello G. Martinez-Navarro, "The influence of online ratings and reviews on hotel booking consideration," *Tourism management*, c. 66, ss. 53–61, 2018.

[157] J. F. O'Callaghan D. M. Mark, "The extraction of drainage networks from digital elevation data," *Computer vision, graphics, and image processing*, c. 28, no. 3, ss. 323–344, 1984.

[158] J. Cheng I. Masser, "Urban growth pattern modeling: a case study of Wuhan city, PR China," *Landscape and urban planning*, c. 62, no. 4, ss. 199–217, 2003.

[159] J. L. Toole, M. Ulm, M. C. González D. Bauer, "Inferring land use from mobile phone activity," *Proceedings of the ACM SIGKDD international workshop on urban computing*, 2012, ss. 1–8.

[160] P. A. Burrough, R. A. McDonnell C. D. Lloyd, *Principles of geographical information systems*. Oxford University Press, USA, 2015.

[161] A. Zanella, N. Bui, A. Castellani, L. Vangelista M. Zorzi, "Internet of things for smart cities," *IEEE Internet of Things journal*, c. 1, no. 1, ss. 22–32, 2014.

[162] G. Cornacchia L. Pappalardo, "STS-EPR: Modelling individual mobility considering the spatial, temporal, and social dimensions together," *Procedia Computer Science*, c. 184, ss. 258–265, 2021.

[163] R. L. Knoblauch, M. T. Pietrucha M. Nitzburg, “Field studies of pedestrian walking speed and start-up time,” *Transportation research record*, c. 1538, no. 1, ss. 27–38, 1996.

[164] A. El-Geneidy, M. Grimsrud, R. Wasfi, P. Tétreault J. Surprenant-Legault, “New evidence on walking distances to transit stops: Identifying redundancies and gaps using variable service areas,” *Transportation*, c. 41, ss. 193–210, 2014.

[165] C. Moreno, Z. Allam, D. Chabaud, C. Gall F. Pratlong, “Introducing the “15-Minute City”: Sustainability, resilience and place identity in future post-pandemic cities,” *Smart cities*, c. 4, no. 1, ss. 93–111, 2021.

[166] Z. Allam, M. Nieuwenhuijsen, D. Chabaud C. Moreno, “The 15-minute city offers a new framework for sustainability, liveability, and health,” *The Lancet Planetary Health*, c. 6, no. 3, e181–e183, 2022.

[167] D. Levinson A. El-Geneidy, “The minimum circuity frontier and the journey to work,” *Regional science and urban economics*, c. 39, no. 6, ss. 732–738, 2009.

[168] N. Gordon, “F. Traffic Flow on Transportation Networks,” *USA: Editorial: The MIT Press Mass*, 1980.

[169] L. Pappalardo, F. Simini, G. Barlacchi R. Pellungrini, “Scikit-mobility: A Python library for the analysis, generation, and risk assessment of mobility data,” *Journal of Statistical Software*, c. 103, ss. 1–38, 2022.

