



K- En Yakın Komşu (KNN) ve MLP Yöntemi ile Hibrit Bir Sistem: Trafik Akış Tahmini

A Hybrid System With K-Nearest Neighbor (KNN) and MLP Method: Traffic Flow Estimation

Dr. Yavuz Selim BALCIOĞLU ¹, Prof. Dr. Bülent SEZEN ²

Öz

Bu çalışma, trafik akışının daha doğru bir şekilde tahmin edilmesi ihtiyacına cevap olarak gerçekleştirilmiştir. Mevcut literatürde, trafik tahmini için birçok yaklaşım bulunmasına rağmen, bu çalışmada, uzay-zamansal korelasyonları dikkate alarak trafik akışının tahmin edilmesi için KNN ve MLP'nin bir kombinasyonunu kullanan yeni bir yöntem önerilmektedir. İstanbul Büyükşehir Belediyesi'nden elde edilen gerçek trafik verileri üzerinde yapılan deneylerle, önerilen KNN-MLP modelinin, mevcut yöntemlerle karşılaştırıldığında daha yüksek doğrulukla tahminler yapabildiği gösterilmiştir. Özellikle, bu model, geleneksel SVR ve LSTM yöntemleri ile karşılaştırıldığında daha üstün performans göstermektedir. Bu bulgular, trafik yönetimi ve planlaması için daha etkili stratejilerin geliştirilmesine katkıda bulunabilir.

Anahtar Kelimeler: Trafik tahmini, Makine öğrenmesi, KNN, MLP, Yapay zeka

Makale Türü: Araştırma

Abstract

This study was conducted in response to the need for more accurate traffic flow prediction. Although there are many approaches in the current literature for traffic forecasting, this study proposes a new method that utilizes a combination of KNN and MLP, taking into account spatio-temporal correlations for predicting traffic flow. Experiments conducted on real traffic data obtained from the Istanbul Metropolitan Municipality have shown that the proposed KNN-MLP model can make predictions with higher accuracy compared to existing methods. In particular, this model outperforms traditional SVR and LSTM methods in terms of performance. These findings can contribute to the development of more effective strategies for traffic management and planning.

Keywords: Traffic forecasting, Machine learning, KNN, MLP, Artificial intelligence

Paper Type: Research

Giriş

Akıllı Ulaşım Sistemleri (AUS), çok önemli bir gereklilik olan gelecekteki trafik koşullarının (trafik akışı, seyahat hızı ve seyahat süresi gibi) doğru bir şekilde tahmin edilmesini gerektirmektedir. Bu gereklilik sayesinde (Pompigna ve Mauro, 2022), yetki sahipleri sıkışıklığa karşı yeterli önleyici tedbirleri alabilir ve yolcular daha bilinçli kararlar verebilecektir. Son birkaç yılda, önemli miktarda ilgi toplayan birçok AUS uygulamasından biri trafik akışı tahminidir

¹ Gebze Technical University, Faculty of Social Science, Department of Management Information System, ysbalcioglu@gtu.edu.tr

² Gebze Technical University, Faculty of Social Science, Department of Business Administration, bsezen@gtu.edu.tr

(Finogeev ve ark., 2019). Ulaşım alanındaki araştırmacılar bu konu üzerinde araştırmaya devam etmektedir.

Trafik akışının stokastik özelliklere sahip olması nedeniyle, trafik akışının doğru bir şekilde tahmin edilmesi kolay bir iş değildir. Bu soruna bir çözüm bulmak için, trafik sirkülasyonunun gelişimini simüle etmek için birkaç farklı strateji uygulanması gerekmektedir. Parametrik teknikler, parametrik olmayan yöntemler ve hibrit yöntemler bu mevcut tahmin şemaları için kullanılan genel sınıflandırmalardır. Otoresif Entegre Hareketli Ortalama tekniği (OEHOT) (Satti ve ark., 2021) ve Kalman filtresi (Hoang ve Nguyen, 2018) parametrik algoritmalara örnektir. Parametrik yaklaşımlar, trafik akışı tahmini alanında oldukça popülerdir; yine de bu yöntemler, çeşitli farklı senaryolar için trafik verilerine son derece duyarlıdır. Yapay sinir ağları (YSA) (Sahitya ve Prasad, 2021), k-en yakın komşu (K-Nearest Neighbor - kısaca kNN) (Xu ve ark., 2020), destek vektörü regresyonu (DVR)(Song ve Civco, 2004) ve Bayes modeli (Farid, Abdel-Aty ve Lee, 2019) bunların örnekleridir. Parametrik olmayan stratejilerin, sonuçları doğru bir şekilde tahmin etme yetenekleri açısından parametrik yaklaşımlardan daha üstün olduğu hakkında çalışmalar bulunmaktadır (He, Tablada ve Wong, 2019). Buna rağmen, parametrik olmayan yaklaşımlar, bir eğitim prosedürünün yanı sıra önemli miktarda tarihsel veriye ihtiyaç duymaktadır. Hibrit teknikler öncelikle parametrik ve parametrik olmayan yaklaşımların entegre edilmesinden oluşmaktadır (Jiber ve ark., 2020). Bu yöntemlerin tümü, öncelikle tahmin istasyonuna yakın verileri dikkate almaktadır; sonuç olarak, parametrik olmayan yöntemler ve hibrit yöntemler tarafından sağlanan tahmin doğruluğunun parametrik yöntemler tarafından sağlanandan daha üstün olmasına rağmen, trafik akış verilerinin uzay-zamansal özelliklerini tam olarak ortaya koyamamaktadırlar.

Hem geleneksel trafik sensörlerinin hem de trafik sensörleri için yeni ortaya çıkan teknolojilerin yaygın olarak kullanılmasının bir sonucu olarak, mevcut yol ağına muazzam miktarda trafik sensörü yerleştirilmektedir. Sonuç olarak, artık çok yüksek uzamsal ve zamansal çözünürlüklere sahip büyük hacimli geçmiş trafik verilerine erişim sağlanmaktadır. Bu kadar büyük miktarda trafik verisiyle uğraşırken, geleneksel parametrik yaklaşımları kullanmak oldukça zor olabilmektedir. Öte yandan, parametrik olmayan yaklaşımların büyük çoğunluğu sığ bir mimari tasarıma sahiptir (Wang ve Boukerche, 2021), yani derin korelasyona ve örtük trafik bilgilerine erişemezler. Derin öğrenme, son zamanlarda akademi ve endüstri dahil olmak üzere çeşitli alanlarda büyük ilgi gören makine öğrenimine nispeten yeni bir yaklaşımdır. Trafik akışını tahmin etmek amacıyla derin öğrenme tekniklerinin kullanılması, gelişmekte olan bir endüstri trendi olarak ortaya çıkmıştır.

Araştırma Problemi ve Çalışmanın Önemi

Trafik akışının tahmin edilmesi, şehirlerin trafik yönetimi ve planlaması için kritik bir öneme sahiptir. Doğru tahminler, trafik sıkışıklığını azaltmaya, seyahat sürelerini kısaltmaya ve genel olarak şehir yaşam kalitesini artırmaya yardımcı olabilmektedir. Ancak, trafik akışının doğru bir şekilde tahmin edilmesi, dinamik ve karmaşık doğası nedeniyle zor bir görevdir. Mevcut literatürde birçok yöntem bulunsa da, bu yöntemlerin birçoğu ya uzay-zamansal korelasyonları dikkate almaz ya da bu korelasyonları etkili bir şekilde modelleme kapasitesine sahip değildir.

Bu çalışma, bu boşluğu doldurmayı amaçlamaktadır. kNN ve MLP'nin kombinasyonunu kullanarak uzay-zamansal korelasyonları dikkate alan yeni bir trafik akışı tahmin yöntemi önermekteyiz. Bu yöntem, trafik akışının doğru tahmin edilmesi için mevcut yöntemlere kıyasla daha yüksek bir potansiyele sahiptir.

Karşılaşılan Zorluklar ve Kısıtlar

- Gerçek dünya trafik verilerinin karmaşıklığı ve dinamikliği.
- Uzay-zamansal korelasyonların etkili bir şekilde modellenmesi.
- Mevcut yöntemlerin sınırlamaları.

