Translated from English to Turkish - www.onlinedoctranslator.com

akıllı şehirler

MDPI

Madde

Kentsel Sürdürülebilirliği Geliştirmek: Akıllı Şehirler için Açık Kaynaklı Bir Yapay Zeka Çerçevesi Geliştirmek

Miljana Shulajkovska *, Maj Smerkol, Gjorgji Noveski ve Matjaž Gams

Akıllı Sistemler Bölümü, Jožef Stefan Enstitüsü, Jamova cesta 39, 1000 Ljubljana, Slovenya; maj.smerkol@ijs.si (MS); g.noveski@yahoo.com (GN); matjaz.gams@ijs.si (MG)
* Yazışma: miljana.sulajkovska@ijs.si ; Tel.: +386-1-477-3633

Önemli Noktalar:

Başlıca bulgular nelerdir?

- Urbanite projesi, her bir şehirdeki belirli hareketlilik zorluklarını etkili bir şekilde ele alan, dört farklı Avrupa şehrine uygulanan birleşik, açık kaynaklı bir simülasyon platformu geliştirdi.
- Simülasyon, gelişmiş görselleştirmeler, karar destek araçları ve makine öğrenimi modüllerinin entegrasyonu, kentsel planlamada karar alma sürecini önemli ölçüde iyileştirir.

Ana bulgunun anlamı nedir?

- Politika yapıcılar, kentsel hareketliliği ve sürdürülebilirliği iyileştirmek için bu yapay zeka destekli araçları kullanarak daha bilinçli ve veri destekli kararlar alabilirler.
- Metodolojinin diğer şehirlere de uyarlanabilmesi, Urbanite platformunun çeşitli kentsel ortamlarda ölçeklenebilirliğini ve esnekliğini göstermektedir.

Soyut: Kentsel politika yapıcılarının trafik yönetimi değişikliklerinin kapsamlı maliyet-fayda analizlerini yürütmelerini sağlayan gelişmiş araçlara olan artan ihtiyacı karşılamak için Urbanite H2020 projesi yenilikçi yapay zeka yöntemleri geliştirdi. Bunlar arasında, politika yapıcıların nesnel ve öznel kriterleri birleştirerek en uygun kentsel hareketlilik planlama değişikliklerini değerlendirmelerine ve seçmelerine yardımcı olan sağlam bir karar destek sistemi bulunmaktadır. Açık kaynaklı mikroskobik trafik simülasyon araçlarını kullanarak, dört pilot şehrin (Bilbao, Amsterdam, Helsinki ve Messina) her biri benzersiz hareketlilik zorluklarını ele alan doğru dijital modelleri (veya "dijital ikizleri") oluşturuldu. Bu zorluklar arasında Bilbao şehir merkezinde özel araç erişimini azaltmak, Amsterdam'da artan bisiklet trafiğinin ve nüfus artışının etkisini analiz etmek, Helsinki'de hareketliliği artıran bir tünel inşa etmek ve Messina'da toplu taşıma bağlantısını iyileştirmek yer almaktadır. Araştırma beş temel yeniliği tanıtmaktadır: çeşitli kentsel ortamlarda tutarlı bir açık kaynaklı simülasyon platformunun uygulanması, entegrasyon ve tutarlılık zorluklarını ele almak; akıllı şehirlerde gelişmiş karar desteği için Dexi'nin öncü kullanımı; gelişmiş görselleştirmelerin uygulanması; ve makine öğrenimi aracı Orange'ın kullanıcı dostu bir GUI arayüzüyle bütünleştirilmesi. Bu yenilikler toplu olarak karmaşık veri analizini teknik olmayan kullanıcılar için erişilebilir hale getirir. Çok etiketli makine öğrenimi tekniklerinin uygulanmasıyla, karar alma süreci üç kat hızlandırılır ve kentsel planlama verimliliği önemli ölçüde artırılır. Urbanite projesinin bulguları, mobilite müdahalelerinin hem beklenen hem de beklenmeyen sonuçlarına ilişkin değerli içgörüler sunarak, dünya çapındaki kentsel karar vericiler için ölçeklenebilir, açık kaynaklı AI tabanlı bir çerçeve sunar.

Anahtar kelimeler:akıllı şehir; simülasyon; hareketlilik politikası; karar desteği; makine öğrenimi

check for updates

Alıntı: Shulajkovska, M.; Smerkol, M.; Noveski, G.; Gams, M. Kentsel Sürdürülebilirliği Geliştirmek: Akıllı Şehirler için Açık Kaynaklı Bir Yapay Zeka Çerçevesi Geliştirmek.*Akıllı Şehirler***2024**, *7*, 2670–2701. https://doi.org/10.3390/akıllı şehirler7050104

Akademik Editör: Pierluigi Siano

Alındı: 4 Temmuz 2024
Gözden geçirildi: 6 Eylül 2024
Kabul edildi: 12 Eylül 2024
Yayımlandı: 18 Eylül 2024

Telif Hakkı:© 2024 yazarlar tarafından. Lisans sahibi MDPI, Basel, İsviçre. Bu makale, Creative Commons Atıf (CC BY) lisansının (https://creativecommons.org/licenses/by/4.0/) hüküm ve koşulları altında dağıtılan açık erişimli bir makaledir.

1. Giriş

1.1. Motivasyon

Kentleşmenin hızlı temposu, çağdaş kent merkezleri için karmaşık zorluklar ortaya çıkarıyor. Buna yanıt olarak, akıllı şehir konsepti [1–4] ortaya çıktı, kentsel yönetimi dönüştürmek için dijital teknolojilerden ve yenilikçi metodolojilerden yararlanıldı. Bu ilerlemeler

şehirlerin geleneksel sınırlamaları aşmasını, daha fazla sürdürülebilirliği, çevresel yöneticiliği, dayanıklılığı ve yaşanabilirliği teşvik etmesini sağlar. Bu kentsel evrimin merkezinde "dijital ikiz" kavramı yer alır [5,6], bir şehrin fiziksel ve sosyal altyapılarının dinamik, gerçek zamanlı temsillerini oluşturmak için dijital teknolojilerden yararlanır. Dijital ikizler, şehir plancılarına ve politika yapıcılara kritik içgörüler sunarak, zorlukları öngörmelerine ve kentsel yaşam kalitesini iyileştirmek için etkili çözümler geliştirmelerine olanak tanır.

Yapay zeka (YZ) [7] makine öğrenimi (ML) ve yapay genel zeka (AGI) gibi alt alanlardan yararlanarak akıllı şehir zorluklarının ele alınmasında önemli bir rol oynar. Yapay zeka modelleri, karmaşık kentsel verileri analiz etmek ve insan analistlerin gözünden kaçabilecek kalıpları belirlemek için paha biçilmezdir. Bu analitik yetenek, kentsel eğilimlere ilişkin öngörücü içgörüler üretir, politikaların etkisini değerlendirir ve altyapı optimizasyon önerilerini bilgilendirir. Ek olarak, yapay zekayı dahil etmek, kentsel ortamlardaki değişikliklerin geniş etkilerini kapsamlı bir şekilde değerlendirmek için çok önemlidir. İster yeni bir altyapı tanıtmak, ister ulaşım sistemlerini yeniden tasarlamak veya yenilikçi politikalar benimsemek olsun, bu değişiklikler, etkililiklerini ve şehrin hedefleri ve değerleriyle uyumlarını sağlamak için dikkatlice değerlendirilmelidir [1,8]. Bu yenilikçi AI tabanlı yaklaşımlar, kentsel planlamaya daha bütünsel bir yaklaşım sağlayarak trafik yönetimi verimliliğini artırır ve daha geniş akıllı şehir gelişimine katkıda bulunur [9].

Yapay zekanın, verilerden öğrenme ve verilere dayalı kararlar alma yeteneğine sahip sistemler oluşturmaya odaklanan bir alt kümesi olan makine öğrenimi (ML) de dahil olmak üzere bu teknolojiler, en etkili kentsel hareketlilik stratejilerini değerlendirmek ve seçmek için temel araçlar haline geldi [10,11]. Büyük miktarda gerçek zamanlı veriyi işleyerek, bu AI destekli sistemler şehir planlamacılarının trafik akışını optimize etmelerini, tıkanıklığı azaltmalarını ve genel kentsel verimliliği artırmalarını sağlayan dinamik, kanıta dayalı öneriler sunar. Urbanite gibi projeler, karar alma süreçlerini desteklemek ve kentsel trafik planlamasının modern şehirlerin gelişen ihtiyaçlarına duyarlı ve uyumlu kalmasını sağlamak için AI teknolojilerini dahil ederek bu dönüşümün ön saflarında yer almıştır.

Yapay Zeka ve Makine Öğrenimine ek olarak, Üretken Önceden Eğitilmiş Dönüştürücülerin (GPT'ler) geliştirilmesi yapay zekaya yeni bir boyut kazandırdı. İnsan benzeri metinler üretebilen bir yapay zeka türü olan GPT modelleri, doğal dil işlemede dikkate değer yetenekler gösterdi ve çeviri, özetleme ve yaratıcı yazma gibi görevlerde mükemmellik gösterdi. Bu modellerin etkileri teknik uygulamaların ötesine geçerek yapay zeka bilincinin kapsamlı analizlerini ve ChatGPT gibi modellerin Turing Testi'ni geçme potansiyelini teşvik etti [12].

Bu yeni ortaya çıkan teknolojiler akıllı şehir zorluklarına gelişmiş çözümler sunuyor. Örneğin, yeni bir tünel inşa etmek kirliliği azaltabilir, ancak aynı zamanda başka faydalar veya dezavantajlar da getirebilir. Karar vericiler genellikle her biri kendi avantaj ve dezavantaj setiyle birlikte gelen çok sayıda seçenekle karşı karşıyadır. Bu karmaşıklık, ekonomik uygulanabilirlik, çevresel sürdürülebilirlik, sosyal eşitlik ve toplum refahı gibi çok çeşitli faktörleri dikkate alma ihtiyacından kaynaklanmaktadır [3,4]. Etkili çözümler, maliyet etkinliği ve verimlilik gibi nesnel ölçütlerin yanı sıra kamuoyu, kültürel değerler ve paydaş katılımı gibi öznel hususları da ele almalıdır [6]. Kentleşme zorluklarının üstesinden gelmek, toplumsal açıdan kapsayıcı, çevresel açıdan sürdürülebilir ve kültürel açıdan alakalı niceliksel veri odaklı analiz ile nitel içgörüler arasında dikkatli bir denge gerektirir [13].

Kentsel trafik yönetimi, trafik akışını optimize etmek ve tıkanıklığı en aza indirmek için uzun zamandır çeşitli araçlar ve metodolojiler kullanmaktadır. Geleneksel yaklaşımlar arasında trafik sinyal kontrol sistemleri, uyarlanabilir trafik yönetim sistemleri (ATMS'ler) ve gerçek zamanlı trafik bilgi hizmetleri yer almaktadır. Bu sistemler genellikle koşulları izlemek ve gerçek zamanlı ayarlamalar yapmak için sensör ağlarına, trafik kameralarına ve GPS verilerine güvenir. Örneğin, uyarlanabilir trafik sinyal sistemleri, akış verimliliğini artırmak için mevcut trafik düzenlerine göre ışık zamanlamalarını değiştirebilir. Ek olarak, öngörücü trafik modellemesi yaygın olarak kullanılmakta olup, şehirlerin geçmiş verilere ve mevcut eğilimlere göre tıkanıklığı tahmin etmelerine olanak tanımaktadır.

Geleneksel yöntemler bir nebze etkili olsa da, modern kentsel ortamların giderek karmaşıklaşan taleplerini karşılamakta sıklıkla zorluk çekerler. Tahmin edilemeyen trafik düzenleri, yeni ulaşım modlarının entegrasyonu ve özellikle kültürel ve toplumsal etkiler göz önünde bulundurulduğunda potansiyel şehir değişikliklerini değerlendirme ihtiyacı gibi zorluklar, bu geleneksel yaklaşımların sınırlamalarını vurgular. Urbanite projesi, gelişmiş AI destekli karar destek sistemleri ve ML algoritmalarının entegrasyonu yoluyla mevcut trafik yönetim araçlarını geliştirerek bu boşlukları ele alır. Bu teknolojiler, daha doğru tahminler ve trafik koşullarına uyarlanabilir yanıtlar sağlayarak, günümüzün şehirlerinin değişen ihtiyaçlarına daha uygun daha dinamik ve esnek yönetim stratejilerini kolaylaştırır.

1.2. Katkı

Bu makale, çok sayıda katılımcının yer aldığı üç yıllık bir girişim olan Urbanite H2020 projesi kapsamında geliştirilen bulgulara ve metodolojilere dayanmaktadır (daha fazla ayrıntı için Urbanite projesinin web sitesini ziyaret edin:https://urbanite-projesi.eu, (11 Eylül 2024'te erişildi). Proje, kentsel karar alma süreçlerini iyileştirmek için yıkıcı teknolojilerden yararlanmaya odaklanıyor.

Urbanite projesinin temeli, çeşitli trafik senaryolarını modellemek için gerçek zamanlı verileri birleştiren açık kaynaklı simülasyon araçlarında yatmaktadır. Bu araçlar, karar vericilere trafiği proaktif bir şekilde yönetmek için eyleme geçirilebilir içgörüler sunan AI ve ML modülleriyle geliştirilmiştir. Dahası, Urbanite'ın yaklaşımı, yerel paydaşları karar alma sürecine dahil etmek, çözümlerin teknolojik olarak gelişmiş, bağlamsal olarak alakalı ve sosyal olarak kapsayıcı olmasını sağlamak için tasarlanmıştır.

Urbanite, bu yeniliklerle geleneksel trafik yönetim sistemlerinin sınırlamalarını ele alıyor. Kentsel mobilite çözümleri için yeni bir standart belirliyor ve öznel ve nesnel değerlendirmelere dayalı sürdürülebilir ve yenilikçi şehir gelişiminin daha geniş hedeflerine katkıda bulunuyor. Bu makale, Urbanite platformunun beş entegre modülünde kapsüllenen çeşitli yenilikleri tanıtıyor. Bu modüllerin her biri belirli bir alanda yeni bir yaklaşımı temsil ediyor:

1. Dört farklı şehirde test edilen birleşik, geliştirilmiş, açık kaynaklı bir simülatör: Bilbao, Amsterdam, Helsinki ve Messina olmak üzere dört büyük şehirde gerçekçi kentsel ortamları modellemek için birleşik, açık kaynaklı bir simülatörün uygulanması, bildiğimiz kadarıyla, kentsel planlamada yeni bir başarıyı temsil ediyor.
2. Dexi aracıyla gelişmiş bir karar destek ve öneri modülü: Bu makale, DEXi'nin çeşitli akıllı şehirler için ilk uygulamasını sunarak, dört farklı kentsel ortamın benzersiz ihtiyaçlarına göre uyarlanmış prototip karar desteği sunma yeteneğini kanıtlıyor.
3. Kapsamlı politika değerlendirmesi için gelişmiş görselleştirmeler: Mevcut görselleştirme yöntemlerine ek olarak, politika etkilerine dayalı çeşitli senaryoların beş boyutlu sunumunu destekleyen gelişmiş görselleştirmeleri sunuyoruz; bu sayede politika değerlendirmesinin derinliği ve netliği önemli ölçüde artıyor.
4. Orange aracıyla bir ML modülü: Simülasyon çıktılarının Orange makine öğrenme aracıyla bütünleştirilmesi [14] şehir ekiplerinin geleneksel programlamaya ihtiyaç duymadan gelişmiş ML yeteneklerinden yararlanmasını sağlayarak bu güçlü araçları daha geniş bir kitleye ulaştırıyor.
5. Gelişmiş çok etiketli ML modülü: Bu modül, çok etiketli analizi etkinleştirmenin yanı sıra, karar alma sürecini önemli ölçüde hızlandırır, yeni politikaları simüle etmek için gereken süreyi üç kat azaltır ve politika değerlendirmelerinin saatler yerine saniyeler içinde gerçekleştirilmesini sağlar [15,16].

Urbanite yaklaşımı, her biri Urbanite şehir ekibi tarafından belirlenen benzersiz gereksinimlere sahip dört şehir olan Bilbao, Amsterdam, Helsinki ve Messina üzerinde değerlendirildi. Bu yazılım platformunun bu çeşitli senaryolardaki başarısı, diğer Avrupa şehirlerine potansiyel uygulanabilirliğini göstermektedir. İş birliğini teşvik ederek, insan içgörülerini AI teknolojileriyle birleştirerek ve bir simülasyon aracı entegre ederek, şehirlere özgü öznel temel performans

Göstergeler (KPI'lar), bir öneri motoru ve ML tekniklerini içeren bu proje, Avrupa şehirlerinin akıllı, geleceğe hazır kent merkezlerine dönüşümünü zenginleştirmeyi hedefliyor.

Bu makalenin geri kalanı şu şekilde düzenlenmiştir. Bölüm2ilgili çalışmaları gözden geçirir ve analiz eder. Bölüm3önerilen sistemin genel bir tanımını sağlar. Bu bölümde, mimari ve modüllerin her biri açıklanır. Önerilen sistemle toplanan verilerin örnek sonuçları Bölüm'de sunulmuştur4ve Bölümde daha ayrıntılı olarak tartışılmıştır5. Bölüm 6Gelecekteki çalışmalara yönelik bir planla son bulur.

2. Literatür Taraması

Akıllı şehir girişimleri, akıllı, verimli ve sürdürülebilir kentsel ekosistemleri desteklemek için teknolojiyi entegre eden kentsel gelişimde dönüştürücü bir dönemin parçasıdır. Bu girişimlerin ön saflarında yer alan öncü bir proje olan Urbanite, Avrupa şehirlerindeki mobilite politikasını ve karar alma süreçlerini yıkıcı teknolojiler aracılığıyla devrim niteliğinde değiştirmeye odaklanmaktadır.

Akıllı şehirler, akıllı, verimli ve sürdürülebilir ekosistemler için teknolojiyi kullanarak kentsel gelişimde bir değişimi ifade eder. Bu girişimler, trafik sıkışıklığı ve sürdürülebilirlik gibi zorlukları ele alır ve kentsel yaşamı iyileştirir. Songdo ve Barselona Akıllı Şehri gibi projelerde görülen konseptin evrimi, kapsamlı kentsel yaşam iyileştirmeleri için dijital teknolojileri entegre eder [17,18]. Temel kavramlar arasında Nesnelerin İnterneti (IoT) ve trafik, hava kalitesi ve enerji tüketimi hakkında gerçek zamanlı veriler için sensör ağları yer almaktadır [19], bilinçli seçimler için karar destek sistemleri ve veri analitiği [20,21], sürdürülebilir ulaşım için kentsel hareketlilik çözümleri, politika etki değerlendirmeleri için simülasyon araçları ve gerçek zamanlı şehir optimizasyonu için dijital ikizler [22–25Sürdürülebilirlik, vatandaş katılımı, siber güvenlik, açık veri girişimleri, iş birliği ve dayanıklılık planlaması, teknolojik olarak gelişmiş, çevreye duyarlı ve vatandaşa duyarlı şehirler yaratmanın ayrılmaz bir parçasıdır.

Tek şehirli akıllı şehir projelerinde, çeşitli girişimler kentsel gelişim için teknolojinin çok yönlü uygulamalarını sergiliyor. Singapur'un Akıllı Ulus Girişimi [26] verimli trafik yönetimi ve bilinçli karar alma için kapsamlı IoT çözümleri ve öngörücü analizler kullanır. Barselona'nın Akıllı Şehir Projesi [18] IoT sensörleri ve veri analitiği uygulayarak sürdürülebilir ulaşım ve veri odaklı karar almaya öncelik verir. Güney Kore'nin Uluslararası İş Bölgesi olan Songdo, akıllı ulaşım sistemleri ve kentsel planlama için dijital ikizler gibi gelişmiş teknolojileri entegre eden yeşil alan akıllı bir şehir olarak öne çıkıyor [17]. Dubai'nin Akıllı Dubai projesi [27] güvenli işlemler ve karar desteği için blok zinciri ve yapay zekayı kullanan kapsamlı bir dönüşüme odaklanıyor. Kopenhag'da, Bağlantı projesi [28] veri odaklı kentsel planlamayı vurgular, akıllı trafik yönetimi ve sürdürülebilir ulaşımla ilgili kararları bilgilendirmek için çeşitli kaynaklardan gelen bilgileri entegre eder. Toronto'nun Kaldırım Laboratuvarları [29] gelişmiş sensörler, veri analitiği ve simülasyon araçları kullanarak yenilikçi kentsel çözümler sundu. Sürdürülebilir kentsel gelişimde makine öğreniminin kablosuz sensör ağlarıyla birleştirilmesinin dönüştürücü potansiyeli kapsamlı bir şekilde incelendi [30], akıllı şehir girişimlerindeki önemlerini vurgulayarak. Amsterdam'ın Akıllı Şehri [31] girişimi, trafik optimizasyonu ve elektrikli mobilite için IoT uygulamalarını kullanarak sürdürülebilir kentsel kalkınmayı teşvik ediyor.

