

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**BÖLGESEL TRAFİK YOĞUNLUK TAHMİNİ İÇİN DERİN
ÖĞRENME TEKNİKLERİ İLE MODEL OLUŞTURULMASI**

Fethiye YASLI

YÜKSEK LİSANS TEZİ
Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Programı

Danışman
Dr. Öğr. Üyesi Mehmet Amaç GÜVENSAN

Şubat, 2020

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BÖLGESEL TRAFİK YOĞUNLUK TAHMİNİ İÇİN DERİN ÖĞRENME
TEKNİKLERİ İLE MODEL OLUŞTURULMASI

Fethiye YASLI tarafından hazırlanan tez çalışması 18.02.2020 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı Bilgisayar Mühendisliği Programı **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Dr. Öğr. Üyesi Mehmet Amaç
GÜVENSAN
Yıldız Teknik Üniversitesi
Danışman

Jüri Üyeleri

Dr. Öğr. Üyesi Mehmet Amaç GÜVENSAN, Danışman
Yıldız Teknik Üniversitesi

Doç. Dr. Mine Elif KARSLIGİL YAVUZ, Üye
Yıldız Teknik Üniversitesi

Dr. Öğretim Üyesi Tuğba YILDIZ, Üye
Bilgi Üniversitesi

Danışmanım Dr. Öğr. Üyesi Mehmet Amaç GÜVENSAN sorumluluğunda tarafımda hazırlanan Bölgesel Trafik Yoğunluk Tahmini İçin Derin Öğrenme Teknikleri ile Model Oluşturulması başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Fethiye YASLI

İmza

Sevgili aileme

TEŞEKKÜR

Tez çalışmam sırasında kıymetli bilgi, birikim ve tecrübeleri ile bana yol gösterici ve destek olan değerli danışman hocam sayın Dr. Öğr. Üyesi M. Amaç GÜVENSAN'a, her zaman desteğini esirgemeyen aileme sonsuz teşekkür ve saygılarımı sunarım.

Fethiye YASLI

İÇİNDEKİLER

KISALTMA LİSTESİ	vii
ŞEKİL LİSTESİ	viii
TABLO LİSTESİ	xi
ÖZET	xiii
ABSTRACT	xiv
1 GİRİŞ	1
1.1 Literatür Özeti	2
1.2 Tezin Amacı ve Kapsamı	4
1.3 Hipotez	5
2 TRAFİK YOĞUNLUK TAHMİNLEME	7
2.1 Trafik Yoğunluk Tahminleme	7
2.1.1 Kısa Vadeli Trafik Yoğunluk Tahminleme	7
2.1.2 Uzun Vadeli Trafik Yoğunluk Tahminleme	7
2.2 Uzun Vadeli Trafik Yoğunluk Tahmini için Kullanılan Yöntemler	8
2.2.1 Merkezi Eğilim Ölçüleri	8
2.2.2 Regresyon	8
2.2.3 Derin Öğrenme Yöntemleri	9
3 TRAFİK VERİSİNİN İNCELENMESİ	11
3.1 Veri Toplama	11
3.1.1 Veri Seti ve Algılayıcılar	11
3.2 Veri Ön İşleme ve Hazırlama	14
3.2.1 Veri Ön İşleme	14
3.2.2 Veri Hazırlama	15
3.2.3 Eğitim, Doğrulama ve Test Veri Seti Oluşturma	27
4 YAZILIM GELİŞTİRME ORTAMI VE KULLANILAN ARAÇLAR	28

5 DENEYLER	29
5.1 Hata Metrikleri	29
5.2 Regresyon ve Ortalama Yaklaşımı ile Uzun vadeli Trafik Yoğunluğu Tahmini	30
5.3 Derin Öğrenme Yöntemleri	37
5.3.1 CNN Yöntemi Uzun Vadeli Hız Tahmini için Parametre Optimizasyonu	37
5.3.2 CNN Yöntemi Uzun Vadeli Hız Tahmini Seçilen Değişken Parametrelerin Farklı Veri Setlerinde Uygulanması	79
5.4 CNN Yöntemi, Polinom Regresyon ve Ortalama Yöntemi Karşılaştırılması	79
5.5 Tüm Algılayıcılar Saat Bazında Tahmin Değerlendirmesi	84
5.6 Tüm Algılayıcılar Haftanın Günü Bazında Tahmin Değerlendirmesi . . .	86
5.7 Algılayıcı Trafik Hız Değerleri Ortalama ve Standart Sapmasının CNN Tahmin Sonuçlarına Etkisi	87
6 SONUÇ VE ÖNERİLER	91
KAYNAKÇA	93
TEZDEN ÜRETİLMİŞ YAYINLAR	95

KISALTMA LİSTESİ

CNN	Evrişimli Sinir Ağı
LSTM	Uzun Kısa Süreli Bellek
MAE	Ortalama Mutlak Hata
MAPE	Ortalama Mutlak Yüzde Hata
MSE	Ortalama Karesel Hata
SGD	Stochastic Gradient Descent

ŞEKİL LİSTESİ

Şekil 2.1	Evrişimli Sinir Ağı Akış	9
Şekil 3.1	İstanbul Uydu Görünümünde 44 Farklı Algılayıcı Konumları	12
Şekil 3.2	Hız Verilerinin 5 Dakika Aralıklarla Ortalama Alınma Yöntemi	14
Şekil 3.3	25.11.2017 Tarihi İçin $k=4$ Hafta Geri Gidilerek Verilerin Elde Edilmesi	15
Şekil 3.4	315 Numaralı Algılayıcı 25.11.2017 Tarihi İçin 4 Hafta Geri Gidildiğinde Elde Edilen Hız Verileri	16
Şekil 3.5	Geriye Gidilen Her Bir k Hafta Verisi İle Veri Seti Oluşturulması . . .	18
Şekil 3.6	Tahmin Edilecek Günden 1 Hafta Geriye Gidildiğinde 15 Dakika İleri ve Geri Hız Verisinin Oluşturulması	20
Şekil 3.7	Tahmin Edilecek Günden 2 Hafta Geriye Gidildiğinde Haftalık Karakteristik Bozulmadan Veri Setinin Oluşturulması	21
Şekil 3.8	Tahmin Edilecek Günden 4 Hafta Geriye Gidildiğinde Haftalık Karakteristik İçeren Veri Setinin Oluşturulması	22
Şekil 3.9	Tahmin Edilecek Günden 2 Hafta Geriye Gidildiğinde Aynı 5 Dakikalar Yan Yana Gelecek Şekilde Veri Seti Oluşturulması	24
Şekil 3.10	Tahmin Edilecek Günden 4 Hafta Geriye Gidildiğinde Aynı 5 Dakikalar Yan Yana Gelecek Şekilde Veri Seti Oluşturulması	25
Şekil 5.1	Kaç Hafta Geri Gidildiğine Göre 44 Farklı Algılayıcı Ortalama Yöntemi ile Elde Edilen Ortalama MAPE Değerleri	31
Şekil 5.2	44 Farklı Algılayıcı Regresyon Eğri Derecesine Göre Ortalama MAPE Değerleri	32
Şekil 5.3	CNN Modeli Filtre Sayısı 2 iken Algılayıcı Bazında Ortalama MAPE ve MAE Değerleri	41
Şekil 5.4	CNN Modeli Filtre Sayısı 2 iken Ay Bazında Ortalama MAPE ve MAE Değerleri	42
Şekil 5.5	CNN Modeli Filtre Sayısı 2 iken Algılayıcı Bazında Ortalama MAPE ve MAE Değer Durumu	43
Şekil 5.6	CNN Modeli Filtre Sayısı 4 iken Algılayıcı Bazında Ortalama MAPE ve MAE Değerleri	46
Şekil 5.7	CNN Modeli Filtre Sayısı 4 iken Ay Bazında Ortalama MAPE ve MAE Değerleri	47

Şekil 5.8	CNN Modeli Filtre Sayısı 4 iken Algılayıcı Bazında Ortalama MAPE ve MAE Değer Durumu	48
Şekil 5.9	CNN Modeli Filtre Sayısı 6 iken Algılayıcı Bazında Ortalama MAPE ve MAE Değerleri	51
Şekil 5.10	CNN Modeli Filtre Sayısı 6 iken Ay Bazında Ortalama MAPE ve MAE Değerleri	52
Şekil 5.11	CNN Modeli Filtre Sayısı 6 iken Algılayıcı Bazında Ortalama MAPE ve MAE Değer Durumu	53
Şekil 5.12	CNN Modeli Kernel Boyutu 4 iken Algılayıcı Bazında Ortalama MAPE ve MAE Değerleri	57
Şekil 5.13	CNN Modeli Kernel Boyutu 4 iken Ay Bazında Ortalama MAPE ve MAE Değerleri	58
Şekil 5.14	CNN Modeli Kernel Boyutu 4 iken Algılayıcı Bazında Ortalama MAPE ve MAE Değer Durumu	59
Şekil 5.15	CNN Modeli Kernel Boyutu 6 iken Algılayıcı Bazında Ortalama MAPE ve MAE Değerleri	62
Şekil 5.16	CNN Modeli Kernel Boyutu 6 iken Ay Bazında Ortalama MAPE ve MAE Değerleri	63
Şekil 5.17	CNN Modeli Kernel Boyutu 6 iken Algılayıcı Bazında Ortalama MAPE ve MAE Değer Durumu	64
Şekil 5.18	CNN Modeli Düğüm Sayısı 70 iken Algılayıcı Bazında Ortalama MAPE ve MAE Değerleri	68
Şekil 5.19	CNN Modeli Düğüm Sayısı 70 iken Ay Bazında Ortalama MAPE ve MAE Değerleri	69
Şekil 5.20	CNN Modeli Düğüm Sayısı 70 iken Algılayıcı Bazında Ortalama MAPE ve MAE Değer Durumu	70
Şekil 5.21	CNN Modeli Stochastic Gradient Descent Öğrenme Oranı Değişimi Ay Bazında Ortalama MAPE ve MAE Değerleri	74
Şekil 5.22	30 Algılayıcısı Ekim Ayı Tahmini Epoch Sayısına Karşılık Kayıp Fonksiyonu MSE Değerleri	77
Şekil 5.23	1749 Algılayıcısı Ekim Ayı Tahmini Epoch Sayısına Karşılık Kayıp Fonksiyonu MSE Değerleri	78
Şekil 5.24	Tüm Algılayıcıların Aylara Göre CNN, Polinom Regresyon, Ortalama Yöntemi Ortalama MAPE Değerleri	83
Şekil 5.25	Tüm Algılayıcıların Aylara Göre CNN, Polinom Regresyon, Ortalama Yöntemi Ortalama MAE Değerleri	84
Şekil 5.26	CNN Modeli Tüm Algılayıcılar Tüm Aylar için Saat Bazında MAPE ve MAE Sonuçları	85

Şekil 5.27 CNN Modeli Tüm Algılayıcılar Tüm Aylar için Haftanın Günü Bazında MAPE ve MAE Sonuçları	87
Şekil 5.28 44 Algılayıcı Tüm Aylar Ortalama Hız Değerine Karşılık CNN ile Elde Edilen MAPE Değerleri	88
Şekil 5.29 44 Algılayıcı Tüm Aylar Ortalama Hız Değerine Karşılık CNN ile Elde Edilen MAE Değerleri	89
Şekil 5.30 44 Algılayıcı Tüm Aylar Standart Sapma Değerine Karşılık CNN ile Elde Edilen MAPE Değerleri	90
Şekil 5.31 44 Algılayıcı Tüm Aylar Standart Sapma Değerine Karşılık CNN ile Elde Edilen MAE Değerleri	90

TABLO LİSTESİ

Tablo 3.1	Algılayıcı Örnek Hız Verisi	11
Tablo 3.2	44 Farklı Algılayıcının Konumları	13
Tablo 3.3	Geriye Gidilen 4 Hafta Günü Hız Verisi (km/saat)	17
Tablo 3.4	Geriye Gidilen Her Bir k Hafta Hız Verisi Yan Yana Olacak Şekilde Oluşturulmuş Veri Seti Öz Nitelik Bilgisi	19
Tablo 3.5	Tahmin Edilecek Günden 4 Hafta Geriye Gidildiğinde Haftalık Karakteristik İçeren Veri Seti Öz Nitelik Bilgisi	23
Tablo 3.6	Tahmin Edilecek Günden 4 Hafta Geriye Gidildiğinde Aynı 5 Dakikalar Yan Yana Gelecek Şekilde Veri Seti Öz Nitelik Bilgisi	26
Tablo 4.1	Projenin Yazılım Gereksinimleri	28
Tablo 5.1	MAPE Değerlendirme Etiketi	30
Tablo 5.2	MAE Değerlendirme Etiketi	30
Tablo 5.3	44 Farklı Algılayıcı Polinom Regresyon MAPE Değerleri	33
Tablo 5.4	44 Farklı Algılayıcı Polinom Regresyon MAE Değerleri	34
Tablo 5.5	44 Farklı Algılayıcı Ortalama Yöntemi MAPE Değerleri	35
Tablo 5.6	44 Farklı Algılayıcı Ortalama Yöntemi MAE Değerleri	36
Tablo 5.7	Polinom Regresyon ve Ortalama Yöntemi Karşılaştırması	37
Tablo 5.8	44 Farklı Algılayıcı Her Bir Hafta Günü Hız Verisi Kullanılarak 2 Filtre ile CNN Modeli Oluşturulması MAPE Değerleri	39
Tablo 5.9	44 Farklı Algılayıcı Her Bir Hafta Günü Hız Verisi Kullanılarak 2 Filtre ile CNN Modeli Oluşturulması MAE Değerleri	40
Tablo 5.10	44 Farklı Algılayıcı Her Bir Hafta Günü Hız Verisi Kullanılarak 4 Filtre ile CNN Modeli Oluşturulması MAPE Değerleri	44
Tablo 5.11	44 Farklı Algılayıcı Her Bir Hafta Günü Hız Verisi Kullanılarak 4 Filtre ile CNN Modeli Oluşturulması MAE Değerleri	45
Tablo 5.12	44 Farklı Algılayıcı Her Bir Hafta Günü Hız Verisi Kullanılarak 6 Filtre ile CNN Modeli Oluşturulması MAPE Değerleri	49
Tablo 5.13	44 Farklı Algılayıcı Her Bir Hafta Günü Hız Verisi Kullanılarak 6 Filtre ile CNN Modeli Oluşturulması MAE Değerleri	50
Tablo 5.14	CNN 2, 4, 6 Filtre Sayısı ile Model Oluşturma ve Polinom Regresyon Model Oluşturma MAPE, MAE Karşılaştırması	54

Tablo 5.15	44 Farklı Algılayıcı Her Bir Hafta Günü Hız Verisi Kullanılarak Kernel Boyutu 4 ile CNN Modeli Oluşturulması MAPE Değerleri	55
Tablo 5.16	44 Farklı Algılayıcı Her Bir Hafta Günü Hız Verisi Kullanılarak Kernel Boyutu 4 ile CNN Modeli Oluşturulması MAE Değerleri	56
Tablo 5.17	44 Farklı Algılayıcı Her Bir Hafta Günü Hız Verisi Kullanılarak Kernel Boyutu 6 ile CNN Modeli Oluşturulması MAPE Değerleri	60
Tablo 5.18	44 Farklı Algılayıcı Her Bir Hafta Günü Hız Verisi Kullanılarak Kernel Boyutu 6 ile CNN Modeli Oluşturulması MAE Değerleri	61
Tablo 5.19	CNN 2, 4, 6 Kernel Boyutu ile Model Oluşturma ve Polinom Regresyon Model Oluşturma MAPE, MAE Karşılaştırması	65
Tablo 5.20	44 Farklı Algılayıcı Her Bir Hafta Günü Hız Verisi Kullanılarak Düğüm Sayısı 70 ile CNN Modeli Oluşturulması MAPE Değerleri . .	66
Tablo 5.21	44 Farklı Algılayıcı Her Bir Hafta Günü Hız Verisi Kullanılarak Düğüm Sayısı 70 ile CNN Modeli Oluşturulması MAE Değerleri . . .	67
Tablo 5.22	CNN 10, 30, 50, 70, 100, 200 Düğüm Sayısı ile Model Oluşturma ve Polinom Regresyon Model Oluşturma MAPE, MAE Karşılaştırması .	71
Tablo 5.23	CNN 1, 2, 3, 4 Katman Sayısı ile Model Oluşturma ve Polinom Regresyon Model Oluşturma MAPE, MAE Karşılaştırması	71
Tablo 5.24	CNN Relu, Sigmoid, Tanh Aktivasyon Fonksiyonu ile Model Oluşturma ve Polinom Regresyon Model Oluşturma MAPE, MAE Karşılaştırması	72
Tablo 5.25	CNN SGD, RMSprop, Adagrad, Adadelata, Adam Optimizasyon Algoritmaları ile Model Oluşturma ve Polinom Regresyon Model Oluşturma MAPE, MAE Karşılaştırması	75
Tablo 5.26	CNN Batch Boyutu 64, 128, 256, 512 veya 1024 ile Model Oluşturma MAPE, MAE Karşılaştırması	76
Tablo 5.27	CNN Epoch Sayısı 5, 10, 15, 30 veya 60 ile Model Oluşturma MAPE, MAE Karşılaştırması	76
Tablo 5.28	Geriye Gidilen k Haftaları Sonucu 5 Dakikalık Hız Verilerinin Dizilimi Farklılaşmasıyla Elde Edilen 2 Farklı Veri Seti CNN Sonuçlarının Karşılaştırılması	79
Tablo 5.29	44 Farklı Algılayıcı CNN Modeli, Polinom Regresyon ve Ortalama Yöntemi MAPE Karşılaştırma	81
Tablo 5.30	44 Farklı Algılayıcı CNN Modeli, Polinom Regresyon ve Ortalama Yöntemi MAE Karşılaştırma	82

Bölgesel Trafik Yoğunluk Tahmini İçin Derin Öğrenme Teknikleri ile Model Oluşturulması

Fethiye YASLI

Bilgisayar Mühendisliği Anabilim Dalı
Yüksek Lisans Tezi

Danışman: Dr. Öğr. Üyesi Mehmet Amaç GÜVENSAN

Trafik, şehirleşmiş yerleşim birimlerinin en önemli sorunlarından biri haline gelmiştir. Trafikte geçen zamanı azaltmak amacı ile insanlara bir noktadan diğerine en hızlı ve konforlu gideceği güzergahı gösteren çeşitli uygulamalar geliştirilmiştir. Fakat bu uygulamalar kısa vadeli hız tahmini için uygun olmasına rağmen uzun vadeli trafik yoğunluğu hakkında öngöründe bulunamamaktadırlar. Bu çalışmada geçmiş hafta hız verilerinin örüntüleri kullanılarak 7 güne kadar tahminde bulunmak için Polinom Regresyon Modeli, Ortalama Yöntemi ve derin öğrenme yöntemlerinden Evrişimli Sinir Ağı(CNN) yöntemleri kullanılmıştır. Bu çalışma İstanbul il genelinde 44 farklı algılayıcıdan elde edilen trafik hız verileri kullanılarak gerçekleştirilmiştir. Derin öğrenme yöntemlerinden CNN kullanılarak 44 algılayıcı için farklı yaklaşım ve parametreler kullanılarak öngörü modelleri kurulmuştur. Elde edilen Ortalama Mutlak Yüzde Hata (MAPE) değerleri algılayıcılara bağlı olarak %2-40 arası değişim göstermektedir ve genel ortalamada MAPE değeri %16,60 olarak elde edilmiştir. CNN ve Ortalama yöntemlerinin başarı oranının algılayıcılara bağlı olarak, Polinom Regresyon yönteminden %3-10 arası daha başarılı olduğu gözlemlenmiştir.

Anahtar Kelimeler: Trafik yoğunluk tahmini, derin öğrenme, evrişimli sinir ağı, uzun vade, haftalık örüntü

Modeling with Deep Learning Techniques for Regional Traffic Density Forecasting

Fethiye YASLI

Department of Computer Engineering
Master of Science Thesis

Advisor: Assist. Prof. Dr. Mehmet Amaç GÜVENSAN

Traffic has become one of the most important problems of urbanized settlements. In order to reduce the time spent in traffic, various applications have been developed which show people the fastest and most comfortable route from one point to another. However, although these applications are suitable for short-term speed prediction, they cannot predict long-term traffic density. In this study, Polynomial Regression Model, Mean Method, and Convolutional Neural Network (CNN) methods, which are among the deep learning methods, were used to predict up to 7 days using the patterns of speed data of the past week. This study was carried out using traffic speed data obtained from 44 different sensors across the city of Istanbul. Forecasting models have been established by using different approaches and parameters for 44 sensors using CNN, which is one of the deep learning methods. The Average Absolute Percentage Error (MAPE) values obtained vary between 2-40% depending on the sensors and the overall average MAPE value is obtained as 16.60%. Depending on the sensors, the success rate of CNN and Mean methods was observed to be 3-10% more successful than Polynomial Regression method.

Keywords: Traffic density estimation, deep learning, convolutional neural network, long-term, weekly pattern

1 GİRİŞ

Kısa sürede aşırı derecede artan nüfus ve buna bağlı artan motorlu taşıt sayısı şehir hayatının kalitesini sekteye uğratmıştır. Trafiğin bu derece sıkışık olması yakıt tüketiminin artışı ve hava kalitesinin düşüşüne sebep olmaktadır. Trafik yoğunluk tahmini sayesinde sürücüler güzergah planlarını daha sağlıklı yapabilmektedir. Ek olarak; tünellerdeki trafik akış tahmini, havalandırma fanlarının çalışma programının daha verimli ayarlanmasına ve maliyetin düşmesine yardımcı olmaktadır [1]. Bu faydalarla trafik akışı tahmini çalışmaları, Akıllı Ulaşım Sistemleri'ne önemli katkılar sağlamaktadır.

Trafik akış tahmini yapan Google Haritalar ve Yandex Haritalar bu alanda en popüler uygulamalardır. Google Haritalar iki konum arasındaki gidiş süresini anlık olarak hesaplamaktadır. Google Haritalar'ın kısa vadeli trafik yoğunluk tahmini dışında, uzun vadeli olarak tahmin yaptığı fakat bu tahmini yaklaşık yarım saat aralıkta verdiği görülmektedir [2]. Yandex Haritalar'ın ise uzun ve kısa vadeli trafik yoğunluk tahmini yapan bir uygulama olduğu görülmektedir [3]. Yandex'in 2015, 2016, 2017 hız verilerini kullanarak yıllara göre karşılaştırmalı trafik yoğunluk analiz çalışmaları bulunmaktadır. İstanbul'da yeni yapılan yolların trafik yoğunluğuna etki ettiği belirtilmiştir. Ayrıca haftanın aynı günlerinin benzer hız dağılımı oluşturduğu grafiklerle gösterilmiştir [4].

Seyahat verileri, yoğunlukla İstatistik ve/veya Hesaplamalı Zeka olmak üzere iki farklı yöntem ile modellenmektedir. İstatistik, verilerin toplanması, düzenlenmesi ve yorumlanmasını matematik yardımıyla yapmaktadır, yoğunlukla verinin örneklem içindeki dağılımı analiz edilmektedir. İstatistik, kusursuz ve yaygın olarak kabul edilmiş matematiksel temellerden oluşmaktadır ve veriler hakkında yeni fikirler verebilir. İstatistiki yaklaşımlar doğrusal olmayan verilerle hesaplama yaparken başarısız olabilmektedirler. Hesaplamalı Zeka, verileri kullanarak bulanık mantık, evrim, adaptasyon ve öğrenme unsurlarını birleştirerek akıllı modeller oluşturur [5].

Bu çalışmada, 2017 yılına ait bir dakika aralıklarla 44 farklı algılayıcıdan toplanan

İstanbul şehri hız verileri kullanılmıştır. Haftanın aynı günlerinin benzer hız dağılımına sahip olduğu hipoteziyle, geçmiş haftalardaki aynı günlerin hız verilerini kullanarak öngörü modeli oluşturan yaklaşım önerilmiştir.

Geçmişteki haftaların aynı günlerinde bulunan hız verilerinin ortalaması alınmıştır. Ortalaması alınan verinin istatistiksel olarak ve regresyon ile eğri denklemi elde edilerek, tahmin modelinin değişimi gözlemlenmiştir. Ayrıca geçmiş haftaların aynı günleri hız verisi kullanılarak 3 farklı veri seti elde edilmiştir ve CNN modeli ile uzun vadeli trafik hız tahmini yapılmıştır. Haftanın tüm günleri kullanıldığı için gelecekteki 7 güne kadar hız tahmini yapan uzun zamanlı öngörü modeli oluşturulmuştur.

Çalışmada birinci bölümün Literatür Özeti kısmında kısa ve uzun vadeli trafik yoğunluk tahmini ile ilgili önceki araştırma ve uygulamalara değinilmiştir. İkinci bölümde trafik yoğunluğu tahminleme tipleri ve çalışmada kullanılan yöntemler açıklanmıştır. Üçüncü bölümde çalışma için kullanılan verinin özellikleri ve ön işleme adımları açıklanmış, kullanılan veri setleri hakkında bilgi verilmiştir. 4. bölümde çalışmada kullanılan yazılım geliştirme ortamı ve kullanılan araçlardan bahsedilmiştir. 5. bölümde deneysel sonuçlar sunulmuş ve değerlendirilmiştir. Son bölümde ise çalışmanın çıktıları yorumlanmış ve gelecek çalışmalardan bahsedilmiştir.

1.1 Literatür Özeti

Literatür özeti kısmında trafik yoğunluğunu tahmini için yapılan çalışmalar incelenmiştir.

Gelecek trafik yoğunluğunu birkaç saniye ile birkaç saat aralığında tahmin eden çalışmalar kısa vadeli trafik yoğunluğu ölçen çalışmalar olarak tanımlanmaktadır [6, 7]. Birkaç saatten ileri geleceği tahmin eden çalışmalar ise uzun vadeli trafik yoğunluğu ölçen çalışmalardır.

İncelenen literatür taramasında yoğunlukla kısa vadeli trafik yoğunluğu ölçen çalışmalar bulunmaktadır. Zaman serileri, makine öğrenmesi ve derin öğrenme yöntemleri, trafik yoğunluk ölçen çalışmalarda sıklıkla kullanılmıştır. Birden çok algoritmanın birleştirilmesiyle elde edilen derin öğrenme yöntemlerine de rastlanmıştır.

Çalışma [8]'de Hong Kong'da takside bulunan GPS algılayıcısından elde edilen düzensiz seyahat verisi üzerinde Naive Yöntem (Naive Method), Basit Üstel Yöntem (Simple Exponential Method) ve Holt'un Yöntemi (Holt's Method) çalıştırılarak kısa vadeli hız tahmin edilmiştir. 60 dakika gelecek tahmin edilmiş ve ortalama mutlak

hata (MAE) 9,9 olarak hesaplanmıştır.