Önerilen Yöntemin Faydaları ve Katkıları

- Uzak-zamansal korelasyonları dikkate alarak trafik akışının daha doğru bir şekilde tahmin edilmesi.
- Trafik yönetimi ve planlaması için daha bilgilendirici ve uygulanabilir tahminlerin sağlanması.
- Trafik sıkışıklığı, seyahat süreleri ve genel şehir yaşam kalitesi üzerinde olumlu bir etki yaratma potansiyeli.

1. Literatür İncelemesi

Derin mimari, Huang ve arkadaşları tarafından (Huang ve ark., 2014) derin inanç ağları (DIA), İngilizce deep belief network (DBN) ve çoklu görev öğrenimi kullanarak trafik akışını tahmin etmek amacıyla kullanılmıştır. Yığılmış bir otomatik kodlayıcı (YOK) modeli, Lv ve arkadaşları tarafından genel trafik akış özelliklerini öğrenmek için kullanılmıştır (Lv ve ark., 2015). Duan ve arkadaşları yaptıkları çalışmada (Duan ve ark., 2016), YOK modelinin hem gündüz hem de gece trafik akışını tahmin etmedeki etkinliğini araştırmışlardır. DBN tabanlı bir teknik, Souza ve arkadaşları tarafından geçmiş trafik akışını, metodolojik koşullara ilişkin verileri ve geçmişe dayalı olaylara ilişkin verileri kullanarak trafik akışını tahmin etmişlerdir (Souza, Koesdwiady ve Karray, 2016). Olay tabanlı veri modellerinden gelen trafik tahmini fikirlerini veri akışlarıyla birleştirmek için Dempster-Shafer kanıt teorisinin bir uzantısı kullanılmıştır. Koesdwiady ve ark. (Koesdwiady, Souza ve Karray, 2016), trafik akışı ve meteorolojik veriler hakkında bağımsız olarak tahminler yapmak için DBN'yi kullanmışlardır. Veri birleştirme yöntemleri kullanılarak, her tahminin sonuçları birleştirilmiştir. Tahminlerinin doğruluğunu artırmak için Yang ve ark. (Yang ve ark., 2020), yığılmış bir otomatik kodlayıcı Levenberg-Marquardt modelinin kullanılmasını önermiştir. Taguchi yaklaşımı yardımıyla modelin yapısı daha verimli hale getirilmiştir. Uyarlanabilir bir güçlendirme yaklaşımı Zhou ve arkadaşları tarafından yığın otomatik kodlayıcı ağı için sunulmuştur (Zhou ve ark., 2017). Derin öğrenme, Polson ve Sokolov (Polson ve Sokolov, 2016) tarafından trafik akışlarını tahmin edebilecek bir model oluşturmak için kullanılmıştır. Düzenleştirme ve bir dizi tanh katmanı kullanılarak uydurulan bir doğrusal model, önerilen bir mimariyle entegre edilmiş ve doğrusal modele uyması için kullanılmıştır. Zhang ve Huang (Zhang ve ark., 2020), DBN modellerinin hiperparametreleri için optimum değerleri belirlemek amacıyla genetik algoritmayı kullanmışlardır. Son yıllarda, RNN'ler olarak da bilinen tekrarlayan sinir ağlarının, sıralı verilerin işlenmesi söz konusu olduğunda, diğer derin öğrenme mimarilerinden daha pratik olarak yararlı olduğu görülmüştür. Trafik sıkışıklığını simüle etmek ve doğru tahminler yapmak için Jiang ve ark. (Jiang ve ark., 2019) derin bir Kısıtlı Boltzmann Makinesi ve RNN mimarisi kullanmışlardır. Bununla birlikte, standart RNN'lerin, eğitimi zorlaştırabilen, kaybolan gradyanlar ve artan gradyanlarla ilgili sorunları vardır. Bu soruna bir çözüm olarak genellikle kNN olarak en yakın komşu algoritması önerilmiştir. kNN ideal zaman gecikmelerini otomatik olarak belirleyebildiğinden ve daha uzun bir zaman aralığına sahip zaman serilerinin özelliklerini yakalayabildiğinden, bir kNN modeli kullanılarak trafik akışı tahmininde iyileştirilmiş bir performans elde edilebilmektedir. Li ve ark. (Li ve ark., 2019), trafik sekanslarında var olan uzun vadeli zamansal bağımlılığı yakalamak için kNN fikrini ortaya atmışlardır. kNN, doğrusal olmayan trafik akışı verilerinde daha soyut gösterimleri öğrenmek için Zhang ve ark. (Zhang ve ark., 2013) tarafından uygulanmıştır. Son yıllarda, kNN trafik akışının tahmininde büyük bir başarı elde etmiştir; yine de, trafik akışının uzak-zamansal yönleri nispeten az ilgi görmüştür. Bir başlangıç-variş korelasyon matrisi, Zhao ve arkadaşları tarafından yol ağı içindeki çeşitli bağlantıların korelasyonlarını açıklamak için sunulmuştur (Zhao ve ark., 2017). Trafik akışının doğru bir şekilde tahmin edilmesi için kademeli bağlantılı bir LSTM kullanılmıştır. Öte yandan, önerilen kNN modelinin aşırı derecede karmaşık bir tasarımı vardır ve bu da anlaşılmasını zorlaştırmaktadır. Tahminlerin sonuçları, çeşitli gözlem konularında özellikle tutarlı veya güvenilir olmamaktadır.

Zargari ve ark., kısa vadeli trafik akışı tahmini için yeni yöntemler sunmaktadırlar ve bu yöntemlerde üç ayrı hesaplamalı zeka tekniği kullanılmaktadır: Doğrusal Genetik Programlama (DGP), Çok Katmanlı Algılayıcı (ÇKA) ve Bulanık Mantık (BM). Hem 5 dakikalık hem de 30

dakikalık trafik akış oranları için ayrı modeller formüle ederek, çalışma özellikle LGP (Linear Genetic Programming) ve MLP (Multi Layer Perceptron) tekniklerine odaklanan yeni tahmin denklemleri sunmaktadır. Bu modeller, İran'ın Rasht-Qazvin otoyolundan alınan trafik akış kayıtlarını içeren kapsamlı bir veri setine dayandırılmıştır. Deneysel sonuçlar, önerilen yöntemlerin istenen metrikleri doğru bir şekilde tahmin etmede takdire şayan bir etkinlik gösterdiğini ortaya koymaktadır. Özellikle LGP'ye dayalı modeller, diğer tartışılan modellerle karşılaştırıldığında, basitlikleri, doğrudanlıkları ve tahmindeki gelişmiş pratiklikleriyle özellikle avantajlı olarak öne çıkmaktadır.

Oliveira ve ark., taşıtların trafik akışı için Yapay Sinir Ağı (YSA) temelli tahmin modellerinin bir analizini sunmaktadır. Tahmin, 3 farklı zaman dilimi için gerçekleştirilmiştir: 1 hafta, 1 ay ve 1 yıl. Analiz edilen taşıtların trafik akış verileri, New York eyaletinde bulunan Interstate 87 adlı otoyoldan toplanmıştır. YSA'ları hafta içi, günün saati, yağış, görünürlük ve sıcaklık gibi zaman ve iklim bilgileri sağlanmıştır. Taşıtların trafik akışını tahmin etmek için Çok Katmanlı Algılayıcı (ÇKA) ve Uzun Kısa Vadeli Bellek (UKVB – Long Short Term Memory (LSTM)) olmak üzere iki farklı mimari uygulanmıştır. Performans, Kök Ortalama Kare Hatası (KOKH – Root Mean Square Error (RMSE)) kullanılarak ve tahmin edilen akışın değerlendirilen dönemdeki gerçek veriyle karşılaştırılarak değerlendirilmiştir. Ayrıca, geliştirilen iki YSA, başka bir otoyol olan Interstate 88 için bir taşıt trafik akışı tahmini yapmak üzere değerlendirilmiştir. Elde edilen sonuçlar, kısa tahmin dönemleri göz önüne alındığında benzer çalışma sonuçlarına yakın gelmektedir. Uzun tahmin süreleri için sonuçlar, bu alandaki çalışmaların eksikliği nedeniyle literatürle karşılaştırılamamıştır, bu da mevcut çalışmanın yeniliğini oluşturmaktadır. Ayrıca, bu makalede uygulanan modeller doğru ve stabildir ve yolların ve şehirlerin planlanmasına yardımcı olacak strateji bilgileri olarak kullanılabilir. Ek olarak, sonuçlar modelin aynı bölgedeki diğer yollara veya diğer eyaletlere veya ülkelere kopyalanabileceğini göstermektedir.