Çok şehirli, akıllı şehir projelerinde, Akıllı Şehirler ve Topluluklar Avrupa Yenilik Ortaklığı (EIP-SCC) [32] Avrupa genelinde akıllı şehir girişimlerini destekleyen işbirlikçi bir platformdur. Uzmanlaşmış bir çözüm olarak Urbanite, özel mobilite politikası yönetimi, gelişmiş karar destek sistemleri ve kentsel planlama için etkili simülasyon araçları sağlayarak akıllı şehir manzarasında öne çıkmaktadır. ML'deki yeniliğe odaklanması, karar alma verimliliğini daha da artırmaktadır. EIP-SCC'nin daha geniş hedefleriyle uyumlu olarak Urbanite, akıllı şehir çözümlerini ilerletmede işbirlikçi çabalara katkıda bulunmakta ve kentsel gelişimin gelişen manzarası içinde uzmanlaşmış ve yenilikçi bir yaklaşım sunmaktadır.

Son çalışmalar, akıllı şehirlerde kentsel sürdürülebilirliği teşvik etmede veri odaklı yaklaşımların önemini vurgulamaktadır. ['de vurgulandığı gibi, paydaş iş birliğini teşvik eden akıllı şehir politikalarına ihtiyaç vardır33], Urbanite'ın AB'yi hızlandırma hedefiyle uyumludur.

Bilgi alışverişi yoluyla ropean şehir dönüşümü. Karar alma sürecinde büyük veri analitiğinin rolü, [34], Urbanite'ın gelişmiş karar destek sistemlerinin kullanımıyla örtüşmektedir. Kentsel verimlilik için dijital çözümlerin keşfi [35] ayrıca Urbanite'ın kentsel yaşam kalitesini artırmaya odaklanmasıyla da uyumludur. Ayrıca, [36,37] Urbanite'ın yenilikçi yaklaşımını yansıtan karar alma ve inovasyon için yapay zekanın nasıl kullanılacağını tartışın. ['de önerilen sürdürülebilirlik değerlendirme çerçeveleri38] Urbanite'ın sürdürülebilirliğe olan bağlılığını tamamlar. Ek olarak, ref. [39] kentsel rekabetin çok boyutlu yapısını vurgulayarak, kentlerin genel rekabet gücünü artırmak için kentsel planlamada sosyo-kültürel, çevresel ve güvenlik yönlerinin bütünleştirilmesinin önemini vurgulamaktadır.

Scopus veritabanındaki akıllı şehir literatürüne ilişkin kapsamlı bir genel bakış [40]. Belirli bir sorgu gönderildiğinde şu sonuçlar elde edildi: “akıllı şehir” (2021'de 4282, 2022'de 3537, 2023'te 3306), “yapay zeka” (2021'de 33.735, 2022'de 35.689, 2023'te 43.409) ve her ikisi bir arada (2021'de 282, 2022'de 230, 2023'te 246). Bu rakamlar, aynı dönemde “yapay zeka” anahtar kelimesi için yapılan sonuçlarda yaklaşık üçte bir oranında önemli bir artış olduğunu ortaya koyuyor. Bu eğilim, özellikle Avrupa Birliği'nin bu alanda Çin, Singapur gibi bazı Asya ülkeleri ve Amerika Birleşik Devletleri'nden yoğun rekabetle karşı karşıya olmasıyla, yapay zekanın akıllı şehir alanında merkezi bir araştırma ve geliştirme alanı olarak giderek artan önemini vurguluyor.

Urbanite, İHA'lar gibi çığır açan teknolojileri entegre ederek öne çıkıyor [41] ve AI ve ML'yi akıllı şehir geliştirme için birleşik bir platforma dönüştürüyor. Belirli yönlere odaklanan diğer çalışmalardan farklı olarak Urbanite, kentsel hareketlilik zorlukları için bütünsel bir çözüm sunuyor. Kişiye özel yaklaşımı, bağlamsal alaka sağlayarak Avrupa şehirlerinin benzersiz ihtiyaçlarını ele alıyor. Dexi ve Orange ML gibi teknolojileri kullanan Urbanite'ın gelişmiş karar destek sistemleri ve simülasyon araçları, bilgilendirilmiş karar alma ve politika simülasyonunu mümkün kılıyor. Dahası, Urbanite gerçek dünya çözümleri uygulayarak pilot şehirlerde etkinliğini doğruluyor ve araştırma-uygulama açığını kapatıyor. Paydaş iş birliğine vurgu yapması kapsayıcılığı sağlıyor ve çeşitli bakış açılarını yansıtıyor, bu da onu akıllı şehir geliştirmede lider bir girişim haline getiriyor. Referanslar Tablo'da şematik olarak sunulmuştur1.

Tablo 1. Akıllı şehir geliştirme ve teknolojilerinde temel referanslar.

Referans	Odak/Katkı	Teknoloji/Tema
[17,18]	Songdo ve Barselona'dan örneklerle akıllı şehir konseptlerinin evrimi	Dijital teknolojiler, kentsel gelişim
[19]	Gerçek zamanlı kentsel veri toplama için IoT ve sensör ağlarının kullanımı	IoT, sensör ağları
[20,21]	Kentsel planlama için karar destek sistemleri ve veri analitiği	Karar destek sistemleri, veri analitiği
[22–25]	Kentsel mobilite çözümleri, politika etki değerlendirmeleri ve dijital ikizler	Simülasyon araçları, kentsel mobilite, dijital ikizler
[26]	Singapur'un Akıllı Millet Girişimi, trafik yönetimi için IoT ve öngörücü analitiği kullanıyor	IoT, öngörücü analiz, trafik yönetimi
[27]	Dubai'nin Blockchain ve AI kullanan Akıllı Şehir dönüşümü	Blockchain, AI, kentsel dönüşüm
[28]	Veri odaklı kentsel planlama için Kopenhag'ın Bağlantı Projesi	Veri analitiği, şehir planlama
[29]	Toronto'nun Sidewalk Labs'ı gelişmiş sensörler, veri analitiği ve simülasyon araçlarıyla donatılmıştır	Sensörler, veri analitiği, simülasyon araçları
[30]	Sürdürülebilir kentsel kalkınmada ML ve WSN'lerin dönüştürücü potansiyeli	Makine öğrenimi, kablosuz sensör ağları

Tablo 1. *Devamı*

Referans	Odak/Katkı	Teknoloji/Tema
[31]	Amsterdam'ın IoT uygulamalarını kullanarak sürdürülebilir kentsel gelişime yönelik akıllı şehir girişimi	IoT, sürdürülebilir kalkınma
[32]	Akıllı Şehirler ve Topluluklar Konusunda Avrupa Yenilik Ortaklığı (EIP-SCC) iş birliği platformu olarak	İşbirliği, akıllı şehir girişimleri
[33]	Akıllı şehir politikalarında iş birliğinin önemi	İşbirliği, politika geliştirme
[34]	Kentsel karar alma süreçlerinde büyük veri analitiğinin rolü	Büyük veri analitiği, karar verme
[35]	Kentsel verimlilik için dijital çözümler	Dijital çözümler, kentsel verimlilik
[36,37]	Kentsel karar alma ve inovasyon için yapay zekanın kullanılması	Yapay zeka, inovasyon
[38]	Akıllı şehirler için sürdürülebilirlik değerlendirme çerçeveleri	Sürdürülebilirlik, değerlendirme çerçeveleri
[39]	Kentsel rekabette sosyo-kültürel, çevresel ve güvenlik boyutlarının bütünleştirilmesi	Kentsel rekabet gücü, sosyo-kültürel, çevresel, güvenlik
[41]	Kentsel mobiliteyi artırmak için İHA'lar ve yapay zeka	İHA'lar, Yapay Zeka, Kentsel Mobilite

Urbanite'ın yenilikçiliği, ML, simülasyon araçları ve karar destek sistemlerinin kullanımında yatmaktadır. Bu teknoloji odaklı yaklaşım yalnızca kentsel planlamayı geliştirmekle kalmaz, aynı zamanda modern şehirlerin dinamik karmaşıklıklarını da ele alır. Projenin mobilite politikası yönetimine vurgu yapması, şehirlerin bugün karşı karşıya olduğu kritik zorluklarla uyumludur.

3. Metodoloji

3.1. Genel Şema

Önerilen çerçeve, Şekil'de gösterilmiştir1, insanların hareketlerini ve şehrin altyapısını kapsayan temel şehirle ilgili verileri toplamakla başlar. Karar vericiler daha sonra belirli kentsel zorlukları ele almak için bir dizi olası senaryo taslağı hazırlar. Bu senaryolar mikroskobik bir trafik simülatörü kullanılarak simüle edilir ve önceden tanımlanır ve değişiklikleri temel senaryoya göre değerlendirmek için öznel KPI'lar hesaplanır.

Temel performans göstergeleri (KPI'ler), Urbanite projesi kapsamında kentsel hareketlilik stratejilerinin etkinliğini ve ilerlemesini değerlendirmek için kullanılan temel ölçütlerdir. Bu göstergeler, trafik akışı, çevresel etki ve kamu memnuniyeti gibi kentsel gelişimin çeşitli boyutlarını değerlendirmek için nicel bir temel sunar. Sağlanan yüzde aralıkları, her katılımcı şehrin KPI'leri kendi benzersiz bağlamına ve belirli hedeflerine uyarlamasını sağlayan esneklik için tasarlanmıştır. Bu değerler, hem uygulanabilir hem de gerçekliğe dayalı olmalarını sağlayarak, tarihsel verilerin, simülasyonların ve uzman görüşlerinin bir sentezinden türetilmiştir. Urbanite 1.0 yazılım sistemi bu KPI'leri karar alma girdileri olarak kullanırken, bunların evrensel olarak uygulanabilir olmadığını kabul etmek önemlidir. Bunun yerine, her şehrin belirli koşullarını ve önceliklerini yansıtacak şekilde özelleştirilmiştir ve hem nesnel ölçümleri (örneğin, trafik akışı) hem de öznel faktörleri (örneğin, vatandaş memnuniyeti) kapsar. Bu genelleştirilmiş çerçeve, her kentsel ortamdaki farklı kısıtlamaları ve fırsatları hesaba katmak için vaka bazında daha ayrıntılı KPI'ler geliştirilerek bir temel görevi görür. Bu özel yaklaşım, KPI'ların güncel ve eyleme geçirilebilir kalmasını sağlayarak projenin kentsel hareketlilik ve sürdürülebilirlik üzerindeki genel etkisini artırıyor.

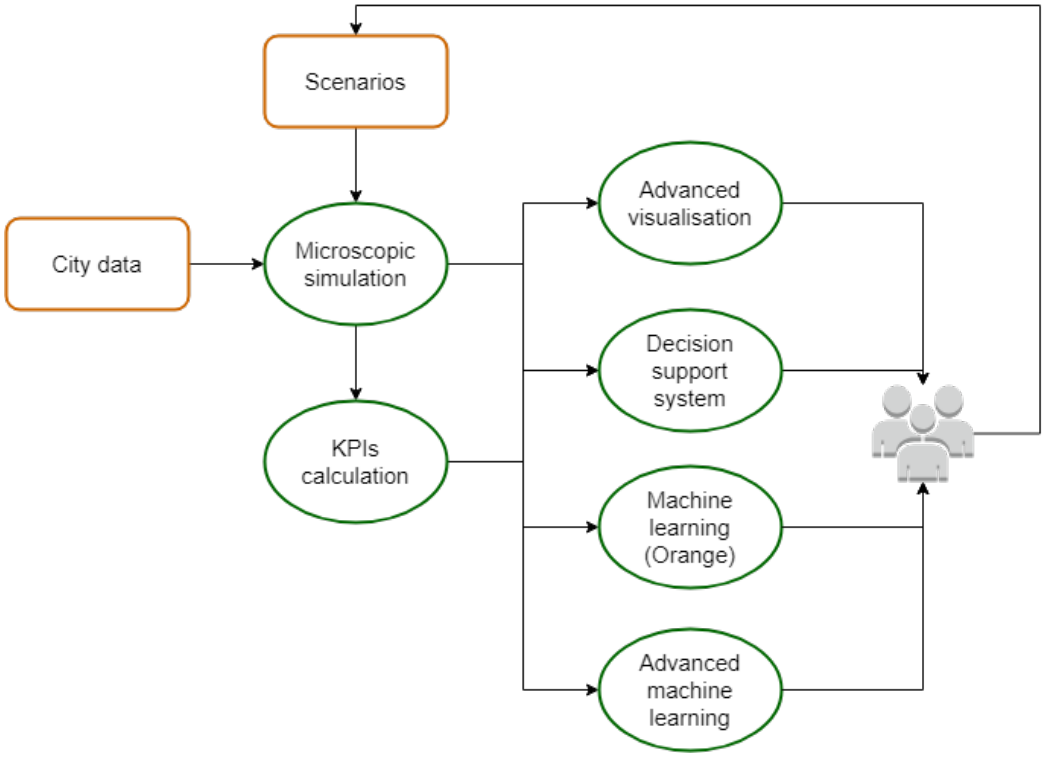

Şekil 1. Genel Şehirli şeması.

Daha sonra, hesaplanan KPI'lar her biri kapsamlı bir analize katkıda bulunan dört ayrı modül için girdilerdir. Bu modüller, kullanıcı dostu gösterimler için gelişmiş görselleştirmeler, bir karar destek sistemi, desen tanıma ve simüle edilmemiş senaryoları tahmin etmek için Orange aracını kullanan bir ML modülü ve kullanıcı tanımlı tercihlere dayalı politikalar öneren gelişmiş bir ML modülü içerir.

Programcı olmayanlar tarafından kullanılmak üzere tasarlanmış Orange aracı, ML modüllerinden birinin sorunsuz bir şekilde uygulanmasını sağlar. Giriş özellikleri olarak KPI'ları ve hedef olarak bir mobilite politikasını kullanan gelişmiş ML modülü, algoritmasını veri öğrenimi yoluyla iyileştirir. Bu süreç, modülün kullanıcı tarafından belirtilen tercihlerle uyumlu en iyi mobilite politikalarını tahmin etmesini sağlar. Özünde, bu mimari veri toplamayı, senaryo simülasyonunu ve analizi kentsel zorlukları ele almak için birleşik ve erişilebilir bir çözüme entegre eder. Aşağıdaki alt bölümler, bu modüllerin her biri hakkında ayrıntılı bir tartışma sunar.

3.2. Simülasyon

Urbanite simülasyon modülü, her biri benzersiz talepler ve kentsel zorluklarla mücadele eden dört ayrı şehri aynı anda modelleme yeteneğiyle karakterize edilir. Bu çalışmadaki simülasyon iki temel amaca hizmet eder: birincisi, her bir şehirdeki mevcut trafik dinamiklerinin doğru bir modelini oluşturmak ve ikincisi, bu temel temsile dayalı çeşitli senaryoları değerlendirmek. Mikroskobik trafik simülasyonları, karmaşık kentsel trafik modellerini anlamak için ayrıntılı, veri odaklı bir çerçeve sağladıkları için bu hedeflere ulaşmak için olmazsa olmazdır.

Dört şehrin eş zamanlı modellemesi, esas olarak her bir kentsel ortamla ilişkili içsel karmaşıklıklar ve özellikler nedeniyle birçok zorlukla karşı karşıyadır. Bu karmaşıklıklar, her bir şehir tarafından sağlanan verilerin çeşitli biçimleri, veri özelliklerindeki farklılıklar ve veri gizliliğini çevreleyen genel endişeler dahil olmak üzere çeşitli faktörler tarafından yönlendirilir. Modelleme süreci MATSim (Çoklu Ajan Taşıma Simülasyonu) aracına dayanmaktadır [42], SUMO (Kentsel Hareketlilik Simülasyonu) gibi diğer önde gelen simülasyon yöntemleriyle karşılaştırıldığında amaçlarımız için en uygun seçim olarak kabul edildi [24] ve PTV Vissim [43]. Seçim için çeşitli simülasyon yazılım paketleri dikkate alındı, en uygun olanlar Tablo'da listelenmiştir.2Gerekli özellikler

araçlar arasında entegrasyon kolaylığı ve genişletilebilirlik, en azından araba, bisiklet ve toplu taşıma modlarını kapsayan çok modlu simülasyonları destekleme yeteneği ve mikroskobik simülasyonlar gerçekleştirme yeteneği yer alır. Çoğu modern trafik simülasyon aracı bu kriterleri karşılar; ancak, MATSim nihayetinde üstün genişletilebilirliği ve entegrasyon kolaylığı nedeniyle seçildi.

Tablo 2. Seçili trafik simülasyon araçlarının karşılaştırılması. Proje teklifinde belirtildiği gibi yalnızca açık kaynaklı yazılım paketleri değerlendirilirken, ticari araçlar endüstri standardı olarak kabul edildi ve özellik bütünlüğü için bir ölçüt olarak kullanıldı.

Simülasyon	Açık Kaynak	Çok modlu	Mikroskobik	Yorum
MATSim	Evet	Evet	Evet	Genişletilmesi ve entegre edilmesi
SUMO	Evet	Evet	Evet	kolay Genişletilmesi ve entegre
TRANSİMLER	Evet	Kısmen	Evet	edilmesi zor Geliştirme etkin değil
Herhangi bir mantık	HAYIR	Evet	Evet	Reklam
PTV Vizyonu	HAYIR	Evet	Evet	Reklam

Yaygın olarak benimsenen bir mikroskobik trafik simülasyon aracı olan SUMO, karmaşık ayrıntılarla geniş ulaşım ağlarını kopyalamada mükemmeldir. Tek tek araçların özelliklerini, etkileşimlerini ve kentsel trafiğin dinamiklerini ustalıkla yakalar. SUMO, şerit değişikliklerini, trafik ışıklarını ve yol altyapısını hesaba katarak son derece gerçekçi kentsel trafik simülasyonları sunar.

Buna karşılık, PTV Vissim, programlar, rotalar ve yolcu davranışları dahil olmak üzere çeşitli toplu taşıma sistemi bileşenlerinin kapsamlı modellemesini sunan toplu taşıma simülasyonlarında uzmanlaşmıştır. PTV Vissim, analistlerin toplu taşıma performansını değerlendirmesini ve verimliliği, güvenilirliği ve yolcu memnuniyetini iyileştirme fırsatlarını belirlemesini sağlar.

MATSim, karmaşık ulaşım sistemlerini modellemek için özel olarak tasarlanmış, aktivite tabanlı, çoklu ajan simülasyon çerçevesidir. MATSim içindeki ajanlar, kapsamlı bir ağdaki bireysel yolcuların karmaşık davranışlarını ve etkileşimlerini simüle eder. Çerçeve, özünde, işe gidiş geliş kalıpları, ulaşım modu seçimleri ve rota seçimi dahil olmak üzere her yolcunun günlük aktivitelerini kopyalar. Bu ayrıntılı simülasyon yaklaşımı, ulaşım dinamikleri ve bunların kentsel hareketlilik için önemli etkileri hakkında ayrıntılı bir anlayış sunar. Simülasyonu yürütmek için, şehir haritaları ve trafik verileri gibi nüfus talebiyle ilgili çeşitli girdi dosyaları (Şekil2), sağlanmalıdır. MATSim, esnekliği ve daha büyük yazılım sistemlerine kusursuz entegrasyonu nedeniyle seçildi.

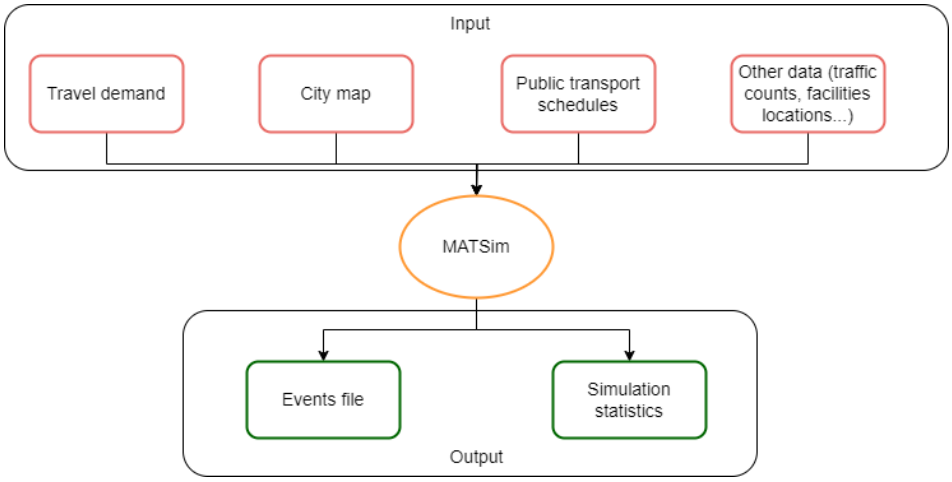

Şekil 2.MATSim giriş/çıkış verileri.