A
PYTHON KODLARI-1

Aşağıda tezde kullanılan RO modelinin tam Python kodu verilmiştir.

```
import matplotlib.pyplot as plt
import pandas as pd
import numpy as np
from sklearn.preprocessing import LabelEncoder
from sklearn.ensemble import RandomForestClassifier
from sklearn.model_selection import train_test_split
from sklearn.metrics import classification_report

data = pd.read_csv("google_poi_all_integrated.csv")

# Sütun isimlerini değiştirmek için dictionary
column_rename_map = {
    'review_cou': 'review_count',
    'IDW_22_mea': 'IDW_22_mean',
    'IDW_23_mea': 'IDW_23_mean',
    'sp_primal_': 'sp_primal_degree',
    'sp_prima_1': 'sp_primal_betweenness',
    'sp_prima_2': 'sp_primal_closeness',
    'sp_prima_3': 'sp_primal_eigenvector',
    'sp_prima_4': 'sp_primal_pagerank',
    'sp_prima_5': 'sp_primal_harmonic',
    'sp_prima_6': 'sp_primal_load',
    'sp_prima_7': 'sp_primal_katz',
    'sp_prima_8': 'sp_primal_clustering',
    'sp_dual_de': 'sp_dual_degree',
    'sp_dual_be': 'sp_dual_betweenness',
    'sp_dual_cl': 'sp_dual_closeness',
    'sp_dual_ei': 'sp_dual_eigenvector',
    'sp_dual_pa': 'sp_dual_pagerank',
    'sp_dual_ha': 'sp_dual_harmonic',
    'sp_dual_lo': 'sp_dual_load',
    'sp_dual_ka': 'sp_dual_katz',
    'sp_dual__1': 'sp_dual_clustering',
    'or_primal_': 'or_primal_degree',
    'or_prima_1': 'or_primal_betweenness',
    'or_prima_2': 'or_primal_closeness',
```

```
    'or_prima_3': 'or_primal_eigenvector',
    'or_prima_4': 'or_primal_pagerank',
    'or_prima_5': 'or_primal_harmonic',
    'or_prima_6': 'or_primal_load',
    'or_prima_7': 'or_primal_katz',
    'or_prima_8': 'or_primal_clustering',
    'or_dual_de': 'or_dual_degree',
    'or_dual_be': 'or_dual_betweenness',
    'or_dual_cl': 'or_dual_closeness',
    'or_dual_ei': 'or_dual_eigenvector',
    'or_dual_pa': 'or_dual_pagerank',
    'or_dual_ha': 'or_dual_harmonic',
    'or_dual_lo': 'or_dual_load',
    'or_dual_ka': 'or_dual_katz',
    'or_dual__1': 'or_dual_clustering',
    'IDW_H17_22': 'IDW_H17_22_mean',
    'IDW_H17__1': 'IDW_H17_22_max',
    'IDW_H17_23': 'IDW_H17_23_mean',
    'IDW_H17__2': 'IDW_H17_23_max',
    'dwellings_': 'dwellings_22_mean',
    'nearest__2': 'dist2street'
}
# Sütunları yeniden adlandır
data.rename(columns=column_rename_map, inplace=True)
# review_count >= 10 olanları seç
df = data[data['review_count'] >= 10]

#df = df[df['type'].isin(['bakery', 'bar','cafe',
↪  'restaurant'])]

# Rating sütununu quantile bazlı kategorilere ayırma
def categorize_rating_quantile(df, num_quantiles):
    # Rating sütununu belirtilen quantile sayısına göre
    ↪  kategorilere ayırıyoruz
    df['rating_quantile'] = pd.qcut(df['rating'],
    ↪  q=num_quantiles, labels=[f'Q{i+1}' for i in
    ↪  range(num_quantiles)])
    return df


# Örneğin, rating'i 4 quantile'a (quartile) bölelim
df = categorize_rating_quantile(df, 2)

# type ve sp_highway sütunlarını kategorik hale getir
for col in ['sp_highway', 'or_highway', 'rating_quantile',
↪  'type']:
    df[col] = LabelEncoder().fit_transform(df[col])


# df_IDWmean için: 'IDW_max' sütunlarını özelliklerden
↪  çıkarıyoruz
```

```
feature_columns_IDWmean = df.columns.difference(['rating',
 ↪  'review_count', 'IDW_22_max',