Çalışma [9]'da benzer trafik örüntülerini tanımaya dayanan, kısa vadeli trafik hız tahmini yapan model, k-en yakın komşuluk (k-NN) algoritması kullanılarak geliştirilmiştir. Önerilen modelin başarımı, değişik bölgelerdeki algılayıcılardan elde edilen otoyol hız verileri kullanılarak test edilmiş, aynı zamanda farklı çalışmalarda önerilen SARIMA ve uyarlamalı Kalman Filtre modeli ile karşılaştırılmıştır. Önerilen model ile MAPE değerinin %25 azaldığı belirtilmiştir.

Derin öğrenme yöntemleri kullanılarak kısa vadeli trafik yoğunluğu tahmin eden çalışmalar da bulunmaktadır.

Çalışma [10]'da kısa vadeli trafik hız tahmini için mikrodalga algılayıcı hız verileri üzerinde, derin öğrenme yöntemlerinden biri olan Uzun Kısa Süreli Bellek (LSTM) çalıştırılmıştır. Tahmin modelinin doğruluğu, ortalama mutlak yüzde hata (MAPE) ve ortalama kare hata (MSE) metrikleriyle değerlendirilmiştir. Uzun Kısa Süreli Bellek sinir ağı için MSE; 4,08, MAPE; %2,88 olarak elde edilmiştir.

Çalışma [11]'de trafik hız verisi; Kaliforniya otoyollarında, farklı eyaletlerde bulunan 15000'den fazla algılayıcıdan 30 saniye aralıklarla toplanmıştır. Elde edilen hız verileri 5 dakikalık aralıklarla oluşacak şekilde ön işleminden geçirilerek derin öğrenme algoritmalarıyla, 15, 30, 45, 60 dakika gelecekteki hız bilgisini tahmin edecek model oluşturulmuştur. Önerilen model, ortalama mutlak hata (MAE), ortalama bağıl hata (MRE) ve kök ortalama kare hata (RMSE) metrikleriyle değerlendirilmiştir. 15 dakika gelecek tahmin edildiğinde MAPE değeri %34,1 olarak hesaplanmıştır.

Çalışma [12]'de enlem, boylam, yön, zaman, hız içeren veri seti Çin'in başkenti Pekin'de 2 dakika arayla GPS algılayıcısı kullanılarak toplanmıştır. Trafik hızları durağan görüntülere dönüştürülerek trafik yoğunluk tahmini için Spatiotemporal Yenilenen Evrişimli Ağlar (Spatiotemporal Recurrent Convolutional Networks) derin öğrenme yöntemi kullanılmıştır. 6 dakika kısa vadeli trafik yoğunluk tahmini için ortalama mutlak yüzde hata (MAPE) değeri %0,12 olarak hesaplanmıştır.

Çalışma [13]'te trafik yoğunluk tahmini için Evrişimli Sinir Ağları'nın (CNN), diğer derin öğrenme ve makine öğrenmesi yöntemlerine göre %45 daha iyi sonuç ürettiği belirtilmiştir.

Çalışma [14]'te Spatiotemporal Yenilenen Evrişimli Ağlar (Spatiotemporal Recurrent Convolutional Networks), k en yakın komşu ve Uzun Kısa Süreli Bellek yöntemleri birleştirilerek elde edilmiştir. Bu yöntemin kısa vadeli trafik yoğunluk tahmininde sıklıkla kullanılan Hareketli Ortalamalar, Destekçi Vektör Makinesi, LSTM

yöntemlerinden %12,59 daha doğru sonuç verdiği gözlemlenmiştir.

Çalışma [15]'te Spatiotemporal Yinelenen Evrişimli Ağlar, Evrişimli Sinir Ağı (CNN) ve Uzun Kısa Süreli Bellek (LSTM) yöntemleri birleştirilerek oluşturulmuştur. Elde edilen yöntemin kısa vadeli trafik yoğunluk tahmininde klasik zaman serileri ve diğer derin öğrenme yöntemlerinden daha iyi sonuç verdiği belirtilmiştir.

Kullanılan trafik hız verisinin haftanın belirli bir gününde olması (hafta içi, hafta sonu, tatil günü), hız verisinin gün içinde bulunduğu zaman aralığı (sabah, öğlen, akşam, iş giriş çıkış saatleri), özel etkinlikler, yol düzenleme çalışmaları, hava durumu, yolun sosyal alanlara olan mesafesi gibi etkenler trafik yoğunluk tahmin çalışmalarını etkilemektedir [1]. Trafik yoğunluğu tahmin çalışmalarını etkileyen bu etkenler kullanılarak trafik hız verilerinin benzerliği ve yeniden aynı hız dizilimlerinin oluşumları, [16] çalışmasında araştırılmış ve doğruluğu kabul edilmiştir. Trafik yoğunluğunu ve trafiğe etki eden faktörlerin birlikte değerlendirilebilmesi için Spatiotemporal Yinelenen Evrişimli Ağlar (Spatiotemporal Recurrent Convolutional Networks) ile derin öğrenmeye dayalı bir yaklaşım denenmiştir.

Çalışma [17]'de derin öğrenme algoritması çalıştırılırken, trafik yoğunluk tahminine etkisi olan etkenlerden hava durumu ve özel etkinlik içeren günlerdeki hız verileri kullanılarak model oluşturulmuştur.

Mevcut çalışmalardan farklı olarak bu çalışmada uzun vadeli trafik hız tahmini Ortalama, Polinom Regresyon ve Evrişimli Sinir Ağı yöntemleri kullanılarak yapılmıştır. Haftanın aynı günlerinin belirli bir hız karakteristiğine sahip olduğuna dayanarak geçmiş haftalarda aynı günün hız verileri tahminleme modellerinde kullanılmıştır. Gelecek 7 güne kadar uzun vadeli hız tahmini yapabilen bir model oluşturulmuş ve karşılaştırmalı olarak incelenmiştir.

1.2 Tezin Amacı ve Kapsamı

Mevcut ve geçmiş trafik bilgilerine dayanarak geleceği birkaç saniye ile birkaç saat arasında tahmin etmek için yapılan çalışmalar kısa vadeli, birkaç saatten ileri zaman dilimi için yapılan tahminler ise uzun vadeli trafik yoğunluğu ölçen çalışmalar olarak değerlendirilmektedir. Bu projede uzun vadeli trafik yoğunluk tahmini yapılması amaçlanmaktadır. Bu çalışmada haftanın aynı günleri kullanılarak elde edilen ortalama hız verisi derin öğrenme yöntemlerinden CNN, regresyon ile eğri uydurularak ve ortalama yöntemi ile tahmin modeli oluşturularak incelenmiştir. Haftanın tüm günleri kullanıldığı için gelecekteki 7 güne kadar hız tahmini yapan uzun zamanlı öngörü modeli oluşturulmuştur.

Uzun vadeli trafik yoğunluğu tahmini için CNN yöntemine farklı dizilimlerle hazırlanmış veri setleri girdi olarak verilmiştir ve trafik hız veri setindeki hız dizilimlerinin öğrenmeye etkisi incelenmiştir. Ayrıca CNN yöntemi model başarısında; filtre sayısı, kernel boyutu, düğüm sayısı, katman sayısı, optimizasyon algoritması, aktivasyon fonksiyonu, batch boyutu, epoch sayısı gibi değişken parametrelerin etkisi incelenmiştir. Her bir 44 farklı algılayıcı için Haziran, Temmuz, Ağustos, Eylül, Ekim, Kasım, Aralık ayları hız verisi kullanılarak tahmin modeli oluşturulmuştur. Algılayıcı konumlarının ve ay bilgisinin tahmin başarısına etkisi incelenmiştir.

1.3 Hipotez

Bu projede hipotezler şunlardır:

-Uzun vadeli trafik yoğunluk tahmini problem olarak ele alınabilir ve regresyon, geçmiş haftaların ortalaması ve derin öğrenme yöntemlerinden CNN kullanılarak doğru sonuç elde edilebilir.

-CNN yöntemi zaman serileri tahmininde başarısı yüksek sonuçlar vermektedir.

-Haftanın aynı günleri benzer trafik yoğunluklarına sahiptir, çeşitli görselleştirme ve istatistiksel yöntemlerle incelenebilir.

-Tahmin edilecek günden k hafta geriye gidilerek elde edilen hız verisi ile uzun vadeli trafik hız tahmini yapılabilir.

-Tahmin edilecek günden k hafta geriye gidilerek aynı 5 dakikalık dizilimde bulunan hız verileri kullanılarak tahmin gücü yüksek veri seti oluşturulabilir.

-Tahmin edilecek günden k hafta geriye gidilerek elde edilen her bir 5 dakikalık hız verisi için 15 dakika ileri ve geri gidilerek elde edilen hız verileri haftalık dizilimde veya aynı 5 dakikalık hız verileri yan yana gelecek şekilde yerleştirilerek, CNN modeli için tahmin gücü yüksek veri seti elde edilebilir.

-Tahmin modeline girdi olarak verilen veri setleri farklı hız dizilimlerinde verilebilir. Hız diziliminin değişmesi modelin öğrenme doğruluğunu değiştirmektedir.

-Veri seti oluşturulurken k hafta geriye gitme, k sayısı 4 seçilerek model başarısı arttırılabilir.

-Algılayıcı verileri seçilirken verinin %30'undan fazla kayıp veri içeren algılayıcılar kullanılmamalıdır.

-Uzun vadeli hız tahmininde CNN yöntemi; Polinom Regresyon ve Ortalama yöntemlerinden daha doğru sonuç vermektedir.

-Uzun vadeli trafik tahmini yaparken her bir algılayıcı ve her bir ay verisi için ayrı tahmin modeli kurulmalıdır.

-Trafik yoğunluğu fazla olan köprü benzeri bölgeler ayrıca ele alınmalıdır.

-Okul açılış kapanış tarihlerini içeren aylar için tahmin model oluşturulması ayrı olarak ele alınmalıdır.

2 TRAFİK YOĞUNLUK TAHMİNLEME

Artan nüfus ve araç sayısı yüzünden trafik yoğunluğu şehir hayatının en büyük problemi olmuştur. Trafik yoğunluğunun fazla olması, hava kirliliği ve yakıt kullanımını da artırmaktadır. Trafik yoğunluk tahmini sayesinde sürücüler kalkış saatlerini ve seyahat yollarını planlayabilmektedirler. Dolayısıyla hem zamandan hem yakıt tüketiminden kar edebilmek mümkündür.

2.1 Trafik Yoğunluk Tahminleme

Son yıllardaki teknolojik gelişmeler, gerçek zamanlı trafik bilgilerinin toplanmasını ve yayılmasını sağlamıştır. Artan trafik hacmi ve tıkanıklığı ile birlikte, trafik modellemeye olan ilgi artmıştır. Trafik akış hızının gerçek zamanlı uzay-zamansal ölçümleri toprak içi dedektörlerden, yol üzerindeki algılayıcılardan veya GPS verilerinden elde edilebilir. Gerçek zamanlı ve geçmiş hız verileri kullanılarak gelecek trafik yoğunluğu tahminlemek mümkündür. Trafik yoğunluğu tahminleme çalışmaları kısa vadeli ve uzun vadeli olmak üzere ikiye ayrılmaktadır.

2.1.1 Kısa Vadeli Trafik Yoğunluk Tahminleme

Gerçek zamanlı hız verisi kullanarak belirli zamana dair gelecek trafiği birkaç saate kadar tahmin edebilen çalışmalar kısa vadeli [6, 7] olarak tanımlanmaktadır. Kısa vadeli çalışmalarda anlık trafik yoğunluğu hesaplanmaktadır. Google Haritalar ve Yandex benzeri uygulamalar anlık seyahat planı oluşturmak için sıkça kullanılmaktadır, kullanıcılar anlık trafik yoğunluğuna göre rotalarını değiştirebilmektedirler.

2.1.2 Uzun Vadeli Trafik Yoğunluk Tahminleme

Gerçek zamanlı ve geçmiş trafik hız bilgilerine dayanarak geleceği, birkaç saatten ileri zaman dilimi tahmin etmek için yapılan çalışmalar ise uzun vadeli trafik

yoğunluğu ölçen çalışmalar olarak değerlendirilmektedir. Bu çalışmalar sayesinde trafik yoğunluğu gelecekteki günler için tahmin edilebilir ve kullanıcılar seyahat planlarını geleceğe yönelik yapabilmektedirler.

2.2 Uzun Vadeli Trafik Yoğunluk Tahmini için Kullanılan Yöntemler

Trafik yoğunluk tahmini için bu çalışmada Merkezi Eğilim Ölçüleri'nden Ortalama, Regresyon, Derin Öğrenme Yöntemlerinden Evrişimli Sinir Ağı yöntemleri kullanılmıştır.

2.2.1 Merkezi Eğilim Ölçüleri

İstatistik, sayılar kullanarak bilgi çıkarımı ve verilerin çözümlenmesinden oluşmaktadır. İstatistik, çıkarımsal ve tanımlayıcı olmak üzere iki daldan oluşmaktadır. Verilerin özetinin çıkarılması ve ortaya konması tanımlayıcı istatistik alanına dahildir. Tanımlayıcı istatistik doğrudan öngörü için kullanılamaz. Tanımlayıcı istatistik; dağılım, varyasyon ve merkezi eğilim ölçülerini içermektedir [18]. Bu çalışmada haftanın aynı günlerinde bulunan hız verilerinin ortalaması kullanılarak, haftanın günlerinde benzer hız örüntülerinin olup olmadığı araştırılacaktır. Tahmin edilecek günden k hafta geriye gidilerek haftanın aynı günlerinde ve saatlerindeki hız verilerinin ortalaması alınacaktır. Ortalama formülü Denklem 2.1'de verilmektedir. V_i ; i. haftanın 1 gününde 5 dakikalık aralıklarla elde edilen hız vektörü iken k; geriye gidilen hafta sayısıdır.

$$\frac{1}{k} \sum_{i=1}^k V_i \quad (2.1)$$

2.2.2 Regresyon

Regresyon analizi, eldeki verilerden, ilerideki tarihlere dair öngörüler yapılması için önemlidir. Regresyon, bağımsız ve bağımlı değişkenler arasındaki ilişkiyi ve doğrusal eğri kavramını kullanarak, tahmin geliştirilmesini sağlar. Değişkenler arasında olan ilişki tanımlandıktan sonra, bağımsız değişkenin değeri bilinmesi halinde bağımlı değişkenin değeri tahmini mümkündür [19]. Bağımlı değişken ve bağımsız değişken arasında olan ilişkiyi açıklamak için çok değişkenli n. dereceden regresyon modeli Denklem 2.2'de verilmektedir. Burada, y, bağımlı değişkenin değeri; b, regresyon doğrusunun kesişim değeri; a, regresyon doğrusunun eğimi ve x bağımsız değişkenin değerini göstermektedir.

$$y = a_0 * x^n + a_1 * x^{n-1} + ... + a_n \quad (2.2)$$

Bu çalışmada 1., 2., 3., 4. ve 5. dereceden regresyon modelleri oluşturularak, elde edilen doğruluk oranları karşılaştırılmıştır.


2.2.3 Derin Öğrenme Yöntemleri

Son yıllarda, derin öğrenme popülerlik kazanmıştır ve literatürde başarı elde edilen birçok çalışma alanı vardır [20, 21].

2.2.3.1 Evrişimli Sinir Ağı (Convolutional Neural Network)

Derin öğrenme yöntemlerinden biri olan Evrişimli Sinir Ağı nesne tanımda başarılı sonuçlar vermiştir. Evrişimli Sinir Ağı girdi olarak verilen resimlerde otomatik olarak derin özellikler çıkarabilmektedir. Diğer derin öğrenme yöntemlerinden farklı olarak çeviri, ölçeklendirme ve döndürmeye karşı sağlam sonuçlar üretebilmektedir. Evrişimli Sinir Ağı'nı, resim tanımadaki başarısından esinlenerek zaman serisi verilerinde de kullanan ve başarılı sonuç elde eden çalışmalar mevcuttur [22].

Evrişimli Sinir Ağı iki bölümden oluşmaktadır. Birinci bölümde evrişim ve havuzlama yöntemleri kullanarak veri setinin derin özellikleri oluşturulmaktadır. İkinci bölümde özellikler çok katmanlı sinir ağına verilerek sınıflandırma yapılmaktadır [23].



Şekil 2.1 Evrişimli Sinir Ağı Akış

Şekil 2.1’de Evrişimli Sinir Ağı Akışı gösterilmektedir. Girdiye evrişim aşamasında belirlenen sayıda filtre uygulanarak veriyi tanımlayıcı özellik haritası çıkartılmaktadır. Havuzlama katmanında özellik haritası seçilen boyutlarda verinin ortalama veya maksimum değeri alınarak ağ içindeki özellikler azaltılır. Evrişim ve Havuzlama işlemi

birkaç kez tekrar edilerek yeni özellikler çıkarılabilmektedir. Evrişim ve Havuzlama işlemlerinden sonra elde edilen tüm özellikler birleştirilerek tam bağlı sinir ağı katmanına verilir ve çıktı değeri üretilir.

3

TRAFİK VERİSİNİN İNCELENMESİ

Bu bölümde veri setinin toplanması ve ön işlemden geçirilerek öngörü gücü yüksek model oluşturmak için elverişli hale getirilme aşamalarından bahsedilmektedir. Ayrıca veri setinin hız dizilimleri değiştirilerek 3 farklı veri seti oluşturulması, veri hazırlama kısmında anlatılmaktadır.

3.1 Veri Toplama

Bu çalışmalarda uzun süreli trafik hız öngörüsünün yapılması amaçlanmıştır. Bu amaç için İstanbul Büyükşehir Belediyesi tarafından sağlanan trafik akış hızı verilerinden faydalanılmıştır. Veriler 2016, 2017 ve 2018 yılları için dakika bazında 3889 tane algılayıcıdan alınan hız verilerini içermektedir. 2016 yılındaki veri eksikliği, 2018 yılında da yalnızca 2 aylık veri bulunması nedeniyle, bu çalışmada 2017 yılına dair hız verileri kullanılmıştır.

3.1.1 Veri Seti ve Algılayıcılar

Veriler İstanbul genelinde farklı noktalara yerleştirilmiş algılayıcılardan dakika bazında toplanmıştır. Bu algılayıcılar bulundukları konuma göre farklı kimliklere sahiptir.

Tablo 3.1 Algılayıcı Örnek Hız Verisi

vSegID	vSegDir	fusedDate	fusedSpeed
1	0	2017-01-01 03:20:00	25 km/saat
1	0	2017-01-01 03:21:00	27 km/saat
1	0	2017-01-01 03:22:00	30 km/saat
1	0	2017-01-01 03:23:00	34 km/saat
1	0	2017-01-01 03:24:00	29 km/saat

Tablo 3.1’de 1 numaralı algılayıcıdan elde edilen veri yapısını gösteren bir örnek yer almaktadır. Tablodaki sütun isimlerinden vSegID hız ölçümü yapılan yol segment

Tablo 3.2 44 Farklı Algılayıcının Konumları

Algılayıcı	Konumu
30	Kartal Samandra Bağlantı Yolu Yakacık Mevki
31	Kartal Samandra Bağlantı Yolu Resim İstanbul Mevki
37	Kartal Samandra Bağlantı Yolu Soğanlık Mevki
63	Barbaros Bulvarı Zincirlikuyu Metrobüs Mevki
64	Barbaros Bulvarı Yahya Kemal Parkı Mevki
73	Büyükdere Caddesi Sanayi Sitesi Mevki
74	Büyükdere Caddesi Sanayi Mahallesi Mevki
75	Büyükdere Caddesi 4. Levent Safir Mevki
76	Büyükdere Caddesi Zincirlikuyu Mezarlık Mevki
119	Atatürk Bulvarı O-7 Mall of İstanbul Mevki
120	Atatürk Bulvarı DeFacto Genel Müdürlük Mevki
121	Atatürk Bulvarı My Office 212 Mevki
122	Atatürk Bulvarı Kültür Üniversitesi Mevki
125	Mahmutbey Atatürk Havalimanı Bağlantısı Altur Otomotiv Mevki
126	Mahmutbey Atatürk Havalimanı Bağlantısı Altur Garaj Mevki
128	Atatürk Havalimanı Caddesi TC Ulaştırma Bakanlığı Mevki
129	Atatürk Havalimanı Caddesi Dünya Ticaret Merkezi Mevki
130	Atatürk Havalimanı Caddesi Görme Özürlüler Derneği Mevki
131	Atatürk Havalimanı Caddesi DHM İşletmesi Mevki
215	Kağıthane Nurtepe Viyadüğü Afet Koordinasyon Merkezi Mevki
216	Kağıthane Nurtepe Viyadüğü Gecekondü Mesken Parkı Mevki
217	Hasdal Okmeydanı Bağlantısı Güzeltepe Mevki
219	İstanbul Çevreyolu O-1 Okmeydanı Mevki
308	Acıbadem Caddesi Kontrol 2000 Otomasyon Mevki
309	D-100 Acıbadem Metro Mevki
310	İstanbul Çevreyolu O-1 Ünalın Mevki
315	D-100 Kozyatağı Mevki
320	D-100 Zümrütevler Mevki
421	E-5 Çobançeşme Mevki
422	E-5 Çobançeşme Kavşağı Mevki
423	E-5 Ataköy Metro Mevki
424	E-5 Şirinevler Metrobüs Mevki
433	O-1 Haliç Köprüsü Mevki
443	O-1 1. Köprü Avrupa Yakası Çıkış Mevki
444	O-1 1. Köprü Anadolu Yakası Giriş Mevki
445	O-1 Beylerbeyi Kavşağı Mevki
472	O-1 Fatih Sultan Mehmet Köprüsü Anadolu Yakası Giriş Mevki
506	Rauf Orbay Caddesi Ataköy
507	Rauf Orbay Caddesi Baruthane Parkı Mevki
511	Bakırköy Sahilyolu Mevki
512	Zeytinburnu Sahilyolu Mevki
1748	O-1 1. Köprü Anadolu Yakası Çıkış Deva Vakfı Mevki
1749	O-1 1. Köprü Anadolu Yakası Çıkış Kavacık Mevki
1779	Rauf Orbay Caddesi Galleria Mevki

3.2 Veri Ön İşleme ve Hazırlama

Bu kısımda veri setinin tahmin gücü yüksek model oluşturmaya uygun hale getirilmesi için veri üzerinde yapılan ön işlemlerden ve hazırlıklardan bahsedilmektedir.

3.2.1 Veri Ön İşleme

Elde edilen veriler algılayıcıdan her bir dakikada ölçülen hız verileridir. Veri setinin işlenmemiş halinde 24 saatte 1440 dakika bulunması sebebiyle 1 gün içinde 1440 veri içermektedir. 1100'den az hız verisi (yaklaşık verinin %70'i) içeren günler hesaplamaya katılmamıştır. Önceden yapılan çalışmalarda [10, 11] 5 dakika aralıklarla hız akış verisinin değerlendirildiği görülmüştür ve çalışmada her 5 dakika için ortalama hız değeri alınarak veri kümesi düzenlenmiştir.

2017-08-25 00:00:00+00:00	82	
2017-08-25 00:01:00+00:00	80	
2017-08-25 00:02:00+00:00	77	Ortalama: 80
2017-08-25 00:03:00+00:00	78	
2017-08-25 00:04:00+00:00	83	
2017-08-25 00:05:00+00:00	84	
2017-08-25 00:06:00+00:00	88	
2017-08-25 00:07:00+00:00	91	Ortalama: 88
2017-08-25 00:08:00+00:00	87	
2017-08-25 00:09:00+00:00	90	
2017-08-25 00:10:00+00:00	90	
2017-08-25 00:11:00+00:00	90	
2017-08-25 00:12:00+00:00	90	Ortalama: 90
2017-08-25 00:13:00+00:00	90	
2017-08-25 00:15:00+00:00	82	
2017-08-25 00:16:00+00:00	82	
2017-08-25 00:17:00+00:00	82	Ortalama: 85,75 = ((82*3)+97)/4
2017-08-25 00:19:00+00:00	97	
.		
.		
.		
2017-08-25 00:45:00+00:00	90	
2017-08-25 00:46:00+00:00	97	Ortalama: 95,25 00:45:00+00:00
2017-08-25 00:47:00+00:00	97	
2017-08-25 00:48:00+00:00	97	
		Ortalama: 95,25 00:50:00+00:00
		Ortalama: 95,25 00:55:00+00:00

Şekil 3.2 Hız Verilerinin 5 Dakika Aralıklarla Ortalama Alınma Yöntemi

Veri setinde kayıp veriler bulunmaktadır. Kayıp veriler için, verinin en yakınında bulunan hız değeri (örneğin; 5 dakika sonraki hız verisi) kabul edilecek şekilde yeniden örnekleme yapılmıştır. Şekil 3.2'de 1 dakika aralıklarla verilen verinin 5 dakika aralık içerisinde ortalama alınma yöntemi görülmektedir. Ortalama alınan


kısımlar değişik renklerde gösterilmiştir. Eksik veri olması durumunda var olan hız verilerinin belirlenen 5 dakika içerisindeki ortalaması alınmıştır. Belirlenen 5 dakika için hiç hız verisi bulunmuyorsa mor renkle gösterilen örnekte olduğu gibi en yakın 5 dakika ortalama hız verisi kullanılmıştır. Hız verisinin 5 dakika aralıklarla ortalaması alınmasıyla veri setinin son halinde her bir gün için 288 adet hız verisi bulunmaktadır.

3.2.2 Veri Hazırlama

Bu kısımda uzun vadeli trafik yoğunluğu tahmin etmek için veri setinin hazırlanma aşamasından bahsedilecektir. Veri setinin hazırlanmasında haftanın aynı günlerinin aynı karakteristiğe sahip olması hipotez olarak kullanılmıştır. Ayrıca derin öğrenme algoritmalarına girdi olarak verilecek veri setinin hazırlanması da bu kısımda anlatılmıştır.

3.2.2.1 Veri Setinin k hafta geriye Gidilerek Hazırlanması


Kısa vadeli hız tahmini yapan çalışmalarda yoğunlukla aynı gün içerisinde bulunan hız verileri kullanılmaktadır. Uzun vadeli hız tahmini için, aynı gün içerisindeki hız verilerini kullanmak yeterli olmamaktadır. Bu çalışmada uzun vadeli hız tahmini için geçmişte benzer karakteristik özelliğe sahip günlerin kullanılmasının tahmin sonuçlarına etkisi incelenmiştir. Burada k kaç hafta geri gidileceğini göstermektedir, çalışmamızda k; 1, 2, 3, 4, 5, 6 değerlerini almaktadır.



Şekil 3.3 25.11.2017 Tarihi İçin k=4 Hafta Geri Gidilerek Verilerin Elde Edilmesi

Şekil 3.3'te 25.11.2017 tarihi için k=4 hafta geri gidildiğinde hangi günlerdeki hız verilerinin kullanıldığı şematik olarak gösterilmiştir. 25.11.2017 Cumartesi tarihi için

sırasıyla 18.11.2017, 11.11.2017, 04.11.2017, 28.10.2017 Cumartesi günü hız verileri hesaplamalarda kullanılır.