Simülasyon, Mobsim modülünde işlenen ve ardından puanlama modülünde bir değerlendirme yapılan ilk bir taleple başlar. Bu değerlendirme, yolculuk süresi, maliyet, çevresel etki ve kullanıcı tercihleri gibi kriterlere dayanır. Simülasyon, sistem performansını sürekli olarak optimize etmek için birden fazla yinelemeden geçerek son derece uyarlanabilirdir. Bu esneklik, simülasyonun yeniden planlama modülü tarafından yönetilen değişen koşullara ve politika müdahalelerine hızla yanıt vermesini sağlar. Bu sürecin döngüsel ve uyarlanabilir doğası Şekil'de gösterilmiştir3.

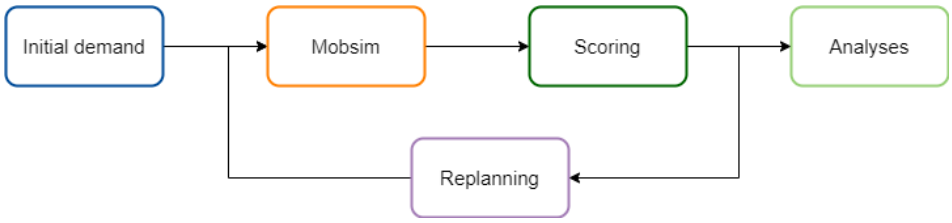

Şekil 3.MATSim çevrimi.

MATSim'i dört şehirde başarıyla uygulamak için, gerçekçi aracıların ve bunlara karşılık gelen taleplerin geliştirilmesi de dahil olmak üzere girdi verilerinde birkaç ayarlama yapılması gerekiyordu. Örneğin, bir öğrenci normal koşullar altında sabahleyin bir fakülteye gitmek için tipik bir rotayı takip edebilir ancak trafik sıkışıklığı durumunda alternatif bir rota seçebilir. Aracılar ve talepleri, Urbanite projesine özgü genel bir çerçeve içinde geliştirilen bir plan oluşturur. Tipik bir Pazartesi gibi belirli bir günde, yaş gibi niteliklere göre kategorize edilen insanların hareketlerine ilişkin şehre özgü verileri içerir. Urbanite simülasyon modelini gösteren bir akış şeması Şekil'de verilmiştir4.

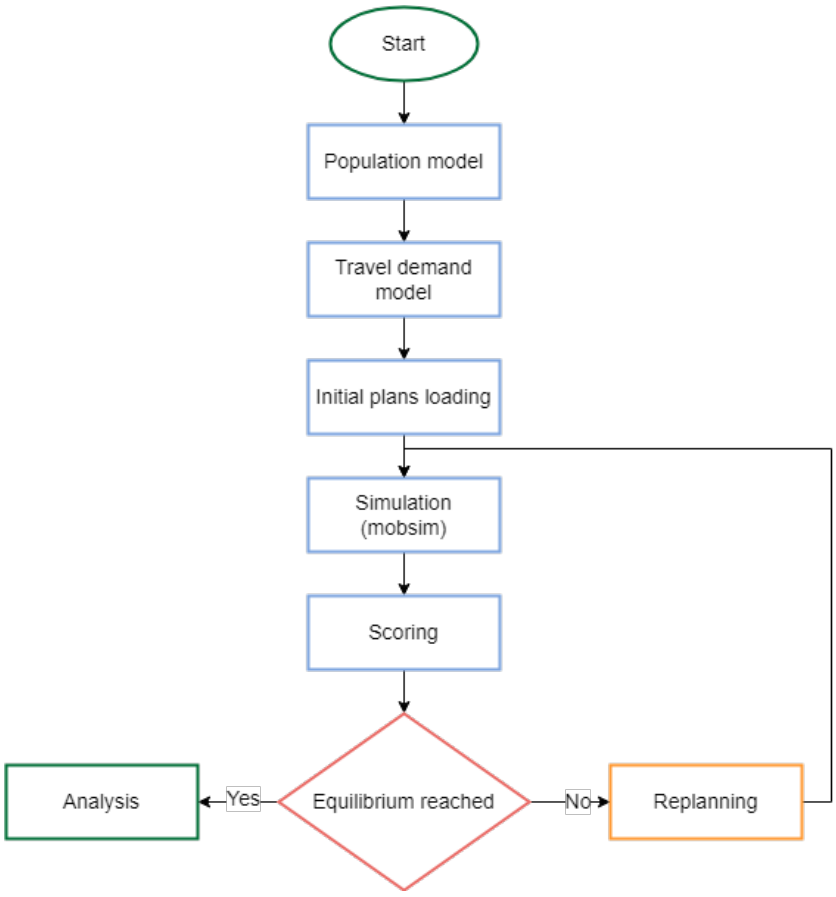

Şekil 4. Urbanite simülasyon modelinin akış şeması.

3.3. KPI'ların hesaplanması

Bu alt bölümde, bir trafik simülasyonunun özünü yakalayan nesnel ve öznel KPI metriklerini belirlemek için kullanılan algoritmaları inceliyoruz. KPI algoritmaları, şehrin karar vericileriyle iş birliği içinde tanımlanan trafik simülasyonu sonuçlarına dayalı olarak belirli metriklerin değerlerini hesaplar. KPI'lar, DSS (Karar Destek Sistemi) bölümünde daha ayrıntılı olarak açıklanan dört pilot şehrin tamamında birleşik bir değerlendirme çerçevesi sağlar. Ek olarak, hesaplanan KPI'lar tercih alanını tanımlayarak farklı mobilite politikalarının değerlendirilmesine ve karşılaştırılmasına olanak tanır.

Her pilot şehirle işbirliği içinde, Tablo'da listelendiği ve açıklandığı gibi çeşitli KPI'lar geliştirildi.3Bu KPI'lar, tutarlı bir çerçeve içinde yaşam kalitesini değerlendirmek için uzman bir yöntem sunar. Bu çerçeve, karar destek ve öneri sistemiyle otomatik entegrasyonu kolaylaştırır.

KPI hesaplamaları, ilgili olayları filtrelemeyi ve verileri uygun şekilde haritalamayı ve toplamayı içeren simülasyon sonuçlarını analiz etmeye dayanır. Bölüm Sonuçları, her şehir için belirli KPI'ların nasıl hesaplandığını ayrıntılı olarak açıklar.

Tablo 3. Temel performans göstergelerinin açıklamaları ve bunların kentsel hareketlilik ve sürdürülebilirliğin çeşitli yönleriyle ilişkisi.

KPI	Tanım	Pilotta Kullanıldı
Bisiklet altyapısı	Puanlar, yol türlerini kategorilere ayıran Open-StreetMap verilerine (OSM) göre her yol segmentine atanır. En yüksek puan "bisiklet yolu" olarak sınıflandırılan segmentlere tahsis edilirken, en düşük puanlar "otoyol" veya "basamaklar" olarak belirlenen segmentlere verilir.	Amsterdam
Bisiklet hız sınırı	Puanlar, OpenStreetMap tarafından sağlanan maksimum hız sınırı etiketine göre her yol segmentine tahsis edilir. En yüksek puanlar, 30 km/saat hız sınırına sahip yol segmentlerine verilirken, en düşük puanlar, 50 km/saat hız sınırını aşan segmentlere atanır.	Amsterdam
Bisiklet yoğunluğu	Yol segmenti başına kaydedilen bisiklet trafiği hacmi.	Amsterdam
Bisiklet sıkışıklığı	Tıkalı yol bölümlerinin toplam uzunluğu, bisiklete binmenin yasak olduğu veya mümkün olmadığı yerler hariç olmak üzere tüm bisiklete binilebilen bölümler için ölçülür. Bu ölçüm, hesaplanan trafik akışı değerlerine dayanır.	Amsterdam
Bisiklet payı	Toplam yolculuk sayısına göre bisiklet yolculuklarının oranı.	Bilbao, Messina
Araba payı	Toplam yolculuk sayısına göre araba yolculuklarının oranı.	Bilbao, Messina
Payı toplu taşıma	Toplu taşıma yolculuklarının toplam yolculuk sayısına oranı.	Bilbao, Messina
Ortak2, ÖĞLEDEN SONRA10, HAYIRx	Hava kirletici emisyonları, simüle edilmiş trafik verilerine dayalı Karayolu Taşımacılığı Emisyon Faktörleri El Kitabı (HBEFA) kullanılarak tahmin edilmiştir.	Bilbao, Helsinki, Messina
Ortalama yaya gezi zamanı	Yaya yolculuklarının ortalama süresi.	Bilbao
Sıkışıklıklar ve darboğazlar	Hesaplanan trafik akış değerlerine göre belirlenen, sıkışıklığın yaşandığı yol segmentlerinin kümülatif uzunluğu.	Helsinki
Liman alanı trafik akışı	Belirli bir noktada, Jätkäsaari Akıllı Kavşağında ölçülen trafik akışı.	Helsinki

Tablo 3.*Devamı*

KPI	Tanım	Pilotta Kullanıldı
Toplu taşıma kullanımı	Tüm toplu taşıma araçlarındaki toplam yolcu sayısı.	Messina
Ortalama hız toplu taşıma	Tüm toplu taşıma araçlarının ortalama hızı.	Messina
Bisiklet gezilerinin sayısı	Bisiklet kullanılarak tamamlanan yolculukların toplam sayısı.	Messina

3.4. Gelişmiş Görselleştirmeler

Çok kriterli karar analizlerinde, gelişmiş görselleştirmeler çeşitli faktörler ve kriterler arasındaki karmaşık etkileşimi sunmada kritik öneme sahiptir ve böylece bunların etkilerinin kapsamlı bir şekilde anlaşılmasını destekler. Ayrıca, görsel araçlar çeşitli politika seçeneklerini karşılaştırmak, paydaşlara her teklifin göreceli güçlü ve zayıf yönleri hakkında net içgörüler sağlamak ve karmaşık ilişkilerin anlaşılmasını sağlamak için önemlidir. Yenilikçi ve gelişmiş görselleştirme teknikleri bu ihtiyaçları karşılamak için oldukça uygundur ve mobilite politikası kararları bağlamında birden fazla KPI'nin ayrıntılı bir şekilde değerlendirilmesini sağlar.

Urbanite projesinde geliştirilen yeni yöntem, renk, zaman ve çok figürlü katmanlar gibi niteliklerin kullanımıyla ek boyutların dahil edilmesini sağlayarak 9 boyuta (9D) kadar görselleştirmeye olanak tanır. Ancak, Urbanite projesinde yürütülen deneylere dayanarak, karmaşıklık ve kullanıcı tarafından anlaşılabilirlik arasında optimum bir denge sağladığı için 5 boyutlu (5D) bir görselleştirme şeması benimsenmiştir. Bu yaklaşım, karar vericilerin her boyutun belirli bir KPI veya niteliği temsil ettiği birden fazla senaryoyu aynı anda karşılaştırmasını sağlar. Sistem hala 9D görselleştirmeleri destekleyebilse de, 5D'nin çoğu kullanıcı için pratik sınır olduğu belirlendi, çünkü daha yüksek boyutlu temsiller ortalama bir insan kullanıcısının bilişsel kapasitesini aşma eğilimindedir. 5D görselleştirmeler bile, karmaşık, etkileşimli değişkenleri tek bir bakış açısıyla kavrayabilen ileri düzey kullanıcılar için oldukça etkili bir araç sunmalarına rağmen, birçok kişi için zorluklar yaratmaktadır. Buna karşılık, 3D ve 4D görselleştirmeler genellikle daha sezgisel ve yorumlanması daha kolay olarak kabul edilir.

Bu yeni görselleştirme tekniklerini kullanarak, karar vericiler KPI'lar arasındaki karmaşık ilişkileri yorumlamak ve analiz etmek için daha iyi donanımlı hale gelir. Bu teknikler, kullanıcıların farklı değişkenler arasındaki karmaşık etkileşimi ve neden-sonuç ilişkilerini görselleştirmesine ve anlamasına olanak tanır ve getirilen değişiklikleri anlama hızını ve kalitesini önemli ölçüde artırır. Bu gelişmiş anlayış, karar vericilerin daha bilgili, stratejik ve zamanında karar alma süreçlerine katılmasını sağlar.

3.5. Karar Destek Sistemi

Bu karar destek sistemi Urbanite projesindeki dört şehrin tamamı için uygulandı. Her şehrin değişen gereksinimleri ve hedefleri nedeniyle dört ayrı karar modeli geliştirildi. Her model, belirli şehirle ilgili temel KPI'lar kullanılarak uyarlandı. Bu bağlamda, KPI'lar nitelikler olarak adlandırılır ve karar modeli çok nitelikli bir model olarak yapılandırıldı.

Karar destek sistemi (DSS) için Dexi aracı kullanıldı [44]. DEXi, sayısal değerlerden ziyade kelimelerden oluşan ayrı ölçekler olarak ifade edilen nitel (sembolik) nitelikleri kullanır. Karar modelinin karmaşıklığına bağlı olarak, birkaç niteliği bir ana nitelik altında gruplamak gerekebilir. Bu gruplama çok önemlidir, çünkü model ölçek değerlerinin tüm olası kombinasyonlarını kapsayan bir kural kümesinin tanımlanmasını gerektirir. Böyle bir gruplama olmadan, ana niteliği olmayan niteliklerin sayısı büyükse ve/veya ölçekleri birden fazla değer içeriyorsa model bir kombinasyonel patlamayla karşı karşıya kalabilir.

Urbanite DSS modelinin akış şeması Şekil'de gösterilmiştir.5Çeşitli senaryoların simülasyonu ve KPI'ların hesaplanmasının ardından bir sonraki adım şunları içerir:

DEXi için verileri hazırlama. DSS (DEXi), hiçbir değişiklik yapılmamış bir temel simülasyonu, parametrelerinde ve/veya şehir ağında bir değişiklik yapılmış bir senaryo simülasyonuyla karşılaştırır. Her iki simülasyonun KPI'ları karşılaştırılır ve ikisi arasındaki yüzdelik değişimi temsil etmek için bir göreli sayı hesaplanır. Bu yüzde, aşağıdaki seçeneklerden düştüğü aralığa atanır:

- < −%15 büyük bir azalmayı ifade eder;
- < −%5 küçük bir azalmayı ifade eder;
- > − %5 ve <%5, hiç veya ihmal edilebilir bir değişikliği ifade eder;
- > %5 küçük bir artışı gösterir;
- > %15 büyük bir artışı ifade eder.

Aralıklar, çok sayıda simülasyon gerçekleştirildikten ve elde edilen KPI değerlerinin istatistiksel analizi yapıldıktan sonra belirlendi ve ardından makul, yuvarlatılmış sayıların manuel olarak seçilmesi sağlandı. Bu aralıklar, ana özellik olarak sınıflandırılmayan özelliklere uygulanır. Buna karşılık, ana özelliklere üç olası değerden biri atanır: Daha İyi, Aynı veya Daha Kötü. Bu değerler, senaryo simülasyonundan gelen KPI'nin temel simülasyondan gelen KPI'ye kıyasla daha iyi, aynı veya daha kötü olup olmadığını belirten öznel bir puan sağlar.

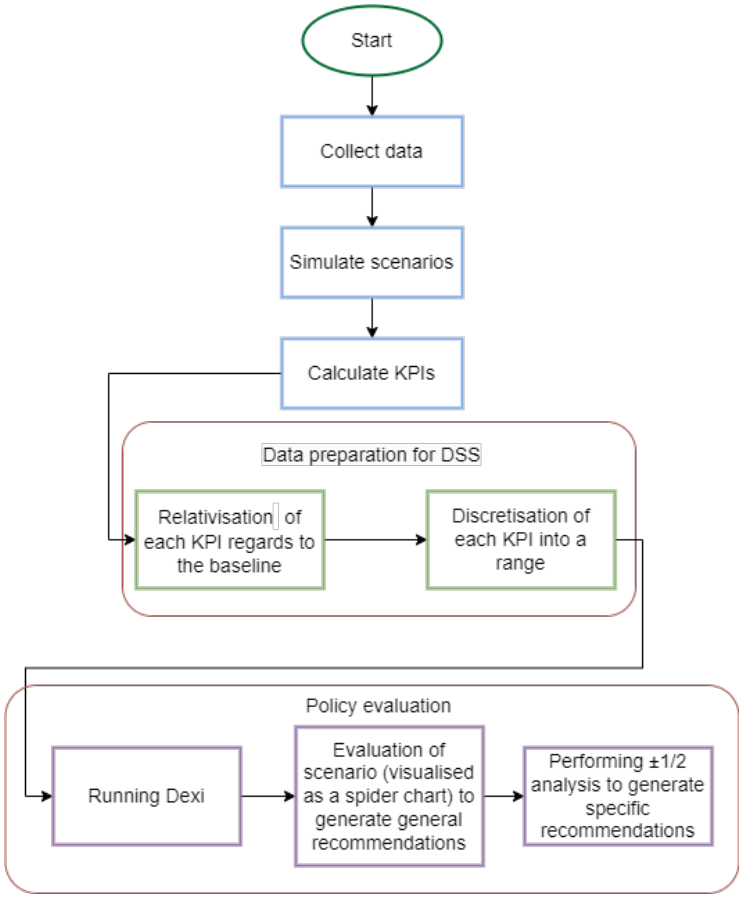

Şekil 5. Urbanite DSS modelinin akış şeması, temel ve senaryo simülasyonlarının karşılaştırılması, KPI hesaplaması ve DEXi kullanılarak çok nitelikli modellemenin uygulanması dahil olmak üzere karar destek sistemi sürecini göstermektedir.

DSS bir simülasyonu bir temel değere göre değerlendirdiğinde, elde edilen sonuçlar her KPI için öznel değerler ve en üst düzey nitelik olan Mobility Policy Quality'dir. Bu nitelik kapsamlı bir puan görevi görerek senaryonun temel değerden daha iyi, eşit veya daha kötü olup olmadığına dair genel bir öneri sunar. Simülasyonun performansının belirlenmiş temel değere kıyasla kapsamlı bir değerlendirmesini kapsar.

Kapsamlı bir±1 ve±2 analiz, nihai değerlendirme için en üst sıradaki politikalar üzerinde gerçekleştirildi. Bu analitik yaklaşım, mobilite politikalarının genel kalitesini iyileştirmeyi amaçlayan belirli öneriler üretir. Bu öneriler,±1 öneri ve±2 öneri.±1 öneri, hava kalitesi veya toplu taşıma gibi belirli alanlarda kademeli iyileştirmeler için içgörüler sunarak politikanın kademeli olarak iyileştirilmesine yol açar. Buna karşılık, ±2. öneri, senaryonun genel kalitesinde daha kapsamlı bir iyileştirme elde etmek için aynı anda birden fazla boyutu ele alan daha kapsamlı ayarlamalar öneriyor.

The±1 ve±2 analiz, DEXi'nin alt düzey niteliklerinin girdi değerlerini yinelemeli olarak ayarlayarak, bunları 1 veya 2 birim artırarak veya azaltarak çalışır. Bu ayarlama, belirli bir KPI'nin düştüğü aralığı kaydırır. İşlem her alt düzey KPI'ye uygulanır ve güncellenmiş sonuçlar üretmek için tüm DEXi değerlendirmesi yeniden çalıştırılır. Bu yeni sonuçlar daha sonra orijinal sonuçlarla karşılaştırılır. Bir değişiklik tespit edilirse, bu, üst düzey KPI'lerde bir iyileştirme meydana geldiğini gösterir.

Bu analiz, şehir ekibine genel politika değerlendirmesini nasıl etkileyeceği (yani analiz edilen şehir değişikliğini nasıl iyileştireceği) konusunda değerli ipuçları sağlar ve hangi KPI'ların iyileştirme için önceliklendirilmesi gerektiğini belirler. Örneğin, analiz, davranışı bireysel araç kullanımından toplu taşımacılığa kaydırmak için kamu kampanyaları uygulamanın, yeni bir otobüs şeridi tanıtıldığında şehirdeki genel yaşam kalitesini önemli ölçüde iyileştirebileceğini ortaya çıkarabilir. Tersine, bu tür önlemleri ihmal etmek, durgunluğa veya hatta önemli metriklerde düşüşe yol açabilir. Şehir ekibi, iyileştirme için doğru KPI'ları hedefleyerek, kentsel yaşamın birçok yönünde daha geniş faydalara yol açan bilinçli kararlar alabilir.