 ↪  'IDW_23_max','IDW_H17_22_max','IDW_H17_23_max',
'rating_quantile', 'sp_primal_clustering',
 ↪  'sp_dual_clustering', 'length',
'or_primal_degree', 'or_primal_betweenness',
 ↪  'or_primal_closeness', 'or_primal_eigenvector',
 ↪  'or_primal_pagerank', 'or_primal_harmonic',
 ↪  'or_primal_load', 'or_primal_katz',
'or_primal_clustering', 'or_dual_degree',
 ↪  'or_dual_betweenness', 'or_dual_closeness',
 ↪  'or_dual_eigenvector', 'or_dual_pagerank',
 ↪  'or_dual_harmonic', 'or_dual_load', 'or_dual_katz',
 ↪  'or_dual_clustering', 'or_highway'])
"""
# df_IDWmax için: 'IDW_mean' sütunlarını özelliklerden
 ↪  çıkarıyoruz
feature_columns_IDWmax = df.columns.difference(['rating',
 ↪  'review_count', 'IDW_22_mean', 'IDW_23_mean',
'IDW_H17_22_mean','IDW_H17_23_mean',
'review_quantile', 'or_highway',
'or_primal_degree', 'sp_dual_clustering',
 ↪  'sp_primal_clustering','sp_primal_pagerank',
'or_primal_betweenness', 'or_primal_closeness',
 ↪  'or_primal_eigenvector',
'or_primal_pagerank', 'or_primal_harmonic',
 ↪  'or_primal_load', 'or_primal_katz',
'or_primal_clustering', 'or_dual_degree',
 ↪  'or_dual_betweenness', 'or_dual_closeness',
'or_dual_eigenvector', 'or_dual_pagerank',
 ↪  'or_dual_harmonic', 'or_dual_load',
'or_dual_katz', 'or_dual_clustering'])

"""
target_column = 'rating_quantile'
# Verileri ayırma (X -> özellikler, y -> hedef (rating))
X = df[feature_columns_IDWmean]
y = df[target_column]
# Eğitim ve test setlerine bölme
X_train, X_test, y_train, y_test = train_test_split(X, y,
 ↪  test_size=0.2, random_state=42)
# Random Forest modelini eğit
rf_model = RandomForestClassifier(random_state=42)
rf_model.fit(X_train, y_train)
# Test verisi üzerinde tahmin yap ve performans ölçümlerini
 ↪  al
y_pred = rf_model.predict(X_test)
print('IDW mean', classification_report(y_test, y_pred))
# y_test DataFrame'e tahmin sonuçlarını ekle
```

```
y_test_df =
 ↪  pd.DataFrame(y_test).rename(columns={y_test.name: 'True
 ↪  Labels'})
y_test_df['Predicted Labels'] = y_pred
y_test_df['result'] = (y_test_df['True Labels'] ==
 ↪  y_test_df['Predicted Labels']).astype('category')

# Test verisini indeks kullanarak ham veriyle birleştir
merged_df = df.join(y_test_df[['Predicted Labels',
 ↪  'result']], how='left')
# CSV dosyasına kaydetme
#merged_df.to_csv("/Users/mhacar/Desktop/Melbourne/csv/google_poi_all_integr
 ↪  index=False)
#graph of importances
feature_names = [f"feature {i}" for i in range(X.shape[1])]
importances = rf_model.feature_importances_
std = np.std([tree.feature_importances_ for tree in
 ↪  rf_model.estimators_], axis=0)
rf_model_importances = pd.Series(importances,
 ↪  index=feature_names)
fig, ax = plt.subplots()
rf_model_importances.plot.bar(yerr=std, ax=ax)
ax.set_title("Feature importances using MDI")
ax.set_ylabel("Mean decrease in impurity")
fig.tight_layout()
plt.show()
"""
# Verileri ayırma (X -> özellikler, y -> hedef (rating))
X = df[feature_columns_IDWmax]
y = df[target_column]
# Eğitim ve test setlerine bölme
X_train, X_test, y_train, y_test = train_test_split(X, y,
 ↪  test_size=0.2, random_state=42)
# Random Forest modelini eğit
rf_model = RandomForestClassifier(random_state=42)
rf_model.fit(X_train, y_train)
# Test verisi üzerinde tahmin yap ve performans ölçümlerini
 ↪  al