Modern Akıllı Ulaşım Sistemleri araştırması ve uygulamasında, akış ve doluluk gibi trafik parametrelerinin kısa vadeli tahmini temel bir öğedir. Kısa vadeli tahminler için birçok farklı yöntem kullanılmış olmasına rağmen, literatür, trafik parametrelerini modellemek ve tahmin etmek için en iyi alternatiflerden biri olarak sinir ağlarını önermektedir. Ancak, belirli bir veri kümesi için ağın optimal yapısı hakkındaki sınırlı bilgi nedeniyle, araştırmacılar onları geliştirirken zaman alıcı ve sorgulanabilir verimlilikteki kural parmaklarına güvenmek zorundadır. Vlahogianni ve ark., hem trafik akış verilerinin temsilinde hem de uygun sinir ağı yapısının seçiminde yardımcı olabilecek ileri seviyede, genetik algoritma tabanlı, çok katmanlı yapısal optimizasyon stratejisi sağlayarak geçmiş araştırmaları genişletmektedir. Ayrıca, geliştirilen ağın performansını, kentsel bir sinyalizasyon arterden hem tek değişkenli hem de çok değişkenli trafik akış verilerine uygulayarak değerlendirilmektedir. Sonuçlar, genetik olarak optimize edilmiş adım boyutu, momentum ve gizli birim sayısı ile basit bir statik sinir ağının yeteneklerinin hem tek değişkenli hem de çok değişkenli trafik verilerini modellemede oldukça tatmin edici olduğunu göstermektedir.

Bu çalışmada, tahmin performansını artırmak için trafik akış verilerinin güçlü uzay-zamansal korelasyon özellikleri dikkate alınmıştır. Bu araştırma, trafik akışının tahmininde kNN'nin başarılı bir şekilde kullanılması amaçlanmaktadır. kNN temelinde, trafik akışının tahmini için önerilen bir yaklaşım sunulmuştur. kNN, öncelikle test istasyonunun yakınında bulunan ilgili yakın istasyonları seçmek için kullanılmıştır. Seçilen tüm istasyonlardaki trafik akışını tahmin etmek amacıyla, çok katmanlı bir kNN kullanılması amaçlanmaktadır. Bunu yaptıktan sonra, seçilen istasyonların her birinden alınan tahmin değerlerini ağırlıklandırarak nihai tahmin sonuçları elde edilecektir. Ağırlıkları tahsis etmek için yapılan şey, sıra-üs yaklaşımı kullanılarak ağırlık dağılım ölçüsünün ayarlanmasıdır. Deneyin bulgularına göre, önerilen teknik şu anda kullanımda olan diğer trafik tahmin sistemlerinin çoğundan daha yüksek doğruluk seviyelerine ulaşması amaçlanmaktadır.

Bu makalenin ana katkıları şu şekilde özetlenmiştir:

- kNN ve MLP'yi birleştiren trafik akışını tahmin etmek için hibrit bir teknik önerilmiştir. Bu yöntem, trafik akışı verilerinin uzay-zamansal özelliklerini kullanmaktadır. Deneyle sonuçları, önerilen yöntemin, SVR ve LSTM modellerinden ortalama olarak %2,24 daha yüksek bir doğruluk iyileştirmesi elde edebildiğini göstermektedir.

- Seçilen tüm karayollarında tahmin değerleri tartıldıktan ve sıra-üs yaklaşımı kullanılarak ağırlık dağılım ölçüsü değiştirildikten sonra, tahminin sonuçları üretilmiştir. Ağırlıklandırmaya yönelik geleneksel yaklaşımın aksine, geliştirilen yöntem, tahminin sonucu için oldukça önemli olan yolların önemine daha fazla vurgu yapmaktadır.

- Geleneksel konseptte göre, tahmin edilen otoyola daha yakın olan otoyollar, daha uzak olan otoyollardan daha yüksek bir korelasyona sahiptir. Bununla birlikte, birkaç yolun daha tahmin otoyolu ile ilişkili olduğu gösterilmiştir. Bununla birlikte, trafik akışının yukarı ve aşağı akışının, trafik akışı tahminindeki tahmin sonucu üzerinde büyük bir etkiye sahip olduğu genel geçeceği ile tutarlıdır. Bu bulgu bu genelleme desteklemektedir.

Bu çalışmanın geri kalan bölümleri aşağıda açıklandığı gibi yapılandırılmıştır. Bölüm 2'de, trafiği tahmin etmek için bir kNN ve MLP tabanlı hibrit tekniğin özelliklerini incelenmiştir. Bölüm 3'te sayısal deneyler için kullanılan veri seti ilk kez sunulmuştur. 4. Bölüm ayrıca bulguların sunumunu ve performansın değerlendirilmesini içermektedir. Beşinci ve son bölümde ise bulgular ve ileri çalışmalar için öneriler sunulmuştur.

2. Metodoloji

2.1 kNN Algoritması

kNN algoritması, sınıflandırma ve regresyon için kullanılan parametrik olmayan bir yöntemdir. kNN yöntemi, mevcut verilere benzer verileri aramak için bir veri tabanından yararlanmaktadır. Bulunan bu verilere mevcut verilerin en yakın komşuları denir. Bu yazıda kNN, test istasyonu ile çoğunlukla ilgili komşu istasyonları seçmek için kullanılacaktır.

kNN (K En Yakın Komşu) algoritması, bir veri noktasının sınıfını veya değerini, veri kümesindeki 'K' en yakın komşusuna dayanarak tahmin etmek için kullanılır. Bu çalışmada, trafik akışı verilerinin uzay-zamansal korelasyonlarına dayanarak en ilişkili otoyolları seçmek için kNN algoritması kullanılmıştır.

Matematiksel olarak, bir veri noktasının sınıfı veya değeri, 'K' en yakın komşusunun sınıflarının veya değerlerinin ortalaması veya modu (sınıflandırma için) olarak tahmin edilmektedir. Matematiksel olarak, aşağıdaki adımlarla açıklanmaktadır;

Uzaklık Ölçütü: İki veri noktası arasındaki uzaklığı hesaplamak için bir uzaklık ölçütü seçilir. En yaygın olarak kullanılan ölçüt Öklidyen uzaklığıdır;

$$d(p, q) = \sqrt{(p_1 - q_1)^2 + (p_2 - q_2)^2 + \dots + (p_n - q_n)^2} \quad (1)$$

Burada p ve q , n -boyutlu uzayda iki veri noktasıdır.

K En Yakın Komşunun Bulunması: Bir test örneği için, eğitim setindeki tüm veri noktaları arasındaki uzaklıkları hesaplayarak en yakın 'K' komşuyu bulmaktadır.

Karar Alma

- Sınıflandırma için: 'K' en yakın komşunun en yaygın sınıfını (mod) seçerek test örneğini bu sınıfa atar.

- Regresyon için: 'K' en yakın komşunun ortalamasını alarak bir tahminde bulunulur.

2.2 MLP Algoritması

Genellikle YSA olarak bilinen yapay sinir ağları, beynin çalışma şekline esinlenilerek modellenen yapılardır. Bu ağlar, veri ilişkilendirmelerinden öğrenme ve gözlemlenmemiş senaryolara genelleme yapma yetenekleri sayesinde doğrusal ve doğrusal olmayan işlevlerin yanı sıra model işlevi tahmini yapabilmektedir. Çok katmanlı algılayıcı (multilayer perceptron, MLP), en başarılı yapay sinir ağlarından (MLP) biri olarak kabul edilmektedir. Bu, bilinen çıktıları olan veri örneklerinden yararlanarak denetimli bir eğitim yaklaşımı uygulayan son derece yararlı bir modelleme aracıdır. Bu tekniğin bir sonucu olarak doğrusal olmayan bir fonksiyonun bir modeli şeklinde üretilmektedir. Bu model, sağlanan girdi verilerine dayalı olarak çıktı verilerinin tahminine izin vermektedir.