3.6. Orange ile Makine Öğrenimi

Bu alt bölümde, karar vericilerin programlama olmadan ML avantajlarından yararlanarak önerilen politikaların kalitesini değerlendirmesini sağlamak için tasarlanmış Urbanite ML modülünü tanıtıyoruz. Örneğin, bir şehrin belirli bir bölümünün kapatılmasının trafiğe etkisi, önceki simülasyonlara dayanarak değerlendirilebilir ve böylece bir politika değişikliği önerildiğinde her seferinde yeni simülasyonlar yürütme ihtiyacı ortadan kaldırılabilir.

Geleneksel olarak, her politika değişikliğinin etkilerini değerlendirmek için kapsamlı bir mikroskobik trafik simülasyonu gerekir. Çok çeşitli olası değerlere sahip nitelikler için, bu genellikle niteliği birkaç ayrı değere bölmeyi ve her senaryo için simülasyonlar çalıştırmayı içerir. Her simülasyon hızlı bir bilgisayarda yaklaşık bir saat sürebileceğinden, bu süreç zaman alıcı hale gelir. Ancak, makul sayıda önceden simüle edilmiş senaryonun sonuçlarından öğrenmek için ML teknikleri uygulanarak, bu zaman yoğun süreç atlatılabilir. Urbanite ML modülü, politika etkilerini öngörür ve tekrarlanan kaynak yoğun simülasyonlara gerek kalmadan hızlı ve verimli değerlendirmeler sağlar.

Bu özel modül, bu politikalara atfedilen nesnel ve öznel tercihleri değerlendirmeyi amaçlamaktadır. Eğitim örneği olarak tek bir simülasyon çalışmasına dayanan yenilikçi bir yaklaşım benimser ve ML modelinin simülasyon sonuçlarından öğrenmesini sağlar. Eğitildikten sonra ML modeli, yeni senaryoları görselleştirme veya değerlendirme gibi daha fazla analize olanak tanır. Simülasyonun giriş ve çıkış parametreleri özellikler olarak hizmet ederken, KPI'lar hedef değişkenleri temsil eder. Her ML görevi için, CO gibi yalnızca bir hedef değişken seçilebilir$_2$emisyonlar.

Bu yaklaşım iki önemli avantaj sunar: Birincisi, analiz ve görselleştirme herhangi bir programlama gerektirmeden bir ML aracı kullanılarak gerçekleştirilebilir. İkincisi, senaryo parametreleri (örneğin, politika değişiklikleri) ML modülü içinde ayarlanabilir, böylece yeni simülasyonlar çalıştırma ihtiyacı ortadan kalkar ve böylece şehrin karar vericilerine en uygun çözümü belirlemek için daha hızlı ve daha verimli araçlar sağlanır.

Birincil hedef, simülasyon aracını ML hizmetleriyle geliştirmektir, örneğin görselleştirme, yeni ilişkilerin keşfi, vb. Bu, hareketlilik politikalarının kalitesini değerlendirirken değerli zaman, enerji ve kaynak tasarrufu sağlayacaktır. İkinci hedef, ML modüllerinden şeffaflık gibi ek hizmetler elde etmektir.

Bu süreci şehir yetkilileri ve karar vericiler de dahil olmak üzere daha geniş bir kitleye erişilebilir kılmak için kullanıcı dostu Orange aracı kullanılmaktadır [45]. Diğer birçok ML aracının aksine, Orange programcı olmayanlar için tasarlanmıştır. Simülasyon sonuçları bir API aracılığıyla Orange girişine bağlanır ve bu da kesintisiz bir veri akışı sağlar. Görsel programlama ortamı olarak hizmet veren Orange'daki diyagramatik bir arayüz aracılığıyla kullanıcılar ML yöntemini ve istenen raporlama veya görselleştirme türünü seçebilirler. Şekilde gösterilen süreç6, simülasyon için gerekli verilerin toplanmasıyla başlar. Daha sonra bir dizi olası senaryo tanımlanır ve ardından simülasyon yürütülür. Tamamlandığında, her örneğin bir simülasyon giriş/çıkış verisi vektörünü ve karşılık gelen KPI'ları temsil ettiği veri setini oluşturmak için önceden tanımlanmış bir dizi KPI hesaplanır. Bu veriler daha sonra Orange aracına aktarılır ve burada farklı araçlar kullanılarak çeşitli analizler yapılabilir. Birden fazla ML modeli uygulanabilir ve bu modeller nihayetinde doğruluk ve öngörücü performansı sağlamak için görülmemiş örnekler üzerinde test edilebilir.

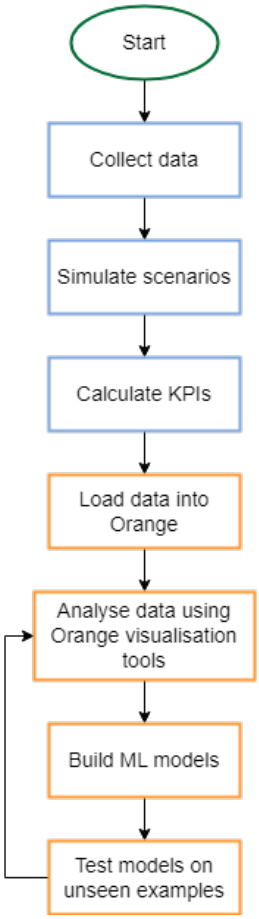

Şekil 6. Orange aracını kullanarak makine öğrenimi sürecinin akış şemasına bir örnek. Bu diyagram, veri içe aktarma, model eğitimi ve görselleştirme dahil olmak üzere adım adım görevleri, sorunsuz analiz için etkileşimli bir işlem hattı aracılığıyla birbirine bağlanmış şekilde göstermektedir.

Orange programının bir örneği Şekil'de gösterilmiştir.7. Bu Orange iş akışında, widget'lar veri içe aktarma, model eğitimi ve görselleştirme gibi farklı görevleri temsil eder. Her widget, ilgili veri sütunlarını seçme, makine öğrenimi modellerini eğitme veya çıktıyı bir karar ağacı gibi görselleştirme gibi belirli bir işlevden sorumludur. Widget'lar arasındaki bağlantılar, bir adımdan diğerine veri akışını görsel olarak tasvir ederek bir widget'tan gelen çıktıların bir diğerinin girdisi olarak hizmet etmesini sağlar. Bu yapı, kullanıcıların çeşitli modelleri ve senaryoları verimli bir şekilde ve programlamaya gerek kalmadan keşfetmesini sağlayan sorunsuz, etkileşimli bir analiz hattı oluşturur.

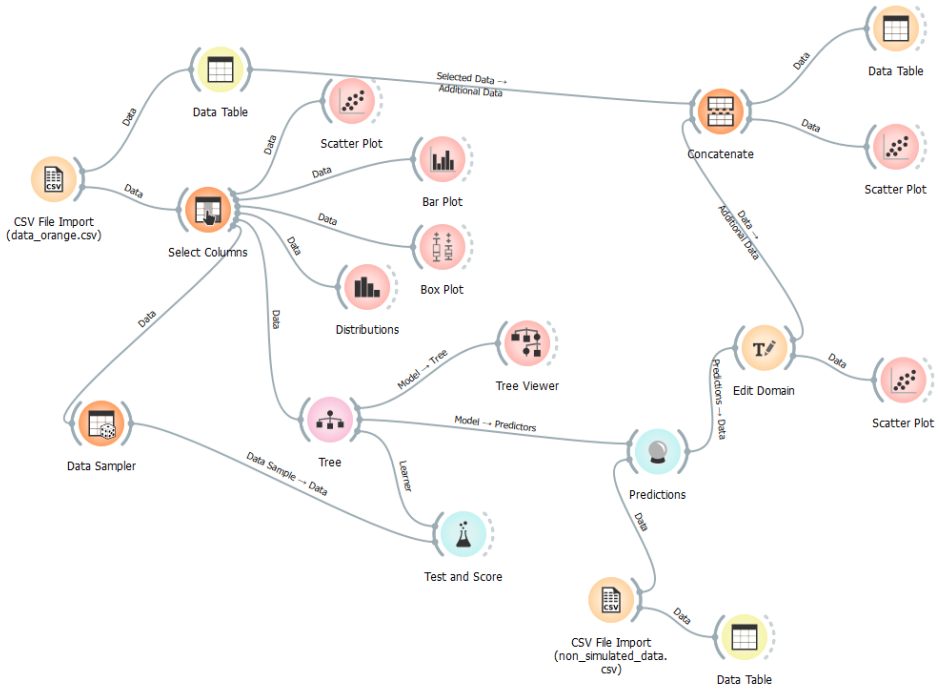

Şekil 7. Orange aracını kullanarak makine öğrenimi sürecinin akış şemasına bir örnek. Bu diyagram, veri içe aktarma, model eğitimi ve görselleştirme dahil olmak üzere adım adım görevleri, sorunsuz analiz için etkileşimli bir işlem hattı aracılığıyla birbirine bağlanmış şekilde göstermektedir.

3.7. Hareketlilik Politikalarını Önermek İçin Çok Çıktılı Makine Öğrenimi

Urbanite projesinin bir parçası olarak Avrupa şehirlerindeki karar alma süreçlerini geliştirmeyi hedeflerken, gelişmiş ML tekniklerinin önemli bir rol oynama potansiyeli vardır. Özellikle, çok çıktılı veya çok etiketli ML, hareketlilik politikaları için daha etkili öneriler üretmek için kullanılabilir ve bu da simülasyon çıktılarını Orange gibi araçlarla entegre ederek elde edilenin ötesinde kentsel alanlarda iyileştirmelere yol açabilir. Önceki durumlarda, mevcut seçeneklerden yalnızca bir sınıf seçilmiş olsa da, akıllı şehir karar alma sürecindeki karmaşık zorlukların ele alınması çok çıktılı öğrenmenin uygulanmasını gerektirir. Bu yaklaşım, birden fazla değişkenin ve bunların birbirine bağımlılıklarının eş zamanlı olarak tahmin edilmesini sağlar.

Urbanite'ta kullanılan gelişmiş ML modülü, bu karmaşık sorunları ele almak için sofistike araçları entegre eder. Temel yeniliği, doğrudan simülasyon sonuçlarına bağlı olan çok çıktılı ML modellerinin uygulanmasında yatmaktadır. Bu, çeşitli girdi değişkenleri kümesine dayalı olarak birden fazla sonucun eş zamanlı olarak tahmin edilmesini sağlayarak politika etkilerinin daha kapsamlı bir analizini sunar. ML modülünün birincil amacı, karar vericilerin potansiyel şehir senaryolarını ve fayda işlevlerini tanımlamalarına yardımcı olmak olduğundan, ML modeli verilen kısıtlamalar ve tercihlerle en iyi şekilde uyumlu olan karmaşık politika çözümlerini belirlemelidir. Örneğin, bu gelişmiş ML modülü hem analiz derinliğini hem de politika test hızını önemli ölçüde artırabilir ve performans iyileştirmeleri potansiyel olarak birkaç büyüklük sırasına ulaşabilir.

Sorunun karmaşıklığı, hem ayrık hem de sürekli olan birden fazla hedef değişkeni tahmin etme ihtiyacından kaynaklanmaktadır. Örneğin, tahmin etmeyi amaçladığımız politika, başlangıç saatlerini, kapanış süresini ve kapatılacak şehir merkezinin belirli alanını içerir. Bu, iki farklı makine öğrenimi görevi türü yaratır: kapanış alanının kategorik doğasını ele alan sınıflandırma ve başlangıç saatleri ve kapanış süresi gibi sürekli değişkenleri tahmin etmekle ilgilenen regresyon. Bu çok çıktılı sorunu ele alırken, bu çalışma her ikisinde de çeşitli makine öğrenimi algoritmalarını test etti

sınıflandırma ve regresyon görevleri. Çok etiketli sınıflandırma için, bir lojistik regresyon (LR) temel sınıflandırıcı uygulandı. Bu yöntem, her etiket için farklı tahminleri verimli bir şekilde üreterek, birden fazla ikili hedef için eş zamanlı tahminlere olanak tanır. Regresyon tarafında, dönüşüm teknikleri, doğrusal destek vektör makinesi (LSVM), gradyan artırma regresörü (GBR), elastik ağ (EN), stokastik gradyan inişi (SGD), destek vektör regresyonu (SVR), Bayes sırtı (BR), doğrusal regresyon (LNR), k-en yakın komşular (KNN), bir karar ağacı (DT) ve rastgele orman (RF) regresörleri dahil olmak üzere çeşitli algoritmalara uygulandı. Bu algoritmalar, çok çıktılı regresyonu ele alma yetenekleri ve yorumlanabilirlikleri nedeniyle seçildi ve bu da onları eyleme dönüştürülebilir içgörüler sağlamak için uygun hale getirdi. Tablolar4Ve5Dönüşüm sürecinde yer alan algoritmaları ve çoklu çıktı regresyonunu destekleyebilen uyarlanmış algoritmaları özetleyin.

Tablo 4.Çoklu çıktı regresyonu için dönüştürülmüş algoritmalar.

Dönüştürülmüş Algoritmalar	**Açıklama**
doğrusal destek vektör makinesi gradyan artırma elastik ağ stokastik gradyan inişi destek vektör regresyonu Bayes sırtı	Destek vektör makinelerini kullanan doğrusal regresyon modelleri. Zayıf öğrenenleri, genellikle karar ağaçlarını birleştiren topluluk yöntemi. Hem L1 hem de L2 düzenlemesi olan doğrusal regresyon. Makine öğrenimi modellerini eğitmek için optimizasyon algoritması. Regresyon görevleri için destek vektör makinelerinin genişletilmesi. Olasılıksal modelleme için Bayes doğrusal regresyonu.

Tablo 5.Çoklu çıktı regresyonu için uyarlanmış algoritmalar.

Uyarlanmış Algoritmalar	**Açıklama**
doğrusal regresyon	Değişkenler arasındaki ilişkinin basit doğrusal modellemesi. K-en yakın
k-en yakın komşular	komşuların çoğunluk sınıfını kullanarak örnek tabanlı öğrenme. Giriş
karar ağacı	özelliklerine dayalı karar alma ağaç benzeri model.
rastgele orman	Çoklu karar ağaçları oluşturan topluluk öğrenme yöntemi.

Birincil görev aşağıdaki gibi tanımlanabilir.Değitim veri kümesini içeren $Kuzeydoğu_{Ben}$= (X_{Ben}, $Evet_{Ben}$)örnekler, neredeBen=1, . . . ,NHer örnekE_{Ben}bir özellik vektörüyle ilişkilidirX_{Ben}= (X_{Ben1},X_{Ben2}, . . . ,X_{Ben})ve bir alt kümesi$Evet_{Ben}$⊆L, Neresi$L$={e_j:j=1, . . . ,Q}kümesidir$Q$olası etiketler. Görev, bir sınıflandırıcı oluşturmaktırHetiketlenmemiş bir örneği doğru bir şekilde tahmin edecek$E$özellik vektörü ile tanımlandıXve etiketlerin tanımlanmamış bir alt kümesi *Evet*, yani,H(E) − >*Evet*.

Figür8Urbanite Advanced ML yaklaşımının akış şemasını sunar. Orange aracının aksine, bu yaklaşım gerçek kodlama gerektirir. Ortaya çıkan program tamamen evrensel değildir, yani başka bir uygulama değişiklik gerektirebilir. Ancak, program açık kaynaklıdır ve yalnızca değişikliklerin kodlanması gerekir.

Çok etiketli algoritmalar, tek etiketli algoritmalara kıyasla farklı değerlendirme yöntemleri gerektirir. Tek etiketli görevlerde, örnekler doğru veya yanlış olarak sınıflandırılırken, çok etiketli görevlerde kısmen doğru olabilirler. Bu, bir tahminin tamamen doğru olmadığı ancak gerçek sonuçla yakın bir şekilde hizalandığı ve kısmi krediye izin verdiği yumuşak eşleşme kavramını ortaya çıkarır. Değerlendirme için, gerçek ve tahmin edilen değerler arasındaki ortalama farkı hesaplamak için hem mikro ortalama hem de makro ortalama kullanılabilir. Mikro ortalama, tüm etiketlerdeki gerçek pozitifleri, yanlış pozitifleri ve yanlış negatifleri toplayarak sonuçları bir araya getirir ve performansa ilişkin daha bütünsel bir görünüm sağlar. Öte yandan, makro ortalama, tüm etiketleri eşit şekilde ele alarak her etiket için belirli bir metriğin ortalamasını hesaplar. Her iki durumda da, önerilen yöntemin performansı, aynı tekniği kullanan diğer yöntemlerin sonuçlarıyla karşılaştırılan sonuçlarla K katlı çapraz doğrulama kullanılarak değerlendirildi. Yumuşak eşleştirme kavramı, özellikle çok etiketli tahminlerde kısmi doğruluğun değerlendirilmesi ve gerçek değerlerle yakından eşleşen tahminlerin uygun şekilde ödüllendirilmesi açısından önemliydi.

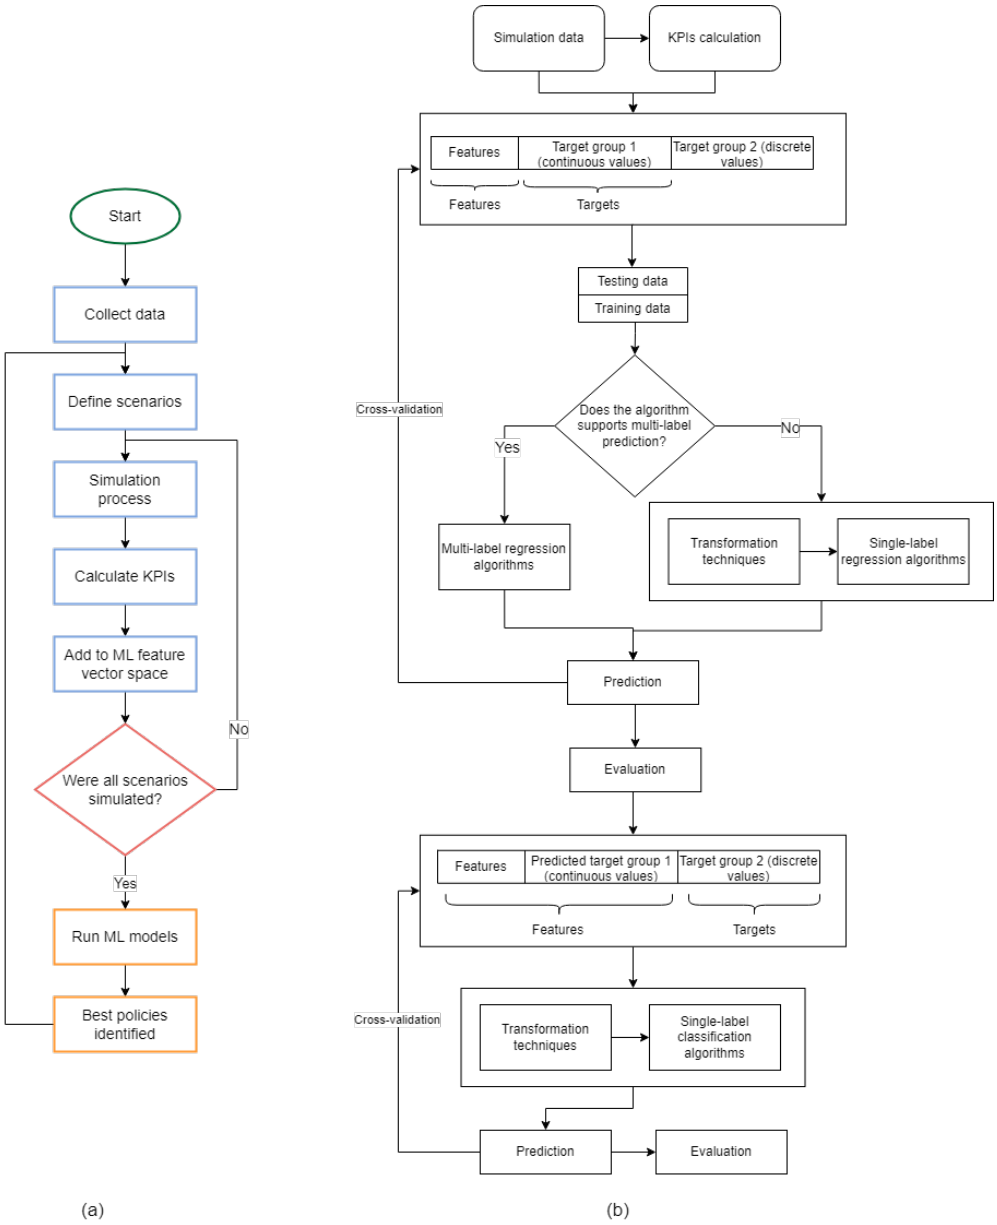

Şekil 8. Gelişmiş makine öğrenimi sürecini gösteren akış şeması (**A**); makine öğrenimi modelinin iş akışı (**B**), veri girişinden model eğitimi, değerlendirmesi ve çıktı analizine kadar olan ardışık adımları ayrıntılı olarak açıklamaktadır.