y_pred = rf_model.predict(X_test)
print('IDW max', classification_report(y_test, y_pred))
#graph of importances
feature_names = [f"feature {i}" for i in range(X.shape[1])]
importances = rf_model.feature_importances_
std = np.std([tree.feature_importances_ for tree in
 ↪  rf_model.estimators_], axis=0)
rf_model_importances = pd.Series(importances,
 ↪  index=feature_names)
fig, ax = plt.subplots()
rf_model_importances.plot.bar(yerr=std, ax=ax)
ax.set_title("Feature importances using MDI")
ax.set_ylabel("Mean decrease in impurity")
```

```
fig.tight_layout()
plt.show()

"""
feature_columns_IDWmean

 'sp_primal_betweenness', 'sp_primal_closeness',
  ↪  'sp_primal_degree', 'sp_primal_eigenvector',
'sp_primal_harmonic', 'sp_primal_katz', 'sp_primal_load',
 ↪  'sp_primal_pagerank',
'sp_dual_betweenness','sp_dual_closeness', 'sp_dual_degree',
 ↪  'sp_dual_eigenvector',
'sp_dual_harmonic', 'sp_dual_katz', 'sp_dual_load',
 ↪  'sp_dual_pagerank',

import matplotlib.pyplot as plt
import numpy as np
import pandas as pd

# Özellik isimleri ve önem değerleri (Random Forest
 ↪  modelinden gelen önem değerlerini varsayıyoruz)
feature_names = ['IDW_22_mean', 'IDW_23_mean',
 ↪  'IDW_H17_22_mean', 'IDW_H17_23_mean',
'sp_primal_betweenness', 'sp_primal_closeness',
 ↪  'sp_primal_degree', 'sp_primal_eigenvector',
'sp_primal_harmonic', 'sp_primal_katz', 'sp_primal_load',
 ↪  'sp_primal_pagerank',
'sp_dual_betweenness','sp_dual_closeness', 'sp_dual_degree',
 ↪  'sp_dual_eigenvector',
'sp_dual_harmonic', 'sp_dual_katz', 'sp_dual_load',
 ↪  'sp_dual_pagerank',
'Sinuosity', 'dist2street', 'dwellings_22_mean',
 ↪  'sp_highway', 'type', 'vor_area']

# Random Forest modelinden gelen önem değerleri ile bu
 ↪  örnekte kullanılacak
importances = rf_model.feature_importances_

# Grupları tanımla ve önem değerlerini topla
fs1_total = sum([importances[feature_names.index(f)] for f
 ↪  in ['IDW_22_mean', 'IDW_23_mean', 'IDW_H17_22_mean',
 ↪  'IDW_H17_23_mean', 'dwellings_22_mean']])
fs2_total = sum([importances[feature_names.index(f)] for f
 ↪  in ['Sinuosity', 'dist2street']])
fs3_total = sum([importances[feature_names.index(f)] for f
 ↪  in ['sp_primal_betweenness', 'sp_primal_closeness',
 ↪  'sp_primal_degree', 'sp_primal_eigenvector',
 'sp_primal_harmonic', 'sp_primal_katz', 'sp_primal_load',
  ↪  'sp_primal_pagerank']])
```

```
fs4_total = sum([importances[feature_names.index(f)] for f
 ↪  in ['sp_dual_betweenness','sp_dual_closeness',
 ↪  'sp_dual_degree', 'sp_dual_eigenvector',
'sp_dual_harmonic', 'sp_dual_katz', 'sp_dual_load',
 ↪  'sp_dual_pagerank']])
fs5_total = importances[feature_names.index('sp_highway')]
fs6_total = sum([importances[feature_names.index(f)] for f
 ↪  in ['type', 'vor_area']])

# Grupların isimleri ve toplam önem değerleri
groups = ['FS 1', 'FS 2', 'FS 3', 'FS 4', 'FS 5', 'FS 6']
importance_totals = [fs1_total, fs2_total, fs3_total,
 ↪  fs4_total, fs5_total, fs6_total]

# Grafiği oluşturma
plt.figure(figsize=(30, 20))
plt.bar(groups, importance_totals)
plt.title("Feature Set Importances - Prediction of Visitors'
 ↪  Score", fontsize=25)
plt.ylabel("Total Importance", fontsize=25)
plt.xlabel("Feature Sets", fontsize=25)
plt.xticks(fontsize=20)
plt.yticks(fontsize=20)
plt.show()
```