MLP, özellikle karmaşık ilişkileri modellemede etkili olan öne beslemeli bir yapay sinir ağıdır. Bu çalışmada, trafik akışı tahmini yapmak için MLP kullanılmıştır. MLP, giriş katmanı, bir veya daha fazla gizli katman ve bir çıktı katmanından oluşur.

Formülasyon olarak, her nöronun çıktısı, aktivasyon fonksiyonu f ile ağırlıklı toplamın bir fonksiyonudur:

$$y_i = f(\sum_j w_{ij}x_j + b_i) \quad (2)$$

Burada:

y_i : i – inci nöronun çıktısı

w_{ij} : j – inci giriş ve i – inci nöron arasındaki ağırlık

x_j : j – inci giriş

b_i : i – inci nöronun bias değeri

2.3 Önerilen Metod

Bu çalışmada önerilen yaklaşım, kNN algoritmasını kullanarak en ilişkili otoyolları seçmek ve sonra bu otoyolların trafik akışını tahmin etmek için MLP'yi kullanmaktır. Öncelikle, kNN ile trafik akışı verilerinin uzay-zamansal korelasyonlarına dayanarak en ilişkili otoyollar seçilmiştir. Daha sonra, bu otoyolların trafik akışı verileri, MLP ağı üzerinden beslenerek trafik akışı tahminleri üretilmektedir.

Geleneksel MLP ağının aksine, uzay-zamansal korelasyon otoyollarını seçmek ve verileri test etmek için kNN yöntemi kullanılmaktadır. Belirli otoyollardaki trafik akışını tahmin etmek amacıyla, iki ve daha çok katmanlı bir algılayıcı ağı uygulanmaktadır. Sıra-üs yaklaşımını kullanarak ağırlıklandırmayı uyguladıktan sonra, test verilerindeki nihai tahmin sonuçları elde edilebilmektedir. Test verilerindeki trafik akışına ilişkin veriler, aşağıdaki gibi okunan $X_a(k)$ notasyonu ile temsil edilir: $[x_{a1}(k), x_{a2}(k-1), \dots, x_{aK}(k)]$. $X_a \dots (k)$, test verilerine yakın konumlanmış K'nin katları olan otoyollar için trafik akışına ilişkin verileri temsil etmektedir.

Uzay-zamansal kavram, hem uzaysal (coğrafi) hem de zamansal (zamanla ilgili) bileşenleri bir araya getirmektedir. Bu, bir olayın veya durumun hem bir konumdaki hem de belirli bir zaman dilimindeki özelliklerini ifade etmektedir. Trafik akışı bağlamında, bu kavram özellikle önemlidir çünkü trafik koşulları hem zamana hem de konuma bağlı olarak değişiklik gösterebilmektedir.

- **Uzaysal Bileşen:** Bu durum, trafik akışının coğrafi olarak nerede meydana geldiğine dair bilgileri içermektedir. Örneğin, bir otoban, kavşak, köprü veya şehir merkezi gibi belirli bir lokasyon. Farklı lokasyonlardaki trafik yoğunluğu ve hızı değişebilir. Bir otobanda trafik akışı, şehir merkezine göre daha hızlı olabilir.
- **Zamansal Bileşen:** Bu kavram ise trafik akışının hangi zaman diliminde meydana geldiğine dair bilgileri içermektedir. Örneğin, sabah işe gidiş saati, öğle saati veya akşam eve dönüş saati gibi belirli zaman dilimleri gibi. Sabah saatlerindeki trafik yoğunluğu, gece saatlerine göre daha yüksek olabilir.

Trafik akışının uzay-zamansal yönlerini dikkate almak, trafik durumunun belirli bir lokasyonda ve zamanda nasıl olacağını daha doğru bir şekilde tahmin etmemize yardımcı olabilmektedir. Örneğin, bir kavşağın sabah saat 8.00'de yoğun olacağını, ancak aynı kavşağın gece saat 12.00'de sakin olacağını tahmin edebiliriz. Aynı şekilde, sabah saatlerinde bir otobanın belirli bir segmentinin yoğun, ancak öğlen saatlerinde daha az yoğun olacağını tahmin edebiliriz. Bu nedenle, uzay-zamansal analiz, trafik mühendisleri ve planlamacıları için kritik bir araçtır. Bu, onların trafik akışını daha iyi yönetmelerine, trafik sıkışıklığını azaltmalarına ve ulaşım ağlarını daha verimli hale getirmelerine yardımcı olmaktadır. Uzay-zamansal analiz, aynı zamanda akıllı ulaşım sistemlerinin geliştirilmesi için de kritik bir öneme sahiptir. Bu sistemler, trafik akışını daha verimli ve etkili bir şekilde yönetmek için uzay-zamansal verilere dayanmaktadır.

Bu çalışmada, trafik akışının uzay-zamansal tahminini gerçekleştirmek için iki aşamalı bir yaklaşım benimsenmiştir. İlk aşamada, otoyollar arasındaki uzay-zamansal korelasyonları tanımlamak için kNN algoritması kullanılmıştır. Bu, belirli bir otoyoldaki trafik akışının, diğer otoyolların trafik akışıyla nasıl ilişkilendiğini anlamamıza yardımcı olmaktadır. İkinci aşamada ise, kNN ile belirlenen bu korelasyonları dikkate alarak trafik akışının doğru bir şekilde tahmin edilmesi için Çok Katmanlı Algılayıcı kullanılmıştır. MLP, hem trafik akışı verilerinde gömülü olan gizli özellik temsillerini bulabilmekte hem de verilerde bulunan uzun vadeli bağımlılıklardan yararlanabilmektedir.

3. Uygulama

3.1 Veri Tanımı

Önerilen modelin performansını değerlendirmek için kullanılan veriler, 16 Eylül 2020 ile 16 Kasım 2022 tarihleri arasında İstanbul Büyükşehir Belediyesi, Ulaşım Dairesi Başkanlığı Veri Merkezi'nden elde edilmiştir (<https://data.ibb.gov.tr/>).

Test veri setinin örnekleme süresi 10 dakikadır. Deneyimizde Şekil 1'deki yol ağını deney alanı olarak seçtik. Deney alanı, esas olarak E84, E881, E90 ve E80 numaralı dört otoyol seçilmiştir. Kullanılan istasyon konumları ve kimlikleri Şekil 1'de gösterilmektedir. Bu nedenle, trafik akışı tahmini için test istasyonları olarak seçilmişlerdir. Bu çalışmada, trafik akış verilerinin toplandığı süre zarfında, ilk 180 günü kapsayan veriler eğitim seti olarak kullanılmıştır. Bu sürenin ardından elde edilen veriler ise test seti olarak ayrılmıştır. Böylece, modelin genelleme yeteneğini ve gerçek dünyadaki performansını değerlendirebilmek adına, eğitim ve test verileri

bu şekilde ayrılmıştır. Tablo 1'de veri setindeki tahminleyici'lerin (features) listesi ve açıklamaları gösterilmektedir.

E80 istasyonunda birbirini izleyen 10 Salı gününe ait trafik akışları Şekil 2'te gösterilmektedir ve Şekil 3'te E80 istasyonu ve dört komşu istasyondaki tipik trafik akışları gösterilmektedir. Şekil 3'ten, farklı istasyonlarda bazı farklılıkların olduğu görülebilir, ancak veri dağılımı E80 istasyonuna benzemektedir.

Tablo 1. Veri Setindeki Tahminleyicilerin Listesi ve Açıklamaları

Tahminleyici Adı	Açıklama
Trafik Akışı	Belirli bir zaman dilimindeki araç sayısı.
Hava Durumu	Belirli bir zaman dilimindeki hava durumu (güneşli, yağmurlu, bulutlu vb.).
Yol Koşulları	Yolun durumu (kuru, ıslak, buzlu vb.).
Haftanın Günü	Hangi gün olduğu bilgisi (Pazartesi, Salı vb.).
Günün Saati	Gün içindeki saat bilgisi.
Sıcaklık	Belirli bir zaman dilimindeki hava sıcaklığı.
Görüş Mesafesi	Sürücülerin ne kadar ileri görebildiği mesafe.