Bir sınıflandırma modelinin etkinliğini belirlemek için hassasiyet ve geri çağırma hesaplanır.

$$ÇHC_{mikro}(H,D) = \frac{\sum_{veve \in Evet} TP'ler(ve_{Ben})}{\sum_{veBen \in Evet} TP'ler(ve_{Ben}) + FP'ler(ve_{Ben})} \quad (1)$$

$$Rcl_{mikro}(H,D) = \frac{\sum_{veBen \in Evet} TP'ler(ve_{Ben})}{\sum_{veBen \in Evet} TP'ler(ve_{Ben}) + FN'ler(ve_{Ben})} \quad (2)$$

$$ÇHC_{benim}(H,D) = \frac{\sum_{veBen \in Evet} ÇHC(D,ve)_{Ben}}{Evet} \quad (3)$$

$$Rcl_{makro}(H,D) = \frac{\sum_{veBen \in Evet} Rcl(D,ve)_{Ben}}{Evet} \quad (4)$$

Regresyon modelinin etkinliğini belirlemek için aşağıdaki ölçütler hesaplandı: ortalama karesel hata (MSE), ortalama mutlak hata (MAE), belirleme katsayısı (R2) ve kök ortalama karesel hata (RMSE).

MAE (Denklem (5)) tahmin edilen ve gerçek değerler arasındaki ortalama mutlak farkı ölçer. Hataların ortalama büyüklüğünü niceliksel olarak belirler:

$$MAE = \frac{\sum_{Ben=1}^{N} Evet_{tahmin} - Y_{doğru}}{N} \quad (5)$$

MSE, tahmin edilen ve gerçek değerler arasındaki ortalama kare farkını ölçer (Denklem (6)). Ayrıca, kareli terim nedeniyle daha büyük hataları vurgular. Negatif işaret, MSE'nin daha düşük değerlerinin daha iyi bir model performansına karşılık geldiğini gösterir. MSE'yi olumsuzlayarak, daha küçük değerlerin daha iyi doğruluğu gösterdiği kuralla uyumlu hale getiririz.

$$olumsuzMSE = -\frac{\sum_{Ben=1}^{N} (Evet_{tahmin} - Y_{doğru})^2}{N} \quad (6)$$

R2, bağımlı değişkendeki varyansın bağımsız değişkenler tarafından açıklanabilen oranını temsil eden istatistiksel bir ölçüdür (Denklem (7)). Regresyon modelinin uyumunun iyi olduğunu gösterir.

$$R2 = 1 - \frac{\sum_{Ben=1}^{N} (Evet_{doğru} - Y_{tahmin})^2}{\sum_{Ben=1}^{N} (Evet_{doğru} - \bar{Y}_{doğru})^2} \quad (7)$$

RMSE, tahmin edilen ve gerçek değerler arasındaki ortalama kare farkının karekökünü ölçen bir MSE çeşididir (Denklem (8)). Tahminlerdeki hataların tipik büyüklüğünü ölçmek için kullanılır:

$$RMSE = \sqrt{\frac{\sum_{Ben=1}^{N} (Evet_{tahmin} - Y_{doğru})^2}{N}} \quad (8)$$

Denklemlerde (5)–(8) üstünde, $Evet_{(Beta)tahmin}$ için öngörülen değeri temsil eder Ben örnek, $Evet_{Ben_{doğru}}$ için gerçek değeri temsil eder Ben örnek, N toplam örnek sayısını temsil eder ve $\bar{S}_{doğru}$ gerçek değerlerin ortalamasını temsil eder.

Modellerin genel performansı, her hedef değişken için değerlendirme ölçümlerinin ortalama değeri olarak hesaplanır $ve_{Ben} \in Evet$:

$$M_{Anlam} = \frac{Q}{\sum_{Ben=1}^{Q} Benim_{Ben}} \quad (9)$$

Denklemde (9), Q hedef değişkenlerin sayısını temsil eder ve M belirli bir metriğe atıfta bulunur. Genel olarak, Urbanite projesinin çoklu çıktı modülü, trafik düzenleri ve seyahat davranışı gibi faktörler arasındaki karmaşık ilişkileri açıklar. Şehir planlamacılarına bilgili kararlarına yardımcı olarak içgörüler ve öneriler sağlar. Bu çalışma, çoklu çıktı ML kullanarak gerçek bir şehirde politika testini ele alan ilk çalışmadır. Ek olarak, ML modülü simülasyonları birkaç büyüklük sırasına göre hızlandırır ve zaman alıcı simülasyonları neredeyse etkileşimli ML modüllerine dönüştürür.

3.8. Veriler

Bu alt bölüm, Urbanite çerçevesi içinde kullanılan veri kaynaklarını özetlemektedir. Temel senaryolar, her şehrin mevcut durumunu doğru bir şekilde temsil eden ve şehir ekipleri tarafından sağlanan ek verilerle desteklenen, kamuya açık veriler kullanılarak titizlikle geliştirilmiştir. Verilerin çoğu, şehir ekiplerinden ve önceden var olan veritabanlarından toplanmış ve simülasyonlar için sağlam bir temel oluşturmuştur. Ayrıntılı şehir haritaları

OpenStreetMap'ten kaynaklanmıştır. Seyahat planlarını modellemek için, Avrupa Birliği Gelir ve Yaşam Koşulları İstatistikleri'nden (EUSILC) alınan veriler kullanılarak sentetik bir nüfus oluşturuldu. Bu sentetik nüfus, doğruluğu sağlamak için her pilot şehre özgü marjinal dağılımlar kullanılarak daha da rafine edildi. Mümkün olduğunda, konumlar arasındaki yolcu akışını temsil etmek için başlangıç-varış matrisleri kullanıldı. Emisyonlar, çevresel etkiyi tahmin etmek için simülasyon çıktılarına uygulanan Emisyon Faktörleri El Kitabı kullanılarak hesaplandı. Simülasyonlar için kullanılan verilerin bir özeti Tablo'da verilmiştir6.

Tablo 6.Şehir haritaları, sentetik nüfus verileri, başlangıç-varış matrisleri ve emisyon faktörleri dahil olmak üzere Urbanite simülasyonları için kullanılan temel veri kaynakları.

Sentetik Nüfus	
Örnek veriler	Yaş ve cinsiyet özelliklerine sahip bireyleri içeren örnek veriler.
Marjinal dağıtımlar	İlçelerdeki bireylerin yaş ve cinsiyete göre dağılımları.
Seyahat Talebi	
OSM verileri	Şehir haritası hakkında XML formatında düğümler, yollar ve ilişkilerle temsil edilen detaylı bilgi.
Hadi bakalım	CSV dosyalarında ulaşım sistemi ayrıntıları
OD matrisleri	Kaynak-hedef matrisleri
Emisyonlar	
HBEFA	Emisyon Faktörleri El Kitabı.

4. Sonuçlar

Aşağıdaki alt bölümler, özellikle Bilbao'ya odaklanarak çeşitli modüllerden elde edilen sonuçları sunmaktadır. Sistemin karmaşıklığı ve bu makalenin alan sınırlamaları göz önüne alındığında, dört şehrin tümü için ayrıntılı sonuçlar sağlamak mümkün değildir. Bu nedenle, Bilbao sistemin işlevselliğini ve performansını göstermek için temsili bir vaka olarak kullanılmıştır.

4.1. Çeşitli Senaryoların Simülasyonu

Dört şehir için veri toplamak, her şehrin kendine özgü gereksinimleri ve özellikleri olduğu için gizlilik hususlarını ve veri kullanılabilirliğini ele almayı içerir. Mevcut trafik koşullarını yakalamak için bir temel senaryo modellemesiyle başlayarak tüm pilot şehirlerde tutarlı bir metodoloji uygulandı. Bunu, temel senaryo ile karşılaştırma için yeni bir hareketlilik politikasını simüle etmek üzere değişikliklerin uygulanması izledi. Her şehir için en az iki simülasyon gerçekleştirildi: biri temel senaryo için ve diğeri önerilen hareketlilik politikasını yansıtan. Değiştirilmiş senaryo için, farklı sonuçları keşfetmek için birden yüzlerce varyasyon gerçekleştirildi. Bilbao durumunda, ML modüllerinin gereksinimlerini karşılamak için ikinci senaryoda ayarlamalar yapıldı. Her şehir için özel senaryolar aşağıdaki gibi özetlenmiştir:

- Bilbao: Şehir merkezindeki Moyua Meydanı'nın özel araçlara kapatılması. Bu senaryodaki değişiklikler arasında çeşitli çevre alanlarının farklı zaman ve sürelerde kapatılması ve yakınlardaki bisikletçi sayısının değiştirilmesi yer alıyor.
- Messina: Şehir merkezine yeni bir otobüs hattının getirilmesi.
- Amsterdam: Yeni bir bölgenin inşası—Amsterdam Nord.
- Helsinki: Liman bölgesini otoyola bağlayacak yeni bir tünel inşaatı.

4.2. KPI'lar

Amsterdam bisiklet hareketliliği, bisiklet güvenliği ve bisiklet sıkışıklığına odaklanmıştır. Aşağıdaki KPI'lar geliştirilmiştir:

- Bisiklet altyapısı: Bisiklete binmeyi desteklemek için mevcut altyapının kapsamı ve kalitesi. Yolun ne kadar uygun olduğuna göre her yol segmentine bir puan verilir.

bisikletçiler için. Sadece bisikletlerin geçtiği yollar, bisiklet şeritleri ve yaşayan sokaklar yüksek puan alırken, otoyollar, ana yollar ve merdivenli yollar düşük puan alır.

- Bisiklet yoğunluğu: Her yol segmentindeki bisikletli sayısı.
- Bisiklet güvenliği: bisikletler ve motorlu taşıtlar tarafından yolların karışık kullanımı ve bunların etkileşimleri için tahmin. Bisikletlilerin olduğu yol bölümlerine yüksek puan verilirken, bisikletlilerin ve motorlu taşıtların yolu paylaştığı yol bölümlerine düşük puan verilir.
- Bisiklet sıkışıklığı: tüm sıkışık yol bölümlerinin toplam uzunluğu. Yolun kapasitede veya kapasiteye yakın olması nedeniyle bisikletçilerin yavaş hareket ettiği her türlü trafik durumu sıkışıklık olarak kabul edilir.

Bilbao, toplu taşıma, bisikletliler ve özel arabalar dahil olmak üzere çok modlu ulaşımı göz önünde bulundurarak şehir merkezindeki yaşam kalitesine odaklanmıştır. Aşağıdaki KPI'lar geliştirilmiştir:

- CO_2 dahil hava kirliliği, $HAYIR_x$ve Başbakan$_{10}$: Emisyon Faktörleri El Kitabı (HBEFA) kullanılarak hesaplanmıştır. Emisyon tahmini, simüle edilen trafik durumlarını (yavaş hareket eden, sıkışık trafik ile serbest akış koşulları vb.), araç filosunun bileşimini, motor tipi ve EURO standardı desteğini ve hatta aracın motorunun soğuk veya sıcak olup olmadığını hesaba katar.
- Gürültü kirliliği: Şehrin bir bölümü üzerindeki bir şebeke üzerinde, simüle edilen trafik durumu ve şehirdeki binaların geometrisi baz alınarak tahmin edilir.
- Günlük şehir içi bisiklet yolculukları:
- Yaya yolculuk süresi: dakikalar cinsinden bir yaya yolculuğunun ortalama uzunluğu. Tüm yolculuklar dikkate alınır, ancak yalnızca 60 dakikadan uzun yaya yolculukları görselleştirilir ve raporlanır.

Helsinki, feribotların Batı Limanı'na varmasıyla oluşan trafiğe odaklanmıştır. Liman, ana karaya tek bir yolla bağlanan bir yarımada üzerinde yer almaktadır ve bu durum bölgede sıkışıklığa ve yaşam kalitesinin düşmesine neden olmaktadır. Aşağıdaki KPI'lar geliştirilmiştir:

- CO_2 dahil hava kirliliği, $HAYIR_x$ve Başbakan$_{10}$: yukarıda anlatıldığı gibi.
- Gürültü kirliliği: Yukarıda açıklandığı gibi.
- Sıkışıklık ve darboğazlar: tüm sıkışık yol segmentlerinin toplam uzunluğu. Yolun kapasitede veya kapasiteye yakın olması nedeniyle araçların yavaş hareket ettiği her türlü trafik durumu sıkışıklık olarak kabul edilir.
- Liman alanı trafik akışı: Limanı anakaraya bağlayan ana yol üzerindeki trafik akışı.

Messina, şehirdeki toplu taşımacılığa odaklanmıştır. Aşağıdaki KPI'lar geliştirilmiştir:

- Toplu taşıma araçlarının ortalama hızı: Her bir araç için ortalama hız hesaplanır ve araçların toplam yolculuk uzunlukları dikkate alınarak ağırlıklı ortalama hesaplanır.
- Toplu taşıma kullanımı: Toplu taşımayı kullanan kişi sayısı.
- Araba, bisiklet ve toplu taşıma yolculuklarının payları: Ulaşım moduna göre yapılan günlük yolculuk payları.

4.3. Gelişmiş Görselleştirmeler

Birden fazla senaryonun kapsamlı bir şekilde karşılaştırılmasını sağlamak için dört şehrin tamamında gelişmiş görselleştirmeler uygulandı. Bu Urbanite görselleştirmeleri, beş boyuta kadar seçim yapılmasına olanak tanır.*ve*-24 saatlik bir gün boyunca saat başına zamanı temsil eden eksen ve*X*-eksen ve*z*-eksen iki temel performans göstergesini (KPI) temsil eder. Ek olarak, başka bir KPI'yi tasvir etmek için renk kullanılır ve bu da ayrıntılı bir karşılaştırmayı kolaylaştırır. Bilbao'dan açıklayıcı bir örnek Şekil'de sunulmuştur9, dört boyutun netlik için sergilendiği yer. Bu 4D görselleştirmede,*X*-eksen farklı senaryoları temsil eder,*ve*-ekseni günün saatini gösterir ve*z*-eksen yerel HAYIR'ı yansıtır$_x$kirlilik seviyeleri. Renk gradyanı yerel CO_2'yi temsil eder$_2$konsantrasyonu, koyu maviden (düşük kirliliği gösterir) sarıya (yüksek kirliliği gösterir) kadar değişir. Örneğin, "Bilbao Moyua" terimi

LTZ" tüm gün boyunca meydanın tamamen kapatılmasını ifade eder ve senaryo adları belirli kapanış saatlerini belirtir.*z*-eksen kümülatif yerel HAYIR'ı gösterirxbeş senaryoda kirlilik. Özellikle, meydanı saat 16:00'dan 20:00'a kadar kapatmak daha yüksek kümülatif NO ile sonuçlanırxtemel senaryoya kıyasla seviyeler, muhtemelen öğleden sonra yoğun saatlerde artan sıkışıklıktan dolayı. Buna karşılık, meydanı sabah 8'den öğlen 12'ye kadar kapatmak kümülatif NO'da önemli bir farka yol açmazx10.00-13.00 saatleri arasında sokağa çıkma yasağı ise kirlilik oranlarının artmasına neden oluyor.

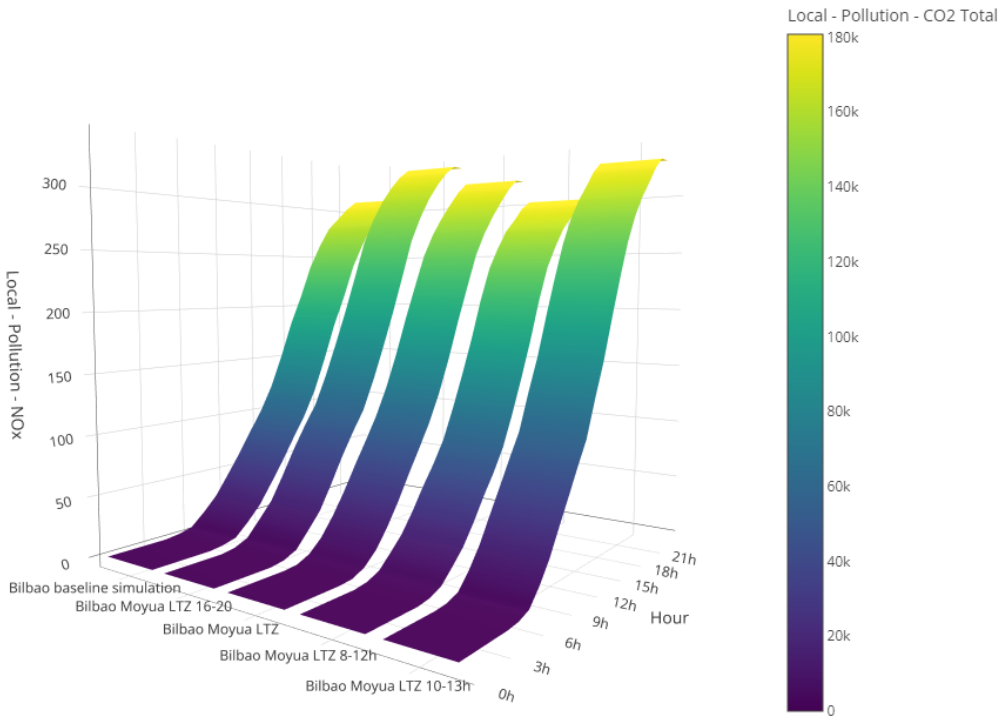

Şekil 9. Gelişmiş görselleştirmeler kullanılarak farklı senaryoların karşılaştırılması.

4.4.KDS

DSS'den elde edilen sonuçlar, Urbanite platformunun iki ana bileşeni olarak sunulur: örümcek grafiği ve öneri sistemi. Örümcek grafiği, seçilen simülasyon ile temel değer arasındaki bağıl değişimi görselleştirir. Örümcek grafiğindeki üç değeri, ilgili nitelikte önemli bir değişiklik olmadığını gösterirken, daha yüksek veya daha düşük değerler, niteliğin karar modelinde nasıl tanımlandığına bağlı olarak iyileştirme veya bozulma anlamına gelir. Ek olarak, öneri sistemi, simülasyon sonuçlarına göre uyarlanmış öneriler sunarak karar vericilerin en etkili mobilite politikalarını belirlemesine yardımcı olur. Bu sistem, çeşitli KPI'ları iyileştirebilecek belirli eylemleri veya ayarlamaları önermek için çok çıktılı makine öğrenimi modellerinden yararlanır. Bu iki bileşen birlikte, farklı senaryoların performansına ilişkin kapsamlı içgörüler sunarak daha bilgili ve veri odaklı bir karar alma sürecini mümkün kılar.

Şekilde10, örümcek grafiği Bilbao şehri için simüle edilmiş bir senaryo tanıtıldıktan sonraki değişiklikleri göstermektedir. Karar modelindeki nitelikleri temsil eden ilgili KPI'ları içerir. Alt düzey nitelikler için daha geniş bir bağlam sağlayan ana nitelikler de görüntülenir. "Bilbao Moyua LTZ (Sınırlı Trafik Bölgesi) 16–20 (saat 16:00'dan 20:00'ye)" senaryosundan önemli bir gözlem, yerel NOx gibi emisyonlarınxve CO_2, azaltıldı ve mobilite politikasında genel bir iyileştirmeye katkıda bulundu. Bu azalmalar, çevresel KPI değerlerinin temel senaryoya kıyasla iyileşme gösterdiği örümcek grafiğinde görselleştirildi. Bu iyileştirme büyük ölçüde, etkilenen bölgedeki kirliliği azaltan yoğun saatlerdeki kısıtlı trafik akışından kaynaklanmaktadır. Ancak, bu tür analizlerde sıklıkla olduğu gibi, bazı KPI'lar bozulma göstermektedir. Örneğin, "Merkeze giriş kapasitesi" niteliği kötüleşti ve şehir merkezine erişimin azaldığını gösterdi

Kapanma döneminde. Kapasitedeki bu azalmanın nedeni muhtemelen sınırlı trafik bölgesi kısıtlamalarıdır. Bu kısıtlamalar çevre kalitesini iyileştirirken aynı zamanda araç akışını kısıtlayarak sakinler ve ziyaretçiler için rahatlığı etkilemektedir. Buna karşılık, "Toplu taşıma kullanımı" gibi bazı KPI'lar aynı kalarak, kapanmanın belirtilen zaman dilimi içinde toplu taşıma yolculuğunu önemli ölçüde etkilemediğini göstermektedir.