Şekil 3.4 315 Numaralı Algılayıcı 25.11.2017 Tarihi İçin 4 Hafta Geri Gidildiğinde Elde Edilen Hız Verileri

Şekil 3.4'te örnek olarak 315 numaralı algılayıcı için 25.11.2017 tarihinden 4 hafta geriye gidilerek elde edilen günlük hız verileri grafikte gösterilmektedir. x eksenini 1 gün içindeki her bir 5 dakikaya denk gelirken y eksenini her bir 5 dakikadaki ortalama hız verisini temsil etmektedir. Haftanın aynı günlerinin belirli bir karakteristiğe sahip olduğu gözlemlenmektedir.

3.2.2.2 Derin Öğrenme Yöntemi için Veri Setinin Hazırlanması

Bu kısımda derin öğrenme algoritmalarına girdi olarak verilen veri setinin hazırlık aşamaları ve eğitim, doğrulama, test veri seti oluşturma aşamaları anlatılmıştır.

Veri setinin hazırlanmasında haftanın aynı günlerinin aynı karakteristiğe sahip olması esas alınmıştır. Derin öğrenme yöntemleri için veri seti hazırlama aşamasında da k hafta geriye gidilerek hız verileri elde edilmiştir. Elde edilen her bir haftanın belirlenen günü hız verisi direkt kullanılmıştır veya artı eksi 15 dakika aralığındaki hız verileri de

dahil edilerek veri seti oluşturulmuştur.

3.2.2.3 Geriye Gidilen Her Bir Hafta Günü Hız Verisinin Kullanılması

Derin öğrenme yöntemiyle, hız verisi tahmin edilmek istenen günden k hafta geriye gidilerek elde edilen günlerin hız vektörleri aynı 5 dakikalık dilim yan yana olacak şekilde birleştirilerek veri seti oluşturulmuştur.

Tablo 3.3 Geriye Gidilen 4 Hafta Günü Hız Verisi (km/saat)

Hedef Hız Vektörü	1 Hafta Önceki Hız Vektörü	2 Hafta Önceki Hız Vektörü	3 Hafta Önceki Hız Vektörü	4 Hafta Önceki Hız Vektörü
90	91.0	90.2	93.2	95.0
92,4	96.5	84.25	92.8	96.4
90,2	94.4	86.6	95.25	87.25
95,2	97.25	87.25	91.4	86.8
95,8	105.25	90.0	95.2	102.8

Tablo 3.3'te gösterilen Hedef Hız Vektörü sütunu tahmin edilmek istenen günün hız verilerinden ilk 25 dakika hız verilerini göstermektedir. Tahmin edilmek istenen günden sırasıyla 1, 2, 3, 4 hafta geri gidilmesiyle elde edilen günlük hız vektörlerinin ilk 25 dakikası tabloda verilmektedir. Günlük hız verileri, 1 günde 288 adet 5 dakika olması sebebiyle 288 hız verisi içermektedir. Günlük hız verileri 00:00 saatinden 23:55 saatine kadar 5 dakikalık aralıklarla sıralanmıştır.

Derin öğrenme algoritmasına girdi olacak veri seti, eğitim için kullanılacak aylar boyunca her bir gün için k hafta geri gidilerek hız verileri elde edilmiş ve her bir gün için hangi ayda olduğu, haftanın hangi günü olduğu bilgisi ve hangi 5 dakikalık zaman aralığında olduğu bilgisi veri setine eklenmiştir.

Şekil 3.5'te derin öğrenme algoritmasında kullanılan veri setinin bir kısmı örnek olarak verilmektedir. Veri seti .csv uzantılı dosyada tutulmaktadır. Tablo 3.4'te veri setinde bulunan öz niteliklerin hangi bilgiyi ifade ettiği ve ne değerler alabildiği verilmiştir.


```

1_Previous_Week;2_Previous_Week;3_Previous_Week;4_Previous_Week;
Week_Day_Info;Month_Info;5_Minute_Order_Info;Target_Speed
91.0 ; 90.2 ; 93.2 ; 95.0 ; 4 ; 12 ; 1 ; 90.0
96.5 ; 84.25; 92.8 ; 96.4 ; 4 ; 12 ; 2 ; 92.4
94.4 ; 86.6 ; 95.25; 87.25; 4 ; 12 ; 3 ; 90.2
97.25 ; 87.25; 91.4 ; 86.8 ; 4 ; 12 ; 4 ; 95.2
105.25; 90.0 ; 95.2 ; 102.8; 4 ; 12 ; 5 ; 95.8
103.0 ; 89.6 ; 95.5 ; 94.8 ; 4 ; 12 ; 6 ; 92.0
103.2 ; 94.8 ; 98.2 ; 96.75; 4 ; 12 ; 7 ; 101.4
100.2 ; 98.6 ; 92.0 ; 94.2 ; 4 ; 12 ; 8 ; 93.6
97.6 ; 100.5; 92.8 ; 100.2; 4 ; 12 ; 9 ; 92.6
99.4 ; 99.4 ; 100.2; 97.8 ; 4 ; 12 ; 10; 96.0
93.8 ; 93.6 ; 105.4; 100.0; 4 ; 12 ; 11; 92.4
110.4 ; 99.6 ; 104.6; 91.0 ; 4 ; 12 ; 12; 98.6
105.25; 96.0 ; 99.0 ; 93.6 ; 4 ; 12 ; 13; 95.2
97.6 ; 99.0 ; 100.4; 99.2 ; 4 ; 12 ; 14; 92.0
102.8 ; 104.0; 98.0 ; 99.0 ; 4 ; 12 ; 15; 93.2
92.2 ; 95.4 ; 99.25; 102.0; 4 ; 12 ; 16; 94.4
93.0 ; 91.2 ; 106.6; 96.8 ; 4 ; 12 ; 17; 100.0
101.2 ; 96.2 ; 114.4; 104.4; 4 ; 12 ; 18; 99.2
106.0 ; 113.6; 93.6 ; 101.6; 4 ; 12 ; 19; 98.8
95.4 ; 106.8; 100.0; 98.0 ; 4 ; 12 ; 20; 105.4
97.0 ; 93.0 ; 102.0; 99.2 ; 4 ; 12 ; 21; 108.6
103.8 ; 96.8 ; 94.8 ; 98.8 ; 4 ; 12 ; 22; 95.8

```


Şekil 3.5 Geriye Gidilen Her Bir k Hafta Verisi İle Veri Seti Oluşturulması

Tablo 3.4 Geriye Gidilen Her Bir k Hafta Hız Verisi Yan Yana Olacak Şekilde Oluşturulmuş Veri Seti Öz Nitelik Bilgisi

Öz Nitelik	Açıklama	Veri Tipi
1_Previous_Week	1 Hafta öncesi 5 dakikalık dilim hız verisi	Nümerik Veri
2_Previous_Week	2 Hafta öncesi 5 dakikalık dilim hız verisi	Nümerik Veri
3_Previous_Week	3 Hafta öncesi 5 dakikalık dilim hız verisi	Nümerik Veri
4_Previous_Week	4 Hafta öncesi 5 dakikalık dilim hız verisi	Nümerik Veri
Week_Day_Info	Haftanın hangi günü olduğu bilgisi	0, dan 7'ye kadar değer alabilmektedir. 0; Pazar, 1; Pazartesi, 2; Salı, 3; Çarşamba, 4; Perşembe, 5; Cuma, 6; Cumartesi gününü temsil etmektedir.
Month_Info	Hangi ay olduğu bilgisi	1'den 12'ye kadar değer alabilmektedir.
5_Minute_Order_Info	Hangi 5 dakikalık dilimde olduğu bilgisi	1 den 288 e kadar değerler alabilmektedir. 1 değeri 00:00 saatini, 288 değeri 23:55 saatini temsil etmektedir.
Target_Speed	Tahmin edilecek hız bilgisi	Nümerik Veri

3.2.2.4 Geriye Gidilen Her Bir Hafta Günü Hız Verisine Artı Eksi 15 Dakika Verisi Eklenmesi

Derin öğrenme yöntemiyle, hız verisi tahmin edilmek istenen günden k hafta geriye gidilerek elde edilen günlerin her bir 5 dakikası için 15 dakika ileri ve 15 dakika geri gidilip hız değerleri alınarak veri seti oluşturulmuştur.



Şekil 3.6 Tahmin Edilecek Günden 1 Hafta Geriye Gidildiğinde 15 Dakika İleri ve Geri Hız Verisinin Oluşturulması

Şekil 3.6'da örnek olarak; tahmin edilecek günden 1 hafta geri gidilmesi ile elde edilen hız vektöründeki her bir 5 dakikaya karşılık gelen hız verisi için, 15 dakika ileri ve geri gidilerek oluşturulan veri dizilimi verilmiştir. 1 hafta geçmişe gidilerek elde edilen n. günün hız vektörünün; sınır kısımlarında bulunan hız verilerinin (00:00, 00:05, 00:10, 23:45, 23:50, 23:55 saatlerine denk gelen hız verileri), 15 dakika ileri ve geri hız verilerinin kullanılabilmesi için (n-1). ve (n+1). gün hız verileri kullanılmıştır.

k Hafta Geri Giderek 15 Dakika İleri Geri Hız Bilgileriyle Haftalık Karakteristikte Veri Seti Oluşturulması

Tahmin edilecek her bir gün için k hafta geri gidilmesiyle elde edilen her bir gündeki her bir 5 dakikalık hız verisi için 15 dakika ileri ve geri hız verisi dizilimi oluşturulmuştur. Haftalık hız verisi karakteristiği bozulmaması için her bir haftanın her 5 dakikası için elde edilen hız dizilimleri yan yana eklenerek veri setinin satırları oluşturulmuştur.

	1 Hafta Geriye Gidildiğinde Hız Dizilimi	2 Hafta Geriye Gidildiğinde Hız Dizilimi
00:00 Hedef Hızı Tahmini İçin:	V286 ⁿ⁻¹ V287 ⁿ⁻¹ V288 ⁿ⁻¹ V1 ⁿ V2 ⁿ V3 ⁿ V4 ⁿ	V286 ^{k-1} V287 ^{k-1} V288 ^{k-1} V1 ^k V2 ^k V3 ^k V4 ^k
00:05 Hedef Hızı Tahmini İçin:	V287 ⁿ⁻¹ V288 ⁿ⁻¹ V1 ⁿ V2 ⁿ V3 ⁿ V4 ⁿ V5 ⁿ	V287 ^{k-1} V288 ^{k-1} V1 ^k V2 ^k V3 ^k V4 ^k V5 ^k
00:10 Hedef Hızı Tahmini İçin:	V288 ⁿ⁻¹ V1 ⁿ V2 ⁿ V3 ⁿ V4 ⁿ V5 ⁿ V6 ⁿ	V288 ^{k-1} V1 ^k V2 ^k V3 ^k V4 ^k V5 ^k V6 ^k
.	.	.
.	.	.
23:55 Hedef Hızı Tahmini İçin:	V285 ⁿ V286 ⁿ V287 ⁿ V288 ⁿ V1 ⁿ⁺¹ V2 ⁿ⁺¹ V3 ⁿ⁺¹	V285 ^k V286 ^k V287 ^k V288 ^k V1 ^{k+1} V2 ^{k+1} V3 ^{k+1}
2 Hafta Geriye Gidilerek Hafta Karakteristik Özelliği Koruyarak Oluşturulan Veri Seti		
00:00 Hedef Hızı Tahmini İçin:	V286 ⁿ⁻¹ V287 ⁿ⁻¹ V288 ⁿ⁻¹ V1 ⁿ V2 ⁿ V3 ⁿ V4 ⁿ V286 ^{k-1} V287 ^{k-1} V288 ^{k-1} V1 ^k V2 ^k V3 ^k V4 ^k	
00:05 Hedef Hızı Tahmini İçin:	V287 ⁿ⁻¹ V288 ⁿ⁻¹ V1 ⁿ V2 ⁿ V3 ⁿ V4 ⁿ V5 ⁿ V287 ^{k-1} V288 ^{k-1} V1 ^k V2 ^k V3 ^k V4 ^k V5 ^k	
00:10 Hedef Hızı Tahmini İçin:	V288 ⁿ⁻¹ V1 ⁿ V2 ⁿ V3 ⁿ V4 ⁿ V5 ⁿ V6 ⁿ V288 ^{k-1} V1 ^k V2 ^k V3 ^k V4 ^k V5 ^k V6 ^k	
.	.	
.	.	
23:55 Hedef Hızı Tahmini İçin:	V285 ⁿ V286 ⁿ V287 ⁿ V288 ⁿ V1 ⁿ⁺¹ V2 ⁿ⁺¹ V3 ⁿ⁺¹ V285 ^k V286 ^k V287 ^k V288 ^k V1 ^{k+1} V2 ^{k+1} V3 ^{k+1}	

Şekil 3.7 Tahmin Edilecek Günden 2 Hafta Geriye Gidildiğinde Haftalık Karakteristik Bozulmadan Veri Setinin Oluşturulması

Şekil 3.7’de 2 hafta geriye gidilerek elde edilen 2 gündeki her bir 5 dakikalık hız verisinin 15 dakika ileri ve geri hız verileri dizilimi gösterilmiştir. 1 hafta geriye gidilerek her bir 5 dakika için hız verisi elde edilmiş ve 15 dakika ileri geri verisi mevcut hız verisinin sağına ve soluna eklenmiştir. Aynı işlem 2 hafta geçmişteki hız verilerin elde edilmesiyle tekrarlanmıştır. Her 2 hafta hız verisi için elde edilen dizilimler yan yana eklenerek, hafta karakteristiği bozulmadan birleştirilmiştir. Bu veri seti derin öğrenme algoritmasına girdi olarak verilerek, haftalık hız verilerinin tahmine etkisi incelenmiştir.

Veri seti .csv uzantılı dosyada saklanmaktadır. Şekil 3.8’de veri seti son haliyle görülmektedir. Pembe ile boyanan kısım 1. hafta, gri 2. hafta, sarı 3. hafta ve yeşil ile boyanan alan 4. hafta geçmiş hız verilerinin 15 dakika ileri ve geri hız verileri eklenmiş dizilimidir. Her bir geçmiş hafta için mevcut 5 dakika hız verisi ve 3 tane 5 dakikalık geçmiş hız verisi, 3 tane 5 dakikalık gelecek hız verisi ile toplamda 7 adet hız verisi bulunmaktadır. Veri seti satırının sonunda bulunan, sarı ve mavi ile boyanmış, son 4 sütun sırasıyla haftanın hangi günü olduğu bilgisi, hangi ay olduğu bilgisi, hangi 5 dakikalık dilimde bulunduğu bilgisi ve tahmin edilmek istenen hız verisidir. Tablo 3.5’te veri setinde bulunan öz niteliklerin açıklaması ve alabileceği değerler verilmiştir.

1_Previous_Week_1;1_Previous_Week_2;1_Previous_Week_3;1_Previous_Week_4;1_Previous_Week_5;1_Previous_Week_6;1_Previous_Week_7;2_Previous_Week_1;2_Previous_Week_2;2_Previous_Week_3;2_Previous_Week_4;2_Previous_Week_5;2_Previous_Week_6;2_Previous_Week_7;3_Previous_Week_1;3_Previous_Week_2;3_Previous_Week_3;3_Previous_Week_4;3_Previous_Week_5;3_Previous_Week_6;3_Previous_Week_7;4_Previous_Week_1;4_Previous_Week_2;4_Previous_Week_3;4_Previous_Week_4;4_Previous_Week_5;4_Previous_Week_6;4_Previous_Week_7;Week_Day_Info;Month_Info;5_Minute_Order_Info;Target_Speed

80.0;72.8;71.0;70.2;78.2;82.4;81.4;75.0;74.8;74.2;74.2;79.2;81.4;80.8;32.4;
30.2;40.0;45.6;63.8;57.2;68.8;78.4;83.6;82.4;74.2;76.8;76.2;82.2;6;10;1;84.
4
72.8;71.0;70.2;78.2;82.4;81.4;81.4;74.8;74.2;74.2;79.2;81.4;80.8;80.8;30.2;
40.0;45.6;63.8;57.2;68.8;85.4;83.6;82.4;74.2;76.8;76.2;82.2;82.8;6;10;2;83.
4
71.0;70.2;78.2;82.4;81.4;81.4;86.0;74.2;74.2;79.2;81.4;80.8;80.8;82.4;40.0;
45.6;63.8;57.2;68.8;85.4;82.8;82.4;74.2;76.8;76.2;82.2;82.8;86.6;6;10;3;85.
2
70.2;78.2;82.4;81.4;81.4;86.0;83.8;74.2;79.2;81.4;80.8;80.8;82.4;83.2;45.6;
63.8;57.2;68.8;85.4;82.8;68.6;74.2;76.8;76.2;82.2;82.8;86.6;81.2;6;10;4;82.
8
78.2;82.4;81.4;81.4;86.0;83.8;89.6;79.2;81.4;80.8;80.8;82.4;83.2;83.6;63.8;
57.2;68.8;85.4;82.8;68.6;80.8;76.8;76.2;82.2;82.8;86.6;81.2;80.2;6;10;5;85.
6
82.4;81.4;81.4;86.0;83.8;89.6;87.2;81.4;80.8;80.8;82.4;83.2;83.6;86.6;57.2;
68.8;85.4;82.8;68.6;80.8;81.8;76.2;82.2;82.8;86.6;81.2;80.2;83.2;6;10;6;88.
6
81.4;81.4;86.0;83.8;89.6;87.2;97.4;80.8;80.8;82.4;83.2;83.6;86.6;86.0;68.8;
85.4;82.8;68.6;80.8;81.8;81.8;82.2;82.8;86.6;81.2;80.2;83.2;83.8;6;10;7;91.
0
81.4;86.0;83.8;89.6;87.2;97.4;94.0;80.8;82.4;83.2;83.6;86.6;86.0;89.0;85.4;
82.8;68.6;80.8;81.8;81.8;91.0;82.8;86.6;81.2;80.2;83.2;83.8;85.0;6;10;8;93.
0

Şekil 3.8 Tahmin Edilecek Günden 4 Hafta Geriye Gidildiğinde Haftalık Karakteristik İçeren Veri Setinin Oluşturulması


Tablo 3.5 Tahmin Edilecek Günden 4 Hafta Geriye Gidildiğinde Haftalık Karakteristik İçeren Veri Seti Öz Nitelik Bilgisi

Öz Nitelik	Açıklama	Veri Tipi
1_Previous_Week_1	1 Hafta öncesi tahmin edilecek hız verisinden 15 dakika geride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
1_Previous_Week_2	1 Hafta öncesi tahmin edilecek hız verisinden 10 dakika geride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
1_Previous_Week_3	1 Hafta öncesi tahmin edilecek hız verisinden 5 dakika geride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
1_Previous_Week_4	1 Hafta öncesi tahmin edilecek hız verisinin bulunduğu 5 dakikalık dilim hız verisi	Nümerik Veri
1_Previous_Week_5	1 Hafta öncesi tahmin edilecek hız verisinden 5 dakika ileride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
1_Previous_Week_6	1 Hafta öncesi tahmin edilecek hız verisinden 10 dakika ileride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
1_Previous_Week_7	1 Hafta öncesi tahmin edilecek hız verisinden 15 dakika ileride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
2_Previous_Week_1	2 Hafta öncesi tahmin edilecek hız verisinden 15 dakika geride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
2_Previous_Week_2	2 Hafta öncesi tahmin edilecek hız verisinden 10 dakika geride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
2_Previous_Week_3	2 Hafta öncesi tahmin edilecek hız verisinden 5 dakika geride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
2_Previous_Week_4	2 Hafta öncesi tahmin edilecek hız verisinin bulunduğu 5 dakikalık dilim hız verisi	Nümerik Veri
2_Previous_Week_5	2 Hafta öncesi tahmin edilecek hız verisinden 5 dakika ileride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
2_Previous_Week_6	2 Hafta öncesi tahmin edilecek hız verisinden 10 dakika ileride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
2_Previous_Week_7	2 Hafta öncesi tahmin edilecek hız verisinden 15 dakika ileride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
3_Previous_Week_1	3 Hafta öncesi tahmin edilecek hız verisinden 15 dakika geride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
3_Previous_Week_2	3 Hafta öncesi tahmin edilecek hız verisinden 10 dakika geride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
3_Previous_Week_3	3 Hafta öncesi tahmin edilecek hız verisinden 5 dakika geride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
3_Previous_Week_4	3 Hafta öncesi tahmin edilecek hız verisinin bulunduğu 5 dakikalık dilim hız verisi	Nümerik Veri
3_Previous_Week_5	3 Hafta öncesi tahmin edilecek hız verisinden 5 dakika ileride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
3_Previous_Week_6	3 Hafta öncesi tahmin edilecek hız verisinden 10 dakika ileride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
3_Previous_Week_7	3 Hafta öncesi tahmin edilecek hız verisinden 15 dakika ileride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
4_Previous_Week_1	4 Hafta öncesi tahmin edilecek hız verisinden 15 dakika geride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
4_Previous_Week_2	4 Hafta öncesi tahmin edilecek hız verisinden 10 dakika geride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
4_Previous_Week_3	4 Hafta öncesi tahmin edilecek hız verisinden 5 dakika geride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
4_Previous_Week_4	4 Hafta öncesi tahmin edilecek hız verisinin bulunduğu 5 dakikalık dilim hız verisi	Nümerik Veri
4_Previous_Week_5	4 Hafta öncesi tahmin edilecek hız verisinden 5 dakika ileride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
4_Previous_Week_6	4 Hafta öncesi tahmin edilecek hız verisinden 10 dakika ileride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
4_Previous_Week_7	4 Hafta öncesi tahmin edilecek hız verisinden 15 dakika ileride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
Week_Day_Info	Haftanın hangi günü olduğu bilgisi	0, dan 7'ye kadar değer alabilmektedir. 0; Pazar, 1; Pazartesi, 2; Salı, 3; Çarşamba, 4; Perşembe, 5; Cuma, 6; Cumartesi gününü temsil etmektedir.
Month_Info	Hangi ay olduğu bilgisi	1'den 12'ye kadar değer alabilmektedir.
5_Minute_Order_Info	Hangi 5 dakikalık dilimde olduğu bilgisi	1 den 288 e kadar değerler alabilmektedir. 1 değeri 00:00 saatini, 288 değeri 23:55 saatini temsil etmektedir.
Target_Speed	Tahmin edilecek hız bilgisi	Nümerik Veri

***k* Hafta Geri Giderek 15 Dakika İleri Geri Hız Bilgileriyle Aynı 5 Dakikalar Yan Yana Gelecek Şekilde Veri Seti Oluşturulması**

Tahmin edilecek her bir gün için, *k* hafta geri gidilmesiyle elde edilen, her bir gündeki her bir 5 dakikalık hız verisi için, 15 dakika ileri ve geri hız verisi elde edilmiştir.

Tüm haftalardaki günlerdeki 5 dakikalık hız verilerinin 15 dakika ileri ve geri hız verileri hafta verisi parçalanarak aynı 5 dakika dilimleri yan yana olacak şekilde dizilmiştir.



Şekil 3.9 Tahmin Edilecek Günden 2 Hafta Geriye Gidildiğinde Aynı 5 Dakikalar Yan Yana Gelecek Şekilde Veri Seti Oluşturulması

Şekil 3.9'da 2 hafta geriye gidilerek elde edilen 2 gündeki her bir 5 dakikalık hız verisinin 15 dakika ileri ve geri hız verileri dizilimi gösterilmiştir. Veri seti oluşturma aşamasında aynı dilimde bulunan 5 dakikalar yan yana gelecek şekilde dizilim yapılmıştır. Şekilde *n* ve *k*, 1 hafta ve 2 hafta geri gidildiğindeki gün bilgisini göstermektedir. 00:00 saati ve diğer 5 dakikalık dilimde bulunan saatlerde, *n*. ve *k*. günler için aynı 5 dakikalık dilimlerin yan yana geldiği görülmektedir.

Tahmin edilecek günden *k* hafta geriye gidildiğinde aynı 5 dakikalar yan yana gelecek şekilde oluşturulan veri seti .csv uzantılı dosyada tutulmaktadır. Şekil 3.10'da veri setinin yapısı görülmektedir. Şekilde ayrı ayrı boyanan 4 hız verisi içeren kısımlar sırayla 1, 2, 3, 4 hafta geriye gidildiğinde elde edilen hız verileridir. Tek renge boyanan alanlar sırasıyla 4 hafta için tahmin edilmek istenen 5 dakikalık zaman diliminden 15 dakika öncesi(4 haftanın 4 hız verisi), 10 dakika öncesi, 5 dakika öncesi, tahmin edilecek saatle aynı dilimde olan hız verileri, 5 dakika sonrası, 10 dakika sonrası

1_Previous_Week_1;1_Previous_Week_2;1_Previous_Week_3;1_Previous_Week_4;1_Previous_Week_5;1_Previous_Week_6;1_Previous_Week_7;2_Previous_Week_1;2_Previous_Week_2;2_Previous_Week_3;2_Previous_Week_4;2_Previous_Week_5;2_Previous_Week_6;2_Previous_Week_7;3_Previous_Week_1;3_Previous_Week_2;3_Previous_Week_3;3_Previous_Week_4;3_Previous_Week_5;3_Previous_Week_6;3_Previous_Week_7;4_Previous_Week_1;4_Previous_Week_2;4_Previous_Week_3;4_Previous_Week_4;4_Previous_Week_5;4_Previous_Week_6;4_Previous_Week_7;Week_Day_Info;Month_Info;5_Minute_Order_Info;Target_Speed

83.8;94.0;87.8;92.0;83.8;94.0;85.8;89.8;84.4;94.0;87.2;90.6;92.4;84.0;86.6;90.8;93.2;84.0;89.0;88.8;91.8;84.5;91.0;98.4;94.4;84.5;92.8;94.0;0;5;1;71.8

83.8;94.0;85.8;89.8;84.4;94.0;87.2;90.6;92.4;84.0;86.6;90.8;93.2;84.0;89.0;88.8;91.8;84.5;91.0;98.4;94.4;84.5;92.8;94.0;90.8;75.8;98.8;94.4;0;5;2;77.2

84.4;94.0;87.2;90.6;92.4;84.0;86.6;90.8;93.2;84.0;89.0;88.8;91.8;84.5;91.0;98.4;94.4;84.5;92.8;94.0;90.8;75.8;98.8;94.4;94.0;80.0;101.4;96.6;0;5;3;74.6

92.4;84.0;86.6;90.8;93.2;84.0;89.0;88.8;91.8;84.5;91.0;98.4;94.4;84.5;92.8;94.0;90.8;75.8;98.8;94.4;94.0;80.0;101.4;96.6;93.4;80.0;94.4;97.0;0;5;4;79.8

93.2;84.0;89.0;88.8;91.8;84.5;91.0;98.4;94.4;84.5;92.8;94.0;90.8;75.8;98.8;94.4;94.0;80.0;101.4;96.6;93.4;80.0;94.4;97.0;97.4;80.0;83.6;96.4;0;5;5;82.8

91.8;84.5;91.0;98.4;94.4;84.5;92.8;94.0;90.8;75.8;98.8;94.4;94.0;80.0;101.4;96.6;93.4;80.0;94.4;97.0;97.4;80.0;83.6;96.4;94.6;80.0;87.6;101.8;0;5;6;79.2

94.4;84.5;92.8;94.0;90.8;75.8;98.8;94.4;94.0;80.0;101.4;96.6;93.4;80.0;94.4;97.0;97.4;80.0;83.6;96.4;94.6;80.0;87.6;101.8;94.0;80.0;95.0;99.4;0;5;7;82.0

Şekil 3.10 Tahmin Edilecek Günden 4 Hafta Geriye Gidildiğinde Aynı 5 Dakikalar Yan Yana Gelecek Şekilde Veri Seti Oluşturulması

15 dakika sonrası olacak şekilde yan yana dizilmiştir. 4x7'den (15, 10, 5 dakika öncesi, kendi saat dilimi, 5, 10, 15 dakika sonrası toplamda 7 farklı saat dizilimi oluşmaktadır.) toplamda bir satırda 28 hız verisi bulunmaktadır. Satırda gri ile boyanan alan sırasıyla haftanın hangi günü olduğu bilgisi, hangi ay olduğu bilgisi, hangi 5 dakikalık dilimde olduğu bilgisi ve tahmin edilmek istenen hız verisinden oluşmaktadır. Tablo 3.6'da veri seti öz nitelik açıklaması ve alabileceği değerler verilmiştir.