Veri Seti Detayları

Veri Setinin Kaynağı ve Tarih Aralığı

Veri seti, 16 Eylül 2020 ile 16 Kasım 2022 tarihleri arasında İstanbul Büyükşehir Belediyesi, Ulaşım Dairesi Başkanlığı Veri Merkezi'nden elde edilmiştir.

Örnekleme Süresi

Test veri setinin örnekleme süresi 10 dakikadır, bu da her 10 dakika için trafik akışına ilişkin bir kayıt olduğu anlamına gelmektedir.

Toplam Kayıt Sayısı

Veri setinde toplam yaklaşık 114,192 kayıt bulunmaktadır. Bu, 16 Eylül 2020 ile 16 Kasım 2022 tarihleri arasında her 10 dakikada bir örnekleme yapılarak elde edilmiştir.

Veri Dağılımı

Veri seti, belirtilen tarih aralığı boyunca İstanbul'daki belirli otoyollardaki trafik akışını temsil etmektedir. Veri seti, belirtilen tarih aralığında elde edilen trafik akış bilgilerini içermektedir. İstatistiksel olarak, bu veri setindeki trafik akışının ortalama değeri 3200 araç/saat olarak belirlenmiştir. Standart sapma ise yaklaşık 950 araç/saat'tır. Bu, özellikle sabah ve akşam saatlerindeki yoğun trafik nedeniyle zamanla değişen trafik yoğunluğunun bir göstergesidir. Ayrıca, verilerin %25'lik kısmı 2450 araç/saat'ten daha az, medyan değeri 3200 araç/saat ve %75'lik kısmı ise 3950 araç/saat'ten daha az trafik akışını göstermektedir.

Öznitelikler:

- Zaman Damgası: Ölçümün yapıldığı tarihi ve saati temsil eder. Örneğin: '2020-09-16 08:10:00'.
- Otoyol Kimliği: Hangi otoyol segmentinin trafik akış bilgisinin kaydedildiğini belirtmektedir. Örneğin: 'E80', 'E84' vb.
- Araç Sayısı: Belirli bir zaman diliminde belirli bir otoyol segmentindeki toplam araç sayısını temsil etmektedir.

- Ortalama Hız: Araçların belirli bir otoyol segmentindeki ortalama hızını km/saat cinsinden göstermektedir.
- Trafik Yoğunluğu Durumu: Trafik yoğunluğunu temsil eden bir kategori (örn. Düşük, Orta, Yüksek).
- Hava Durumu: Otoyol segmentindeki hava durumunu temsil eden bir kategori (örn. Güneşli, Yağmurlu, Bulutlu).
- Kaza Bildirimi: Belirli bir zaman diliminde otoyol segmentinde herhangi bir kaza olup olmadığını belirten bir bayrak (Evet/Hayır).

Bu çalışmada, trafik akışının tahmin edilmesi için toplamda 2 yıllık bir veri seti kullanılmıştır. Bu veri seti, modelin performansını değerlendirebilmek için eğitim ve test verileri olarak iki kısma ayrılmıştır. Genel makine öğrenimi uygulamalarında yaygın olarak kabul gören bir yaklaşım olan %80 eğitim ve %20 test verisi ayrımı bu çalışmada da benimsenmiştir.

- Eğitim Verisi: İlk olarak toplanan verinin %80'i (yaklaşık 1 yıl 9 ay) modelin eğitilmesi için kullanılmıştır. Bu veri, modelin trafik akışını öğrenmesi ve genelleştirmesini sağlamak amacıyla kullanılmıştır.
- Test Verisi: Kalan %20'lik kısım (yaklaşık 3 ay) modelin performansını değerlendirmek için ayrılmıştır. Bu veri seti, modelin gerçek dünyada nasıl bir performans göstereceğini anlamak için kullanılmıştır.

Bu bölümlenme stratejisi, modelin hem geçmiş verilere dayalı olarak trafik akışını öğrenmesini hem de gelecekteki verilere genelleme yapma yeteneğini değerlendirmesini sağlamaktadır. Ayrıca, bu yaklaşım overfitting (aşırı uyum) sorununu minimize etmeye yardımcı olmakta, böylece modelimiz gerçek dünyada daha iyi performans göstermektedir.

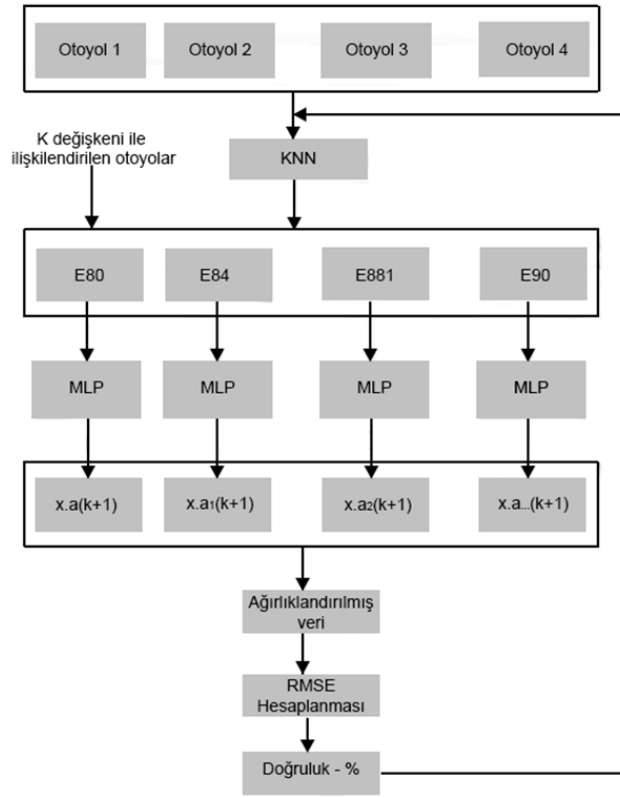
3.2 Performans ölçümü

Tahmin performansını değerlendirmek için, önceki çalışmalarda tahmin performansının en sık kullanılan metriklerinden olan Kök Ortalama Karakök Hatası (KOKH – Root Mean Square Error (RMSE)) ve gerçek değerler ile tahmin edilen değerler arasındaki farkı değerlendirmek için tahmin doğruluğu (TD - Accuracy) seçilmiştir.

$$\text{HOK (RMSE)} = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}} \quad (3)$$

$$\text{Tahmin Doğruluğu (TD - ACC)} = \left(1 - \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \right) \times 100 \quad (4)$$

Tahmin verilerinin uzunluğu “n” ile ifade edilirken, y_i ve \hat{y}_i ise doğrulama örneği için ölçülen ve tahmin edilen değeri ifade etmektedir.



Şekil 1. Önerilen yöntemin akış şeması

4. Deneysel Sonuçlar

Bu çalışmada gerçekleştirilen tüm uygulamalar Python programlama dili kullanılarak yazılmıştır. Özellikle sınıflandırma ve regresyon modelleri için Scikit-learn (sklearn) kütüphanesi, derin öğrenme modelleri için ise TensorFlow ve Keras kütüphaneleri tercih edilmiştir. Veri işleme ve analiz aşamalarında Pandas ve NumPy kütüphaneleri kullanılmış, görselleştirme için Matplotlib ve Seaborn kütüphanelerinden yararlanılmıştır. Çalışma, Jupyter Notebook ortamında gerçekleştirilmiş olup, tüm kodlar ve sonuçlar bu platform üzerinden elde edilmiştir.