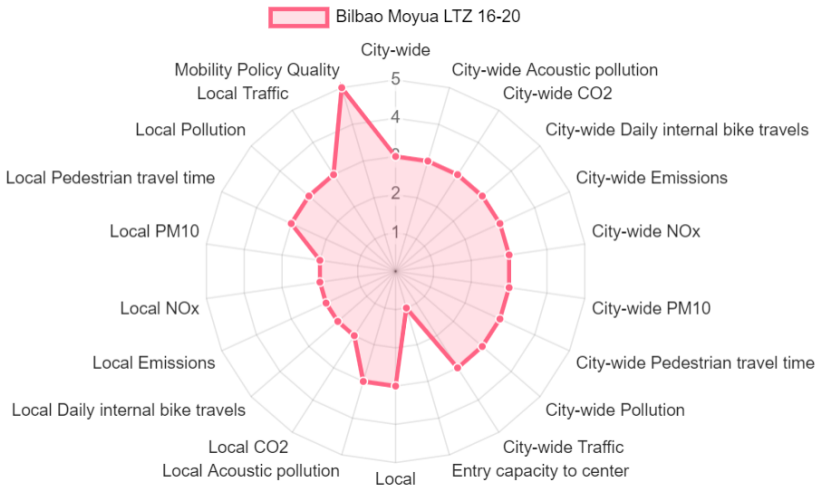

Şekil 10. Bilbao şehrine yönelik senaryo simülasyonuna ait örümcek grafiği, "Bilbao Moyua LTZ (Sınırlı Trafik Bölgesi) 16–20" senaryosu için temel KPI'ların göreceli performansını gösteriyor ve emisyonlardaki, giriş kapasitesindeki ve diğer özelliklerdeki değişiklikleri temel duruma göre karşılaştırıyor.

Çevresel faktörlerdeki iyileştirmeler ile erişilebilirlikteki olası tavizler arasındaki bu denge, kentsel hareketlilik politikası kararlarının karmaşıklığını ortaya koyuyor. Burada bir niteliğin iyileştirilmesi diğerlerinin azalmasına yol açabiliyor ve karar vericiler tarafından dikkatli bir değerlendirme yapılması gerekiyor.

Urbanite sisteminin öneri bileşeninde, DSS ayrıca kullanıcıya seçili senaryo simülasyonunun temel çizgiden daha iyi, aynı mı yoksa daha kötü mü olduğuna dair metinsel bilgi sağlamak için kullanılır. Aşağıda öneri motoru tarafından oluşturulan metinsel öneriler yer almaktadır:

• Mobilite Politikası Kalitesi KPI'sını %10 oranında değiştirebilmek için PM'nin %10 oranında iyileştirilmesi gerekmektedir.

• Yerel Emisyonlar KPI'sını %10 değiştirmek için PM'nin %10 iyileştirilmesi gerekmektedir.

• Giriş kapasitesinin merkeze göre KPI'sını %20 oranında değiştirebilmek için PM'nin %10 oranında iyileştirilmesi gerekmektedir.

• Mobilite Politikası Kalitesi KPI'sını %10 oranında değiştirebilmek için merkeze giriş kapasitesinin %20 oranında iyileştirilmesi gerekmektedir.

Bu öneriler, kentsel hareketlilik bağlamında belirli KPI'ları optimize etmeyi amaçlayan karar vericiler için eyleme geçirilebilir içgörüler sağlar. DSS'den elde edilen sonuçlar, Urbanite projesi sırasında oluşturulan web platformunda Bilbao için mevcuttur. (Daha fazla ayrıntı için Urbanite Bilbao proje web sitesini ziyaret edin:https://bilbao.urbanite.esilab.org/pages/ ana sayfa(11 Eylül 2024'te erişildi).

4.5. Orange ile Makine Öğrenimi

Pratik bir gösterim için, Bilbao'daki analiz, şehir merkezindeki Moyua Meydanı'nın kapatılmasının ve bisikletçi sayısının artırılmasının hava kirliliği seviyeleri üzerindeki potansiyel etkilerine odaklanıyor ve özellikle CO2 tahminine odaklanıyor.2emisyonları. Birden fazla ML algoritması test edildi ve bulgular, şehir merkezi meydanının kapatılmasının ve bisiklet kullanımının teşvik edilmesinin CO2 emisyonlarını azaltmada olumlu bir etkiye sahip olduğunu gösteriyor.2emisyonlar.

Orange için veri setini oluşturmak amacıyla, şehir merkezindeki Moyua Meydanı'nın özel araçlara kapatılmasının sonuçlarını inceleyen Bilbao'da 14 simülasyon gerçekleştirildi. İki senaryo uygulandı: mevcut ağ durumunu yansıtan temel senaryo ve Moyua Meydanı'nın kapatıldığı değiştirilmiş bir senaryo. İkinci senaryodaki değişiklikler, bisikletçi sayısındaki (1500 ila 19.000 arasında) ve sakin sayısındaki (2000 ila 20.000 arasında) ayarlamaları içeriyordu. Bu değişiklikler, uygulanan politika ve bisikletçi sayısı değişirse olası sonuçları gösterdi.

Figür11Uygulanan politikanın sonuçlarını gösterir ve bisikletçi sayısı ile CO arasındaki ilişkiyi açıkça ortaya koyar2emisyonları.*X*-ekseni meydanın yakınındaki bisikletçileri gösterirken,*ve*-eksen merkezdekileri temsil eder. Farklı renkler farklı CO seviyelerini belirtir2emisyonları, turuncu dairenin temel senaryoyu gösterdiği şekilde. Bulgular, ana meydanı özel araçlara kapatmanın ve yakınlardaki araç sayısını azaltmanın CO2'de bir azalmaya yol açtığını gösteriyor2emisyonlar.

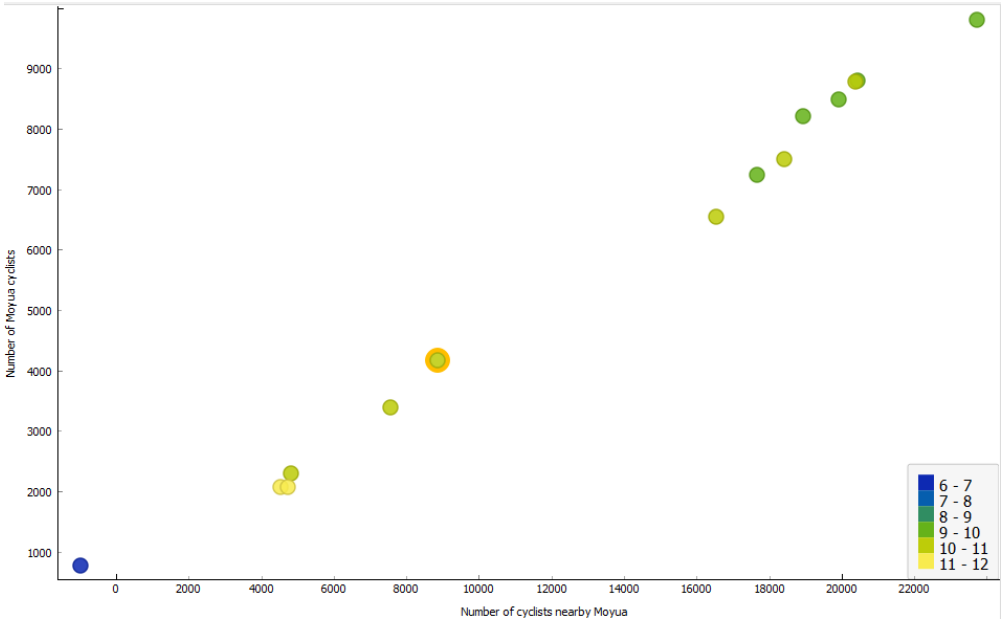

Şekil 11. Bisikletçi sayısı ile CO arasındaki ilişkiyi göstermе2emisyonlar.

Şekilden birkaç çıkarım yapılabilir11, meydanın içindeki ve dışındaki bisikletçi sayısının güçlü bir şekilde ilişkili olduğu gözlemi de dahil olmak üzere - ne kadar çok bisikletçi girerse, o kadar çok bisikletçi çıkar. Bu beklenen ilişki simülatör tarafından yakalanır. Ek olarak, şekil ana meydanı özel araçlara (araba ve motosiklet gibi) kapatmanın CO'da önemli bir düşüşe yol açtığı beklenen sonucu doğrular2Ayrıca, özel araçlara kapalı olan meydanda daha fazla bisikletlinin bulunması, daha az araba ve dolayısıyla daha az emisyon anlamına geliyor.

Ancak, geriye kalan bir miktar trafik olduğu için, örneğin toplu taşıma araçları ve bunların CO'ları nedeniyle ilişki tamamen doğrusal değildir.2Şekildeki sol-aşağı simülasyonu11büyük miktarda CO olduğunu gösterir2emisyonları; ancak, girdi verilerinde bir hata olduğu ortaya çıktı. Bu, simülasyon çıktılarını doğrulamanın önemini vurgular ve şeffaf görselleştirmelerin ve insan doğrulamasının bu tür sorunları belirlemede ve ele almada ne kadar önemli bir rol oynadığını vurgular.

Daha önce bahsedilen verileri kullanarak ML modelini (karar ağacı) oluşturduktan sonra, daha önce simüle edilmemiş yeni örnekler için sonuçları tahmin etmek mümkün hale gelir. Şekilde12, CO'yu tahmin etmenin sonuçları2yeni veri noktaları için emisyonlar, önceden simülasyon yapılmadan sunulur. Yeni veri noktaları ölçeklendirilir ve CO seviyesini temsil eden rengin2, diğer örneklerle tutarlı bir şekilde hizalanır.

Daha önce bahsedilen verileri kullanarak bir karar ağacı biçiminde bir ML modeli oluşturulduktan sonra, daha önce görülmemiş sonuçları tahmin etmek mümkün hale gelir.

örnekler—ilk simülasyonların parçası olmayan durumlar. Şekilde12, CO'yu tahmin etmenin sonuçları2Daha önce simüle edilmemiş olan bu yeni veri noktaları için emisyonlar görüntülenir. Yeni örnekler netlik için ölçeklendirilir ve CO seviyesini temsil eden rengin2daha önce simüle edilmiş diğer örneklerle oldukça tutarlı bir şekilde uyumludur. Bu, ML bilgi modellerinin yeni senaryolar için sonuçları tahmin etmedeki etkinliğini gösterir ve ek simülasyonlara ihtiyaç duyulmadan daha hızlı ve daha verimli politika değerlendirmesine olanak tanır.

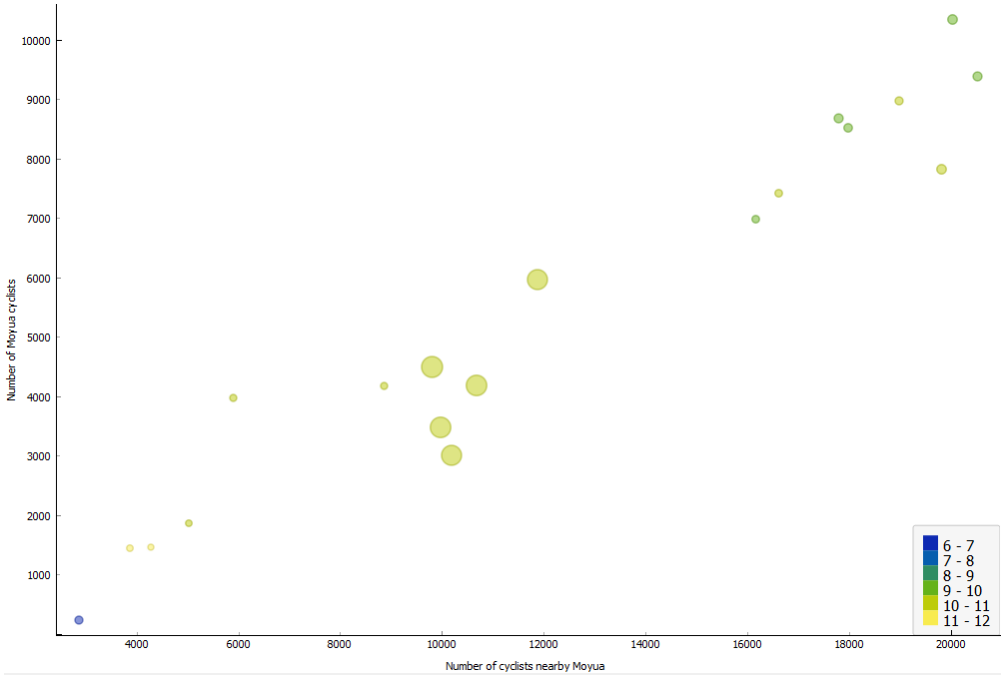

Şekil 12.ML modeli tarafından üretilen ve CO'nun görülmemiş örnekleri için öngörülen sonuçları gösteren yeni ek veri noktaları2emisyonları. Bu tahminler daha önce simüle edilmiş senaryolarla uyumludur ve ML modelinin analizi orijinal simülasyon sonuçlarının ötesine taşıma yeteneğini göstermektedir.

4.6. Gelişmiş Makine Öğrenimi

Gelişmiş ML modeli, simüle edilmiş ve öğrenilmiş senaryolardan elde edilen verilere dayanarak belirli bölgeleri özel araçlara kapatmak ve bu kapatmalar için ideal zamanlamayı belirlemek için en iyi politikaları bulmaya çalışırken Bilbao'nun Moyua bölgesinde test edildi. Senaryolar, kapatmaların başlangıç saatini ve süresini belirterek 1452 olası kombinasyonla sonuçlandı. Zaman ve kaynak kısıtlamaları nedeniyle, simülasyon için senaryoların bir alt kümesini seçmek için Latin hiperküp örneklemesi kullanıldı. Kirleticilerle (CO_2, HAYIR$_x$, ve PM) farklı coğrafi düzeylerde ölçüldü ve kirlilik azaltma önlemlerinin etkinliği hakkında fikir verdi. Analiz, şehir merkezindeki sokakların kapatılması gibi belirli önlemlerin kirlilik düzeyleri ve tıkanıklık üzerindeki etkisini ele aldı. Kirliliğe farklı ulaşım modlarının katkıları incelendi ve etkili hareketlilik politikaları formüle etmeye yardımcı oldu. Analiz ayrıca tıkanıklığı da hesaba kattı ve sürdürülebilir bir kentsel çevre için hem tıkanıklığı hem de kirliliği ele alan politikalar geliştirmek üzere seyahat sürelerini dahil ederek modelleme yaptı. Analizdeki hedef değişkenler, başlangıç zamanı ve süre için sürekli değerler ve dokuz öznitelikli ikili bir biçimde kodlanmış kapalı alanlar içeren KPI'lar da dahil olmak üzere girdi özelliklerinin etkilediği bir hareketlilik politikasını temsil ediyordu.

Gelişmiş ML modeli, belirli bölgeleri özel araçlara kapatmak için en uygun politikaları belirlemek ve hem simüle edilmiş hem de öğrenilmiş senaryolardan elde edilen verilere dayanarak bu kapatmalar için en iyi zamanlamayı belirlemek amacıyla Bilbao'nun Moyua bölgesinde test edildi. Senaryolar, kapatmaların başlangıç saati ve süresi gibi değişkenleri içeriyordu ve 1452 olası kombinasyonla sonuçlandı. Zaman ve kaynak kısıtlamaları nedeniyle, Latin hiperküp örneklemesi uygulandı

simülasyon için senaryoların makul bir alt kümesini seçmek için kullanılır. CO gibi kirleticilerle ilgili KPI'lar$_2$, HAYIR$_x$, ve partikül madde (PM), farklı coğrafi düzeylerde ölçüldü ve kirlilik azaltma stratejilerinin etkinliği hakkında fikir verdi. Analiz, şehir merkezindeki sokakların kapatılması gibi belirli müdahalelerin kirlilik düzeyleri ve trafik sıkışıklığı üzerindeki etkisini değerlendirdi. Genel kirliliğe farklı ulaşım modlarının katkıları da incelendi ve daha etkili mobilite politikalarının geliştirilmesine yardımcı oldu. Analiz, kirlilik düzeylerine ek olarak, hem tıkanıklığı hem de kirliliği ele alan politikalar geliştirmek için seyahat süresi verilerini dahil ederek tıkanıklığı da hesaba kattı ve daha sürdürülebilir bir kentsel çevreyi teşvik etti. Analizdeki hedef değişkenler, başlangıç zamanı ve süre için sürekli değerler ve dokuz değişken boyunca ikili nitelikler olarak kodlanan kapalı alanlar dahil olmak üzere çeşitli girdi özelliklerinden etkilenen bir mobilite politikasını temsil ediyordu.

Süreç, başlangıç zamanını ve süresini tahmin etmeyi amaçlayan bir regresyon göreviyle başlar. Tahmin edilen değerler daha sonra özellik alanına eklenir ve sonraki sınıflandırma adımı için özellikler olarak hizmet eder. Bu son aşamada, kapanış alanı tahmin edilir ve lojistik regresyon kullanılarak dokuz ikili sınıf olarak modellenir. Kapsamlı bir değerlendirme sağlamak için her görev bağımsız olarak değerlendirilir.

Analizin ilk bölümünde, 10 farklı regresyon algoritması test edilerek kapsamlı bir değerlendirme yapıldı: doğrusal regresyon, k-en yakın komşular (KNN), karar ağacı, rastgele orman, doğrusal destek vektör makinesi (LSVM), gradyan artırma, elastik ağ, stokastik gradyan inişi (SGD), destek vektör regresyonu (SVR) ve Bayes sırtı. İlk dört algoritma - doğrusal regresyon, KNN, karar ağacı ve rastgele orman - algoritmik uyarlama yoluyla çok etiketli regresyonu doğal olarak desteklerken, kalan modeller birden fazla çıktıyı işlemek için problem dönüştürme teknikleri kullanılarak eğitilir.

k katlı çapraz doğrulamanın uygulanması, ML modellerinin performanslarını değerlendirmek için yaygın olarak kullanılır. k = 10 için sonuçlar Şekil'de sunulmuştur13, her katlamadaki puanların dağılımını bir kutu grafiği kullanarak gösterir. Doğrusal regresyon, 1,514'lük ortalama mutlak hata (MAE) ve 0,230'luk standart sapma ile en etkili algoritma olarak ortaya çıkar. Bu, doğrusal regresyonun özel araçlar için Moyua karesinin kapanmasının başlangıç zamanı ve süresi için yaklaşık bir buçuk saatlik ortalama hata ile doğru tahminler sağladığını gösterir.

Bir sonraki zorluk, önceden tahmin edilen başlangıç zamanı ve süreyi girdi özellikleri olarak kullanarak kapanış alanını tahmin etmek için bir model oluşturmayı içerir. Bunu ele almak için, çok etiketli sınıflandırma görevini ele almak için bir problem dönüştürme yöntemi esastır. Her alanı tahmin etmek için ayrı ayrı uygulanan lojistik regresyon, uygun bir yaklaşım olarak tanımlanmıştır.

ML modelinin genel performansı Şekil'de gösterilmiştir.14. Model, özellikler ve etiketler arasındaki tam eşleşmeler dikkate alındığında (turuncu renkle gösterilmiştir) %90'lık bir hatırlama puanı (gerçek pozitif oranı) ve %77'lik bir doğruluk elde etti. Buna ek olarak, modelin etkinliğinin daha kapsamlı bir değerlendirmesini sağlamak için iki alternatif yaklaşım araştırıldı.

Tam eşleşmenin sınırlaması, bir alan için tek bir hatalı tahmin nedeniyle örneklerin yanlış sınıflandırılma olasılığında yatmaktadır. Bu, tahmin edilen kapanışların bir kombinasyonu yoluyla iyileştirilmiş sonuçlar elde etme fırsatını göz ardı ederek CO'nun azaltılmasına yol açar$_2$emisyonlar ve daha kısa yolculuk süreleri. Bunu ele almak için alternatif bir yaklaşım, tahmin edilen ve gerçek değerler arasındaki Öklid mesafesini dahil etti. Tanımlı bir eşik değerinin tanıtılması, her örnek için doğru ve yanlış sınıflandırmalar arasında bir ayrım yapılmasına olanak sağladı. Sonuçları maviyle vurgulayan çubuk grafiği, %77'den %87'ye çıkan bir doğruluk artışı gösterdi. Bu değişiklik, tam bir eşleşme olmasa bile yeterince yakın bir çözümün kabul edilebilir olma olasılığının yüksek olduğunu gösteriyor. Bu gibi durumlarda gerçek simülasyonlar aracılığıyla ince ayar yapmak gerekebilir.