Tablo 3.6 Tahmin Edilecek Günden 4 Hafta Geriye Gidildiğinde Aynı 5 Dakikalar Yan Yana Gelecek Şekilde Veri Seti Öz Nitelik Bilgisi

Öz Nitelik	Açıklama	Veri Tipi
1_Previous_Week_1	1 Hafta öncesi tahmin edilecek hız verisinden 15 dakika geride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
1_Previous_Week_2	2 Hafta öncesi tahmin edilecek hız verisinden 15 dakika geride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
1_Previous_Week_3	3 Hafta öncesi tahmin edilecek hız verisinden 15 dakika geride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
1_Previous_Week_4	4 Hafta öncesi tahmin edilecek hız verisinden 15 dakika geride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
1_Previous_Week_5	1 Hafta öncesi tahmin edilecek hız verisinden 10 dakika geride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
1_Previous_Week_6	2 Hafta öncesi tahmin edilecek hız verisinden 10 dakika geride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
1_Previous_Week_7	3 Hafta öncesi tahmin edilecek hız verisinden 10 dakika geride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
2_Previous_Week_1	4 Hafta öncesi tahmin edilecek hız verisinden 10 dakika geride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
2_Previous_Week_2	1 Hafta öncesi tahmin edilecek hız verisinden 5 dakika geride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
2_Previous_Week_3	2 Hafta öncesi tahmin edilecek hız verisinden 5 dakika geride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
2_Previous_Week_4	3 Hafta öncesi tahmin edilecek hız verisinden 5 dakika geride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
2_Previous_Week_5	4 Hafta öncesi tahmin edilecek hız verisinden 5 dakika geride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
2_Previous_Week_6	1 Hafta öncesi tahmin edilecek hız verisinin bulunduğu 5 dakikalık dilim hız verisi	Nümerik Veri
2_Previous_Week_7	2 Hafta öncesi tahmin edilecek hız verisinin bulunduğu 5 dakikalık dilim hız verisi	Nümerik Veri
3_Previous_Week_1	3 Hafta öncesi tahmin edilecek hız verisinin bulunduğu 5 dakikalık dilim hız verisi	Nümerik Veri
3_Previous_Week_2	4 Hafta öncesi tahmin edilecek hız verisinin bulunduğu 5 dakikalık dilim hız verisi	Nümerik Veri
3_Previous_Week_3	1 Hafta öncesi tahmin edilecek hız verisinden 5 dakika ileride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
3_Previous_Week_4	2 Hafta öncesi tahmin edilecek hız verisinden 5 dakika ileride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
3_Previous_Week_5	3 Hafta öncesi tahmin edilecek hız verisinden 5 dakika ileride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
3_Previous_Week_6	4 Hafta öncesi tahmin edilecek hız verisinden 5 dakika ileride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
3_Previous_Week_7	1 Hafta öncesi tahmin edilecek hız verisinden 10 dakika ileride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
4_Previous_Week_1	2 Hafta öncesi tahmin edilecek hız verisinden 10 dakika ileride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
4_Previous_Week_2	3 Hafta öncesi tahmin edilecek hız verisinden 10 dakika ileride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
4_Previous_Week_3	4 Hafta öncesi tahmin edilecek hız verisinden 10 dakika ileride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
4_Previous_Week_4	1 Hafta öncesi tahmin edilecek hız verisinden 15 dakika ileride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
4_Previous_Week_5	2 Hafta öncesi tahmin edilecek hız verisinden 15 dakika ileride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
4_Previous_Week_6	3 Hafta öncesi tahmin edilecek hız verisinden 15 dakika ileride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
4_Previous_Week_7	4 Hafta öncesi tahmin edilecek hız verisinden 15 dakika ileride bulunan 5 dakikalık dilim hız verisi	Nümerik Veri
Week_Day_Info	Haftanın hangi günü olduğu bilgisi	0, dan 7'ye kadar değer alabilmektedir. 0; Pazar, 1; Pazartesi, 2; Salı, 3; Çarşamba, 4; Perşembe, 5; Cuma, 6; Cumartesi gününü temsil etmektedir.
Month_Info	Hangi ay olduğu bilgisi	1'den 12'ye kadar değer alabilmektedir.
5_Minute_Order_Info	Hangi 5 dakikalık dilimde olduğu bilgisi	1 den 288 e kadar değerler alabilmektedir. 1 değeri 00:00 saatini, 288 değeri 23:55 saatini temsil etmektedir.
Target_Speed	Tahmin edilecek hız bilgisi	Nümerik Veri

3.2.3 Eğitim, Doğrulama ve Test Veri Seti Oluşturma

Çalışmada 44 farklı algılayıcı verisi kullanılmıştır. Her bir algılayıcı için, veri hazırlanması kısmında bahsedilen 3 farklı veri seti oluşturulmuştur. Eğitim veri seti oluşturulurken tahmin edilmek istenen aydan önceki 3 ay hız verileri kullanılmıştır. Test ve doğrulama veri seti olarak tahmin edilmek istenen ayın hız verisi kullanılmıştır.

4

YAZILIM GELİŞTİRME ORTAMI VE KULLANILAN ARAÇLAR

Regresyon, Merkezi Eğilim Ölçüleri ve Derin öğrenme algoritmaları Python dilinde geliştirilmiştir. Python dili, makine öğrenmesi alanındaki kütüphaneleri ve araçlarındaki çeşitlilik nedeniyle tercih edilmiştir.

Geliştirme ortamı olarak PyCharm IDE kullanılmıştır. Python dilinde kütüphane olarak Numpy; verileri liste olarak ifade etmek ve yeniden boyutlandırmak için, Pandas; .csv uzantılı dosyaları okumak ve veri seti içerisinde sorgulama yapmak için, Matplotlib kütüphanesi sonuçları grafik halinde çizdirmek için, sklearn; hata metriklerinin ve regresyon sonuçlarının hesaplanması için kullanılmıştır.

Derin öğrenme yöntemlerini çalıştırmak için Keras kütüphanesi kullanılmıştır. Keras arka planda Tensorflow kütüphanesini çağırılmaktadır.

Tablo 4.1’de projenin yazılım gereksinimleri ve kullanılan sürümler verilmektedir.

Tablo 4.1 Projenin Yazılım Gereksinimleri

Yazılım İsmi	Kullanılan Sürüm
Python	2.7
PyCharm IDE	2018.2.1
Numpy	1.14.5
Pandas	0.23.4
Matplotlib	2.2.3
Sklearn	0.0
Keras	2.2.4
TensorFlow	1.10.0

Uygulamalar, 8 GB 1600 MHz DDR3 bellek, Macintosh HD Disk, Intel HD Graphics 6000 1536 MB ekran kartı, 1,6 GHz Intel Core i5 işlemci, macOS High Sierra işletim sistemi içeren diz üstü bilgisayarda çalıştırılmıştır.

Bu kısımda uzun vadeli trafik yoğunluk öngörüsü için yapılan deneylerin detayları ve sonuçları verilmiştir. Uzun vadeli trafik yoğunluk tahmininde kullanılan hata metrikleri, ortalama, regresyon ve CNN yöntemlerinin uygulanması ve elde edilen sonuçlar incelenmiştir.

5.1 Hata Metrikleri

Çalışmada elde edilen tahmin sonuçlarının hata miktarı Ortalama Karesel Hata(MSE), Ortalama Mutlak Hata(MAE) ve Ortalama Mutlak Yüzde Hata(MAPE) metrikleri kullanılarak hesaplanmıştır.

Denklem 5.1, 5.2, 5.3'te sırasıyla MSE, MAE, MAPE hata metriklerinin formülleri verilmektedir. Formüllerdeki d ; tahmin edilen değer ile test edilen değer arasındaki farkı, y her bir test verisini, N veri sayısını belirtmektedir.

$$\frac{l}{N} \sum_{i=1}^N V^2 \quad (5.1)$$

$$\frac{l}{N} \sum_{i=1}^N |d| \quad (5.2)$$

$$\frac{\%100}{N} \sum_{i=1}^N \frac{|d|}{|y|} \quad (5.3)$$

Çalışmanın devamında MAPE ve MAE hata metrikleri değerlendirilirken sırasıyla Tablo 5.1 ve Tablo 5.2'de verildiği gibi değerine göre etiket verilmiş ve etiket durumuna göre ilgili hücre boyanmıştır.

Tablo 5.1 MAPE Değerlendirme Etiketi

MAPE Yüzdelik Dilim	Etiket
%0-15	Çok İyi
%15-30	İyi
%30 üzeri	Kötü


Tablo 5.2 MAE Değerlendirme Etiketi

MAE Değer (km/sa)	Etiket
0-10	Çok İyi
10-20	İyi
20 üzeri	Kötü

5.2 Regresyon ve Ortalama Yaklaşımı ile Uzun vadeli Trafik Yoğunluğu Tahmini


Trafik yoğunluğu tahmin edilmek istenen günün hafta içi, hafta sonu veya resmi tatil günü olması, gün içi hız verisi dağılımında belirli bir karakteristik oluşturmaktadır. Çalışmada 2017 44 farklı algılayıcı hız verisinin tüm günleri için; tahmin edilmek istenen günden sırasıyla 2, 3, 4, 5, 6 hafta geriye giderek elde edilen haftanın aynı günü hız verilerinin ortalaması hesaplanmıştır. Elde edilen ortalama ile tahmin gücünün doğruluğu hata metrikleri ile hesaplanmıştır. Ayrıca ortalama hız bilgisi ile n . dereceden regresyon denklemi oluşturulmuş ve tahmin edilmek istenen gün hız verileri denkleme verilerek hata oranı hesaplanmıştır. Bu hesaplamalar ile önceki haftanın aynı günü hız verisi ortalaması kullanılmasının tahmine etkisi gözlemlenmiştir.

Kaç hafta geri gidileceği bilgisi olan k değeri için 44 farklı algılayıcının Haziran, Temmuz, Ağustos, Eylül, Ekim, Kasım, Aralık aylarındaki tüm günleri için Ortalama Yöntemi ile tahminleme yapılmış ve MAPE sonuçları Şekil 5.1’de verilmiştir. En doğru sonucun k ; 4 olduğunda elde edildiği gözlemlenmektedir. Çalışmanın devamında 4 hafta geriye gidilerek haftanın aynı günlerindeki hız verileri kullanılacaktır.



Şekil 5.1 Kaç Hafta Geri Gidildiğine Göre 44 Farklı Algılayıcı Ortalama Yöntemi ile Elde Edilen Ortalama MAPE Değerleri

Regresyon Yöntemi, denklemi elde edilecek regresyon eğrisinin derecesini belirlemek için 44 farklı algılayıcı Haziran, Temmuz, Ağustos, Eylül, Ekim, Kasım, Aralık ayları için 1'den 5'e kadar değişen eğri dereceleri ile oluşturulan denklemler kullanılarak elde edilen MAPE sonuçları karşılaştırılmıştır. Şekil 5.2'de eğri derecesine göre elde edilen MAPE değerleri verilmiştir. En doğru tahmin sonucu eğri derecesi 5 olduğunda elde edilmiştir. Çalışmanın devamında Regresyon Yöntemi için 5. dereceden denklem kullanılarak tahminleme yapılmıştır.



Şekil 5.2 44 Farklı Algılayıcı Regresyon Eğri Derecesine Göre Ortalama MAPE Değerleri

44 farklı algılayıcı için, 4 hafta geriye gidilerek Haziran, Temmuz, Ağustos, Eylül, Ekim, Kasım, Aralık ayları için her ay ve her algılayıcı için elde edilen hız verilerinin aynı 5 dakikalık dilimdeki ortalamaları alınarak tahmin edilmek istenen günün başarısı MAPE ve MAE hata metrikleriyle ölçülmüştür. Aynı zamanda elde edilen ortalama değerleri ile 5. dereceden polinom regresyon eğrisi oluşturularak, tahmin edilmek istenen günün başarısı MAPE ve MAE hata metrikleri ile hesaplanmıştır. 5. dereceden polinom denklemi oluşturularak elde edilen tahminlerin MAPE, MAE hata metrikleri Tablo 5.3'te ve Tablo 5.4'te verilmiştir. Ortalama yöntemi kullanılarak oluşturulan tahmin modelinde MAPE ve MAE değerleri Tablo 5.5'te ve Tablo 5.6'da verilmiştir.

Tablo 5.3 44 Farklı Algılayıcı Polinom Regresyon MAPE Değerleri

Algılayıcı Numarası	Haziran MAPE	Temmuz MAPE	Ağustos MAPE	Eylül MAPE	Ekim MAPE	Kasım MAPE	Aralık MAPE	Algılayıcı Ortalama
30	5,8562	5,7575	5,8515	6,6827	8,5548	7,6264	7,3854	6,8163
31	5,7845	5,4100	5,8685	6,4627	7,5626	7,5996	6,2437	6,4187
37	4,8733	4,4182	4,9161	5,2760	5,8419	6,8225	6,7535	5,5573
63	15,9328	20,3582	18,5052	20,3040	27,8910	33,4700	30,2255	23,81238
64	10,3670	14,2061	8,5142	9,2223	11,2716	11,2211	10,0728	10,6964
73	11,1217	10,2000	10,1977	22,9180	23,0150	19,5227	18,6412	16,5166
74	8,8357	12,9864	15,3468	28,9093	18,6965	15,8583	15,0158	16,5212
75	9,8710	18,8485	22,2713	30,9140	19,8803	22,2423	21,1017	20,7327
76	27,9940	40,9257	35,5297	43,1310	27,8400	24,7030	24,3834	32,0724
119	14,8770	10,6246	10,0290	12,0737	8,9532	15,2714	12,6548	12,0691
120	43,0237	56,0114	37,7271	50,1900	37,2758	32,5107	35,1779	41,7023
121	41,8917	48,0893	36,2000	42,8157	40,9148	39,9243	39,9914	41,4038
122	22,9053	21,5854	23,6819	25,4387	26,3787	25,6617	25,4828	24,4477
125	22,6777	21,7061	18,4455	26,2840	29,3432	32,0269	28,5745	25,5797
126	20,3987	21,7228	20,4616	27,5800	23,6383	28,5939	36,7048	25,5857
128	6,8353	17,4296	8,0155	7,5490	8,0532	8,6583	11,3711	9,7017
129	5,8583	7,1243	7,0926	7,6447	8,3623	6,7662	8,6922	7,3629
130	3,7183	3,7171	3,3774	3,7897	4,2261	4,5147	4,2476	3,9415
131	3,8543	3,9811	3,5603	3,8673	4,2771	5,3073	4,5267	4,1963
215	10,3273	9,5068	9,6113	7,5543	10,5255	7,4415	8,5493	9,0737
216	7,7260	10,1793	9,3232	7,8223	8,3655	7,6375	8,0090	8,4375
217	14,2863	13,3086	13,8280	13,3493	12,9263	15,9405	20,8860	14,9321
219	20,2307	20,1633	24,8495	33,1132	26,0643	26,8873	23,9067	25,0307
308	11,9857	14,7604	8,9939	33,4713	21,9165	10,9366	9,0372	15,8716
309	13,5017	18,0504	11,9735	25,1930	19,9135	11,7570	10,2659	15,8078
310	18,2823	23,5836	13,8971	24,7890	16,3574	12,8453	13,7769	17,6473
315	32,2087	21,2957	21,2784	52,8797	42,1655	30,6060	31,9579	33,1988
320	14,7767	13,5525	13,3968	23,1983	17,9921	18,9108	30,3800	18,8867
421	32,4120	34,6139	28,7294	43,7873	31,5342	27,5482	30,2983	32,7033
422	26,1380	27,2896	26,4184	33,6660	29,5800	27,3055	25,3590	27,9652
423	24,4460	26,3471	24,4265	28,8017	30,9523	30,9727	26,2793	27,4608
424	28,8477	28,3157	24,8781	30,1800	26,3287	28,0817	24,0424	27,2391
433	9,8630	7,6968	8,1584	11,3047	11,1694	10,3324	11,9076	10,0617
443	37,9590	36,0739	38,5526	22,0982	26,4997	17,2703	23,2862	28,8199
444	42,3213	30,9521	33,7661	23,7207	24,8666	18,0203	23,3929	28,1485
445	64,4057	29,6564	26,5184	33,2427	25,8468	21,8400	25,0697	32,3685
472	17,4170	14,8518	13,9690	12,7253	15,9017	11,3520	11,5100	13,9609
506	31,4350	31,8911	19,9919	19,0297	14,6632	20,8547	24,1507	23,1451
507	22,5733	20,8632	15,3016	18,7370	15,3223	19,6817	16,7903	18,4670
511	19,3936	9,1721	5,6194	18,3310	17,4061	20,6752	24,9486	16,5065
512	14,4803	6,5521	4,8994	12,5523	12,6700	16,2133	18,9143	12,3259
1748	29,9350	26,2350	20,9065	30,7150	30,6755	17,4637	16,4017	24,6189
1749	51,4473	46,1139	32,9939	79,3163	83,6974	27,2247	30,9414	50,2478
1779	18,4777	29,5679	20,4661	17,5937	14,6436	17,2147	14,9697	18,9904

Tablo 5.4 44 Farklı Algılayıcı Polinom Regresyon MAE Değerleri

Algılayıcı Numarası	Haziran MAE	Temmuz MAE	Ağustos MAE	Eylül MAE	Ekim MAE	Kasım MAE	Aralık MAE	Algılayıcı Ortalama
30	4.9345	4.6350	5.2546	6.0777	6.7081	6.1176	6.5087	5.7480
31	4.9210	4.5275	5.3023	5.9373	6.3187	5.9692	5.4575	5.4904
37	3.3887	3.0718	3.2665	3.5907	4.2803	4.7257	4.4978	3.8316
63	6.7331	5.6043	6.6058	6.6437	7.8263	9.5337	8.8638	7.4015
64	5.3480	4.5571	4.2510	4.1530	4.6839	5.6143	4.5297	4.7338
73	6.5870	5.7296	5.9997	9.2750	9.9850	8.4960	8.1769	7.7498
74	5.6087	6.7843	7.8887	10.3670	7.8016	6.6087	6.9546	7.4305
75	6.0793	7.7700	8.1406	10.9343	8.4635	7.9773	8.0148	8.1971
76	10.1717	9.7993	9.3952	10.2813	7.2048	6.8517	7.0259	8.6757
119	8.5707	6.0632	5.6335	6.6633	5.6606	7.7110	7.1348	6.7767
120	16.4250	15.8186	14.2239	17.4087	13.3519	13.2137	13.2355	14.8110
121	16.4690	14.3918	13.6132	15.5910	13.4510	14.9117	14.3003	14.6754
122	11.6803	9.3514	10.8074	12.0047	11.3797	11.8940	11.7934	11.2729
125	13.7367	10.6068	11.0168	12.0627	13.5365	13.5862	12.8210	12.4809
126	12.7043	10.4536	11.1842	11.7060	11.8386	12.2129	14.3272	12.0609
128	4.8907	9.4600	4.3452	4.0083	4.4526	4.3083	5.4396	5.2721
129	4.1970	4.6418	4.6694	4.9193	5.6887	4.4221	5.4574	4.8565
130	2.8260	2.7261	2.5513	2.8337	3.2135	3.4237	3.1414	2.9593
131	2.9380	2.8843	2.6735	2.9080	3.2077	3.6717	3.3541	3.0910
215	6.5070	5.2939	6.0990	5.1603	6.0681	5.7237	5.8471	5.8141
216	5.8907	4.7875	6.0984	5.3707	5.4597	5.6511	5.7100	5.5668
217	8.9573	6.9314	8.4768	7.9103	7.5943	8.9438	10.5796	8.4847
219	8.3307	6.9589	9.7050	10.9653	9.2743	8.2867	9.2625	8.9690
308	6.4730	7.1489	5.9610	9.5127	10.8626	6.7297	5.6259	7.4734
309	7.7047	8.2811	8.0174	14.5323	11.6081	7.2737	6.7500	9.1667
310	11.1063	10.4950	9.3452	12.2333	9.7881	8.0500	8.3207	9.9055
315	14.3273	10.8539	10.3142	15.3730	14.0384	12.7167	11.0528	12.6680
320	9.6390	7.5521	8.1710	11.1783	10.9986	11.4596	14.7300	10.5326
421	11.1677	10.7464	8.6229	15.6573	11.5100	11.4964	9.9931	11.3134
422	10.8733	10.4275	9.3845	12.9653	11.1161	11.5914	10.4476	10.9722
423	11.1037	11.2489	10.3200	11.1453	11.7906	12.3500	10.7976	11.2508
424	13.5433	12.2732	10.5948	11.9143	10.1155	10.8217	9.6300	11.2703
433	6.5367	4.9386	5.4358	5.9613	6.1203	5.8348	6.1214	5.8498
443	16.2223	15.9582	19.3448	13.3646	13.3541	12.3355	11.8092	14.6269
444	16.5383	12.5261	17.8068	13.0993	11.9652	11.9883	11.6662	13.6557
445	20.3860	12.3057	14.6348	14.2693	11.8723	12.4437	12.0693	13.9973
472	12.3863	9.9879	10.6303	9.5323	12.0334	9.6483	8.3804	10.3712
506	11.3247	10.6029	9.2545	7.8863	6.5016	8.2557	8.4343	8.8942
507	8.4943	7.3854	8.2245	7.0777	6.0468	7.6670	6.4817	7.3396
511	6.9232	4.9421	3.5810	5.8903	6.4661	8.6915	7.7586	6.3218
512	6.9800	4.2761	3.5590	4.7750	4.9652	7.0637	6.8486	5.4953
1748	16.7430	14.1996	14.7929	16.1327	17.3874	13.6783	10.2897	14.7462
1749	22.1257	19.8175	20.5371	22.7007	25.1161	18.6240	15.4617	20.6261
1779	7.4340	7.6082	7.5513	6.6553	5.7375	7.1217	6.0141	6.8745

Tablo 5.5 44 Farklı Algılayıcı Ortalama Yöntemi MAPE Değerleri

Algılayıcı Numarası	Haziran MAPE	Temmuz MAPE	Ağustos MAPE	Eylül MAPE	Ekim MAPE	Kasım MAPE	Aralık MAPE	Algılayıcı Ortalama
30	5,5638	5,8775	6,2715	6,7673	8,7694	7,8196	6,6804	6,8213
31	5,4607	5,4500	6,2231	6,5305	7,6732	7,5116	5,5938	6,3489
37	4,9777	4,6450	5,2152	5,5667	5,9110	7,0407	6,6396	5,7137
63	14,2266	19,3546	15,3242	18,0103	21,8973	23,3123	21,1476	19,0389
64	10,1633	14,4754	8,9310	9,4657	10,4406	10,5807	9,3566	10,4876
73	10,0520	9,9839	9,9800	21,0293	17,9411	14,1990	14,5715	13,9652
74	7,9687	12,7421	15,5735	28,5953	17,3739	12,5717	12,1823	15,2867
75	8,2200	18,0462	21,8365	29,6633	17,3661	17,4020	15,8641	18,3426
76	22,8183	35,4150	28,8171	37,1587	19,5168	18,0570	18,4817	25,7520
119	12,5213	10,8339	9,9552	12,0103	8,4119	13,2724	9,7297	10,9621
120	28,9040	45,3996	27,7910	42,6667	24,1235	19,0650	19,0983	29,5783
121	29,3790	37,2889	26,4510	35,6537	25,4390	23,3127	23,2252	28,6785
122	20,6180	17,8104	19,0006	22,5990	18,4610	17,4550	18,3124	19,1794
125	18,3060	16,5586	13,8797	23,8527	22,0639	22,0400	19,3893	19,4414
126	17,4210	17,7396	16,4045	25,2570	17,1934	19,9393	25,9634	19,9883
128	6,6343	17,5875	8,0884	7,8347	8,2332	7,9320	10,8956	9,60081428
129	6,3177	7,6121	7,4771	8,0710	8,9987	7,1245	9,0856	7,8123
130	4,0213	3,8475	3,4881	3,8513	4,3155	4,6833	4,4428	4,0928
131	4,1147	4,0371	3,6026	3,8917	4,2655	5,4360	4,6548	4,2860
215	9,0913	8,6296	7,8339	7,6203	9,8903	7,4926	8,0118	8,3671
216	6,8260	10,1871	7,7471	7,7403	7,7426	7,3529	6,9690	7,795
217	11,4537	11,7954	12,1920	12,4577	10,2413	12,9986	14,6996	12,2626
219	18,0134	20,0300	24,3575	33,0526	25,3350	23,8330	22,5433	23,8806
308	11,0333	12,7985	7,6190	33,2760	18,8010	9,0234	7,9179	14,3527
309	11,5757	13,8979	9,4071	24,3313	15,3252	9,2110	8,6500	13,1997
310	16,1197	18,6611	10,8471	23,8217	13,4458	10,4547	11,3362	14,9551
315	28,7007	19,3061	21,0384	49,1610	28,0294	20,2533	24,3262	27,2593
320	12,3133	11,0139	10,5497	20,0690	13,6986	15,2546	24,5300	15,3470
421	23,6373	28,3325	20,9442	40,1373	22,7255	17,6707	17,6614	24,4441
422	19,6613	21,3704	16,8216	28,5240	19,7706	18,4390	16,5559	20,1632
423	19,6670	21,8050	18,1281	24,9760	22,2426	22,9353	19,7762	21,3614
424	23,0453	24,6943	20,3613	26,7000	18,2135	19,7660	17,0355	21,4022
433	10,0663	8,2068	8,4410	11,5910	11,0635	10,2497	11,8972	10,2165
443	38,3430	36,4146	38,1000	22,0896	23,9972	16,4321	22,3113	28,2411
444	41,4907	29,8743	32,3316	22,8700	22,4486	16,4969	21,3242	26,6909
445	61,5813	25,6929	23,1690	31,5970	22,9132	17,8070	20,7848	29,0778
472	16,5743	14,3796	13,0052	13,1620	16,9648	10,7027	10,6881	13,6395
506	27,0527	30,4232	18,3426	17,4427	10,8274	17,3320	21,5418	20,4232
507	18,1647	19,6075	12,9503	16,4397	10,0103	14,4723	13,5703	15,0307
511	15,5946	8,2307	5,2374	16,8903	13,8487	15,5411	19,8900	13,6046
512	13,1133	7,1400	5,1010	12,6413	11,7594	14,3793	16,7800	11,5591
1748	26,8430	22,4250	16,4439	29,2027	29,3968	14,3750	11,9697	21,5222
1749	44,9773	37,7504	22,9619	74,6240	75,0794	18,9097	18,9666	41,8956
1779	14,4270	28,4261	18,7048	15,5873	10,5075	13,0800	11,8890	16,0888
Aylık Ortalama	17,6603	18,0863	14,9305	21,9200	17,1062	14,3913	14,9304	