B
PYTHON KODLARI-2

```
# Step 1 (n=1): Load population data and initialize flow
 ↪  model
import pandas as pd
import ast
# Load the n1hexa_w3.csv file (average sensor values used to
 ↪  determine tile populations)
df= pd.read_csv('n1hexa_w3.csv')
# add new columns
df['N1flow'] = None
df['Destination'] = None
df['Population']= None
df.rename(columns={'tile_ID': 'Origin'}, inplace=True)
df.to_csv("n1hflow_hexaw3.csv", index=False)
#Expand neighbors and compute proportional flows
df = pd.read_csv("n1hflow_hexaw3.csv")
df_neighbors = pd.read_excel("hexa_nh_2023.xlsx")

# Neighbors
df_neighbors['Neighbors'] =
 ↪  df_neighbors['Neighbors'].apply(ast.literal_eval)
df_neighbors_exploded = df_neighbors.explode('Neighbors')
merged_df = pd.merge(df, df_neighbors_exploded,
 ↪  left_on='Origin', right_on='tile_ID', how='left')
merged_df['Destination'] = merged_df['Neighbors']
merged_df.drop(columns=['Neighbors', 'tile_ID'],
 ↪  inplace=True)
merged_df.to_csv("n1hflow_hexaw3_new2.csv", index=False)
df_new = pd.read_csv('n1hflow_hexaw3_new2.csv')
df_pop = pd.read_csv('n1hexa_w3.csv')
df_pop.columns.tolist()
df_new['Population'] = df_new.apply(
    lambda row: df_pop.loc[df_pop['tile_ID'] ==
     ↪  row['Destination'], 'Population'].values[0]
                if row['Destination'] in
                 ↪  df_pop['tile_ID'].values else None,
                 ↪  axis=1)
```

```
df_new.to_csv('n1hflow_hexaw3_new3.csv', index=False)
df_new.head()
df_new = pd.read_csv('n1hflow_hexaw3_new3.csv')
df_pop = pd.read_csv('n1hexa_w3.csv')
df_merged = df_new.merge(df_pop[['tile_ID', 'Population']],
 ↪  left_on='Origin', right_on='tile_ID', how='left',
 ↪  suffixes=('_new', '_pop'))
df_new['flow'] = df_merged['Population_pop']
df_new.to_csv('n1hflow_hexaw3_new3_updated.csv',
 ↪  index=False)
import pandas as pd
df_done = pd.read_csv('n1hflow_hexaw3_new3_updated.csv')
def calculate_nflow_proportional(row, df):

    total_population = df[df['flow'] ==
     ↪  row['flow']]['Population'].sum()


    if total_population == 0:
        return 0
    else:
        return row['flow'] * (row['Population'] /
         ↪  total_population)

df_done['N1flow'] =
 ↪  df_done.apply(calculate_nflow_proportional, axis=1,
 ↪  df=df_done)
df_done.drop(columns=['Population','flow'], inplace=True)
df_done.rename(columns={'N1flow': 'flow'}, inplace=True)
df_done.to_csv('n1hflow_hexaw3_new_done.csv', index=False)
df_done.to_excel('n1hflow_hexaw3_new_done.xlsx')
df_done.head()



#2.step, n=2
import pandas as pd
df= pd.read_csv('n1hflow_hexaw3_new_done.csv')
df.rename(columns={'Destination': 'Destination1'},
 ↪  inplace=True)
df['N2flow'] = None
df['Destination'] = None
df['Population']= None

df.to_csv('n2hflow_hexaw3_new.csv', index=False)
df = pd.read_csv('n2hflow_hexaw3_new.csv')
df_neighbors = pd.read_excel("hexa_nh_2023.xlsx")
df_neighbors['Neighbors'] =
 ↪  df_neighbors['Neighbors'].apply(ast.literal_eval)
```

```
df_neighbors_exploded = df_neighbors.explode('Neighbors')
merged_df = pd.merge(df, df_neighbors_exploded,
 ↪  left_on='Destination1', right_on='tile_ID', how='left')
merged_df['Destination'] = merged_df['Neighbors']
merged_df.drop(columns=['Neighbors', 'tile_ID'],
 ↪  inplace=True)
merged_df.to_csv('n2hflow_hexaw3_new2.csv', index=False)
merged_df.head()
df_new = pd.read_csv('n2hflow_hexaw3_new2.csv')
df_pop = pd.read_csv('n1hexa_w3.csv')
df_pop.columns.tolist()

df_new['Population'] = df_new.apply(
    lambda row: df_pop.loc[df_pop['tile_ID'] ==
     ↪  row['Destination'], 'Population'].values[0]