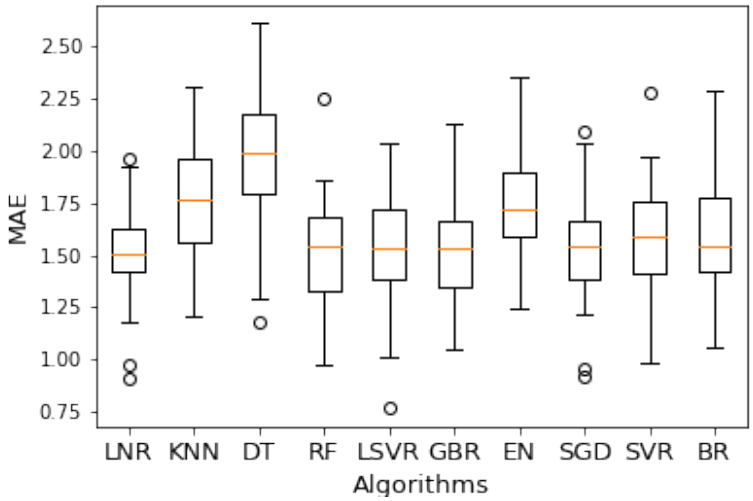

Şekil 13. Regresyon görevi için yöntemlerin karşılaştırılması, test edilen 10 regresyon algoritmasının her biri için ortalama mutlak hatayı (MAE) ve standart sapmaları sunarak, Moyua kare kapanışlarının başlangıç zamanını ve süresini tahmin etmede yöntemler arasındaki performans farklılıklarını vurgulamaktadır. Doğrusal regresyon en düşük MAE'yi gösterirken, diğer modeller farklı tahmin doğruluğu dereceleri göstermektedir.

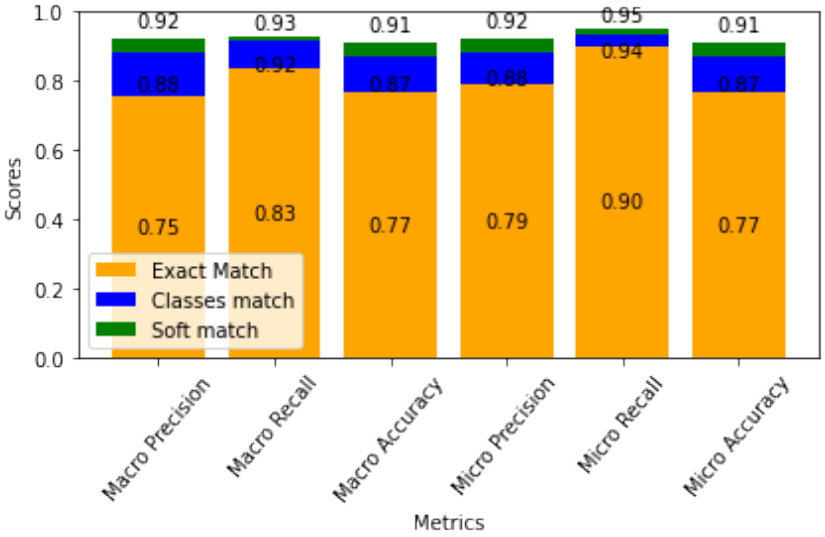

Şekil 14. Tam eşleştirme, Öklid mesafesine dayalı sınıflandırma ve özellik vektörü hizalaması dahil olmak üzere sınıflandırma görevi için farklı değerlendirme yaklaşımlarının doğruluğu, sonuçlar turuncu, mavi ve yeşil olarak görüntülenir.

Tam eşleştirmenin sınırlaması, bir boyutta, örneğin bir kapanış alanında tek bir hatalı tahminin, tüm bir örneğin yanlış sınıflandırılmasına yol açabilmesidir. Bu katı yaklaşım, tahmin edilen kapanışların bir kombinasyonu yoluyla iyileştirilmiş sonuçlar elde etme potansiyelini göz ardı eder ve bu da CO'nun azalmasına yol açabilir2 emisyonlar ve daha kısa yolculuk süreleri. Bunu ele almak için, tahmin edilen ve gerçek değerler arasındaki Öklid mesafesini içeren alternatif bir yaklaşım tanıtıldı. Bir eşik tanımlayarak, bu yöntem, tahminler tam olarak eşleşmese bile, her örnek için doğru ve yanlış sınıflandırmalar arasında ayrım yapar.

Şekildeki çubuk grafiği14, sonuçları mavi olarak gösterilen, %77'den %87'ye çıkan önemli bir doğruluk iyileştirmesi gösterir. Bu ayarlama, gerçekle mükemmel bir şekilde eşleşmese bile, "yeterince yakın" bir çözümün genellikle kabul edilebilir olduğunu gösterir.

her boyutta değerler, ancak kabul edilebilir bir genel sonuç sağlar. Ancak, bu gibi durumlarda en iyi sonuçları sağlamak ve tahminleri daha da iyileştirmek için ek simülasyonlar aracılığıyla ince ayar yapmak yine de gerekli olabilir.

Ek olarak, benzer politika sonuçları, kapanışlar ve sürelerle ilişkili özellik vektörlerini Öklid uzaklık ölçümlerini kullanarak keşfetmek için üçüncü bir yaklaşım tanıtıldı. Tahmin edilen sınıf vektörünün bu seçili özellik vektörü sınıflarından herhangi biriyle yakından hizalanması durumunda, tahmin doğru kabul edildi. Şekildeki çubuk grafiğinde yeşil renkle gösterilen bu semantik yaklaşım, parametre ayarlaması gerektirmeden %91 doğruluk elde etti. Bunun anlamı, karar vericilerin hedefleriyle uyumlu politikalar aracılığıyla benzer veya daha iyi sonuçların elde edilebileceği ve manuel veya otomatik parametre ölçeklemesine gerek kalmayacağıdır.

4.7. Modüllerin Özet Listesi

Tabloda birkaç Urbanite modülünün listesi sunulmaktadır7.

Tablo 7. Urbanite projesinde kullanılan simülasyon platformları, makine öğrenimi modelleri ve görselleştirme teknikleri gibi araçlar ve teknolojiler, bunların veri analizi, politika değerlendirmesi ve karar desteğindeki rollerini vurgulamaktadır.

Araç Adı	Tanım	Şehirlilikteki Rol
Turuncu	Makine öğrenimi için açık kaynaklı bir veri görselleştirme ve analiz aracı. Programlama olmadan karmaşık veri analizleri yürütmek için kullanıcı dostu bir arayüz sağlar.	Simülasyon sonuçlarından gelen girdileri kullanarak, görselleştirme ve makine öğrenimi modüllerini kullanan programcı olmayan kişiler için veri analizini kolaylaştırmak amacıyla kullanılır.
MATSim	Mikroskobik bir trafik simülasyon aracı, bir ulaşım ağı içindeki bireysel yolcuların davranışlarını ve etkileşimlerini modelliyor.	Çeşitli şehirlerdeki trafik senaryolarını simüle etmek, kentsel hareketliliğe ve farklı politika kararlarının etkisine dair detaylı bilgiler sağlamak için kullanılır.
DEXi	Karmaşık senaryoları değerlendirmek ve öznel tercihlere dayalı öneriler üretmek için nitel çok nitelikli modeller kullanan bir karar destek aracı.	Çeşitli kriterlere göre politika senaryolarını değerlendirerek karar alma süreçlerini destekler ve kent plancılarının çeşitli paydaş girdilerini ve tercihlerini dengelemesine yardımcı olur.
Çok etiketli ML	Kararların veya sınıflandırmaların birbirine bağlı olduğu senaryolarda yararlı olan, tek bir girdi örneği için birden fazla çıktı etiketini tahmin edebilen algoritmaları içerir.	Farklı kentsel politikaların sonuçlarını tahmin etmek ve bunların etkilerini aynı anda birden fazla kriter üzerinden değerlendirmek, böylece karar alma sürecini hızlandırmak için kullanılır.
Gelişmiş Görselleştirme Araçları	Karmaşık verilerin çok boyutlu grafiksel gösterimini sağlayan, farklı senaryoların sonuçlarını yorumlamayı ve anlamayı kolaylaştıran araçlar.	Politika yapıcıların, genellikle üç ve nadiren dört olmak üzere beş veri boyutunu görselleştirmelerine olanak tanır. Kullanıcı dostu bir şekilde politika etkilerinin kapsamlı bir şekilde değerlendirilmesini kolaylaştırmak.

5. Tartışma ve Sonuçlar

Urbanite H2020 projesi, karar vericilerin karmaşık kentsel hareketlilik zorluklarını etkili bir şekilde ele almalarını sağlayan birleşik bir çerçeve sağlayan çeşitli yenilikçi AI tabanlı modüller sunar. Kirliliği azaltmaktan altyapıyı iyileştirmeye kadar çok çeşitli kentsel zorlukları ele alarak, Urbanite sistemi gerçek dünya hareketlilik sorunlarını ele almada uyarlanabilirliğini ve etkinliğini göstermiştir. Dahası, Urbanite'ın iş birliğini ve bilgi paylaşımını teşvik etmeye odaklanması, akıllı şehir geliştirmede bir yenilik ve sürekli öğrenme kültürünü teşvik eder. Ortaklıklar kurarak ve en iyi uygulamaları yayarak, Urbanite kentsel sürdürülebilirliği ve dayanıklılığı artırmak için kolektif bir çabada önemli bir rol oynar. Projenin çeşitli coğrafi ve profesyonel grupları birbirine bağlayan iş birlikçi ruhu, kentleşmenin çok yönlü zorluklarını ele almak ve kentsel gelişime kapsayıcı, katılımcı yaklaşımları savunmak için hayati öneme sahiptir.

Belirli modüller açısından, simülasyonlar, açık kaynaklı simülasyon platformundaki geliştirmeler yoluyla bir şehir haritası ve seyahat verileri dahil etmek gibi minimum ayarlamalarla herhangi bir şehre uyarlanabilir. Sistem dört pilot şehirde başarıyla test edildi; ancak, alan kısıtlamaları nedeniyle, yalnızca Bilbao'dan gelen sonuçlar ayrıntılı olarak sunulmaktadır. Şehir ekipleriyle yapılan görüşmeler, sistemin etkinliğini ve gerçek dünya zorluklarını ele alma potansiyelini doğruladı. Dahası, Orange aracından yararlanılarak, simülasyon çıktıları makine öğrenimi metodolojilerine sorunsuz bir şekilde bağlanarak, doğrudan programlamaya gerek kalmadan zahmetsiz desen tanımlaması sağlar. Ek olarak, gelişmiş çoklu ML yaklaşımı, bir politikayı test etmek için gereken süreyi önemli ölçüde azaltır ve bunu birkaç saniyeye indirir. Makine öğrenimi kullanılarak sonuçların hesaplanması, tam simülasyonları çalıştırmaktan yaklaşık üç kat daha hızlıydı ve yine de %90 doğruluk elde edildi. Son doğrulama yalnızca en umut verici çözümler belirlendikten sonra gerekliydi, bu da yüzlerce simülasyon çalıştırma ihtiyacını yalnızca birkaçına indirerek süreci önemli ölçüde hızlandırdı.

Ek olarak, kapsamlı karar destek aracı, önerilen kentsel değişikliklerin faydaları ve dezavantajlarının hem öznel hem de nesnel analizlerini sunarak kapsamlı bir değerlendirme süreci sağlar. Özetle, hem proje ekibi hem de AB değerlendiricileri, proje tarafından getirilen yenilikleri işlevsel bir prototip aşamasında bile işlevsel olarak önemli olarak kabul ettiler.

Gelişmiş görselleştirme modülü karmaşık sonuçların görüntülenmesini sağlayarak tek bir grafiksel gösterimde beş boyuta kadar temsil olanağı sağlar. Çeşitli senaryolar için 24 saat boyunca saatlik olarak simülasyon sonuçlarını görselleştirir ve belirli boyutları KPI'lara ayırır. Bu modül öncelikle iki senaryoda kullanılır ve seçili KPI'lara odaklanır. Başlangıçta, farklılıkları tespit etmek için 3-5 KPI seçilir, ancak genellikle birkaç KPI perspektifinde hiçbir farklılık gözlemlenmez. Sonraki analizler genellikle belirgin farklılıklar gösteren KPI'lara yoğunlaşır.

ML modülleri iki düzeyde çalışır: simüle edilen verilerdeki kalıpları belirler ve simülatörü yansıtan bir ML modeli oluştururlar. Orange kullanılarak geliştirilen ve kodlama deneyimi gerektirmeyen belirli bir ML modülü, CO gibi belirli KPI'ları tahmin edebilir2emisyonlarını azaltarak kapsamlı simülasyonlara olan ihtiyacı ortadan kaldırır. Örneğin, CO'yu tahmin edebilir2Moyua Meydanı'nın kapatılmasının etkisi, Şekil'de gösterildiği gibi daha önce karşılaşılmamış senaryolar için doğru tahminler sağlıyor12.

Gelişmiş ML modülü, önceden tanımlanmış kullanıcı tercihleriyle uyumlu mobilite politikaları önererek karar alma sürecini daha da iyileştirir ve simülasyonların ve uzman analizlerinin geleneksel, zaman alıcı döngüsüne olan bağımlılığı azaltır. Bu yaklaşım, simülatörün hızlı bir ML modelini etkili bir şekilde oluşturur ve politika geliştirme sürecini önemli ölçüde hızlandırır. Bilbao bağlamında, modül, kullanıcı tarafından belirtilen KPI'ların iyileştirilmesiyle yönlendirilen şehir merkezindeki ve çevresindeki alanlardaki sokakların kapatılmasını önerir. Bu yenilik, mobilite politikalarının sadece saniyeler içinde hızlı bir şekilde değerlendirilmesini sağlar ve bu, daha önce tam simülasyonlar için gereken saatlere kıyasla önemli bir iyileştirmedir. ML tabanlı model, orijinal simülatörün sonuçlarını tam olarak kopyalamasa da, Şekil 1'de gösterildiği gibi %90'ın üzerinde doğruluk elde eder.14Sonuç olarak, çeşitli hareketlilik politikalarının test edilmesinde ML simülatör modülünün kullanılması, hareketlilik politikalarının hızlı bir şekilde doğrulanmasını ve son ayarlamaların orijinal simülatör aracılığıyla doğrulanmasını sağlar.

Ancak, Urbanite'ın kapsamlı yaklaşımı ve AI ve ML teknolojilerinin yenilikçi uygulaması akıllı şehir planlamasında önemli bir ilerlemeyi temsil ederken, projenin karmaşıklığı ve büyüklüğü önemli zorluklar ortaya koymaktadır. Projenin ayrıntılı ve karmaşık bir araştırma prototipi olarak statüsü birincil endişe kaynağıdır. Tamamen işlevsel bir yazılımın uygulanabilirliğini göstermesine rağmen, pratik, gerçek dünya uygulaması için önemli bir yeniden yazma gerekebilir. Potansiyel yeniden mühendislik ihtiyacı, prototip oluşturma ile dağıtılabilir, kullanıcı dostu çözümlerin geliştirilmesi arasındaki uçurumu vurgular. Başka bir sorun da bir alt modelin veya sistem desteğinin birkaç ayda bir güncellenmesidir. Mevcut prototipin boyutu ve karmaşıklığı, sistemin inceliklerine aşina olmayan topluluk grupları için onu bir şekilde erişilemez hale getiriyor.

Urbanite sisteminin pratik uygulaması ek karmaşıklıklar getirir. Gerçekte, bu projenin kapsamı dahilinde tünellerin inşası veya yeni bölgelerin geliştirilmesi gibi kentsel ortamlarda altyapısal değişiklikler yapmak genellikle mümkün değildir. Dahası, doğru simülasyonlar ve tahminler sağlamak için kapsamlı veri toplama gerekliliği, projenin ölçeklenebilirliğini ve çeşitli kentsel manzaralarda uyarlanabilirliğini engelleyebilecek kaynak gerektiren bir yönünü vurgulayarak, birden fazla simülasyona olan ihtiyacı vurgular.

Toplumsal bir bakış açısından, Urbanite'ın açık kaynaklı çerçevesi, AI odaklı mobilite çözümlerini keşfetmek, akıllı şehir planlamasını demokratikleştirmek ve yenilikçi teknolojilerin daha geniş çapta benimsenmesini teşvik etmek için şeffaf ve erişilebilir bir platform sunar. Bu çerçeve, herhangi bir topluluğun potansiyel kentsel mobilite iyileştirmelerini değerlendirmesine olanak tanır. Dahası, Urbanite'ın yaklaşımı, enerji ve su yönetimi gibi diğer sektörlere genişletilebilir ve kaynak kullanımını optimize etmek ve kentsel hizmetler genelinde sürdürülebilirliği teşvik etmek için veri odaklı içgörüler sağlayabilir.

Girişte beyan edilen beş önemli katkıya ilişkin olarak özetle şunlar çıkarılabilir:

1. Dört farklı şehirde test edilen birleşik, yükseltilmiş, açık kaynaklı bir simülatör: Dört şehirde test edilen bu platform, çeşitli kentsel ortamlar için simülasyonları standartlaştırma zorluğunu ele alıyor. Kentsel politikaları karşılaştırmada güvenilirliği ve tutarlılığı artırıyor, ancak önemli yürütme süresine duyulan ihtiyaç bir zorluk olmaya devam ediyor.
2. Dexi aracıyla gelişmiş bir karar destek ve öneri modülü: DEXi aracının entegrasyonu, öznel tercihlere dayalı ayrıntılı öneriler sunarak bağlam farkında karar desteğini mümkün kılar. Ancak, kullanıcıların potansiyelinden tam olarak yararlanabilmeleri için eğitim gereklidir.
3. Kapsamlı politika değerlendirmesi için gelişmiş görselleştirmeler: Görselleştirme araçları karmaşık verilerin keşfini basitleştirir, ancak çoğu kullanıcı yalnızca 3B veya 4B gösterimleri işleyebilir. Daha yüksek boyutlu verilerin sunulması bir zorluk olmaya devam etmektedir.
4. Orange aracına sahip bir ML modülü: Bu modül, kentsel planlama için makine öğrenimini demokratikleştirir ve veri odaklı karar vermeyi uzman olmayanlar için erişilebilir hale getirir. Ancak, kullanıcıların sistemin yeteneklerini en üst düzeye çıkarmak için yine de birkaç saatlik eğitime ihtiyacı vardır.
5. Gelişmiş çok etiketli ML modülü: Modül, hızlı senaryo testine olanak tanıyan önemli hız iyileştirmeleri sunar. Ancak karmaşıklığı, kullanıcıların sonuçları yorumlama ve içgörüleri etkili bir şekilde uygulama konusunda uzmanlık geliştirmesini gerektirir.

6. Sonuçlar

Sonuç olarak, Urbanite H2020 projesi, kentleşme ve şehir genişlemesinin getirdiği karmaşık zorluklarla başa çıkmayı amaçlayan çığır açıcı bir çerçeve sunuyor. Yapay zeka ve makine öğrenimi gibi yıkıcı teknolojilerin gücünden yararlanarak, proje kentsel hareketlilik ikilemleriyle boğuşan karar vericiler için bütünsel bir strateji sunuyor. Girişim, beş yenilikçi bileşenle öne çıkıyor: açık kaynaklı bir simülatör, gelişmiş karar destek ve öneri modülleri, politika değerlendirmesi için son teknoloji görselleştirmeler ve iki makine öğrenimi modülü.

Urbanite'ın yaklaşımı, tarihsel olarak uzman bilgisine dayanan ve kapsamlı testlerin pratik olmaması nedeniyle potansiyel çözümleri keşfetmeyi sınırlayan geleneksel şehir planlamasını devrim niteliğinde değiştiriyor. Yazılım simülatörleri bu zorluğun hafifletilmesine yardımcı olurken, Urbanite bunu daha da ileri götürerek karar alma sürecini standartlaştırıyor ve bilgilendiriyor ve çeşitli senaryolara ilişkin değerli içgörüler sunuyor. Bu çerçeve, bireysel şehirlere veya alanlara odaklanan önceki çalışmalara göre önemli bir ilerlemeyi işaret ediyor. Bilbao, Messina, Amsterdam ve Helsinki olmak üzere dört Avrupa şehrinde yapılan titiz testler, Urbanite'ın kirliliğin azaltılmasından toplu taşımacılığa ve bisikletli güvenliği iyileştirmelerine kadar bir dizi zorluğun üstesinden gelme yeteneğini gösterdi. Sistem, önerilen değişikliklerin etkilerine ilişkin kritik içgörüler sağladı ve hem nesnel hem de öznel kriterlere dayalı öneriler sundu.