Tablo 5.6 44 Farklı Algılayıcı Ortalama Yöntemi MAE Değerleri

Algılayıcı Numarası	Haziran MAE	Temmuz MAE	Ağustos MAE	Eylül MAE	Ekim MAE	Kasım MAE	Aralık MAE	Algılayıcı Ortalama
30	4,7269	4,7850	5,6162	6,1764	6,9187	6,3084	5,9638	5,7850
31	4,6900	4,6000	5,6054	6,0209	6,4355	5,9508	4,9729	5,4679
37	3,4703	3,2382	3,4765	3,8050	4,3290	4,9050	4,4757	3,9571
63	6,1755	5,3357	5,6935	6,1963	6,4350	7,2677	6,6893	6,2561
64	5,2953	4,7761	4,4981	4,3553	4,4174	5,4771	4,3607	4,7400
73	6,0310	5,8139	5,9597	8,8247	8,2579	6,9860	6,8046	6,9539
74	5,0597	6,7111	8,0613	10,3337	7,4719	5,7420	5,9538	7,0476
75	5,0797	7,4588	8,1171	10,5047	7,6552	6,9943	6,4076	7,4596
76	8,9000	9,0611	8,4529	9,3690	5,4135	5,1560	5,5131	7,4093
119	7,4473	6,2282	5,6065	6,6983	5,3516	6,8200	5,6155	6,2524
120	12,3643	12,9793	10,9974	15,2890	9,1190	8,7380	8,4717	11,1369
121	12,7670	11,8075	10,7255	13,6883	9,3245	10,2943	10,0741	11,2401
122	10,9620	8,4836	9,2823	11,1967	8,6748	9,0277	9,4010	9,5754
125	11,7737	8,5579	8,9555	11,0563	10,6913	9,9166	9,2003	10,0216
126	11,3910	8,8972	9,3590	10,8473	9,2331	9,1054	10,4755	9,9012
128	4,7657	9,6404	4,4548	4,2137	4,5942	4,0930	5,4100	5,3102
129	4,5343	5,0150	4,9755	5,2697	6,1503	4,6931	5,7752	5,2018
130	3,0513	2,8236	2,6323	2,8870	3,2758	3,5580	3,2959	3,0748
131	3,1320	2,9264	2,7032	2,9320	3,2000	3,7780	3,4544	3,1608
215	5,9933	5,1768	5,3048	5,2377	5,7090	5,7011	5,5818	5,5292
216	5,2700	4,7679	5,3174	5,3437	5,0503	5,3418	5,0234	5,1592
217	7,2620	6,2800	7,6332	7,4953	5,9870	7,0048	8,0104	7,0961
219	7,9769	7,2467	9,9595	11,4616	9,5518	7,7417	9,0108	8,9927
308	5,9803	6,5244	5,3652	9,6440	9,6874	5,8079	5,0790	6,8697
309	6,7930	6,8157	6,9732	14,3423	9,8932	5,9997	5,8448	8,0945
310	9,8043	8,4082	7,7177	11,8747	8,3584	6,4780	6,7572	8,4855
315	13,1070	10,3536	10,4448	14,4943	9,8613	9,3000	8,5541	10,8735
320	8,0437	6,2954	6,5187	9,8080	8,5332	9,4000	11,9400	8,6484
421	8,7367	9,4736	7,1335	14,8667	9,4506	8,6475	6,9434	9,3217
422	9,0830	9,1668	6,7458	11,6000	8,6781	9,1597	7,8838	8,9024
423	9,7417	10,2339	8,3232	10,0933	9,0774	9,6863	8,6041	9,3942
424	11,2973	11,3200	8,9681	10,8050	7,2684	7,8800	7,0066	9,2207
433	6,7263	5,3904	5,6587	6,2410	6,1858	5,8472	6,2266	6,0394
443	16,5887	16,2775	19,2855	13,5425	12,6297	12,1145	11,5692	14,5725
444	16,2880	12,0929	17,1535	12,6571	11,0034	11,0676	10,5917	12,9791
445	19,0713	11,1339	13,4177	13,7497	10,7571	10,1153	9,9900	12,6050
472	11,7707	9,7000	9,8671	9,8933	12,8910	9,1707	7,8915	10,1691
506	9,8950	10,1832	8,5723	7,2770	4,8558	6,5843	7,2204	7,7982
507	6,9907	7,0871	7,3932	6,3513	4,2100	5,7417	5,2310	6,1435
511	5,9689	4,5871	3,4206	5,5977	5,4397	7,1581	7,0000	5,5960
512	6,6840	4,7575	3,7081	4,9920	4,8635	6,6763	6,6871	5,4812
1748	14,6387	12,0561	11,6132	15,2297	16,7700	11,3340	7,3979	12,7199
1749	18,5337	15,8075	14,8384	20,7263	22,2297	13,4657	9,1841	16,3979
6 1779	5,9400	7,2936	6,9310	6,0473	4,2457	5,6070	4,7338	5,8283
Aylık Ortalama	8,6318	7,8992	7,8053	9,2962	7,9576	7,4509	7,0972	

Tablo 5.7’de polinom regresyon ve ortalama yöntemi ile uzun vadeli hız tahmini sonucu elde edilen, tüm algılayıcıların tüm aylarda ortalama MAPE ve MAE değerleri verilmiştir. Ortalama yönteminin polinom regresyon yöntemine göre yaklaşık %3 daha doğru MAPE sonucu verdiği gözlemlenmektedir.

Tablo 5.7 Polinom Regresyon ve Ortalama Yöntemi Karşılaştırması

Model	MAPE	MAE
Polinom Regresyon	20,1602	9,0841
Ortalama Yöntemi	17,0036	8,0198

5.3 Derin Öğrenme Yöntemleri

Bu kısımda uzun vadeli trafik yoğunluk tahmini için derin öğrenme yöntemlerinden Evrişimli Sinir Ağı algoritması kullanılarak elde edilen sonuçlar incelenecektir. Evrişimli Sinir Ağı yöntemi uygulanırken, yöntemin değişken parametreleri değiştirilerek sonuca etkisi incelenecektir.

5.3.1 CNN Yöntemi Uzun Vadeli Hız Tahmini için Parametre Optimizasyonu

Bu kısımda derin öğrenme yöntemi CNN için değişken parametrelerin farklı seçilmesinin model başarısına etkisi ve elde edilen başarı sonuçlarına yer verilecektir.

44 farklı algılayıcı için Haziran, Temmuz, Ağustos, Eylül, Ekim, Kasım aylarındaki her bir 5 dakika hız değeri tahmin edilecektir. Her bir ayın tahmin edilmesi için öngörülecek aydan 3 ay öncesi ay hız verileri eğitim için, tahmin edilecek ay hız verisi test ve doğrulama veri seti için kullanılmıştır. 44 farklı algılayıcı ve her algılayıcı için 7 ay olacak şekilde toplamda 44x7 farklı eğitim, test ve doğrulama veri seti oluşturulmuştur. Aynı zamanda bu kısımda CNN yöntemi için değişken parametrelerden olan filtre sayısı, kernel boyutu, derin öğrenme katmanındaki düğüm sayısı, katman sayısı, aktivasyon fonksiyonu, optimizasyon algoritması ve öğrenme oranı, batch boyutu, epoch sayısı değiştirilerek tüm algılayıcıların tüm ay veri setlerinde parametrelerin başarıya etkisi incelenecektir.

Bölüm 3.2.2.3’te bahsedilen geriye gidilen her bir hafta günü hız verisinin kullanılması ile elde edilen veri seti, değişken parametrelerin modele etkisi incelenirken kullanılacaktır. Şekil 3.5’te kullanılan veri setinin örnek görünümü verilmiştir. En başarılı sonuç veren değişken parametreler, 15 dakika ileri ve geri hız bilgilerini; aynı dakikalar yan yana olacak şekilde ve haftalık dizilim korunacak şekilde oluşturulan 2 farklı veri seti için de uygulanarak modelin 44 farklı algılayıcıdaki genel başarısı incelenecektir.

5.3.1.1 CNN Yöntemi Öngörü Gücüne Filtre Sayısının Etkisi

CNN yönteminde girdi verisine evrişim aşamasında belirlenen sayıda filtre uygulanarak veriyi tanımlayan özellik haritası çıkarılmaktadır. Modelin başarısını arttıran en uygun filtre sayısı, ele alınan probleme göre değişiklik göstermektedir. Bu kısımda CNN için mevcut diğer değişken parametrelerden; kernel boyutu 2, katmandaki düğüm sayısı 10, katman sayısı 1, aktivasyon fonksiyonu RELU, optimizasyon algoritması adam, batch boyutu 128, epoch sayısı 15 olacak şekilde sabit tutularak, filtre sayısı 2, 4 veya 6 olmasının öngörü sonucuna etkisi incelenecektir.

Tablo 5.8'de 44 farklı algılayıcı için geriye gidilen 4 hafta öncesi haftalık hız verilerinin yan yana yerleştirilmesi ile oluşturulan veri seti üzerinde CNN modeli filtre sayısı 2 verilerek çalıştırılmış ve MAPE değerleri 44 farklı algılayıcı için verilmiştir. Tabloda aynı zamanda algılayıcı bazında ortalama MAPE değeri; Algılayıcı Ortalama sütununda ve ay bazlı ortalama MAPE değeri; Aylık Ortalama satırında verilmiştir. MAPE değerlerinin algılayıcı bazında değişiklik gösterdiği gözlemlenmektedir. Tablo 5.9'da aynı gözlemin MAE değerleri verilmiştir. CNN modeli filtre sayısı 2 verilerek çalıştırılmış ve MAE değerleri 44 farklı algılayıcı için verilmiştir. Tabloda aynı zamanda algılayıcı bazında ortalama MAE değeri; Algılayıcı Ortalama sütununda ve ay bazlı ortalama MAE değeri; Aylık Ortalama satırında verilmiştir. MAE değerlerinin algılayıcı bazında değişiklik gösterdiği gözlemlenmektedir.


Tablo 5.8 44 Farklı Algılayıcı Her Bir Hafta Günü Hız Verisi Kullanılarak 2 Filtre ile CNN Modeli Oluşturulması MAPE Değerleri

Algılayıcı Numarası	Haziran MAPE	Temmuz MAPE	Ağustos MAPE	Eylül MAPE	Ekim MAPE	Kasım MAPE	Aralık MAPE	Algılayıcı Ortalama
30	5,5763	5,7073	6,4427	6,9015	9,085	8,1481	7,289	7,0214
31	5,4515	5,2355	6,4037	6,6687	7,9314	7,6977	5,7228	6,4444
37	4,9905	4,6362	5,266	5,5524	5,9955	7,0484	6,5677	5,7223
63	14,2029	19,2158	15,4519	18,0798	21,7765	23,3725	21,3455	19,0635
64	10,0969	14,9437	8,7824	9,2908	10,4359	10,9265	9,5736	10,5785
73	9,996	9,962	10,0318	20,8924	17,9726	13,6877	14,3239	13,8380
74	7,9105	12,8266	15,075	28,4168	19,6512	12,507	12,0561	15,4918
75	8,202	18,1564	20,7632	29,6359	18,9603	16,349	15,4671	18,2191
76	23,1466	36,6225	28,4954	37,1208	18,712	18,3609	18,1541	25,8017
119	12,4846	10,8541	10,0099	11,9845	8,3064	12,9006	9,7621	10,9003
120	28,2942	47,7617	28,4681	43,8693	23,5489	18,9339	19,6438	30,0742
121	29,0965	38,8703	27,265	36,5761	25,1642	23,5724	23,5594	29,1577
122	20,6387	17,9318	19,3741	22,6823	18,3243	17,2977	18,6457	19,2706
125	18,9507	16,9666	13,8792	23,9731	21,795	21,0808	19,7279	19,4819
126	17,5817	17,9802	16,4353	25,1981	16,9062	19,5495	26,1144	19,9664
128	6,7333	17,6845	8,398	8,3657	10,0487	7,7918	10,8804	9,9860
129	6,3656	7,6779	7,5778	8,0156	9,3154	7,1935	9,0028	7,8783
130	4,0308	3,9018	3,5849	3,8558	4,3617	4,6847	4,4351	4,1221
131	4,1511	4,1518	3,7142	3,8927	4,3329	5,4238	4,674	4,3343
215	9,1435	8,5539	8,0682	7,5666	10,0117	7,4316	7,9997	8,3964
216	6,8645	10,1129	7,762	7,6594	7,796	7,3349	6,9176	7,7781
217	11,5205	11,9749	12,3064	12,222	10,432	12,9061	14,8465	12,3154
219	17,9332	19,6323	24,0404	32,465	24,9436	22,8661	22,4221	23,4718
308	11,0258	12,8365	7,6142	33,2815	19,9518	9,0009	7,8611	14,5102
309	11,5499	14,1424	9,4581	23,6799	18,2751	9,7268	9,6959	13,7897
310	16,1483	18,5251	10,9724	23,0647	13,8738	10,7881	11,4653	14,9768
315	28,4708	19,4967	20,3598	49,4305	25,6401	21,434	23,0052	26,8338
320	12,034	11,2981	10,6863	20,1145	13,8778	15,1342	23,4496	15,2277
421	23,747	28,9608	21,615	40,8745	24,1699	17,8402	18,4163	25,0891
422	19,7185	21,7279	17,0499	29,4033	19,8637	18,2396	17,389	20,4845
423	19,6718	22,0341	18,3947	25,1597	22,1903	22,639	19,6321	21,3888
424	22,6033	25,8804	20,6697	27,8444	18,0011	19,5013	17,0133	21,6447
433	10,0581	8,1913	8,5206	11,5756	11,2516	10,3174	11,6434	10,2225
443	36,9627	34,7561	38,5902	21,7317	22,8866	16,1349	21,3573	27,4885
444	39,2412	27,4651	32,9227	22,6705	21,3762	16,417	20,594	25,8123
445	55,6704	21,6393	23,0575	30,1362	22,3788	17,7542	20,58	27,3166
472	16,1046	14,1914	13,1887	13,0644	16,7067	10,6249	10,5274	13,4868
506	26,9226	29,7127	19,3841	17,441	11,3633	17,333	21,1872	20,4777
507	18,2497	18,9887	13,8232	16,1552	10,555	14,5401	13,4143	15,1037
511	15,5683	8,2355	5,5155	16,5633	13,8579	15,5171	19,3774	13,5192
512	13,2516	7,2185	5,0337	12,0448	12,128	14,3868	15,6941	11,3939
1748	26,1825	22,0421	16,9693	28,9736	26,2384	12,6102	12,0347	20,7215
1749	44,033	37,3312	23,9975	74,5856	67,9886	18,0018	20,2112	40,8784
1779	14,7718	27,9134	19,2331	15,4609	10,8079	13,1613	11,8842	16,1760
Aylık Ortalama	17,3942	18,0442	15,1057	21,9122	17,0270	14,276545	14,8991	

Tablo 5.9 44 Farklı Algılayıcı Her Bir Hafta Günü Hız Verisi Kullanılarak 2 Filtre ile CNN Modeli Oluşturulması MAE Değerleri


Algılayıcı Numarası	Haziran MAE	Temmuz MAE	Ağustos MAE	Eylül MAE	Ekim MAE	Kasım MAE	Aralık MAE	Algılayıcı Ortalama
30	4,7335	4,6551	5,8231	6,3349	7,1632	6,6738	6,5658	5,9927
31	4,6813	4,4341	5,8217	6,1825	6,6319	6,1627	5,1181	5,5760
37	3,4929	3,2393	3,5305	3,7927	4,3978	4,9057	4,4318	3,9701
63	6,1956	5,3088	5,8477	6,1857	6,4173	7,2745	7,212	6,3488
64	5,2594	4,9374	4,4004	4,2659	4,5114	5,7207	4,5266	4,8031
73	5,995	5,7607	5,9995	8,7971	8,458	6,7874	6,8046	6,9431
74	5,0277	6,7505	7,8411	10,4672	9,3153	5,8763	5,9417	7,3171
75	5,0975	7,5108	7,7017	10,9249	8,9541	6,5675	6,3531	7,5870
76	9,2435	9,1286	8,2061	9,3858	5,3549	5,7119	5,7248	7,5365
119	7,5814	6,2694	5,6716	6,6669	5,2946	6,7484	5,7495	6,2831
120	12,5535	13,5913	11,1622	15,4149	9,1864	8,7621	8,9504	11,3744
121	13,0876	12,1061	10,9146	13,7973	9,4882	10,6288	10,4736	11,4994
122	11,1004	8,4805	9,3427	11,2309	8,892	9,3645	10,1655	9,7966
125	12,7166	8,65	8,7805	11,0342	10,8225	9,9021	9,6677	10,2248
126	11,6585	8,7819	9,1912	10,7739	9,3391	9,1811	11,4585	10,0548
128	4,8553	9,695	4,7593	4,6691	5,8599	4,0512	5,4435	5,6190
129	4,5866	5,0515	5,0808	5,2601	6,4342	4,7201	5,731	5,2663
130	3,0642	2,8618	2,7149	2,8917	3,3163	3,5629	3,29	3,1002
131	3,1692	3,0057	2,7996	2,9339	3,2594	3,7765	3,4676	3,2017
215	6,054	5,1102	5,51	5,2353	5,8862	5,697	5,6427	5,5907
216	5,3132	4,6982	5,3492	5,2958	5,147	5,3892	5,0267	5,1741
217	7,4059	6,3887	7,8209	7,376	6,2355	7,0029	8,347	7,2252
219	8,1811	7,1026	10,0797	11,2729	9,5328	7,5386	9,2587	8,9952
308	5,963	6,5326	5,3692	9,6326	10,4688	5,7952	5,0668	6,9754
309	6,6857	6,8776	7,0332	13,9946	12,2703	6,5944	6,9394	8,6278
310	9,8945	8,3516	7,856	11,5543	8,8951	6,9067	7,1894	8,6639
315	13,7141	10,4588	10,0129	14,4063	9,9918	10,3853	8,8696	11,1198
320	7,8568	6,3897	6,7532	9,8424	8,7634	9,5301	11,8753	8,7158
421	8,9519	9,6532	7,4156	15,2206	11,0359	8,7667	7,1999	9,7491
422	9,1004	9,2168	6,6717	11,872	8,8616	9,2157	8,6355	9,0819
423	9,9455	10,3097	8,3463	10,1468	9,5658	9,782	8,7304	9,5466
424	11,1117	11,5239	9,1451	11,0357	7,4721	8,1089	7,1205	9,3597
433	6,7177	5,365	5,6976	6,2232	6,3907	5,9881	6,135	6,0739
443	15,9985	16,3119	20,6412	14,1195	12,0963	11,7123	11,1258	14,5722
444	15,4546	11,7219	18,1405	12,4507	10,3766	10,783	10,3531	12,7543
445	17,6239	10,0211	13,3655	13,9075	10,3188	9,9955	10,026	12,1797
472	11,5955	9,6401	10,1708	9,8587	12,7139	9,1074	7,7523	10,1198
506	9,9511	10,0186	9,414	7,3596	5,2759	6,5388	7,203	7,9658
507	7,2062	6,8215	7,9169	6,3113	4,5844	5,7391	5,2385	6,2597
511	6,0279	4,5454	3,628	5,5902	5,4254	7,3061	6,6938	5,6024
512	6,6461	4,8069	3,6861	4,7738	5,2608	6,9524	6,2632	5,4841
1748	14,5758	12,0391	12,2757	15,0844	15,4864	9,6791	7,7553	12,4136
1749	18,7185	16,2539	16,1004	21,019	21,4833	12,541	10,8668	16,7118
1779	6,2616	7,1131	7,5425	6,1498	4,3714	5,6099	4,7595	5,9725
Aylık Ortalama	8,6603	7,8975	7,9893	9,3350	8,2046	7,4782	7,2988	

Şekil 5.3'te 44 farklı algılayıcı için CNN modeli filtre sayısı 2 olarak seçildiğinde algılayıcı bazında ayların ortalama MAPE ve MAE değerlerini göstermektedir. Elde edilen MAPE ve MAE değerleri arasında doğrusal bir orantı olduğu gözlemlenmektedir.




Şekil 5.3 CNN Modeli Filtre Sayısı 2 iken Algılayıcı Bazında Ortalama MAPE ve MAE Değerleri

Şekil 5.4'te CNN modeli filtre sayısı 2 olarak seçildiğinde ay bazında ortalama MAPE ve MAE değerlerini göstermektedir. Elde edilen MAPE ve MAE değerleri arasında doğrusal bir orantı olduğu gözlemlenmektedir. Eylül ayında diğer aylara göre daha az doğru sonuç elde edildiği gözlemlenmiştir.



Şekil 5.4 CNN Modeli Filtre Sayısı 2 iken Ay Bazında Ortalama MAPE ve MAE Değerleri

Şekil 5.5'te CNN modelinde filtre 2 seçildiğinde elde edilen MAPE ve MAE hata metriklerinin Çok İyi, İyi, Kötü etiketlerine göre dağılımı verilmiştir.



Şekil 5.5 CNN Modeli Filtre Sayısı 2 iken Algılayıcı Bazında Ortalama MAPE ve MAE Değer Durumu

Tablo 5.10'da filtre sayısı 4 olduğunda CNN modeli öngörü sonucu MAPE değeri 44 farklı algılayıcı için verilmiştir. Tablo 5.11'de ise MAE değerleri ve algılayıcı bazında ortalama MAE değeri etiketleri ile verilmiştir.


Tablo 5.10 44 Farklı Algılayıcı Her Bir Hafta Günü Hız Verisi Kullanılarak 4 Filtre ile CNN Modeli Oluşturulması MAPE Değerleri

Algılayıcı Numarası	Haziran MAPE	Temmuz MAPE	Ağustos MAPE	Eylül MAPE	Ekim MAPE	Kasım MAPE	Aralık MAPE	Algılayıcı Ortalama
30.0	5.5864	5.7382	6.4753	6.9328	9.2012	8.0599	7.5541	7.0782
31.0	5.475	5.2622	6.4398	6.6943	8.0098	7.6421	5.8751	6.4854
37.0	5.0188	4.6629	5.2865	5.6632	6.0478	7.0839	6.681	5.7777
63.0	14.2248	19.2281	15.3636	17.9858	21.6825	23.3945	21.2748	19.0220
64.0	10.3726	14.5957	8.8473	9.4055	10.5357	10.752	9.5961	10.5864
73.0	10.0119	9.9099	9.9829	21.1988	17.9434	13.7101	14.2942	13.8644
74.0	7.9977	12.7396	14.8236	28.3073	19.5716	12.4433	12.0792	15.4231
75.0	8.3885	18.0753	20.3181	29.4126	19.1142	16.4413	15.4591	18.1727
76.0	23.0809	35.522	28.128	37.116	18.6704	18.1288	18.1038	25.5357
119.0	12.4846	10.9249	10.0074	12.1893	8.2729	13.1585	9.7453	10.9689
120.0	27.8121	44.5752	28.2621	38.4659	22.5281	19.0858	19.8223	28.6502
121.0	29.0308	38.659	27.0372	31.3838	24.6634	23.5404	23.2933	28.2296
122.0	20.6807	18.0391	19.3398	22.5491	18.1221	17.1803	18.3608	19.1817
125.0	18.9386	16.9788	13.8765	23.9625	21.7035	21.2279	19.5497	19.4625
126.0	17.6137	17.9982	16.3876	25.2149	16.8719	19.5411	25.926	19.9362
128.0	6.8549	18.4774	8.4076	8.3624	10.1572	7.818	10.8918	10.1384
129.0	6.4218	7.6945	7.5918	8.0493	9.3773	7.2391	9.1059	7.9256
130.0	4.1179	3.9413	3.5734	3.8868	4.4161	4.7341	4.488	4.1653
131.0	4.2253	4.2035	3.7134	3.9346	4.3202	5.476	4.6931	4.3665
215.0	9.062	8.5023	7.9205	7.5179	9.9874	7.3983	7.9937	8.3403
216.0	6.828	10.2013	7.831	7.6687	7.7328	7.4031	6.975	7.8057
217.0	11.5348	11.9387	12.3127	12.4585	10.3823	13.0094	14.9698	12.3723
219.0	17.8587	19.6312	24.0261	32.3975	24.8042	22.944	22.421	23.4403
308.0	11.0541	13.0049	7.6611	33.3149	19.9734	9.0288	7.8052	14.5489
309.0	11.5337	14.2147	9.4935	23.7942	18.0269	9.7363	10.0393	13.8340
310.0	16.1471	18.6122	10.9427	23.663	13.8812	10.9082	11.7397	15.1277
315.0	28.5868	19.5707	20.2986	50.6333	25.6135	21.5905	23.0443	27.0482
320.0	12.2344	11.3804	10.6044	20.3777	13.9861	15.1152	23.5699	15.3240
421.0	23.7255	28.547	21.5902	39.1083	24.0124	17.7781	18.6499	24.7730
422.0	19.6501	21.6614	16.842	29.2561	19.595	17.9105	17.553	20.3525
423.0	19.8047	22.1015	18.3606	25.2803	22.1424	22.3564	19.6541	21.3857
424.0	22.8164	25.8617	20.3949	29.1873	17.5108	19.2982	16.8889	21.7083
433.0	10.1439	8.2864	8.5552	11.5441	11.3135	10.2127	11.7323	10.2554
443.0	37.5691	34.5646	38.6457	21.7023	23.025	15.8893	21.0136	27.4870
444.0	40.1124	27.1159	32.9237	23.3584	21.1666	16.1511	20.5629	25.9130
445.0	55.4998	21.6881	23.1063	29.9521	22.0981	17.6858	20.5808	27.2301
472.0	16.2464	14.2492	13.1937	13.0241	16.8411	10.7103	10.5346	13.5427
506.0	27.0559	29.9429	19.4792	18.0952	11.704	17.4215	21.3448	20.7205
507.0	18.1806	19.1514	13.7683	16.5858	10.5393	14.5416	13.7031	15.2100
511.0	15.5845	8.2329	5.5739	16.3503	14.087	15.3737	19.0915	13.4705
512.0	13.2537	7.2606	5.0986	11.9878	12.0967	14.6041	15.3354	11.3767
1748.0	26.4658	22.0682	17.0713	28.7894	26.5018	12.4962	12.0413	20.7762
1749.0	44.0501	37.5064	24.0933	74.8258	67.7598	18.3748	20.3417	40.9931
1779.0	14.7225	27.9528	19.3908	15.4621	10.8495	13.1745	12.0341	16.2266
Aylık Ortalama	17.4558	17.9653	15.0690	21.7511	16.9736	14.2674	14.9184	