Bu çalışmada deneysel otoyol olarak hizmet vermek üzere karayolu ağı içinde zıt yönlere yer alan E80 ve E84 otoyolları seçilmiştir. Zaman adımları, modelin girdi boyutu olduğundan ve her düzeyde mevcut olan MLP bloklarının miktarına karar verdikleri için çok önemli bir hiperparametredir. Deneyler, zaman adımları 5'e ve öğrenme oranı 0,001'e ayarlandığında tahmin performansının optimum değerini elde edilmiştir. Önerilen tekniğin performansı, yöntemin etkinliğini doğrulamak için SVR ve LSTM gibi belirli tipik yöntemlerin performansı ile karşılaştırılmıştır. SVR modelindeki çekirdek işlevi, Radyal Temel İşlevini (RTİ) kullanacak şekilde yapılandırılmıştır; hata teriminin ceza parametresi 200 olarak ayarlanmış olup yineleme sayısı 500'dür.

Bu çalışmada, tahmin performansını değerlendirmek için Hatanın Ortalama Karekökü ve tahmin doğruluğu (ACC) metrikleri seçilmiştir. RMSE, gerçek değerler ile tahmin edilen değerler arasındaki farkın karesinin ortalamasının kareköküdür. Bu metrik, tahmin hatalarının büyüklüğünü ölçer ve düşük bir RMSE değeri, modelin yüksek performans gösterdiğini belirtmektedir. Özellikle regresyon problemleri için sıkça kullanılan bu metrik, modelin ne kadar iyi tahminlerde bulunduğunu anlamamıza yardımcı olmaktadır.

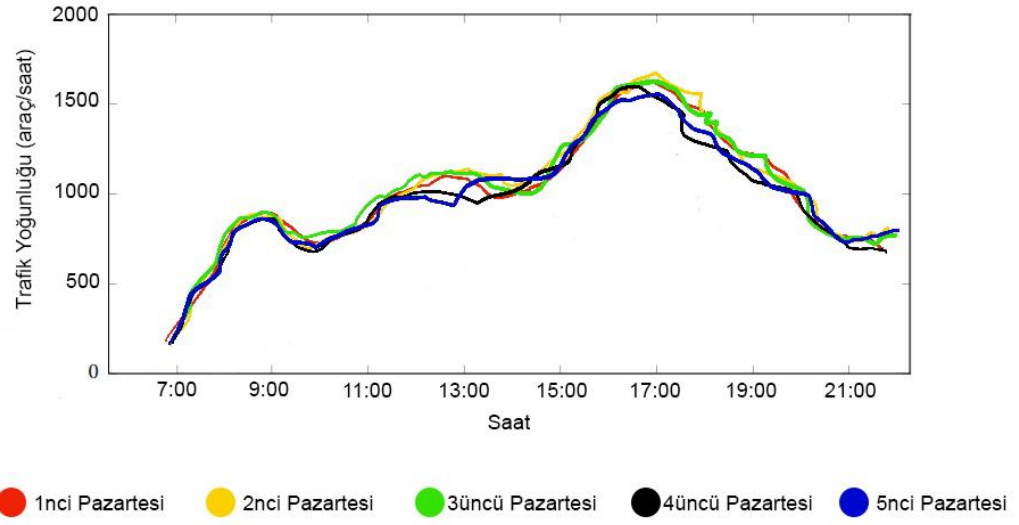
Diğer yandan, ACC, gerçek değerler ile tahmin edilen değerler arasındaki yüzdesel farkı ölçmektedir. Yüksek bir ACC değeri, modelin tahminlerinin gerçek değerlere ne kadar yakın olduğunu gösterir. ACC, modelin genel performansını özetleyen bir metriktir ve bu çalışma için önemlidir çünkü trafik akışı tahmini, sadece modelin doğruluğunu değil, aynı zamanda tahminlerin gerçek değerlere ne kadar yakın olduğunu da bilmemizi gerektirir.

Her iki metrik de gerçekleştirilen tahminlerin kalitesini ve doğruluğunu belirlemek için sıkça kullanılan standart metriklere dayanmaktadır. Bu çalışma için seçilmelerinin ana sebebi, trafik akışı tahminlerinin hem doğruluğunu hem de gerçek değerlere olan yakınlığını etkili bir şekilde ölçebilmeleridir.

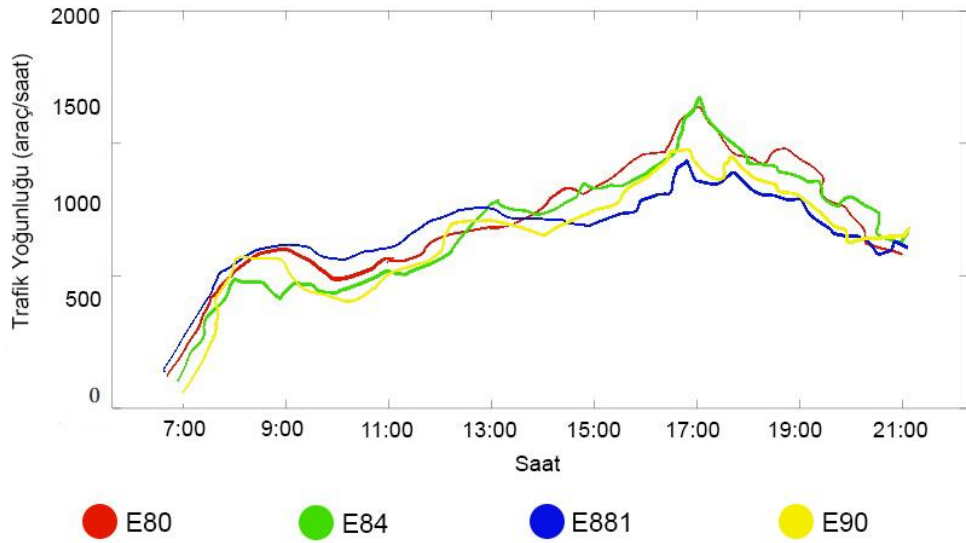
Şekil 5, hem birkaç modelin beklenen sonuçlarını hem de bir gün boyunca gerçek trafik akışını göstermektedir. Öngörülen trafik akışının, gerçek trafik akışıyla karşılaştırılabilir trafik örüntülerine sahip olduğu ve önerilen kNN-MLP modelinin tahmin değerinin, özellikle sabah ve akşam yoğun saatlerde ölçülen verilerle neredeyse örtüştüğü bulunmuştur. Bu özellikle sabah zirve saati ve akşam zirve saati için geçerlidir. Tablo 1, E80 ve E84 otoyolları için çeşitli modeller için RMSE ve ACC göstermektedir. Önerilen tekniğin en düşük RMSE değerini verdiği görülmektedir. Önerilen yaklaşım için genel ACC, %92,01'dir; bu, önceki modellerle karşılaştırıldığında %3,59 ve genel olarak %0,89'luk bir gelişmedir. SVR modeliyle karşılaştırıldığında, LSTM tekniği üstün RMSE ve ACC sonuçları sağlamıştır; yine de bu sonuçlar, derin öğrenme yöntemleriyle elde edilenler kadar güçlü değildir.



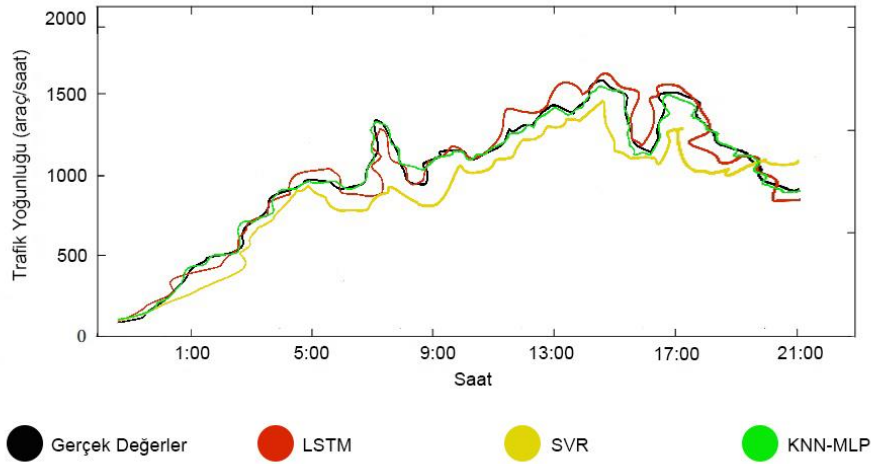
Şekil 2. Analiz için kullanılan otoyol ve numaraları