Analizlerden iki önemli gözlem ortaya çıktı. Birincisi, kentsel planlama değişiklikleri her zaman temel senaryoyu aşan sonuçlar üretmez ve genellikle karmaşık sonuçlar doğurur.

sonuçlar. Örneğin, CO'yu azaltmak$_2$şehir merkezlerindeki emisyonlar, çevre bölgelerdeki sıkışıklığı istemeden artırabilir. Bu, her KPI'nin genel kentsel yaşam kalitesi üzerindeki daha geniş etkisinin değerlendirilmesinin önemini vurgular. İkinci olarak, Urbanite sisteminin karmaşıklığı, yeteneklerini tam olarak kullanabilmek için uygun kullanıcı eğitimi gerektirir. Çoğu kullanıcı üç boyutlu (3B) ve dört boyutlu (4B) görselleştirmeleri kolayca yorumlayabilirken, beş boyutlu (5B) gösterimler zorlayıcıdır. Ancak, yeterli pratik ile kullanıcıların yaklaşık üçte biri 5B görselleştirmeleri anlamada yetkin hale gelir ve bu da sistemin potansiyelini en üst düzeye çıkarmak için kapsamlı eğitimi gerekli kılar.

Güçlü yönlerine rağmen, Urbanite projesi bazı sınırlamalarla karşı karşıyadır. Birincil zorluklardan biri, yaklaşık bir milyon satır kod ve onlarca modülden oluşan yazılım sisteminin muazzam boyutu ve karmaşıklığında yatmaktadır. Bu geniş kod tabanı, bakımı, hata ayıklamayı ve güncellemeleri özellikle zorlaştırarak ölçeklenebilirliği ve kullanıcı benimsemesi için potansiyel engeller yaratmaktadır. Sistemin karmaşıklığı, uzman olmayan kullanıcılar veya özel teknik ekipleri olmayan daha küçük belediyeler için erişilebilirliğini de sınırlayabilir ve daha geniş çekiciliğini azaltabilir. İkinci olarak, Urbanite sistemi, büyük ölçekli dağıtıma hazır, tamamen doğrulanmış ve test edilmiş bir uygulama olmaktan ziyade bir araştırma prototipi olmaya devam etmektedir. Kavram kanıtı birçok pilot şehirde gösterilmiş olsa da, sistem ölçekte gerçek dünya uygulaması için gereken titiz doğrulamadan geçmemiştir. Bu, özellikle geliştirme aşamasında kapsamlı bir şekilde test edilmemiş senaryolarda keşfedilmemiş sorunlar olabileceği anlamına gelir. Bir prototip olarak, mevcut şehir altyapılarına sorunsuz entegrasyon için üretim düzeyindeki bir sistemin gerektireceği ince ayar ve kullanıcı dostu olma özelliğinden de yoksundur.

Daha fazla geliştirme için önemli bir alan, çerçeveyi daha geniş bir Avrupa şehri yelpazesini kapsayacak şekilde genişletmek ve farklı kentsel bağlamlarda potansiyel çözümlerin daha kapsamlı bir şekilde değerlendirilmesine olanak sağlamaktır. Ek olarak, çerçeve su tüketimi veya kamusal aydınlatma gibi diğer şehir sektörlerini de kapsayacak şekilde genişletilebilir ve bu da faydasını daha da artırabilir. Ayrıca, ML modülleri gibi yalnızca belirli modülleri daha fazla şehirde uygulama fırsatı da vardır ve bu da Urbanite çerçevesinin çok yönlülüğünü ve genel etkisini artırır. Daha geniş bir benimsenmeyi sağlamak için, kullanıcı dostu arayüzler ve kapsamlı kılavuzlar sağlamak, sistemi çok çeşitli kullanıcılar için daha erişilebilir ve pratik hale getirmek çok önemli olacaktır.

Özetle, Urbanite'ın devam eden araştırma ve geliştirme çabaları akıllı şehir planlamasında devam eden ilerlemenin sinyalini veriyor. AI tabanlı metodolojilerden ve dört pilot şehirden elde edilen içgörülerden yararlanarak Urbanite daha fazla yeniliğe hazır. Proje yalnızca günümüzün kentsel zorluklarını ele almakla kalmıyor, aynı zamanda teknolojinin sürdürülebilir büyümeyi yönlendirdiği ve kentsel yaşamı iyileştirdiği bir gelecek öngörüyor. Urbanite'ın kentsel gelişimde AI kullanımı, sosyal, ekonomik ve çevresel faktörleri dikkate almanın önemini vurgulayarak daha dayanıklı ve sürdürülebilir şehirler için zemin hazırlıyor. AB vatandaşlarına bağımsız mobilite değişiklikleri için açık kaynaklı bir platform sağlama hedefi henüz tam olarak gerçekleştirilmemiş olsa da, bu işlevsel prototip konseptin uygulanabilirliğini gösteriyor ve gelecekteki gelişmeler için sahneyi hazırlıyor.

Yazar Katkıları:MG, Urbanite sisteminin Jozef Stefan Enstitüsü (JSI) kısmı için kavramsallaştırmanın, denetimin ve metodolojinin çoğunu ve dolayısıyla bu makaledeki genel yaklaşımı da sağladı. MS (Miljana Shulajkovska), MS (Maj Smerkol) ve GN, programlamanın, entegrasyonun, rapor yazmanın, proje yönetiminin ve benzerlerinin çoğunu sağladı. Tüm yazarlar, el yazmasının yayınlanmış versiyonunu okumuş ve kabul etmiştir.

Finansman: Bu çalışma, 870338 numaralı hibe sözleşmesi kapsamında Avrupa Birliği'nin Ufuk 2020 araştırma ve inovasyon programından fon alan bir projenin parçasıdır. Yazarlar ayrıca Slovenya Araştırma ve İnovasyon Ajansı'nın (araştırma çekirdek fonu No. P2-0209) finansal desteğini de kabul etmektedir.

Veri Kullanılabilirliği Beyanı: Bu çalışmayla ilişkili veriler şu adrese depolanmıştır:https://repo.ijs.si/urbanite/ml-mobility-proposal/-/tree/master(11 Eylül 2024'te erişildi).

Teşekkürler: Bu çalışma, 870338 numaralı hibe sözleşmesi kapsamında Avrupa Birliği'nin Ufuk 2020 araştırma ve inovasyon programından fon alan bir projenin parçasıdır.

yazarlar ayrıca Slovenya Araştırma Ajansı'nın mali desteğini de kabul etmektedirler (araştırma çekirdek finansmanı No. P2-0209). Sergio Campos, Dino Alessi, Tatiana Bartolomé, Sonia Bilbao, Mario Colosi, Giuseppe Ciulla, Erik Dovgan, Maria Fazio, María José López, Maria Llambrich, Francesco Martella, Isabel Matranga, Ignacio Olabarrieta, Massimo Villari, Arianna Villari, Marit dahil olmak üzere birçok kişi ilgili projede önemli bir rol oynadı. Hoefsloot, Jure Grabnar, Jorge Garcia, Eduardo Green, Maitena Ilardia, Torben Jastrow, Julia Jansen, Giovanni Parrino, Heli Ponto, Nathalie van Loon, Thomas van Dijk, Keye Wester, Zdenko Vuk ve Iñaki Etxaniz.

Çıkar Çatışmaları: Çıkar çatışması yoktur. Bazı proje üyeleri ortak yazarlık için değerlendirildi; ancak, makalede listelenen yazarlar tarafından temel katkıların yapıldığı belirlendi. Çalışmaya daha az önemli katkıda bulunan kişiler, teşekkürler bölümünde kabul edilmektedir.

Referanslar

1. Dameri, RP Akıllı şehir tanımı arayışı: Kapsamlı bir teklif. ÇaprazRef] *Uluslararası Bilgisayar Teknolojileri Dergisi* **2013**, *11*, 2544–2551.
2. Law, KH; Lynch, JP Akıllı şehir: Teknolojiler ve zorluklar. *Bilişim Prof.* **2019**, *21*, 46–51. [ÇaprazRef]
3. Anthopoulos, LG Akıllı şehir alanını anlamak: Bir literatür incelemesi. *Başarılı Akıllı Şehirler İçin Şehir Yönetimlerini Dönüştürmek*; Springer: Berlin/Heidelberg, Almanya, 2015; s. 9–21.
4. Bibri, SE; Krogstie, J. Geleceğin akıllı sürdürülebilir şehirleri: Kapsamlı bir disiplinlerarası literatür taraması. *Sürdürülebilir. Şehirler Topluluğu* **2017**, *31*, 183–212. [ÇaprazRef]
5. Roda-Sanchez, L.; Cirillo, F.; Solmaz, G.; Jacobs, T.; Garrido-Hidalgo, C.; Olivares, T.; Kovacs, E. Akıllı Kampüs Dijital İkizi Oluşturmak: Sistem, Analitik ve Gerçek Dünya Projesinden Öğrenilen Dersler. *IEEE İnternet Nesneleri J.* **2024**, *11*, 4614–4627. [ÇaprazRef]
6. White, G.; Zink, A.; Codecá, L.; Clarke, S. Vatandaş geri bildirimi için dijital ikiz akıllı şehir. *Şehirler* **2021**, *110*, 103064. [ÇaprazRef]
7. Russell, SJ; Norvig, P. *Yapay Zeka Modern Bir Yaklaşım*; Pearson: Londra, İngiltere, 2010.
8. Washburn, D.; Sindhu, U.; Balaouras, S.; Dines, RA; Hayes, N.; Nelson, LE CIO'ların "akıllı şehir" girişimlerini anlamalarına yardımcı olmak. *Büyüme* **2009**, *17*, 1–17.
9. Batty, M. Yapay Zeka ve Akıllı Şehirler. *Çevre. Plan. B Kentsel Anal. Şehir Bilimi.* **2018**, *45*, 3–6. [ÇaprazRef]
10. Geron, A. *Scikit-Learn, Keras ve TensorFlow ile Uygulamalı Makine Öğrenimi: Akıllı Sistemler Oluşturmak İçin Kavramlar, Araçlar ve Teknikler*; O'Reilly Media: Sebastopol, CA, ABD, 2019.
11. Sarker, IH *Makine Öğrenmesi: Algoritmalar, Gerçek Dünya Uygulamaları ve Araştırma Yönleri*; Springer: Berlin/Heidelberg, Almanya, 2021.
12. Gams, M.; Kramar, S. ChatGPT'nin Bilincinin ve Turing Testini Geçme Kapasitesinin Değerlendirilmesi: Kapsamlı Bir Analiz. *J. Bilgisayar.* **2024**, *12*, 219–237. [ÇaprazRef]
13. Farsça, M.; Daneshkhah, A.; Hosseinian-Far, A.; Jahankhani, H. *Dijital İkiz Teknolojileri ve Akıllı Şehirler*; Springer: Berlin/Heidelberg, Almanya, 2020.
14. Naik, A.; Samant, L. Veri madenciliği araçları kullanılarak sınıflandırma algoritmasının korelasyon incelemesi: WEKA, Rapidminer, Tanagra, Orange ve Knime. *Procedia Bilgisayar Bilimleri* **2016**, *85*, 662–668. [ÇaprazRef]
15. Shulajkovska, M.; Smerkol, M.; Dovgan, E.; Gams, M. Bir hareketlilik politikası önerisine yönelik makine öğrenimi yaklaşımı. *Heliyon* **2023**, *9*, e20393. [ÇaprazRef]
16. Shulajkovska, M.; Noveski, G.; Smerkol, M.; Grabnar, J.; Dovgan, E.; Gams, M. AB akıllı şehirleri: Kentsel dijital dönüşümün yeni bir çerçevesine doğru. *Bilişim* **2023**, *47*.
17. Kshetri, N.; Alcantara, LL; Park, Y. Akıllı bir şehrin gelişimi ve benimsenmesi ve kabul görmesi: Yeni songdo örneği. *İletişim Stratejisi* **2014**, *96*, 113–128.
18. Bakici, T.; Almirall, E.; Wareham, J. Akıllı şehir girişimi: Barselona örneği. *J. Knowl. Ekonomi.* **2013**, *4*, 135–148. [ÇaprazRef]
19. Syed, AS; Sierra-Sosa, D.; Kumar, A.; Elmaghraby, A. Akıllı şehirlerde IoT: Teknolojiler, uygulamalar ve zorlukların bir araştırması. *Akıllı Şehirler* **2021**, *4*, 429–475. [ÇaprazRef]
20. Bartolozzi, M.; Bellini, P.; Nesi, P.; Pantaleo, G.; Santi, L. Akıllı şehir için akıllı karar destek sistemi. 2015 IEEE Uluslararası Akıllı Şehir/SocialCom/SustainCom Konferansı (SmartCity), Chengdu, Çin, 19–21 Aralık 2015 Bildirilerinde; IEEE: Piscataway, NJ, ABD, 2015; s. 117–122.
21. Bonczek, RH; Holsapple, CW; Whinston, AB *Karar Destek Sistemlerinin Temelleri*; Akademik Basın: Cambridge, MA, ABD, 2014.
22. Barceló, J.; Codina, E.; Casas, J.; Ferrer, JL; García, D. Mikroskobik trafik simülasyonu: Akıllı ulaşım sistemlerinin tasarımı, analizi ve değerlendirilmesi için bir araç. *J. Intell. Robot. Sist.* **2005**, *41*, 173–203. [ÇaprazRef]
23. Fellendorf, M.; Vortisch, P. Mikroskobik trafik akış simülatörü VISSIM. *Trafik Simülasyonunun Temelleri*; Springer: Berlin/Heidelberg, Almanya, 2010; s. 63–93.
24. Lopez, Pensilvanya; Behrisch, M.; Bieker-Walz, L.; Erdmann, J.; Flötteröd, YP; Hilbrich, R.; Lücken, L.; Rummel, J.; Wagner, P.; Wießner, E. Sumo kullanarak mikroskobik trafik simülasyonu. 2018 21. Uluslararası Akıllı Ulaşım Sistemleri Konferansı (ITSC), Maui, HI, ABD, 4–7 Kasım 2018 Bildirilerinde; IEEE: Piscataway, NJ, ABD, 2018; sayfa 2575–2582.
25. Balmer, M.; Rieser, M.; Meister, K.; Charypar, D.; Lefebvre, N.; Nagel, K. MATSim-T: Mimari ve simülasyon zamanları. *Trafik ve Ulaşım Mühendisliği için Çoklu Ajan Sistemleri*; IGI Global: Hershey, PA, ABD, 2009; s. 57–78.

26. Chang, F.; Das, D. Akıllı ulus Singapur: Vatandaş odaklı akıllı şehir girişimi için politikalar geliştirmek. *Ulusal Kentsel Politikaların Geliştirilmesi: Yeşil ve Akıllı Şehirlere Giden Yollar*; Springer: Berlin/Heidelberg, Almanya, 2020; s. 425–440.
27. Breslow, H. Akıllı şehir ve gayriresmîliğin sınırlandırılması: Dubai örneği. *Kentsel Aygır.* **2021**, *58*, 471–486. [ÇaprazRef]
28. Ghasemi, A. *Akıllı Şehirde Sürdürülebilirlik ve Veri Toplama—Kopenhag'daki Wi-Fi ve Bluetooth İzleme Projesinin Bir Vaka Çalışması*; Lund Üniversitesi: Lund, İsveç, 2015.
29. Flynn, A.; Valverde, M. Kaldırımın bittiği yer: Toronto'nun kıyı şeridindeki kaldırım laboratuvarları anlaşmasının yönetimi. *Windsor Yearb. Erişim Adaleti* **2019**, *36*, 263–283. [ÇaprazRef]
30. Priyadarshi, R.; Ranjan, R.; Vishwakarma, AK; Kumar, RR Sürdürülebilir Kentsel Gelişimde Makine Öğrenimi ve Kablosuz Sensör Ağlarının Dönüştürücü Potansiyeline Kapsamlı Bir Genel Bakış. 2024 Siber Güvenlik için Akıllı Sistemler Uluslararası Konferansı (ISCS) Bildirilerinde, Gurugram, Hindistan, 3-4 Mayıs 2024; IEEE: Piscataway, NJ, ABD, 2024; s. 1-6. [ÇaprazRef]
31. Capra, CF Akıllı Şehir ve Vatandaşları: Amsterdam Akıllı Şehrinde Yönetim ve Vatandaş Katılımı. *Uluslararası J. Plan. Res. (IJEPR)* **2016**, *5*, 20–38. [ÇaprazRef]
32. Macrorie, R.; Marvin, S.; Smith, A.; While, A. Avrupa akıllı şehirleri için ortak bir yönetim çerçevesi? Akıllı şehirler ve topluluklar için Avrupa inovasyon ortaklığı örneği altı ulus forumu. *J. Kentsel Teknoloji.* **2023**, *30*, 63–80. [ÇaprazRef]
33. Anthony Jnr, B. Akıllı şehir gelişimi için veri odaklı girişimlerin araştırılması: teknoloji paydaşlarının bakış açısından ampirik kanıtlar. *Kentsel Ar. Uyg.* **2022**, *15*, 529–560. [ÇaprazRef]
34. Shahat Osman, AM; Elragal, A. Akıllı şehirler ve büyük veri analitiği: Veri odaklı karar alma kullanım örneği. *Akıllı Şehirler* **2021**, *4*, 286–313. [ÇaprazRef]
35. Ahvenniemi, H.; Huovila, A. Şehirler kentsel sürdürülebilirliği ve akıllılığı nasıl teşvik ediyor? Altı büyük Finlandiya şehrinin şehir stratejilerinin değerlendirilmesi. *Çevre. Geliştirme. Sürdürülebilirlik.* **2021**, *23*, 4174–4200. [ÇaprazRef]
36. Bokolo, AJ Akıllı şehir planlama ve tasarımı için veri odaklı yaklaşımlar: Kentsel veri yönetimine ilişkin bir vaka senaryosu. *Rakam. Politika Düzenlemesi. Hükümet.* **2023**, *25*, 351–367. [ÇaprazRef]
37. Ortega-Fernández, A.; Martín-Rojas, R.; García-Morales, VJ Kentsel ortamda yapay zeka: Yenilikçilik ve sürdürülebilirliğin geliştirilmesi için model olarak akıllı şehirler. *Sürdürülebilirlik* **2020**, *12*, 7860. [ÇaprazRef]
38. Benites, AJ; Simoes, AF Kentsel sürdürülebilir kalkınma stratejisinin değerlendirilmesi: Akıllı şehir hizmetleri sürdürülebilirlik taksonomisinin bir uygulaması. *Ekol.Hindistan* **2021**, *127*, 107734. [ÇaprazRef]
39. Komasi, H.; Zolfani, S.; Nemati, A. Sürdürülebilir kalkınma yaklaşımı temelinde kentlerin sosyo-kültürel rekabet gücünün değerlendirilmesi. *Decis. Mak. Uygulama Yönetim Müh.* **2023**, *6*, 583–602. [ÇaprazRef]
40. Wolniak, R. Yapay Zeka ve Akıllı Şehirler: Scopus Tabanlı Bir Literatür İncelemesi. *J. Kentsel Teknoloji.* **2024**, *31*, 45–67.
41. Garau Guzman, J.; Baeza, V. İHA'lar ve VLC Teknolojileriyle Trafik Yönetimi Aracılığıyla Kentsel Hareketliliğin Geliştirilmesi. *İnsansız hava araçları* **2023**, *8*, 7. [ÇaprazRef]
42. W Axhausen, K.; Horni, A.; Nagel, K. *Çoklu Ajan Taşıma Simülasyonu MATSim*; Ubiquity Press: Londra, İngiltere, 2016.
43. Kučera, T.; Chocholáč, J. PTV VISSIM yazılımını kullanarak şehir lojistiği simülasyon modelinin tasarımı. *Transp. Res. Procedia* **2021**, *53*, 258–265. [ÇaprazRef]
44. Berčič, T.; Bohanec, M.; Ažman Momirski, L. Akıllı Kent Planlamasında Çok Kriterli Karar Modellerinin Entegre Edilmesi: Mimarlık ve Kentsel Tasarım Yarışmalarına İlişkin Bir Vaka Çalışması. *Akıllı Şehirler* **2024**, *7*, 786–805. [ÇaprazRef]
45. Zupan, B.; Demsar, J.; Kattan, MW; Ohori, M.; Graefen, M.; Bohanec, M.; Beck, JR Orange ve eldeki kararlar: Tahmini veri madenciliği ve karar desteğini birleştirme. ECML/PKDD Veri Madenciliği, Karar Desteği ve Meta-Öğrenmenin Tümleştirme Yönleri Çalıştayı Bildirilerinde, Freiburg, Almanya, 3-5 Eylül 2001; s. 151-162.

Yasal Uyarı/Yayıncının Notu: Tüm yayınlarda yer alan ifadeler, görüşler ve veriler yalnızca bireysel yazar(lar) ve katkıda bulunan(lar)a aittir ve MDPI ve/veya editör(ler)e ait değildir. MDPI ve/veya editör(ler), içerikte atıfta bulunulan herhangi bir fikir, yöntem, talimat veya üründen kaynaklanan herhangi bir kişi veya mal yaralanmasından sorumlu değildir.