Tablo 5.11 44 Farklı Algılayıcı Her Bir Hafta Günü Hız Verisi Kullanılarak 4 Filtre ile CNN Modeli Oluşturulması MAE Değerleri


Algılayıcı Numarası	Haziran MAE	Temmuz MAE	Ağustos MAE	Eylül MAE	Ekim MAE	Kasım MAE	Aralık MAE	Algılayıcı Ortalama
30.0	4.745	4.6809	5.8524	6.3581	7.255	6.599	6.8249	6.0450
31.0	4.7024	4.4588	5.857	6.1994	6.6936	6.127	5.2649	5.6147
37.0	3.5147	3.2541	3.5447	3.8675	4.4434	4.9168	4.5062	4.0067
63.0	6.2138	5.294	5.8123	6.1763	6.424	7.2802	7.271	6.3530
64.0	5.4532	4.7924	4.4545	4.3151	4.5478	5.638	4.5679	4.8241
73.0	5.9963	5.7329	5.9604	8.8482	8.4616	6.8102	6.7796	6.9413
74.0	5.1034	6.702	7.7486	10.4675	9.279	5.7556	5.9542	7.2871
75.0	5.2344	7.4624	7.5865	10.8619	9.0614	6.5613	6.3605	7.5897
76.0	9.2976	9.0534	8.2285	9.4207	5.3612	5.6315	5.737	7.5328
119.0	7.5834	6.279	5.6846	6.7695	5.2877	6.8114	5.7519	6.3096
120.0	12.4269	13.4177	11.1993	14.7612	8.9316	8.8351	9.0467	11.2312
121.0	13.0042	12.1223	10.9367	13.2653	9.3282	10.7021	10.5515	11.4157
122.0	11.1379	8.4894	9.3272	11.195	8.881	9.3796	10.0721	9.7831
125.0	12.7132	8.6624	8.7873	11.0413	10.8365	9.818	9.6875	10.2208
126.0	11.6635	8.8057	9.1804	10.7906	9.3508	9.2033	11.3935	10.0554
128.0	4.9433	10.1464	4.7837	4.6621	5.9335	4.0564	5.4582	5.7119
129.0	4.6298	5.0558	5.0919	5.2705	6.4831	4.741	5.7946	5.2952
130.0	3.1322	2.8872	2.7063	2.914	3.3619	3.5902	3.3318	3.1319
131.0	3.227	3.0378	2.7976	2.9648	3.2539	3.8038	3.4857	3.2243
215.0	5.9904	5.1121	5.4209	5.231	5.9701	5.6704	5.6352	5.5757
216.0	5.2888	4.7852	5.3839	5.325	5.1147	5.4144	5.0685	5.1972
217.0	7.4456	6.3172	7.8203	7.5148	6.2385	7.0235	8.395	7.2506
219.0	8.1381	7.1029	10.0206	11.2691	9.5426	7.539	9.2316	8.9777
308.0	5.9896	6.6183	5.3902	9.609	10.6954	5.8239	5.0644	7.0272
309.0	6.6721	6.9274	7.0359	14.0855	12.1793	6.539	7.2681	8.6724
310.0	9.8954	8.4079	7.7945	11.7771	8.9456	7.0223	7.4601	8.7575
315.0	13.778	10.5506	9.9806	14.6915	10.0735	10.5956	8.8341	11.2148
320.0	8.0081	6.4127	6.6422	9.9214	8.8559	9.4613	11.8687	8.7386
421.0	8.9569	9.6072	7.4162	15.0712	11.02	8.746	7.2503	9.7239
422.0	9.1473	9.1945	6.6538	11.8514	8.9514	9.1475	8.6292	9.0821
423.0	10.0172	10.3409	8.3456	10.2065	9.5987	9.7498	8.7449	9.5719
424.0	11.2111	11.5318	9.1086	11.511	7.272	8.0758	7.0946	9.4007
433.0	6.8095	5.445	5.7132	6.2257	6.4734	5.9208	6.1814	6.1098
443.0	16.2683	16.2341	20.5856	14.1604	12.2163	11.5071	10.9302	14.5574
444.0	15.8212	11.618	18.1452	13.3668	10.2698	10.5729	10.2973	12.8701
445.0	17.5567	10.0719	13.4044	13.8932	10.2919	9.9888	10.0392	12.1780
472.0	11.6878	9.6765	10.1464	9.8313	12.8365	9.1636	7.7648	10.1581
506.0	9.987	10.0645	9.4802	7.7447	5.5833	6.5357	7.2422	8.0910
507.0	7.2096	6.8559	7.8925	6.4777	4.6173	5.7069	5.4613	6.3173
511.0	6.0156	4.5416	3.6588	5.6156	5.5417	7.2683	6.6124	5.6077
512.0	6.6502	4.8331	3.731	4.7709	5.3223	6.9536	6.0398	5.4715
1748.0	14.6972	12.1125	12.3553	15.0295	15.6217	9.5568	7.7766	12.4499
1749.0	18.705	16.3008	16.1336	21.2081	21.5105	12.8899	10.8137	16.7945
1779.0	6.2565	7.0987	7.5986	6.1603	4.4744	5.6062	4.8354	6.0043
Aylık Ortalama	8.7028	7.9112	7.9863	9.3794	8.2361	7.4713	7.3267	8.1448

Şekil 5.6'da filtre sayısı 4 olarak verildiğinde algılayıcı bazında ortalama MAPE ve MAE değerleri grafikte verilmiştir. MAE ve MAPE değerlerinin algılayıcı bazında orantılı olduğu gözlemlenmektedir.




Şekil 5.6 CNN Modeli Filtre Sayısı 4 iken Algılayıcı Bazında Ortalama MAPE ve MAE Değerleri

Şekil 5.7'de CNN model filtre sayısı 4 olduğunda aylık ortalama MAPE ve MAE değerleri verilmiştir. Ay bazında elde edilen MAPE ve MAE değerlerinin algılayıcı bazında ortalama değerlere göre fazla olduğu gözlemlenmektedir. Bunun sebebi MAPE ve MAE değeri yüksek çıkan algılayıcıların da aylık ortalama hesabında kullanılmış olmasıdır.



Şekil 5.7 CNN Modeli Filtre Sayısı 4 iken Ay Bazında Ortalama MAPE ve MAE Değerleri

Şekil 5.8’de CNN modeli filtre sayısı 4 olduğunda algılayıcı bazında elde edilen MAPE ve MAE değerleri etiket yüzdeleri grafikte verilmiştir.



Şekil 5.8 CNN Modeli Filtre Sayısı 4 iken Algılayıcı Bazında Ortalama MAPE ve MAE Değer Durumu

Tablo 5.12’de 44 farklı algılayıcı için geriye gidilen 4 hafta öncesi haftalık hız verilerinin yan yana yerleştirilmesi ile oluşturulan veri seti üzerinde CNN modeli filtre sayısı 6 verilerek çalıştırılmış ve MAPE değerleri 44 farklı algılayıcı için verilmiştir. Tabloda aynı zamanda algılayıcı bazında ortalama MAPE değeri; Algılayıcı Ortalama sütununda ve ay bazlı ortalama MAPE değeri; Aylık Ortalama satırında verilmiştir. MAPE değerlerinin algılayıcı bazında değişiklik gösterdiği gözlemlenmektedir.

Tablo 5.12 44 Farklı Algılayıcı Her Bir Hafta Günü Hız Verisi Kullanılarak 6 Filtre ile CNN Modeli Oluşturulması MAPE Değerleri


Algılayıcı Numarası	Haziran MAPE	Temmuz MAPE	Ağustos MAPE	Eylül MAPE	Ekim MAPE	Kasım MAPE	Aralık MAPE	Algılayıcı Ortalama
30	5,5533	5,8381	6,3948	6,8843	8,8213	8,1354	7,0993	6,9609
31	5,429	5,3091	6,347	6,6594	7,7993	7,6743	5,7976	6,4308
37	4,9718	4,6005	5,2803	5,5271	5,9488	7,0626	6,4734	5,6949
63	14,1479	19,201	15,4629	18,0329	21,6437	23,2052	21,4311	19,0178
64	9,9545	14,8843	8,7684	9,2705	10,4236	10,9436	9,4599	10,5292
73	9,9133	9,9058	10,0077	20,7898	17,8535	13,7291	14,3053	13,7863
74	7,8587	12,7611	14,9291	28,6914	19,0581	12,4524	12,0301	15,3972
75	8,1688	18,0204	20,4044	29,942	18,4306	16,3806	15,3615	18,1011
76	23,0769	34,8257	27,3843	35,4601	18,77	18,3291	18,1831	25,1470
119	12,4207	10,7412	10,0616	12,0824	8,2947	12,7856	9,7708	10,8795
120	27,7922	44,8353	27,8238	38,7051	24,1589	19,2972	19,6703	28,8975
121	28,4084	37,7468	27,2868	33,343	25,9028	23,4208	23,5902	28,5284
122	20,6374	17,8183	19,3625	22,2953	18,059	17,108	18,5346	19,1164
125	18,9731	16,8107	13,8755	23,9598	21,8016	21,1524	19,5917	19,4521
126	17,7138	17,9744	16,3689	25,2683	16,9325	19,8948	25,8552	20,0011
128	6,6088	16,9407	8,4375	8,3681	9,8605	7,7499	10,8755	9,8344
129	6,2919	7,7122	7,5421	8,0409	9,2168	7,1466	8,9113	7,8374
130	3,9544	3,8552	3,5696	3,8737	53,726	4,7915	4,5365	11,1867
131	4,0517	4,1065	3,7088	3,9147	4,3774	5,5113	4,6983	4,3383
215	9,1522	8,4643	7,8175	7,5044	9,9781	7,4103	8,0018	8,3326
216	6,8524	10,094	7,6933	7,5879	7,762	7,3518	6,9025	7,7491
217	11,4353	11,9873	12,423	12,152	10,4305	13,032	15,0285	12,3555
219	17,8498	19,6441	24,0537	31,8052	24,7433	22,6238	22,3792	23,2998
308	11,0628	12,91	7,6524	33,3312	19,4706	9,0269	7,8261	14,4685
309	11,6416	14,0038	9,6936	23,7595	19,1696	9,6223	9,8113	13,9573
310	16,1779	18,486	11,2989	23,08	13,5292	11,1814	11,5524	15,0436
315	28,7727	19,6421	20,6973	48,6827	25,5953	21,7346	22,6584	26,8261
320	11,9648	11,3933	10,7132	19,7095	14,2233	15,142	23,518	15,2377
421	23,2772	28,5212	21,3339	40,2714	23,8195	17,6886	18,1652	24,7252
422	19,6432	21,3344	16,5802	29,0731	19,5913	17,819	17,149	20,1700
423	19,7521	22,0736	18,2757	25,3458	22,0141	22,4488	19,6508	21,3658
424	22,8135	25,8565	20,3706	27,46	17,6141	18,8431	16,6693	21,3753
433	9,9863	8,0921	8,504	11,6012	11,1781	10,2418	11,6747	10,1825
443	36,6887	34,5683	38,5765	21,1129	22,8749	16,1159	21,2595	27,3138
444	38,8404	27,1425	32,8982	22,6911	21,303	16,3947	20,5778	25,6925
445	55,7491	21,7072	23,0455	30,136	22,0132	17,7023	20,5997	27,2790
472	16,0094	14,1348	13,195	13,0676	16,7101	10,4039	10,3706	13,4130
506	26,8309	29,8051	19,3659	17,5116	11,3768	17,4156	21,2477	20,5076
507	17,9574	19,471	14,3819	16,0935	10,3724	14,5737	13,9995	15,2641
511	14,9538	8,2556	5,5645	16,7045	14,1644	15,2042	18,3025	13,3070
512	13,0876	7,1594	5,1031	11,8348	12,0267	14,3887	16,0365	11,3766
1748	26,0321	21,9259	16,9996	28,8293	26,0329	12,5194	12,0805	20,6313
1749	43,609	36,9806	24,1655	73,4272	67,9921	19,3087	20,0956	40,7969
1779	14,6667	28,4272	19,7893	15,4231	10,7638	13,1618	12,229	16,3515
Aylık Ortalama	17,2893	17,8629	15,0729	21,5750	18,0870	14,2755	14,8627	17,0036

Tablo 5.13'te aynı gözlemin MAE değerleri verilmiştir. CNN modeli filtre sayısı 6 verilerek çalıştırılmış ve MAE değerleri 44 farklı algılayıcı için verilmiştir. Tabloda aynı zamanda algılayıcı bazında ortalama MAE değeri; Algılayıcı Ortalama sütununda ve ay bazlı ortalama MAE değeri; Aylık Ortalama satırında verilmiştir. MAE değerlerinin algılayıcı bazında değişiklik gösterdiği gözlemlenmektedir.

Tablo 5.13 44 Farklı Algılayıcı Her Bir Hafta Günü Hız Verisi Kullanılarak 6 Filtre ile CNN Modeli Oluşturulması MAE Değerleri


Algılayıcı Numarası	Haziran MAE	Temmuz MAE	Ağustos MAE	Eylül MAE	Ekim MAE	Kasım MAE	Aralık MAE	Algılayıcı Ortalama
30	4.7217	4.7583	5.7644	6.2986	6.9705	6.67	6.3818	5.9379
31	4.67	4.5038	5.7576	6.1575	6.5465	6.1393	5.1847	5.5656
37	3.4753	3.2175	3.5428	3.7766	4.3631	4.8935	4.3822	3.9501
63	6.1393	5.2779	5.8421	6.1864	6.4088	7.2978	7.3523	6.3578
64	5.1732	4.9119	4.3976	4.2585	4.5171	5.7287	4.4842	4.7815
73	5.9426	5.7181	5.9751	8.8333	8.3876	6.7803	6.7974	6.9191
74	4.9929	6.7212	7.7759	10.6765	8.9196	5.7935	5.9275	7.2581
75	5.0741	7.4396	7.5872	11.1433	8.5929	6.5802	6.3484	7.5379
76	9.4117	9.0599	8.2168	9.2283	5.3743	5.7399	5.7988	7.5471
119	7.5246	6.1875	5.7555	6.7235	5.2901	6.7055	5.7567	6.2776
120	12.3034	13.607	12.3413	14.7541	9.1915	8.7911	8.9266	11.4164
121	12.7741	12.1786	11.2626	13.4628	9.551	10.7866	10.8568	11.5532
122	11.1762	8.4093	9.3806	11.119	8.9539	9.3383	10.3849	9.8231
125	12.8932	8.6039	8.7976	11.0444	10.7588	9.8547	9.8292	10.2545
126	11.8004	8.7373	9.1662	10.8199	9.4001	9.3527	11.5402	10.1166
128	4.7628	9.2792	4.7939	4.6674	5.7398	4.0229	5.4616	5.5325
129	4.5254	5.0854	5.0505	5.2868	6.3618	4.6748	5.7024	5.2410
130	3.0005	2.8325	2.701	2.9071	41.2413	3.6254	3.3648	8.5246
131	3.0889	2.9778	2.7946	2.9524	3.3018	3.824	3.4951	3.2049
215	6.0588	5.0383	5.375	5.1739	5.9081	5.6908	5.6704	5.5593
216	5.306	4.7115	5.3136	5.2209	5.1496	5.4041	5.0376	5.1633
217	7.3576	6.3522	7.9978	7.3648	6.2692	7.2919	8.6898	7.3318
219	8.0978	7.1118	9.9956	11.1577	9.5156	7.5906	9.2089	8.9539
308	5.9835	6.5956	5.3812	9.7382	10.2694	5.8242	5.0703	6.9803
309	6.7664	6.8817	7.2543	14.2193	12.9808	6.4908	7.048	8.8059
310	9.9153	8.3069	8.1754	11.5588	8.625	7.2616	7.2628	8.7294
315	13.895	10.7145	10.1269	14.2618	9.9914	10.7617	8.6428	11.1991
320	7.8015	6.4232	6.7664	9.7812	9.0738	9.5496	11.8323	8.7468
421	8.8378	9.6206	7.3765	15.2477	10.6153	8.7002	7.1137	9.6445
422	9.1601	9.0881	6.6439	11.8893	8.8001	9.1341	8.4536	9.0241
423	9.9186	10.3248	8.3287	10.2121	9.4413	9.7901	8.832	9.5496
424	11.2303	11.6224	9.0788	10.9226	7.2069	8.0446	7.0367	9.3060
433	6.657	5.2886	5.697	6.2765	6.3348	5.9318	6.1592	6.0492
443	15.8908	16.2566	20.5971	13.3932	12.012	11.7253	11.0925	14.4239
444	15.2949	11.6191	18.0995	12.5458	10.3846	10.8023	10.3251	12.7244
445	17.7386	10.1034	13.1847	13.7097	10.2757	9.8344	10.0358	12.1260
472	11.5258	9.6095	10.1494	9.8664	12.719	8.8879	7.6419	10.0571
506	9.9132	10.0469	9.4178	7.4022	5.2891	6.5478	7.2446	7.9802
507	7.178	6.9846	8.2977	6.2704	4.4445	5.7525	5.7361	6.3805
511	5.9107	4.611	3.6038	5.7203	5.5537	7.4376	6.9049	5.6774
512	6.5543	4.7599	3.725	4.7011	5.2046	7.11	6.5243	5.5113
1748	14.491	11.9969	12.266	15.0237	15.4074	9.5903	7.8156	12.3701
1749	18.6755	16.2076	16.4844	21.8157	21.5062	14.0436	10.7617	17.0706
1779	6.1283	7.2912	7.9568	6.0965	4.3575	5.6363	4.9854	6.0645
Aylık Ortalama	8.6303	7.8880	8.0499	9.3151	9.0274	7.5325	7.3432	8.2552

Şekil 5.9’da CNN modeli filtre sayısı 6 ile çalıştırıldığında elde edilen algılayıcı bazında ortalama MAPE ve MAE değerleri verilmiştir. MAPE ve MAE değerleri arasında algılayıcı bazında orantı olduğu gözlemlenmektedir.




Şekil 5.9 CNN Modeli Filtre Sayısı 6 iken Algılayıcı Bazında Ortalama MAPE ve MAE Değerleri

Şekil 5.10'da CNN modeli filtre sayısı 6 ile çalıştırıldığında tüm algılayıcıları içeren aylara göre ortalama MAPE ve MAE değerleri verilmiştir.



Şekil 5.10 CNN Modeli Filtre Sayısı 6 iken Ay Bazında Ortalama MAPE ve MAE Değerleri

Şekil 5.11’de CNN modeli filtre sayısı 6 ile çalıştırıldığında algılayıcı bazında tüm ayların MAPE ve MAE değerlerinin sahip olduğu etiketlere göre yüzde oranı grafikte verilmiştir.



Şekil 5.11 CNN Modeli Filtre Sayısı 6 iken Algılayıcı Bazında Ortalama MAPE ve MAE Değer Durumu

CNN modeli filtre sayısı değiştirilerek algılayıcı ve ay bazında hata oranları MAPE ve MAE metrikleri ile hesaplanmıştır. Farklı filtre sayısı ile elde edilen tüm aylardaki ve algılayıcılardaki sonuçların ortalaması alınarak modelin genel başarısı hesaplanmıştır. CNN modellerinin filtre sayısı farklılığı ile elde edilen başarısı ve polinom regresyon tüm algılayıcılarda ve aylardaki ortalama başarısı karşılaştırılmış ve sonuçlar Tablo 5.14'te verilmiştir. CNN modeli 4 filtre kullanarak en az MAPE değeri edilmiştir. Bunu sırasıyla 2 filtre, 6 filtre, ortalama yöntemi ve polinom regresyon takip etmektedir. En az MAE değeri de filtre sayısı 2 olduğunda elde edilmiştir. CNN yönteminin, polinom regresyona göre yaklaşık %3 daha doğru sonuç elde ettiği gözlemlenmektedir.

Tablo 5.14 CNN 2, 4, 6 Filtre Sayısı ile Model Oluşturma ve Polinom Regresyon Model Oluşturma MAPE, MAE Karşılaştırması

Hata Metrik	CNN Modeli Filtre Sayısı 2	CNN Modeli Filtre Sayısı 4	CNN Modeli Filtre Sayısı 6	Polinom Regresyon	Ortalama Yöntemi
MAPE	17,2933	16,9144	17,0036	20,1602	17,0036
MAE	8,1234	8,1448	8,2552	9.0841	8,0198

5.3.1.2 CNN Yöntemi Öngörü Gücüne Kernel Boyutunun Etkisi

CNN yönteminde girdi verisine evrişim aşamasında uygulanan filtrenin boyutu kernel boyutu olarak adlandırılmaktadır. Modelin öngörü gücünü arttıran en uygun kernel boyutu, ele alınan probleme göre değişiklik göstermektedir. Bu kısımda CNN için mevcut diğer değişken parametrelerden; filtre sayısı 2, aktivasyon fonksiyonu RELU, katmandaki düğüm sayısı 10 olacak şekilde sabit tutularak, kernel boyutu 2, 4 veya 6 olmasının öngörü sonucuna etkisi incelenecektir. Kernel boyutu 2 olduğunda model için elde edilen hata metrikleri bir önceki bölümde verilmiştir. Bu kısımda filtre sayısı bir önceki bölümde hata metriği MAE en düşük çıkması sebebiyle 2 olarak kullanılmıştır.

Veri setine CNN yöntemi değişken parametresi kernel boyutu 2, 4 ve 6 verilerek, 44 farklı algılayıcı için öngörü sonucu MAPE ve MAE hata metrikleri ile elde edilmiştir.

Tablo 5.15 ve Tablo 5.16’da kernel boyutu 4 olarak seçildiğinde CNN modelinin öngörü gücü sırasıyla MAPE ve MAE metrikleri ile hesaplanarak verilmiştir.


Tablo 5.15 44 Farklı Algılayıcı Her Bir Hafta Günü Hız Verisi Kullanılarak Kernel Boyutu 4 ile CNN Modeli Oluşturulması MAPE Değerleri

Algılayıcı Numarası	Haziran MAPE	Temmuz MAPE	Ağustos MAPE	Eylül MAPE	Ekim MAPE	Kasım MAPE	Aralık MAPE	Algılayıcı Ortalama
30	5,5383	5,7282	6,4213	6,8593	8,9365	8,092	7,1941	6,9671
31	5,4159	5,2576	6,4011	6,6224	7,8306	7,642	5,7242	6,4134
37	4,9683	4,6243	5,2499	5,4976	5,9453	7,0304	6,4851	5,6858
63	14,1512	19,2495	15,4204	17,9823	21,7772	23,3892	21,3926	19,0517
64	10,2562	14,6845	8,8397	9,2033	10,4847	10,902	9,5774	10,5639
73	9,9567	9,8559	10,0876	20,7947	17,8953	13,7111	14,2829	13,7977
74	7,9098	12,753	15,0085	28,4639	19,8851	12,4711	12,0686	15,5085
75	8,1556	18,0657	20,5535	29,6791	19,0429	16,2611	15,4011	18,1655
76	23,0258	36,4799	28,2272	36,7155	18,6883	18,317	18,1688	25,6603
119	12,4495	10,8815	9,9886	11,9989	8,273	12,8827	9,7461	10,8886
120	28,211	47,5948	28,3286	43,566	23,5139	18,9136	19,5744	29,9574
121	29,0269	38,7829	27,121	36,3396	25,0997	23,5539	23,507	29,0615
122	20,6066	17,9443	19,3167	22,4744	18,2985	17,2672	18,5813	19,2127
125	18,8667	16,9718	13,8568	23,9057	21,742	21,0974	19,7702	19,4586
126	17,565	17,9905	16,4038	25,1139	16,9033	19,5354	25,982	19,9276
128	6,6263	17,3091	8,4098	8,3469	9,9058	7,7611	10,8928	9,8931
129	6,3139	7,6369	7,5732	8,0116	9,1716	7,16	8,9749	7,8345
130	3,9833	3,8609	3,5717	3,8496	4,3347	4,6672	4,4106	4,0968
131	4,0839	4,1266	3,6964	3,8877	4,3129	5,4207	4,6706	4,3141
215	9,0926	8,4899	7,8971	7,5251	9,9461	7,4318	8,0071	8,3413
216	6,8202	10,0888	7,71	7,5868	7,7462	7,3388	6,9238	7,7449
217	11,4356	11,9278	12,2498	12,2213	10,3837	12,9842	14,7419	12,2777
219	17,8075	19,6126	24,0148	32,3931	24,883	22,9183	22,4303	23,4370
308	11,0026	12,8498	7,5768	33,1189	19,5929	9,0363	7,8462	14,4319
309	11,5054	14,1326	9,4584	23,4709	18,0776	9,7293	10,0157	13,7699
310	16,0606	18,4806	10,8601	23,8456	13,6558	10,8656	11,603	15,0530
315	28,42	19,4823	20,3268	48,79	25,6133	21,2635	23,0374	26,7047
320	11,9721	11,3154	10,6089	19,9957	13,7927	15,116	23,5064	15,1867
421	23,6608	28,9062	21,5396	40,672	24,0381	17,8051	18,3448	24,9952
422	19,6318	21,6804	16,9882	29,2668	19,8422	18,2241	17,3405	20,4248
423	19,7625	22,092	18,3615	25,1932	22,1564	22,6319	19,6479	21,4064
424	22,8174	25,8861	20,3146	27,2609	17,9472	19,5431	16,9894	21,5369
433	9,9697	8,1252	8,5463	11,5228	11,2278	10,2812	11,6456	10,1883
443	36,7112	34,5956	38,6423	21,5789	22,8971	16,1532	21,2519	27,4043
444	39,215	27,3601	32,9069	22,5937	21,382	16,4389	20,5883	25,7835
445	55,7505	21,5852	23,1601	29,9339	22,024	17,6933	20,565	27,2445
472	15,9986	14,2186	13,1666	13,0649	16,6757	10,5467	10,4439	13,4450
506	26,6641	29,7209	19,6462	17,6098	11,5426	17,3962	21,2301	20,5442
507	18,0069	19,117	13,797	16,3399	10,2898	14,5587	13,4476	15,0795
511	15,4657	8,2263	5,5367	16,3875	14,0409	15,4537	18,9044	13,4307
512	13,1463	7,1532	5,0937	11,9988	12,1212	14,4371	15,398	11,3354
1748	26,024	21,9946	16,9664	28,8886	26,1509	12,511	12,0447	20,6543
1749	43,9107	37,256	23,9938	74,3418	67,7269	17,7219	20,0387	40,7128
1779	14,5572	27,8883	19,6201	15,4649	10,8263	13,1776	11,8575	16,1988
Aylık Ortalama	17,3299	17,9996	15,0786	21,8267	16,9686	14,2575	14,8694	16,9043

Tablo 5.16 44 Farklı Algılayıcı Her Bir Hafta Günü Hız Verisi Kullanılarak Kernel Boyutu 4 ile CNN Modeli Oluşturulması MAE Değerleri