                if row['Destination'] in
                 ↪  df_pop['tile_ID'].values else None,
                 ↪  axis=1)



df_new.to_csv('n2hflow_hexaw3_new3.csv', index=False)
df_done = pd.read_csv('n2hflow_hexaw3_new3.csv')
def calculate_nflow_proportional(row, df):

    total_population = df[df['flow'] ==
     ↪  row['flow']]['Population'].sum()


    if total_population == 0:
        return 0
    else:
        return row['flow'] * (row['Population'] /
         ↪  total_population)


df_done['N2flow'] =
 ↪  df_done.apply(calculate_nflow_proportional, axis=1,
 ↪  df=df_done)
df_done.drop(columns=['Population','flow', 'Destination1'],
 ↪  inplace=True)
df_done.rename(columns={'N2flow': 'flow'}, inplace=True)
df_done.to_csv('n2hflow_hexaw3_new_done.csv', index=False)
df_done.to_excel('n2hflow_hexaw3_new_done.xlsx')
df_done.head()

data = pd.read_csv('n2hflow_hexaw3_new_done.csv')
filtered_data = data[data['Origin'] != data['Destination']]
filtered_data.to_excel('n2hflow_hexaw3_senza_loops.xlsx')
```

```
# Her bir 'origin-destination' çifti için 'flow' değerlerini
 ↪  toplayalım,looplar silindikten sonra bu adımda aynı od
 ↪  ye sahip pairlerr aggregate edilir
aggregated_data = filtered_data.groupby(['Origin',
 ↪  'Destination']).sum().reset_index()
aggregated_data.to_excel('n2hflow_hexaw3_aggregated.xlsx')
aggregated_data.to_csv('n2hflow_hexaw3_aggregated.csv')

#n=3, third step
df= pd.read_csv('n2hflow_hexaw3_aggregated.csv')
df.rename(columns={'Destination': 'Destination2'},
 ↪  inplace=True)
df['N3flow'] = None
df['Destination'] = None
df['Population']= None
df.to_csv('n3hflow_hexaw3_new.csv', index=False)
df = pd.read_csv('n3hflow_hexaw3_new.csv')
df = df.loc[:, ~df.columns.str.contains('^Unnamed')]
df_neighbors = pd.read_excel('hexa_nh_2023.xlsx')
df_neighbors['Neighbors'] =
 ↪  df_neighbors['Neighbors'].apply(ast.literal_eval)
df_neighbors_exploded = df_neighbors.explode('Neighbors')
merged_df = pd.merge(df, df_neighbors_exploded,
 ↪  left_on='Destination2', right_on='tile_ID', how='left')
merged_df['Destination'] = merged_df['Neighbors']
merged_df.drop(columns=['Neighbors', 'tile_ID'],
 ↪  inplace=True)
merged_df.to_csv('n3hflow_hexaw3_new2.csv', index=False)
df_new = pd.read_csv('n3hflow_hexaw3_new2.csv')
df_pop = pd.read_csv('n1hexa_w3.csv')
df_pop.columns.tolist()
df_new['Population'] = df_new.apply(
    lambda row: df_pop.loc[df_pop['tile_ID'] ==
     ↪  row['Destination'], 'Population'].values[0]
                if row['Destination'] in
                 ↪  df_pop['tile_ID'].values else None,
                 ↪  axis=1)


df_new.to_csv('n3hflow_hexaw3_new3.csv', index=False)
df_done = pd.read_csv('n3hflow_hexaw3_new3.csv')
def calculate_nflow_proportional(row, df):
    # Belirli bir N1flow değeri için toplam nüfusu bul
    total_population = df[df['flow'] ==
     ↪  row['flow']]['Population'].sum()

    # Eğer total_population değeri 0 ise, N1flow da 0 olacak
    if total_population == 0:
        return 0
    else:
```

```
        return row['flow'] * (row['Population'] /
        ↪  total_population)

df_done['N3flow'] =
↪  df_done.apply(calculate_nflow_proportional, axis=1,
↪  df=df_done)
df_done.drop(columns=['Population','flow', 'Destination2'],
↪  inplace=True)
df_done.rename(columns={'N3flow': 'flow'}, inplace=True)
df_done.to_csv('n3hflow_hexaw3_new_done.csv', index=False)
df_done.to_excel('n3hflow_hexaw3_new_done.xlsx')
data = pd.read_csv('n3hflow_hexaw3_new_done.csv')
filtered_data = data[data['Origin'] != data['Destination']]