Şekil 3. E80 yolu için art arda 5 pazartesi günü trafik yođunluđu



Şekil 4. 4 farklı otoyol ve seçilen aynı gün, aynı saatlerdeki trafik yođunluđu



Şekil 5. Farklı makine öğrenmesi algoritmaları ile E80 üzerinde elde edilen gerçek ve tahmin edilen trafik yoğunluğu

Bu makalede, test verileriyle en yakından ilişkili olan otoyolu seçmek için kNN algoritması kullanılmıştır. Çeşitli K değerlerinin her biri, tahmin için kullanıldığında benzersiz bir sonuç modeli oluşmaktadır. K değeri için birçok olasılığa bakılmış ve en düşük RMSE'ye sahip olan model en iyi seçim olarak kabul edilmiştir. Deney için ideal kabul edilen K değeri 6 olup, seçilen otoyolların ID numaraları E80, E84, E90 ve E881'dir. K'nin en iyi değeri 5 olarak ayarlanan E84 otoyoluna atanmıştır ve seçilen otoyolların kimlik kodları E90 ve E881'dir. Şekil 2'de görülebileceği gibi, seçilen yolların çoğu, test verilerinin hem yukarı hem de aşağı bölümlerinde bulunabilmektedir. Geleneksel konseptte göre, tahmin edilen otoyola daha yakın olan otoyollar, daha uzak olan otoyollardan daha yüksek bir korelasyona sahiptir. Aslında, birkaç yolun daha tahmin otoyolu ile ilişkili olduğu gösterilmiştir. E80 otoyolundaki test amacıyla, daha yakın olan E84 otoyolu seçilmemiştir; benzer şekilde, E881 otoyolundaki test amacıyla, daha yakın olan E90 otoyolu seçilmemiştir. Bununla birlikte, trafik akışının yukarı ve aşağı akışının, trafik akışı tahminindeki tahmin sonucu üzerinde büyük bir etkiye sahip olduğu tespit edilmiştir. K değeri 2 olarak değiştirildiğinde, sadece zamansal korelasyon dikkate alınmıştır ve ortalama ACC %91,19'dur, bu da sunulan tekniğe kıyasla %0,89'luk bir kayıp oluşturmaktadır. Uzaysal-zamansal faktörlerin trafik tahmininde çok önemli roller oynadığı tespit edilmiştir. Bu bulgular kNN-MLP tekniğinin uygulanabilirliğini gösterdiği kadar üstünlüğünü de göstermektedir. kNN-MLP, zamansal düzenliliği araştırmak ve mekansal özellikleri toplamak için kNN ile bağlantılı olarak MLP ağlarını kullanmaktadır.

Tablo 2. Farklı algoritmaların tahmin performansları

Algoritmalar	E80		E84	
	Rmse	Acc-%	Rmse	Acc-%
Lstm	3.7921	91.68	3.4751	90.71
kNN-MLp	3.4957	92.36	3.1879	91.67
Svr	5.6785	89.72	6.4587	87.69

5. Sonuç

Tablo 2, farklı tahmin algoritmalarının E80 ve E84 otoyolları için performanslarını göstermektedir. Algoritmalar arasında LSTM, kNN-MLP ve SVR bulunmaktadır ve bu algoritmaların performansları RMSE ve doğruluk yüzdesi (Acc-%) metrikleri ile değerlendirilmiştir. E80 otoyolu için, kNN-MLP algoritması en düşük RMSE değerine (3.4957) sahip olup, aynı zamanda en yüksek doğruluk yüzdesi olan %92.36 ile en iyi sonucu vermektedir. LSTM, RMSE'de 3.7921 ve doğruluk yüzdesinde %91.68 ile kNN-MLP'nin hemen ardından gelmektedir. SVR ise bu iki algoritmadan daha düşük bir performansla, RMSE'de 5.6785 ve doğruluk yüzdesinde %89.72 ile son sırada yer almaktadır. E84 otoyolu için de benzer bir trend gözlemlenmektedir. kNN-MLP yine en iyi performansı göstererek RMSE'de 3.1879 ve doğruluk yüzdesinde %91.67 değerlerine ulaşmıştır. LSTM, bu otoyol için de RMSE'de 3.4751 ve doğruluk yüzdesinde %90.71 ile ikinci sıradadır. SVR'nin performansı bu otoyol için de en düşük olanıdır; RMSE 6.4587 ve doğruluk yüzdesi %87.69 ile. Genel olarak, kNN-MLP algoritmasının bu veri seti üzerinde en iyi performansı gösterdiği görülmektedir. LSTM, genel olarak kNN-MLP'nin hemen ardından gelirken, SVR algoritması bu iki algoritmadan daha düşük bir performans sergilemektedir. Bu sonuçlar, kNN-MLP'nin trafik akışı tahmininde etkili bir yöntem olduğunu göstermektedir.

Bu araştırmada, kNN ve MLP'nin bir kombinasyonunu kullanarak trafik akışının uzay-zamansal tahmini için bir teknik önerdik. kNN, birincil olarak birbirine bağlı olan ve olası serbest yollarla uzay-zamansal bir ilişki öneren otoyolları seçmek için kullanılmaktadır. Belirli yollardaki trafik akışı hakkında doğru projeksiyonlar sağlamak için bir MLP ağı kullanılmıştır. MLP, hem trafik akışı verilerinde gömülü olan gizli özellik temsillerini bulabilmekte hem de verilerde bulunan uzun vadeli bağımlılıklardan yararlanabilmektedir ve bu da sonuçta iyileştirilmiş tahmin performansı sağlamaktadır. Sıra-üs yaklaşımını kullanarak ağırlıklandırmayı uyguladıktan sonra, test verilerindeki nihai tahmin sonuçları elde edilebilmiştir. İstanbul Büyükşehir Belediyesi ulaşım dairesi başkanlığı tarafından elde edilen gerçek trafik verilerini kullanarak modelimizin performansını değerlendirdik ve LSTM ve SVR algoritmaları ile karşılaştırdık. Elde edilen bulgulara göre önerilen modelin alternatiflere göre tercih edilebilir olduğu açıktır. Gelecek çalışmalarda, trafik akışına ilişkin veriler hava durumundan, olaylardan ve diğer koşullardan etkilendiğinden, bu faktörlerin trafik akışı verileri üzerindeki etkisi, tahminin doğruluğunu artırmak için daha fazla araştırılması planlanmaktadır. Ayrıca, çalışmamız, hava durumu, olaylar ve trafik akışını önemli ölçüde etkileyen diğer koşullar gibi dış faktörleri dahil etmeyi hedeflediğimiz gelecek çalışmalar için temel oluşturmaktadır. Bu ek değişkenleri modelimize entegre ederek, trafik akışı tahminlerinin doğruluğunu ve güvenilirliğini artırmayı ve sonuç olarak daha akıllı ulaşım ağlarının geliştirilmesine ve genel trafik yönetiminin iyileştirilmesine katkıda bulunmayı umuyoruz.

Makine öğrenmesi, son yıllarda birçok alanda karmaşık sorunların çözümü için etkili bir araç olarak ortaya çıkmıştır. Bu teknoloji, büyük veri kümelerinden öğrenme yeteneği sayesinde, geleneksel yöntemlerle sınırlı olan veya zaman alıcı olan görevlerde önemli ilerlemeler sağlamıştır. Trafik akış tahmini, makine öğrenmesi tekniklerinin özellikle etkili olduğu alanlardan biridir. Geleneksel istatistiksel yöntemler, trafik akışını tahmin etmede sınırlı başarıya sahipken, makine öğrenmesi algoritmaları, trafik akışının karmaşık doğasını daha iyi yakalayarak daha doğru tahminler yapabilmektedir. Bu çalışmada, kNN ve MLP gibi makine öğrenmesi algoritmalarının trafik akış tahmininde nasıl kullanılabileceği detaylı olarak incelenmiştir. Bu algoritmalar, geçmiş trafik verilerini analiz ederek, gelecekteki trafik akışını tahmin etmek için kullanılmıştır. Sonuçlar, makine öğrenmesi algoritmalarının, geleneksel yöntemlere göre trafik akışını daha doğru bir şekilde tahmin edebildiğini göstermektedir.