Algılayıcı Numarası	Haziran MAE	Temmuz MAE	Ağustos MAE	Eylül MAE	Ekim MAE	Kasım MAE	Aralık MAE	Algılayıcı Ortalama
30	4,7053	4,6659	5,8048	6,2845	7,0481	6,6264	6,4756	5,9443
31	4,654	4,4466	5,8196	6,1295	6,5546	6,1164	5,122	5,5489
37	3,4751	3,2285	3,5192	3,759	4,3602	4,8831	4,382	3,9438
63	6,1574	5,3116	5,8526	6,1649	6,4203	7,2751	7,2299	6,3445
64	5,3743	4,8303	4,4531	4,2324	4,5414	5,7013	4,5491	4,8117
73	5,9575	5,6985	6,0811	8,7877	8,4169	6,7839	6,8464	6,9388
74	5,0323	6,7159	7,8154	10,4596	9,4944	5,837	5,9519	7,3295
75	5,063	7,4675	7,6369	10,9935	9,0267	6,5487	6,3635	7,5856
76	9,1386	9,1215	8,1938	9,3444	5,3628	5,6769	5,7144	7,5074
119	7,5534	6,2531	5,6612	6,6767	5,2775	6,7279	5,727	6,2681
120	12,5017	13,5459	11,1732	15,3808	9,1699	8,7552	8,8912	11,3454
121	13,0492	12,0988	10,9315	13,7684	9,464	10,6227	10,4405	11,4821
122	11,1324	8,4793	9,3408	11,1498	8,8661	9,3229	10,0701	9,7659
125	12,6103	8,6716	8,7735	11,0226	10,8434	9,8728	9,7197	10,2162
126	11,6109	8,797	9,1886	10,7709	9,2605	9,1911	11,4276	10,0352
128	4,771	9,4844	4,7737	4,6541	5,7687	4,0393	5,4648	5,5651
129	4,5408	5,0305	5,0762	5,2557	6,3206	4,6934	5,7243	5,2345
130	3,0255	2,8337	2,7054	2,8881	3,2944	3,5467	3,2772	3,0815
131	3,1144	2,9884	2,786	2,9316	3,2431	3,7723	3,4684	3,1863
215	6,0146	5,0694	5,4413	5,2188	5,8653	5,6964	5,6659	5,5673
216	5,2764	4,6965	5,3177	5,2317	5,117	5,3846	5,0436	5,1525
217	7,3494	6,3343	7,809	7,3643	6,2114	7,0548	8,2993	7,2032
219	8,078	7,1127	10,0287	11,2853	9,5486	7,5364	9,278	8,9811
308	5,9521	6,5351	5,3321	9,5924	10,3314	5,8279	5,0706	6,9487
309	6,6617	6,8712	7,0266	13,91	12,1189	6,5927	7,2458	8,6324
310	9,8405	8,3291	7,7372	11,8659	8,7128	6,993	7,3426	8,6887
315	13,6443	10,4367	10,0292	14,265	9,9876	10,1983	8,8695	11,0615
320	7,7923	6,3921	6,6795	9,8053	8,6985	9,415	11,9052	8,6697
421	8,899	9,631	7,4495	15,207	10,9083	8,7384	7,1913	9,7177
422	9,1257	9,1917	6,6923	11,8425	8,8382	9,1962	8,5823	9,0669
423	9,9598	10,3204	8,3798	10,1867	9,5361	9,7654	8,7323	9,5543
424	11,145	11,5537	9,0937	10,8863	7,444	8,0245	7,0849	9,3188
433	6,6499	5,3271	5,7145	6,2103	6,3751	5,9578	6,1479	6,0546
443	15,9021	16,322	20,7123	13,9289	12,1066	11,742	11,1106	14,5463
444	15,4434	11,7534	18,1291	12,808	10,3886	10,8119	10,3559	12,8129
445	17,5926	10,08	13,4623	13,8526	10,2741	9,915	10,0343	12,1729
472	11,5161	9,6646	10,1271	9,8655	12,6746	9,0276	7,6968	10,0817
506	9,8745	10,0383	9,6434	7,544	5,4446	6,549	7,1975	8,0416
507	7,1071	6,858	7,9184	6,4991	4,3797	5,7383	5,2308	6,2473
511	5,9827	4,5464	3,639	5,6049	5,4826	7,2874	6,6782	5,6030
512	6,6008	4,761	3,7222	4,7829	5,2279	6,9623	6,1402	5,4567
1748	14,4723	12,0413	12,247	15,0518	15,4416	9,5695	7,7772	12,3715
1749	18,6124	16,2593	16,1433	20,9752	21,4479	12,2969	10,7509	16,6408
1779	6,1705	7,105	7,8688	6,1792	4,4209	5,6083	4,7384	6,0130
Aylık Ortalama	8,6165	7,8840	7,9984	9,3322	8,1753	7,4518	7,2958	8,1077

Şekil 5.12’de CNN modeli kernel boyutu 4 ile çalıştırıldığında elde edilen algılayıcı bazında ortalama MAPE ve MAE değerleri verilmiştir. MAPE ve MAE değerleri arasında algılayıcı bazında orantı olduğu gözlemlenmektedir.




Şekil 5.12 CNN Modeli Kernel Boyutu 4 iken Algılayıcı Bazında Ortalama MAPE ve MAE Değerleri

Şekil 5.13’te CNN modeli kernel boyutu 4 ile çalıştırıldığında tüm algılayıcıları içeren aylara göre ortalama MAPE ve MAE değerleri verilmiştir.



Şekil 5.13 CNN Modeli Kernel Boyutu 4 iken Ay Bazında Ortalama MAPE ve MAE Değerleri

Şekil 5.14'te CNN modeli kernel boyutu 4 ile çalıştırıldığında algılayıcı bazında tüm ayların MAPE ve MAE değerlerinin sahip olduğu etiketlere göre yüzde oranı grafikte verilmiştir.



Şekil 5.14 CNN Modeli Kernel Boyutu 4 iken Algılayıcı Bazında Ortalama MAPE ve MAE Değer Durumu

Tablo 5.17 ve Tablo 5.18’de kernel boyutu 6 olarak seçildiğinde CNN modelinin öngörü gücü sırasıyla MAPE ve MAE metrikleri ile hesaplanarak verilmiştir.


Tablo 5.17 44 Farklı Algılayıcı Her Bir Hafta Günü Hız Verisi Kullanılarak Kernel Boyutu 6 ile CNN Modeli Oluşturulması MAPE Değerleri

Algılayıcı Numarası	Haziran MAPE	Temmuz MAPE	Ağustos MAPE	Eylül MAPE	Ekim MAPE	Kasım MAPE	Aralık MAPE	Algılayıcı Ortalama
30	5,6129	5,7228	6,4399	6,9382	9,2808	8,1046	7,5318	7,0901
31	5,4977	5,2525	6,3901	6,7099	8,0656	7,677	5,7946	6,4839
37	5,0128	4,6504	5,2676	5,6647	6,0662	7,0568	6,7106	5,7755
63	14,2298	19,3456	15,3979	18,0515	21,7178	23,4627	21,394	19,0856
64	10,1574	15,008	8,8024	9,3802	10,4644	10,779	9,6044	10,5994
73	10,0649	10,0331	10,0172	21,0815	17,9827	13,7731	14,3277	13,8971
74	7,9555	12,7747	15,2754	28,3356	19,8438	12,4401	12,1031	15,5326
75	8,2911	18,1323	20,9784	29,4872	19,209	16,4499	15,4736	18,2887
76	23,1523	36,8582	28,7587	37,2347	18,7122	18,2298	18,1629	25,8726
119	12,5249	10,9552	9,9827	12,0925	8,3172	13,0841	9,7393	10,9565
120	28,4125	47,8571	28,5076	43,6716	23,6982	18,9256	19,6493	30,1031
121	29,2268	38,9928	27,2643	36,4061	25,3001	23,5965	23,5572	29,1919
122	20,7304	18,1063	19,3412	22,5977	18,42	17,2783	18,5399	19,2876
125	18,8426	16,9446	13,9034	24,2011	21,8426	21,2408	19,6203	19,5136
126	17,5706	18,0452	16,5126	25,4889	16,9331	19,5684	26,0153	20,0191
128	6,8698	18,5777	8,3316	8,353	10,2386	7,8223	10,8504	10,1490
129	6,4123	7,7296	7,5587	8,0307	9,4751	7,2323	9,0837	7,9317
130	4,1082	3,9627	3,5519	3,8706	4,4176	4,7187	4,4775	4,1581
131	4,2328	4,2108	3,6894	3,9187	4,3313	5,4442	4,6662	4,3561
215	9,1231	8,5385	7,9511	7,5831	9,9984	7,4878	7,972	8,3791
216	6,8604	10,1718	7,8316	7,7006	7,7755	7,3631	6,9331	7,8051
217	11,5774	11,9785	12,3425	12,4053	10,4209	12,9181	14,9935	12,3766
219	17,8189	19,6415	24,0792	32,5223	24,9093	23,117	22,3928	23,4972
308	11,0637	12,9426	7,612	33,438	19,9795	9,027	7,7949	14,5511
309	11,59	14,1837	9,4311	24,1248	17,8178	9,5995	9,73	13,7824
310	16,216	18,6099	10,9058	24,0065	13,9108	10,7459	11,5222	15,1310
315	28,4361	19,3718	20,4593	49,2554	25,6809	21,1235	23,1658	26,7846
320	12,1666	11,3348	10,6694	20,3817	14,015	15,1187	23,5823	15,3240
421	23,7728	29,0234	21,7316	40,5887	24,0041	17,8278	18,3598	25,0440
422	19,6754	21,7157	17,1597	29,2155	20,0019	18,2728	17,2078	20,4641
423	19,8296	22,122	18,4254	25,242	22,2395	22,6849	19,6375	21,4544
424	22,867	25,7273	20,541	27,5336	18,0011	19,4988	16,9924	21,5944
433	10,1684	8,2788	8,5603	11,5901	11,3023	10,2513	11,7093	10,2657
443	37,4438	34,6816	38,5855	21,0707	22,9037	16,1088	21,3466	27,4486
444	40,081	27,3521	32,8861	22,6683	21,2931	16,382	20,6319	25,8992
445	56,2431	21,6069	23,0043	30,209	22,0091	17,7059	20,5922	27,3386
472	16,294	14,1874	13,1775	13,0176	16,825	10,7173	10,5751	13,5419
506	27,2463	29,8077	19,3228	17,5021	11,3926	17,4048	21,2622	20,5626
507	18,4904	19,3548	13,5941	16,2238	10,3864	14,5195	13,4958	15,1521
511	15,7166	8,1755	5,3931	16,6876	13,8468	15,447	19,2034	13,4957
512	13,3516	7,3278	5,0717	12,2587	12,0821	14,4495	15,6701	11,4587
1748	26,5346	22,0263	16,9647	28,9282	26,4413	12,5908	12,0405	20,7894
1749	44,4901	37,2802	23,883	74,6721	67,9257	17,3504	20,08	40,8116
1779	14,9671	28,2604	19,0932	15,5345	10,7808	13,1231	11,9299	16,2412
Aylık Ortalama	17,5211	18,1104	15,1056	21,9516	17,0513	14,2663	14,9118	

Tablo 5.18 44 Farklı Algılayıcı Her Bir Hafta Günü Hız Verisi Kullanılarak Kernel Boyutu 6 ile CNN Modeli Oluşturulması MAE Değerleri


Algılayıcı Numarası	Haziran MAE	Temmuz MAE	Ağustos MAE	Eylül MAE	Ekim MAE	Kasım MAE	Aralık MAE	Algılayıcı Ortalama
30	4,7614	4,6725	5,8152	6,3737	7,3149	6,6383	6,8034	6,0542
31	4,7166	4,4534	5,8071	6,2237	6,735	6,1517	5,1869	5,6106
37	3,5093	3,2484	3,5288	3,8658	4,456	4,9076	4,5209	4,0052
63	6,2061	5,3066	5,7607	6,1806	6,4043	7,2593	7,2426	6,3371
64	5,2942	4,9589	4,4049	4,3079	4,5213	5,6528	4,5574	4,8139
73	6,0252	5,8089	5,9836	8,8374	8,4777	6,8226	6,7989	6,9649
74	5,0568	6,714	7,9282	10,448	9,4559	5,7789	5,9444	7,3323
75	5,1526	7,4832	7,7927	10,8873	9,1246	6,6002	6,3512	7,6274
76	9,1627	9,1423	8,2423	9,3698	5,4019	5,6161	5,6748	7,5157
119	7,6054	6,3014	5,6472	6,7237	5,3047	6,8001	5,7547	6,3053
120	12,5466	13,4944	11,1402	15,3862	9,1825	8,7443	8,8073	11,3287
121	13,1101	12,0997	10,8918	13,7624	9,479	10,6383	10,3598	11,4773
122	11,24	8,5362	9,3037	11,208	8,8891	9,2788	9,9529	9,7726
125	12,5523	8,6407	8,7858	11,1103	10,858	9,8603	9,6265	10,2048
126	11,6059	8,8113	9,2154	10,8721	9,2925	9,1665	11,4269	10,0558
128	4,9573	10,2014	4,7254	4,6607	5,9845	4,0551	5,421	5,7150
129	4,6266	5,0753	5,0651	5,2634	6,5608	4,7404	5,7726	5,3006
130	3,1247	2,9018	2,6878	2,9013	3,363	3,5828	3,3183	3,1256
131	3,2337	3,0428	2,7786	2,9518	3,2623	3,7834	3,4612	3,2162
215	6,0288	5,1201	5,4187	5,2731	5,8873	5,7285	5,6033	5,5799
216	5,3091	4,745	5,376	5,3513	5,1398	5,3958	5,0256	5,1918
217	7,4588	6,3706	7,8119	7,4902	6,2522	6,9721	8,3993	7,2507
219	8,0538	7,1036	9,9679	11,2811	9,5621	7,5537	9,2272	8,9642
308	5,9798	6,5846	5,3652	9,6401	10,6326	5,8365	5,0393	7,0111
309	6,6954	6,8998	6,9965	14,1481	11,9305	6,4763	6,9732	8,5885
310	9,9235	8,3982	7,7828	11,9065	8,9038	6,872	7,2213	8,7154
315	13,6183	10,2697	10,0372	14,372	10,0272	10,0764	8,853	11,0362
320	7,9429	6,393	6,7126	9,9182	8,8737	9,4141	11,9558	8,7443
421	8,9438	9,5693	7,4157	15,1284	10,7334	8,6977	7,1292	9,6596
422	9,1941	9,1763	6,6908	11,7653	8,8571	9,1798	8,4459	9,0441
423	10,016	10,3021	8,3648	10,1723	9,4975	9,7526	8,7109	9,5451
424	11,1968	11,4682	9,1221	10,9471	7,4557	8,0227	7,086	9,3283
433	6,8174	5,4355	5,7102	6,2378	6,4545	5,9511	6,1549	6,1087
443	16,2146	16,2714	20,6045	13,321	12,1193	11,7203	11,1201	14,4815
444	15,8081	11,684	18,0934	12,4863	10,3814	10,7921	10,3386	12,7977
445	17,7599	10,0509	13,3138	13,6899	10,2808	9,8352	10,0103	12,1344
472	11,7186	9,6283	10,1562	9,8222	12,8353	9,184	7,7855	10,1614
506	10,0372	10,0431	9,3769	7,3858	5,3072	6,5376	7,232	7,9885
507	7,2683	6,9255	7,7879	6,3309	4,4576	5,7126	5,2772	6,2514
511	6,0386	4,5265	3,5419	5,6025	5,4527	7,2401	6,727	5,5899
512	6,6714	4,8874	3,6957	4,8134	5,299	6,9081	6,1955	5,4957
1748	14,7454	12,0206	12,2641	15,0603	15,5939	9,6649	7,76	12,4441
1749	18,793	16,2251	15,97	20,9188	21,4183	11,8362	10,7015	16,5518
1779	6,329	7,1811	7,415	6,1661	4,3713	5,5799	4,7768	5,9741
Aylık Ortalama	8,7056	7,9130	7,9658	9,3309	8,2225	7,4322	7,2893	

Şekil 5.15'te CNN modeli kernel boyutu 6 ile çalıştırıldığında elde edilen algılayıcı bazında ortalama MAPE ve MAE değerleri verilmiştir. MAPE ve MAE değerleri arasında algılayıcı bazında orantı olduğu gözlemlenmektedir.




Şekil 5.15 CNN Modeli Kernel Boyutu 6 iken Algılayıcı Bazında Ortalama MAPE ve MAE Değerleri

Şekil 5.16'da CNN modeli kernel boyutu 6 ile çalıştırıldığında tüm algılayıcıları içeren aylara göre ortalama MAPE ve MAE değerleri verilmiştir.



Şekil 5.16 CNN Modeli Kernel Boyutu 6 iken Ay Bazında Ortalama MAPE ve MAE Değerleri

Şekil 5.17’de CNN modeli kernel boyutu 6 ile çalıştırıldığında algılayıcı bazında tüm ayların MAPE ve MAE değerlerinin sahip olduğu etiketlere göre yüzde oranı grafikte verilmiştir.



Şekil 5.17 CNN Modeli Kernel Boyutu 6 iken Algılayıcı Bazında Ortalama MAPE ve MAE Değer Durumu

CNN modeli kernel boyutu değiştirilerek algılayıcı ve ay bazında hata oranları MAPE ve MAE metrikleri ile hesaplanmıştır. Farklı kernel boyutu ile elde edilen tüm aylardaki ve algılayıcılardaki sonuçların ortalaması alınarak modelin genel başarısı hesaplanmıştır. CNN modellerinin kernel boyutu farklılığı ile elde edilen başarısı, ortalama yöntemi başarısı ve polinom regresyon tüm algılayıcılarda ve aylardaki ortalama başarısı karşılaştırılmış ve sonuçlar Tablo 5.19’da verilmiştir. CNN modeli kernel boyutu 4 kullanarak en az MAPE değeri edilmiştir. Bunu sırasıyla kernel boyutu 6, kernel boyutu 2, ortalama yöntemi ve polinom regresyon takip etmektedir. En az MAE değeri de kernel boyutu 4 olduğunda elde edilmiştir. CNN yönteminin, polinom regresyona göre yaklaşık %3 daha doğru sonuç elde ettiği gözlemlenmektedir.

Tablo 5.19 CNN 2, 4, 6 Kernel Boyutu ile Model Oluřturma ve Polinom Regresyon Model Oluřturma MAPE, MAE Karřılařtırması

Hata Metrik	CNN Modeli Kernel Boyutu 2	CNN Modeli Kernel Boyutu 4	CNN Modeli Kernel Boyutu 6	Polinom Regresyon	Ortalama Yöntemi
MAPE	17,2933	16,9043	16,9883	20,1602	17,0036
MAE	8,1234	8,1077	8,1228	9.0841	8,0198

5.3.1.3 CNN Yöntemi Öngörü Gücüne Döğüm Sayısının Etkisi

Derin öğrenmede katmanlar arası bağlantıyı döğümler sağlamaktadır. CNN yönteminde de evriřim aşamasından sonra tam bağlantılı derin öğrenme ağı oluřturulmaktadır. Modelin öngörü gücünü arttıran en uygun döğüm sayısı, ele alınan probleme göre deęiřiklik göstermektedir. Bu kısımda CNN için mevcut diğerk deęiřken parametrelerden; filtre sayısı 2, kernel boyutu 4, katman sayısı 1, optimizasyon algoritması adam, aktivasyon fonksiyonu RELU, batch boyutu 128, epoch sayısı 15 olacak řekilde sabit tutularak, döğüm sayısının 10, 50 veya 100 olmasının öngörü sonucuna etkisi incelenecektir. Döğüm sayısı 10 olduğunda model için elde edilen hata metrikleri bir önceki bölümde verilmiştir. Bu kısımda kernel boyutu bir önceki bölümde hata metrięi MAE en düşük çıkması sebebiyle 4 olarak kullanılmıştır.

Veri setine CNN yöntemi deęiřken parametresi döğüm sayısı 10, 30, 50, 70, 100 ve 200 verilerek, 44 farklı algılayıcı için öngörü sonucu MAPE ve MAE hata metrikleri ile elde edilmiştir.

Tablo řekil 5.20 ve Tablo řekil 5.21’de döğüm sayısı 70 seçilerek oluřturulan CNN modeli öngörü gücü, hata metrikleri MAPE ve MAE ile ölçölmüş ve sonuçlar verilmiştir.


Tablo 5.20 44 Farklı Algılayıcı Her Bir Hafta Günü Hız Verisi Kullanılarak Düğüm Sayısı 70 ile CNN Modeli Oluşturulması MAPE Değerleri

Algılayıcı Numarası	Haziran MAPE	Temmuz MAPE	Ağustos MAPE	Eylül MAPE	Ekim MAPE	Kasım MAPE	Aralık MAPE	Algılayıcı Ortalama
30	5,582	5,7904	6,4802	6,8713	8,9615	7,9503	7,3391	6,9964
31	5,4408	5,3213	6,4811	6,6476	7,8535	7,5551	5,7139	6,4304
37	4,9639	4,6062	5,2586	5,629	5,9105	7,0191	6,4389	5,6894
63	14,1222	19,2232	15,5356	17,9057	21,7955	23,4628	21,3756	19,0600
64	10,8436	14,1622	9,0799	9,2227	10,5159	11,0709	9,493	10,6268
73	10,0685	9,7093	10,0857	20,8953	17,9008	13,6908	14,2878	13,8054
74	8,1155	12,8452	14,8378	28,1029	19,6099	12,6499	12,1313	15,4703
75	8,3794	18,2212	20,1478	29,577	18,765	16,5276	15,6246	18,1775
76	23,3684	37,3146	28,4471	38,5094	18,6453	18,1911	18,0825	26,0797
119	12,4176	10,8307	10,0173	12,1754	8,2546	12,8163	9,7485	10,89434
120	28,7697	48,5069	28,7602	44,1485	23,5113	19,1966	20,0393	30,4189
121	29,4061	39,5035	27,962	36,3205	26,003	23,7961	23,8265	29,5453
122	20,6583	18,228	19,4525	22,4646	18,3827	17,1979	18,7042	19,2983
125	18,9671	17,2041	13,9361	24,1857	21,864	21,4043	19,7543	19,6165
126	17,682	18,2533	16,4676	24,9316	16,9497	19,9299	25,9419	20,0222
128	6,8375	17,5166	8,4511	8,3169	10,0661	7,7811	10,9034	9,9818
129	6,2956	7,6818	7,5344	7,9968	9,2157	7,1568	8,922	7,8290
130	3,9654	3,8745	3,5461	3,8612	4,3525	4,6839	4,3646	4,0926
131	4,0385	4,0436	3,7144	3,8951	4,3678	5,4247	4,7073	4,3130
215	9,1054	8,4723	7,9682	7,5156	9,9886	7,4039	8,0123	8,3523
216	6,8714	10,1199	7,8085	7,5734	7,7979	7,3307	6,9426	7,7777
217	11,4341	12,0654	12,3471	12,2027	10,3897	12,9628	14,9083	12,3300
219	17,8045	19,579	24,0752	31,99	25,067	22,9307	22,439	23,4121
308	11,0513	12,8686	7,6284	33,5157	19,8633	9,181	7,8642	14,5674
309	11,5122	14,1454	9,6947	23,5783	18,6978	9,7153	11,0995	14,0633
310	16,0903	18,5928	11,0353	23,4208	13,9111	11,0182	12,044	15,1589
315	28,8441	19,5582	20,3323	52,2407	26,0039	21,5645	22,6686	27,3160
320	11,8905	11,6568	10,7354	20,2299	13,8436	15,1091	23,6018	15,2953
421	23,8449	29,6996	22,4525	41,5358	24,574	18,0208	19,0999	25,6039
422	19,6919	22,2092	17,3813	29,7264	20,1401	18,2867	17,9095	20,7635
423	19,7667	22,2163	18,7569	25,679	22,5575	22,6709	19,6869	21,6191
424	22,8011	25,8945	21,6228	28,8027	18,1303	19,488	17,0298	21,9670
433	9,9774	8,0866	8,5386	11,4088	11,2481	10,2577	11,6391	10,1651
443	36,5001	34,9848	38,9386	22,8437	23,3497	15,7318	20,827	27,5965
444	39,797	27,4636	32,6708	22,807	21,1399	16,4194	20,5789	25,8395
445	56,4143	21,8468	23,0797	29,6698	22,704	18,1792	20,7304	27,5177
472	15,9343	14,175	13,1138	12,9927	16,628	10,5822	10,6607	13,4409
506	26,8858	29,8488	19,7297	18,2381	12,3099	17,405	21,2897	20,8152
507	18,0661	19,2127	13,8889	17,7074	10,6195	14,5985	13,7652	15,4083
511	15,7905	8,3073	6,0565	16,3776	14,1753	15,396	18,9335	13,5766
512	13,2747	7,1879	5,1965	12,1411	12,2847	14,3351	15,4427	11,4089
1748	26,0492	22,1399	16,9453	28,6942	26,1922	12,931	12,2281	20,7399
1749	44,1621	37,9157	24,3573	74,8148	71,3343	19,3729	20,9334	41,8415
1779	14,5585	27,8329	19,4171	16,0867	11,0561	13,1812	11,9282	16,2943
Aylık Ortalama	17,4554	18,1571	15,2265	22,1238	17,2029	14,3540	14,9923	

Tablo 5.21 44 Farklı Algılayıcı Her Bir Hafta Günü Hız Verisi Kullanılarak Düğüm Sayısı 70 ile CNN Modeli Oluşturulması MAE Değerleri


Algılayıcı Numarası	Haziran MAE	Temmuz MAE	Ağustos MAE	Eylül MAE	Ekim MAE	Kasım MAE	Aralık MAE	Algılayıcı Ortalama
30	4,7334	4,7116	5,8677	6,2923	7,0687	6,4655	6,6177	5,9652
31	4,6698	4,4931	5,9039	6,1533	6,5735	6,0009	5,1104	5,5578
37	3,4691	3,2224	3,5273	3,8376	4,3301	4,8822	4,3565	3,9464
63	6,0912	5,3315	5,8973	6,1428	6,4117	7,2881	7,2307	6,3419
64	5,7842	4,6646	4,6547	4,233	4,5376	5,7957	4,4949	4,8806
73	5,9937	5,5725	6,0855	8,8031	8,4437	6,7752	6,7772	6,9215
74	5,2132	6,7509	7,7446	10,1997	9,2418	5,8182	5,9677	7,2765
75	5,2464	7,5279	7,5106	11,038	8,7875	6,5832	6,381	7,5820
76	9,4328	9,1685	8,2016	9,5812	5,3555	5,506	5,6329	7,5540
119	7,4986	6,2541	5,6981	6,7499	5,2665	6,7404	5,7168	6,2749
120	12,3066	13,9675	12,0215	15,5126	9,0224	8,617	9,2347	11,5260
121	12,8192	12,2928	11,6023	13,8285	9,487	10,4981	10,6235	11,5930
122	11,0064	8,5329	9,3443	11,1513	8,9203	9,1169	10,1597	9,7473
125	12,713	8,6705	8,8469	11,1016	10,7753	9,9877	9,7183	10,2590
126	11,7518	8,8022	9,1117	10,6943	9,3103	9,1879	11,4952	10,0504
128	4,9436	9,6023	4,7986	4,6304	5,8738	4,0306	5,4524	5,6188
129	4,526	5,0543	5,0358	5,2538	6,3595	4,6885	5,7	5,2311
130	3,007	2,8435	2,6825	2,8971	3,3095	3,5559	3,2516	3,0781
131	3,0706	2,9349	2,8007	2,9392	3,2918	3,7759	3,5133	3,1894
215	6,0089	5,0597	5,5233	5,2198	5,9444	5,6636	5,6318	5,5787
216	5,3439	4,7102	5,4332	5,2255	5,1942	5,371	5,0794	5,1939
217	7,3367	6,4012	7,919	7,3959	6,1936	7,1126	8,5435	7,2717
219	7,8666	7,0012	9,963	11,041	9,4912	7,5333	9,0245	8,8458
308	5,9305	6,5503	5,3867	9,7174	10,4873	6,0013	5,0858	7,0227
309	6,6548	6,8596	7,2663	13,9168	12,4188	6,5864	8,2667	8,8527
310	9,8611	8,345	7,9155	11,6728	8,9056	7,0748	7,7687	8,7919
315	13,8282	10,5185	10,2511	14,9615	9,9894	10,5384	8,6866	11,2533
320	7,6341	6,5522	6,8305	9,9039	8,7262	9,4395	11,8993	8,7122
421	8,8673	9,9264	7,8284	15,1973	11,3593	8,6575	7,5912	9,9181
422	9,0618	9,5889	6,8867	11,8899	8,9847	9,128	9,0835	9,2319
423	9,9334	10,3538	8,5495	10,2462	9,1762	9,7555	8,8267	9,5487
424	11,1902	11,6226	9,3764	11,2815	7,436	8,1026	7,1379	9,4496
433	6,6583	5,2986	5,7708	6,1805	6,3971	5,9442	6,1483	6,0568
443	15,8269	16,0887	20,3378	15,4098	13,0351	11,3996	10,9884	14,7266
444	15,6397	11,6601	17,7292	13,1221	10,4306	10,6582	10,4464	12,8123
445	17,7886	10,0761	13,0467	14,3287	10,3962	10,1352	10,0475	12,2598
472	11,5247	9,6737	10,07	9,8419	12,7086	9,05	7,8323	10,1001
506	9,9103	10,0033	9,6677	7,6408	5,8607	6,616	7,4204	8,1598
507	7,1087	6,8535	7,8688	7,128	4,5914	5,7218	5,5372	6,4013
511	6,2	4,6473	4,0296	5,6351	5,5308	7,2491	6,6659	5,7082
512	6,6561	4,7802	3,7683	4,8563	5,3177	6,8545	6,1481	5,4830
1748	14,585	12,1057	12,2113	15,0143	15,4111	10,0618	7,9383	12,4753
1749	18,9342	16,7845	15,9284	21,894	21,7637	13,3642	11,541	17,1728
1779	6,1144	7,0748	7,6684	6,4978	4,5389	5,5907	4,7736	6,0369
Aylık Ortalama	8,6532	7,9303	8,0582	9,4604	8,2421	7,4755	7,3988	

Şekil 5.18’de CNN modeli düğüm sayısı 70 ile çalıştırıldığında elde edilen algılayıcı bazında ortalama MAPE ve MAE değerleri verilmiştir. MAPE ve MAE değerleri arasında algılayıcı bazında orantı olduğu gözlemlenmektedir.