filtered_data.to_excel('n3hflow_hexaw3_senza_loops.xlsx')
filtered_data.to_csv('n3hflow_hexaw3_senza_loops.csv')
aggregated_data = filtered_data.groupby(['Origin',
↪  'Destination']).sum().reset_index()
aggregated_data.to_excel('n3hflow_hexaw3_aggregated.xlsx')
aggregated_data.to_csv('n3hflow_hexaw3_aggregated.csv',
↪  index=False)
aggregated_data.head()



#4. step, n=4, the last step
df= pd.read_csv('n3hflow_hexaw3_aggregated.csv')
df.rename(columns={'Destination': 'Destination3'},
↪  inplace=True)
df['N4flow'] = None
df['Destination'] = None
df['Population']= None
df.to_csv('n4hflow_hexaw3_new.csv', index=False)
df = pd.read_csv('n4hflow_hexaw3_new.csv')
df_neighbors = pd.read_excel('hexa_nh_2023.xlsx')
df_neighbors['Neighbors'] =
↪  df_neighbors['Neighbors'].apply(ast.literal_eval)
df_neighbors_exploded = df_neighbors.explode('Neighbors')
merged_df = pd.merge(df, df_neighbors_exploded,
↪  left_on='Destination3', right_on='tile_ID', how='left')
merged_df['Destination'] = merged_df['Neighbors']
merged_df.drop(columns=['Neighbors', 'tile_ID'],
↪  inplace=True)
merged_df.to_csv('n4hflow_hexaw3_new2.csv', index=False)
merged_df.head()
df_new = pd.read_csv('n4hflow_hexaw3_new2.csv')
df_pop = pd.read_csv('n1hexa_w3.csv')
df_pop.columns.tolist()
df_new['Population'] = df_new.apply(
    lambda row: df_pop.loc[df_pop['tile_ID'] ==
    ↪  row['Destination'], 'Population'].values[0]
```

```
                if row['Destination'] in
                ↪  df_pop['tile_ID'].values else None,
                ↪  axis=1)


df_new.to_csv('n4hflow_hexaw3_new3.csv', index=False)
df_done = pd.read_csv('n4hflow_hexaw3_new3.csv')
def calculate_nflow_proportional(row, df):
    # Belirli bir N1flow değeri için toplam nüfusu bul
    total_population = df[df['flow'] ==
    ↪  row['flow']]['Population'].sum()

    # Eğer total_population değeri 0 ise, N1flow da 0 olacak
    if total_population == 0:
        return 0
    else:
        return row['flow'] * (row['Population'] /
        ↪  total_population)
df_done['N4flow'] =
↪  df_done.apply(calculate_nflow_proportional, axis=1,
↪  df=df_done)
df_done.drop(columns=['Population','flow', 'Destination3'],
↪  inplace=True)
df_done.rename(columns={'N4flow': 'flow'}, inplace=True)
df_done.to_csv('n4hflow_hexaw3_new_done.csv', index=False)
df_done.to_excel('n4hflow_hexaw3_new_done.xlsx')
df_done.head()
data = pd.read_csv('n4hflow_hexaw3_new_done.csv')
filtered_data = data[data['Origin'] != data['Destination']]
filtered_data.to_excel('n4hflow_hexaw3_senza_loops.xlsx')
filtered_data.to_csv('n4hflow_hexaw3_senza_loops.csv')
aggregated_data = filtered_data.groupby(['Origin',
↪  'Destination']).sum().reset_index()
aggregated_data.to_excel('n4hflow_hexaw3_aggregated.xlsx')
aggregated_data.to_csv('n4hflow_hexaw3_aggregated.csv')
aggregated_data.head()
#end
```

TEZDEN ÜRETİLMİŞ YAYINLAR

Makale

1. Ö. Öztürk Hacar, M. Hacar, F. Gülgen, and L. Pappalardo, "Where we rate: The impact of urban characteristics on digital reviews and ratings," Applied Sciences, vol. 15, no. 2, p. 931, 2025, doi: 10.3390/app15020931.

2. Ö. Öztürk Hacar, L. Pappalardo, F. Gülgen, and M. Nanni, "N-Step flow algorithm in pedestrian dynamics: Novel approaches to modeling urban flows," Scientific Reports, under review, 2025.

Konferans Bildirisi

1. M. Hacar, Ö. Öztürk Hacar, D. Altafini, L. Pappalardo, F. Gülgen, and V. Cutini, "From streets to screens: A deep dive into urban configuration and Google reviews," 14th Int. Space Syntax Symposium (SSS 14), Lefkoşa, Cyprus, Jun. 24–28, 2024.