Gelecekteki araştırmalara yönelik, trafik koşullarının daha kapsamlı bir şekilde anlaşılmasını sağlamak için sosyal medya, trafik kameraları ve gerçek zamanlı bilgiler gibi ek

veri kaynaklarını dahil ederek önerilen modelin kapsamını genişletmeye odaklanılmalıdır. Ek olarak, Grafik Sınır Ağları (GSA) ve takviyeli öğrenme gibi diğer makine öğrenimi algoritmalarının keşfi, trafik akışını modellemek ve tahmin etmek için daha etkili yolları ortaya çıkarabilir. Trafik sinyallerinin dinamik optimizasyonu, rota planlaması ve tıkanıklık yönetimi için bu iyileştirilmiş tahminlerden yararlanan uyarlanabilir trafik yönetim sistemlerinin geliştirilmesinde de potansiyel bulunmaktadır. Ayrıca, toplu taşıma, bisiklet ve yaya gibi çeşitli ulaşım modlarını entegre eden çok modlu ulaşım sistemlerinin araştırılması, kentsel hareketlilik için daha sürdürülebilir ve verimli çözümler sağlayabilir. Bu araştırma yönergelerini takip ederek, kentleşme ve nüfus artışının artan zorluklarını ele alan daha akıllı, daha dayanıklı ulaşım ağlarının geliştirilmesine katkıda bulunulabilir.

Kaynakça

- Duan, Y. *et al.* (2016) 'An efficient realization of deep learning for traffic data imputation', *Transportation Research Part C: Emerging Technologies*. doi: 10.1016/j.trc.2016.09.015.
- Farid, A., Abdel-Aty, M. and Lee, J. (2019) 'Comparative analysis of multiple techniques for developing and transferring safety performance functions', *Accident Analysis and Prevention*. doi: 10.1016/j.aap.2018.09.024.
- Finogeev, A. *et al.* (2019) 'Intelligent monitoring system for smart road environment', *Journal of Industrial Information Integration*. doi: 10.1016/j.jii.2019.05.003.
- He, Y., Tablada, A. and Wong, N. H. (2019) 'A parametric study of angular road patterns on pedestrian ventilation in high-density urban areas', *Building and Environment*. doi: 10.1016/j.buildenv.2019.01.047.
- Hoang, N. D. and Nguyen, Q. L. (2018) 'Automatic Recognition of Asphalt Pavement Cracks Based on Image Processing and Machine Learning Approaches: A Comparative Study on Classifier Performance', *Mathematical Problems in Engineering*. doi: 10.1155/2018/6290498.
- Huang, W. *et al.* (2014) 'Deep architecture for traffic flow prediction: Deep belief networks with multitask learning', *IEEE Transactions on Intelligent Transportation Systems*. doi: 10.1109/TITS.2014.2311123.
- Jiang, R. *et al.* (2019) 'Deepurbanevent: A system for predicting citywide crowd dynamics at big events', in *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. doi: 10.1145/3292500.3330654.
- Jiber, M. *et al.* (2020) 'Road traffic prediction model using extreme learning machine: The case study of tangier, morocco', *Information (Switzerland)*. doi: 10.3390/info11120542.
- Koesdwiady, A., Soua, R. and Karray, F. (2016) 'Improving Traffic Flow Prediction with Weather Information in Connected Cars: A Deep Learning Approach', *IEEE Transactions on Vehicular Technology*. doi: 10.1109/TVT.2016.2585575.
- Li, L. *et al.* (2019) 'Day-ahead traffic flow forecasting based on a deep belief network optimized by the multi-objective particle swarm algorithm', *Knowledge-Based Systems*. doi: 10.1016/j.knosys.2019.01.015.
- Lv, Y. *et al.* (2015) 'Traffic Flow Prediction with Big Data: A Deep Learning Approach', *IEEE Transactions on Intelligent Transportation Systems*. doi: 10.1109/TITS.2014.2345663.
- Polson, N. and Sokolov, V. (2016) 'Deep Learning Predictors for Traffic Flows', *arXiv stat.AP*.
- Pompigna, A. and Mauro, R. (2022) 'Smart roads: A state of the art of highways innovations in the Smart Age', *Engineering Science and Technology, an International Journal*. doi: 10.1016/j.jestch.2021.04.005.

- Sahitya, K. S. and Prasad, C. S. R. K. (2021) 'GIS-based urban road network accessibility modeling using MLR, ANN and ANFIS methods', *Transport and Telecommunication*. doi: 10.2478/tjt-2021-0002.
- Satti, S. K. *et al.* (2021) 'A machine learning approach for detecting and tracking road boundary lanes', *ICT Express*. doi: 10.1016/j.icte.2020.07.007.
- Song, M. and Civco, D. (2004) 'Road extraction using SVM and image segmentation', *Photogrammetric Engineering and Remote Sensing*. doi: 10.14358/PERS.70.12.1365.
- Soua, R., Koesdwiady, A. and Karray, F. (2016) 'Big-data-generated traffic flow prediction using deep learning and dempster-shafer theory', in *Proceedings of the International Joint Conference on Neural Networks*. doi: 10.1109/IJCNN.2016.7727607.
- Oliveira, D. D., Rampinelli, M., Tozatto, G. Z., Andreão, R. V., & Müller, S. M. (2021). Forecasting vehicular traffic flow using MLP and LSTM. *Neural Computing and applications*, 33, 17245-17256.
- Vlahogianni, E. I., Karlaftis, M. G., & Golias, J. C. (2005). Optimized and meta-optimized neural networks for short-term traffic flow prediction: A genetic approach. *Transportation Research Part C: Emerging Technologies*, 13(3), 211-234.
- Wang, J. and Boukerche, A. (2021) 'Non-parametric models with optimized training strategy for vehicles traffic flow prediction', *Computer Networks*. doi: 10.1016/j.comnet.2020.107791.
- Xu, D. *et al.* (2020) 'Real-time road traffic state prediction based on kernel-KNN', *Transportmetrica A: Transport Science*. doi: 10.1080/23249935.2018.1491073.
- Yang, L. *et al.* (2020) 'Griffin: An Ensemble of AutoEncoders for Anomaly Traffic Detection in SDN', in *2020 IEEE Global Communications Conference, GLOBECOM 2020 - Proceedings*. doi: 10.1109/GLOBECOM42002.2020.9322187.
- Zargari, S. A., Siabil, S. Z., Alavi, A. H., & Gandomi, A. H. (2012). A computational intelligence-based approach for short-term traffic flow prediction. *Expert Systems*, 29(2), 124-142.
- Zhang, H. *et al.* (2020) 'A real-Time and ubiquitous network attack detection based on deep belief network and support vector machine', *IEEE/CAA Journal of Automatica Sinica*. doi: 10.1109/JAS.2020.1003099.
- Zhang, L. *et al.* (2013) 'An Improved K-nearest Neighbor Model for Short-term Traffic Flow Prediction', *Procedia - Social and Behavioral Sciences*. doi: 10.1016/j.sbspro.2013.08.076.
- Zhao, Z. *et al.* (2017) 'LSTM network: A deep learning approach for Short-term traffic forecast', *IET Intelligent Transport Systems*. doi: 10.1049/iet-its.2016.0208.
- Zhou, T. *et al.* (2017) ' δ -agree AdaBoost stacked autoencoder for short-term traffic flow forecasting', *Neurocomputing*. doi: 10.1016/j.neucom.2017.03.049.

ETİK ve BİLİMSEL İLKELER SORUMLULUK BEYANI

Bu çalışmanın tüm hazırlanma süreçlerinde etik kurallara ve bilimsel atıf gösterme ilkelerine riayet edildiğini yazar(lar) beyan eder. Aksi bir durumun tespiti halinde Afyon Kocatepe Üniversitesi Sosyal Bilimler Dergisi'nin hiçbir sorumluluğu olmayıp, tüm sorumluluk makale yazarlarına aittir.

ARAŞTIRMACILARIN MAKALEYE KATKI ORANI BEYANI

1. yazar katkı oranı : %70

2. yazar katkı oranı : %30