Şekil 5.18 CNN Modeli Düğüm Sayısı 70 iken Algılayıcı Bazında Ortalama MAPE ve MAE Değerleri

Şekil 5.19’da CNN modeli düğüm sayısı 70 ile çalıştırıldığında tüm algılayıcıları içeren aylara göre ortalama MAPE ve MAE değerleri verilmiştir.



Şekil 5.19 CNN Modeli Düğüm Sayısı 70 iken Ay Bazında Ortalama MAPE ve MAE Değerleri

Şekil 5.20’de CNN modeli düğüm sayısı 70 ile çalıştırıldığında algılayıcı bazında tüm ayların MAPE ve MAE değerlerinin sahip olduğu etiketlere göre yüzde oranı grafikte verilmiştir.



Şekil 5.20 CNN Modeli Düğüm Sayısı 70 iken Algılayıcı Bazında Ortalama MAPE ve MAE Değer Durumu

Tablo 5.22’de detaylı MAPE değerleri verilmeyen CNN modeli 30, 50, 100, 200 düğüm sayısı değiştirilerek; tüm algılayıcılar ve aylar ortalaması alınarak elde edilen MAPE ve MAE değerleri verilmiştir. Ayrıca Kernel boyutu etkisi bölümünde düğüm sayısı 10’un algılayıcı ve ay bazında detaylı MAPE, MAE değerleri verilirken, düğüm sayısı 70’in detaylı MAPE, MAE değerleri bu bölümde verilmiştir. Tüm düğüm sayılarında elde edilen MAPE ve MAE değerleri karşılaştırıldığında en doğru sonucun düğüm sayısı 10 ile elde edildiği gözlemlenmektedir.

Tablo 5.22 CNN 10, 30, 50, 70, 100, 200 Düğüm Sayısı ile Model Oluşturma ve Polinom Regresyon Model Oluşturma MAPE, MAE Karşılaştırması

Model	MAPE	MAE
CNN Modeli Düğüm Sayısı 10	16,9043	8,1077
CNN Modeli Düğüm Sayısı 30	17,8985	8,9985
CNN Modeli Düğüm Sayısı 50	17,4704	8,6037
CNN Modeli Düğüm Sayısı 70	17,0732	8,1740
CNN Modeli Düğüm Sayısı 100	17,1401	8,2709
CNN Modeli Düğüm Sayısı 200	17,1761	8,2162
Polinom Regresyon	20,1602	9,0841
Ortalama Yöntemi	17,0036	8,0198

5.3.1.4 CNN Yöntemi Öngörü Gücüne Katman Sayısının Etkisi

Ele alınan problemin tipine göre derin öğrenme modelinde kullanılan katman sayısı öngörü başarısını etkilemektedir. Bu kısımda CNN için mevcut diğer değişken parametrelerden; filtre sayısı 2, kernel boyutu 4, katmanlardaki düğüm sayıları 10, aktivasyon fonksiyonu RELU, optimizasyon algoritması Adam, batch boyutu 128, epoch sayısı 15 olacak şekilde sabit tutularak, katman sayısı 1, 2, 3, 4 olmasının öngörü sonucuna etkisi incelenecektir. Sabit tutulan model değişkenleri, önceki bölümlerde en az hata oranı sağlayan parametrelerdir. Önceki bölümlerde katman sayısı 1 olduğunda elde edilen sonuçlar incelenmiştir.

Tablo 5.23'te detaylı MAPE değerleri verilmeyen CNN modeli 1, 2, 3, 4 katman sayısı değiştirilerek; tüm algılayıcılar ve aylar ortalaması alınarak elde edilen MAPE ve MAE değerleri verilmiştir. En başarılı sonucun katman sayısı 1 olduğunda elde edildiği gözlemlenmektedir.

Tablo 5.23 CNN 1, 2, 3, 4 Katman Sayısı ile Model Oluşturma ve Polinom Regresyon Model Oluşturma MAPE, MAE Karşılaştırması

Model	MAPE	MAE
CNN Modeli Katman Sayısı 1	16,9043	8,1077
CNN Modeli Katman Sayısı 2	17,4548	8,2892
CNN Modeli Katman Sayısı 3	17,1166	8,1733
CNN Modeli Katman Sayısı 4	17,1911	8,2060
Polinom Regresyon	20,1602	9,0841
Ortalama Yöntemi	17,0036	8,0198

5.3.1.5 CNN Yöntemi Öngörü Gücüne Aktivasyon Fonksiyonunun Etkisi

Sinir ağlarında aktivasyon fonksiyonu, mevcut düğümü besleyen giriş ile bir sonraki katmana giden çıkış arasındaki matematiksel geçittir. Ele alınan problemin tipine göre düğümler arası kullanılan aktivasyon fonksiyonu öngörü başarısını etkilemektedir. Bu kısımda CNN için mevcut diğer değişken parametrelerden; filtre sayısı 2, kernel boyutu 4, katmanlardaki düğüm sayıları 10, katman sayısı 1, batch boyutu 128, epoch sayısı 15 olacak şekilde sabit tutularak, aktivasyon fonksiyonunun relu, sigmoid veya tanh olmasının öngörü sonucuna etkisi incelenecektir. Sabit tutulan model değişkenleri, önceki bölümlerde en az hata oranı sağlayan parametrelerdir. Önceki bölümlerde aktivasyon fonksiyonu relu olduğunda elde edilen sonuçlar incelenmiştir.

Tablo 5.24'te 2 filtre, 4 kernel, 10 düğüm, 1 katman içeren CNN modelinde aktivasyon fonksiyonu relu, sigmoid, tanh değiştirilerek tüm algılayıcılarda tüm ayların elde edilen ortalama MAPE ve MAE değerleri verilmiştir. 16,9043 değeri ile en doğru sonucu Relu aktivasyon fonksiyonu vermiştir.

Tablo 5.24 CNN Relu, Sigmoid, Tanh Aktivasyon Fonksiyonu ile Model Oluşturma ve Polinom Regresyon Model Oluşturma MAPE, MAE Karşılaştırması


Aktivasyon Fonksiyonu	MAPE	MAE
Relu	16,9043	8,1077
Sigmoid	52,4495	38,0491
Tanh	54,1905	39,4846
Polinom Regresyon	20,1602	9,0841

5.3.1.6 CNN Yöntemi Öngörü Gücüne Optimizasyon Algoritmasının Etkisi

Derin öğrenme ağında optimizasyon algoritması kullanılarak, en az kayıp ile sonuç üreten ağırlıklar ve değişken parametreler belirlenmektedir. Farklı optimizasyon algoritmalarının, farklı teknikleriyle problemin yapısına göre başarıları değişmektedir. Optimizasyon algoritmalarında, öğrenme oranı değişken parametresi; her adımda seçilen ağırlıkların ne kadar değişeceğini belirlemektedir. Öğrenme oranının çok küçük olması veya çok büyük olması, elde edilebilecek en az hata oranının kaçırılmasına sebep olabilmektedir. Optimizasyon algoritmalarında öğrenme oranı belirli bir değerden başlayarak, algoritmanın çalışma yapısına göre her bir derin öğrenme adımında değişebileceği gibi her adımda sabit olarak kullanılabilir. Bu kısımda optimizasyon algoritmasının değiştirilmesinin CNN modelinin tahmin gücüne etkisi incelenmiştir.

CNN için mevcut diğer değişken parametrelerden; filtre sayısı 2, kernel boyutu 4, katmanlardaki düğüm sayıları 10, katman sayısı 1, aktivasyon fonksiyonu Relu olacak şekilde sabit tutularak; Stochastic Gradient Descent, RMSProp, Adagrad, Adadelata ve Adam optimizasyon algoritmaları denenerek model başarısına etkisi incelenmiştir.

Stochastic Gradient Descent, sabit öğrenme oranı kullanmaktadır. Stochastic Gradient Descent üzerinde öğrenme hızının etkisini gözlemlemek için öğrenme oranı 0.1, 0.01, 0.001, 0.0001 için CNN modeli oluşturularak sonuca etkisi gözlemlenmiştir. RMSProp, Adagrad, Adadelata ve Adam algoritmaları belirli bir öğrenme oranından başlayarak, probleme göre öğrenme oranını her bir adımda değiştirmektedir.



Şekil 5.21 CNN Modeli Stochastic Gradient Descent Öğrenme Oranı Değişimi Ay Bazında Ortalama MAPE ve MAE Değerleri

Şekil 5.21’de SGD, öğrenme oranı değişimine göre tüm algılayıcılarda tüm aylar için elde edilen MAPE ve MAE değerleri verilmiştir. En iyi sonucun öğrenme oranı 0.001 olduğunda elde edildiği gözlemlenmektedir.

Tablo 5.25 CNN SGD, RMSprop, Adagrad, Adadelata, Adam Optimizasyon Algoritmaları ile Model Oluşturma ve Polinom Regresyon Model Oluşturma MAPE, MAE Karşılaştırması

Model	MAPE	MAE
SGD Öğrenme Oranı 0.001	16.8476	8.0564
RMSprop	17,0592	8,1566
Adagrad	16,8393	8,0483
Adadelata	17,2468	8,2737
Adam	16.9043	8.1077

Tablo 5.25'te SGD; öğrenme oranı 0.001, RMSprop, Adagrad, Adadelata, Adam optimizasyon algoritmaları değiştirilerek çalıştırıldığında CNN modeli hata oranı MAPE ve MAE cinsinden verilmiştir. En iyi sonuç 16,8393 MAPE ve 8,0483 MAE değeri ile Adagrad optimizasyon algoritması kullanıldığında elde edilmiştir.

5.3.1.7 CNN Yöntemi Öngörü Gücüne Batch Boyutunun Etkisi

Batch boyutu, sinir ağlarında bir yinelemede kullanılan eğitim örneklerinin sayısını ifade etmektedir. Batch boyutu, 1 den fazla ve eğitim veri seti boyutundan küçük olmalıdır. Batch boyutunun fazla büyük olmaması veya fazla küçük olmamasına dikkat edilmelidir. Problemin tipine göre en uygun batch boyutu değişebilmektedir. GPU belleğine sığması için belirlenen batch boyutu genellikle 2'nin katları şeklinde seçilmektedir. Bu kısımda batch boyutunun CNN ile uzun vadeli trafik tahmin modeline etkisi incelenmiştir.

CNN için mevcut diğer değişken parametrelerden; filtre sayısı 2, kernel boyutu 4, katmanlardaki düğüm sayıları 10, katman sayısı 1, aktivasyon fonksiyonu Relu, optimizasyon algoritması Adagrad, epoch sayısı 15 olacak şekilde sabit tutularak; batch boyutu 64, 128, 256, 512 ve 1024 olmasının model başarısına etkisi incelenmiştir. Tablo 5.26'da CNN modeli, batch boyutu 64, 128, 256, 512, 1024 olduğunda MAPE ve MAE hata metrikleri ile değerlendirme sonuçları verilmiştir. En doğru sonucun 16,8358 ile batch boyutu 256 olduğunda elde edildiği gözlemlenmektedir.

Tablo 5.26 CNN Batch Boyutu 64, 128, 256, 512 veya 1024 ile Model Oluşturma MAPE, MAE Karşılaştırması

Batch Boyutu	MAPE	MAE
64	16.8548	8.0549
128	16,8393	8,0483
256	16,8358	8,0478
512	16,8444	8,0540
1024	16,8523	8.0591

5.3.1.8 CNN Yöntemi Öngörü Gücüne Epoch Sayısının Etkisi

Derin öğrenmede model eğitimi sırasında, veri setinde bulunan tüm veriler kullanılarak ağırlık parameterlerinin güncellenmesi 1 epoch olarak kabul edilmektedir. Epoch sayısı arttıkça modelin başarısı artabilir, epoch sayısı belli bir sayıyı geçtiğinde ise model başarısı durağanlaşabilmektedir. Problemin tipine göre uygun epoch sayısı değişebilmektedir. En uygun epoch sayısı belirlenerek, fazla epoch kullanmadan modelin eğitim hızı azaltılabilir.

CNN için mevcut diğer değişken parametrelerden; filtre sayısı 2, kernel boyutu 4, katmanlardaki düğüm sayıları 10, katman sayısı 1, aktivasyon fonksiyonu Relu, optimizasyon algoritması Adagrad, batch boyutu 256 olarak sabit tutularak epoch sayısı 5, 10, 15, 30 veya 60 olmasının model başarısına etkisi incelenmiştir.


Tablo 5.27’de epoch sayısı değişimine göre CNN modeli MAPE ve MAE değerleri verilmiştir. En iyi sonucun epoch sayısı 15 olduğunda elde edildiği gözlemlenmektedir. Epoch sayısı 5 ve 10 için de elde edilen sonuçlar, epoch sayısı 15 ile elde edilen sonuçlara yakın çıkmıştır, daha hızlı model eğitimi için epoch sayısı 5’in kullanımı da uygundur.

Tablo 5.27 CNN Epoch Sayısı 5, 10, 15, 30 veya 60 ile Model Oluşturma MAPE, MAE Karşılaştırması


Epoch Sayısı	MAPE	MAE
5	16,8442	8,0630
10	16,8445	8,0603
15	16,8358	8,0478
30	16,8427	8,0567
60	16,8582	8,0619

Şekil 5.22 ve Şekil 5.23’te sırasıyla en az hata ile tahmin edilen algılayıcılardan 30 ve diğerlerine göre daha hatalı tahmin edilen 1749 numaralı algılayıcıları ekim ayı eğitim

aşamasında epoch sırasında elde edilen kayıp fonksiyonu MSE değerleri verilmiştir. Algılayıcı 30 için epoch sayısı 3'ten sonra kayıp fonksiyonu MSE değerinde fazla miktarda bir düşüş gözlemlenmemiştir. 1749 algılayıcısında ise 1 epochtan sonra kayıp fonksiyonu MSE değerinde düşüş gözlemlenmemiştir.



Şekil 5.22 30 Algılayıcısı Ekim Ayı Tahmini Epoch Sayısına Karşılık Kayıp Fonksiyonu MSE Değerleri



Şekil 5.23 1749 Algılayıcısı Ekim Ayı Tahmini Epoch Sayısına Karşılık Kayıp Fonksiyonu MSE Değerleri

5.3.2 CNN Yöntemi Uzun Vadeli Hız Tahmini Seçilen Değişken Parametrelerin Farklı Veri Setlerinde Uygulanması

Bölüm 5.3.1’de uzun vadeli hız tahmini için oluşturulan CNN modelinde değişken parametreler değiştirilerek başarıya etkileri incelenmiştir. CNN modelinde en iyi MAPE, MAE hata metriklerini üreten değişken parametreler; filtre sayısı 2, kernel boyutu 4, node sayısı 10, katman sayısı 1, optimizasyon algoritması Adagrad, aktivasyon fonksiyonu Relu, batch boyutu 256 ve epoch sayısı 15 olarak seçilmiştir. Bu kısımda derin öğrenme için oluşturulan ve Bölüm 3.2.2.4’te detaylı açıklanan, her bir hafta geri gidilmesi sonucu elde edilen hız bilgilerine artı, eksi 15 dakika hız bilgileri eklenmesiyle oluşturulan 2 farklı veri setidir. 2 veri setinin farkı ise aynı 5 dakikalık zaman dilimindeki hız verilerinin yan yana veya haftalık dizilim olarak oluşturulmasından kaynaklanmaktadır.

Tablo 5.28 Geriye Gidilen k Haftaları Sonucu 5 Dakikalık Hız Verilerinin Dizilimi Farklılaşmasıyla Elde Edilen 2 Farklı Veri Seti CNN Sonuçlarının Karşılaştırılması

Veri Seti	MAPE	MAE
4 hafta Geri Hız Bilgilerinin Yan Yana Olması	16,8358	8,0478
4 hafta Geri 15 Dakika İleri Geri Hız Bilgilerinin Aynı 5 Dakikaların Yanyana Olması ile Oluşturulan Veri Seti	16,6006	7,8598
4 hafta Geri 15 Dakika İleri Geri Hız Bilgilerinin Haftalık Dizilimi Korunarak Oluşturulan Veri Seti	16,6029	7,8595

Tablo 5.28’de 3 farklı veri setinin; seçilen değişken parametrelerle CNN modelinin oluşturulması sonucu elde edilen MAPE, MAE değerleri verilmiştir. En doğru sonucun 4 hafta geri 15 dakika ileri geri hız bilgilerinin aynı 5 dakikaların yanyana olması ile oluşturulan veri seti ile elde edildiği gözlemlenmektedir.

5.4 CNN Yöntemi, Polinom Regresyon ve Ortalama Yöntemi Karşılaştırılması

CNN yöntemi seçilen en uygun değişken parametrelerle 4 hafta geçmiş verisi kullanılarak 44 farklı algılayıcı, 7 ay ve 3 farklı veri setinde toplamda 44x7x3 farklı model oluşturularak, ortalama en doğru MAPE değeri 16,6029 olarak elde edilmiştir. 5. dereceden Polinom Regresyon ve Ortalama yöntemleri, 4 hafta geçmiş hız verisi kullanılarak 44 farklı algılayıcı ve 7 ay için en düşük MAPE değeri sırasıyla 20,1602 ve 17,0036 olarak elde edilmiştir. Bu kısımda 3 farklı yöntemle elde edilen en iyi tahmin

sonuçları algılayıcı bazında karşılaştırılacaktır. Tablo 5.29'da algılayıcı bazında CNN Modeli, Polinom Regresyon ve Ortalama Yöntemi MAPE karşılaştırması verilmiştir. Tablo satırları algılayıcılar için yeşil, pembe ve sarı olarak gruplandırılmıştır. Yeşil algılayıcının en iyi sonuç elde ettiği modeli, sarı orta dereceli sonuç elde ettiği modeli, pembe en kötü sonuç elde ettiği modeli belirtmektedir. Sonuçlar incelendiğinde algılayıcı bazında da en iyi sonucu CNN modeli ile elde edildiği gözlemlenmektedir. CNN modeli ve Ortalama yöntemi algılayıcılar için birbirine yakın sonuçlar elde etmiştir. En düşük sonuç elde edilen bölgelerden 443, 444, 445 1. Köprüde bulunan algılayıcılar, 1749 ise 2. köprüde bulunan algılayıcılardır. Bu algılayıcılarda CNN modeli, Polinom Regresyona göre MAPE değerinde %3'ten %10'a kadar oranla iyileşme sağlamıştır. En başarılı MAPE değeri 130 numaralı algılayıcıda %3,9434 olarak elde edilmiştir.


Tablo 5.30'da algılayıcı bazında CNN Modeli, Polinom Regresyon ve Ortalama Yöntemi MAE karşılaştırması verilmiştir. Tablo satırları algılayıcılar için yeşil, pembe ve sarı olarak gruplandırılmıştır. Yeşil algılayıcının en iyi sonuç elde ettiği modeli, sarı orta dereceli sonuç elde ettiği modeli, pembe en kötü sonuç elde ettiği modeli belirtmektedir. Algılayıcı bazında genel olarak CNN modelinin en az MAE değerini elde ettiği gözlemlenmektedir. En düşük MAE değeri 2,9591 ile 130, en yüksek MAE değeri 16,2996 ile 1749 numaralı algılayıcı modelinden elde edilmiştir. CNN modeli ve Ortalama Yöntemi MAE değerlerinin birbirine yakın olduğu gözlemlenmektedir. CNN modeli, polinom regresyona göre MAE değerinde yaklaşık 1-4 arasında daha doğru tahmin sonucu üretmiştir.

Tablo 5.29 44 Farklı Algılayıcı CNN Modeli, Polinom Regresyon ve Ortalama Yöntemi MAPE Karşılaştırma

Algılayıcı Numarası	CNN Modeli MAPE	Polinom Regresyon MAPE	Ortalama Yöntemi MAPE
30	6,7286	6,8163	6,8213
31	6,1766	6,4188	6,3489
37	5,4712	5,5573	5,7137
63	18,7177	23,8123	19,0389
64	10,1450	10,6964	10,4876
73	13,6802	16,5166	13,9652
74	15,2567	16,5212	15,2867
75	18,1271	20,7327	18,3426
76	24,8862	32,0724	25,7520
119	10,6548	12,0691	10,9621
120	29,4066	41,7023	29,5783
121	28,5544	41,4038	28,6785
122	19,0701	24,4477	19,1794
125	19,2423	25,5797	19,4414
126	19,8563	25,5857	19,9883
128	9,7586	9,7017	9,6008
129	7,5085	7,3629	7,8123
130	3,9434	3,9415	4,0928
131	4,1073	4,1963	4,2860
215	8,1230	9,0737	8,3671
216	7,5872	8,4375	7,7950
217	12,1248	14,9321	12,2626
219	22,8400	25,0307	23,8806
308	14,2161	15,8716	14,3527
309	13,3340	15,8078	13,1997
310	14,7782	17,6473	14,9551
315	26,4105	33,1988	27,2593
320	15,0920	18,8867	15,3470
421	24,4680	32,7033	24,4441
422	20,1325	27,9652	20,1632
423	21,0592	27,4608	21,3614
424	21,1564	27,2391	21,4022
433	9,9359	10,0617	10,2165
443	26,5925	28,8199	28,2411
444	25,4494	28,1485	26,6909
445	26,8604	32,3685	29,0778
472	13,1068	13,9609	13,6395
506	20,1470	23,1451	20,4232
507	14,8072	18,4670	15,0307
511	13,2276	16,5065	13,6046
512	11,2609	12,3259	11,5591
1748	20,4298	24,6189	21,5223
1749	40,0486	50,2478	41,8956
1779	15,9473	18,9904	16,0888


Tablo 5.30 44 Farklı Algılayıcı CNN Modeli, Polinom Regresyon ve Ortalama Yöntemi MAE Karşılaştırma

Algılayıcı Numarası	CNN Modeli MAE	Polinom Regresyon MAE	Ortalama Yöntemi MAE
30	5,7209	5,7480	5,7851
31	5,3195	5,4905	5,4679
37	3,7756	3,8316	3,9571
63	6,1423	7,4015	6,2561
64	4,5478	4,7339	4,7400
73	6,7950	7,7499	6,9540
74	7,0939	7,4305	7,0476
75	7,5267	8,1971	7,4596
76	7,2471	8,6757	7,4094
119	6,1046	6,7767	6,2525
120	11,0622	14,8110	11,1370
121	11,1948	14,6754	11,2402
122	9,5271	11,2730	9,5754
125	9,9810	12,4810	10,0217
126	9,8608	12,0610	9,9012
128	5,4500	5,2721	5,3103
129	4,9763	4,8565	5,2019
130	2,9591	2,9594	3,0748
131	3,0253	3,0910	3,1609
215	5,3370	5,8142	5,5292
216	4,9989	5,5669	5,1592
217	7,0849	8,4848	7,0961
219	8,5971	8,9691	8,9927
308	6,7774	7,4734	6,8697
309	8,1971	9,1668	8,0946
310	8,3681	9,9055	8,4855
315	10,7981	12,6680	10,8736
320	8,5096	10,5327	8,6484
421	9,3551	11,3134	9,3217
422	8,8222	10,9722	8,9025
423	9,2191	11,2509	9,3943
424	9,0804	11,2704	9,2208
433	5,8616	5,8498	6,0394
443	13,7658	14,6270	14,5725
444	12,4432	13,6557	12,9792
445	11,7907	13,9973	12,6050
472	9,7746	10,3713	10,1692
506	7,7050	8,8943	7,7983
507	6,0462	7,3396	6,1436
511	5,3849	6,3218	5,5960
512	5,3283	5,4954	5,4812
1748	12,2042	14,7462	12,7199
1749	16,2996	20,6261	16,3979
1779	5,7732	6,8746	5,8283



Şekil 5.24 Tüm Algılayıcıların Aylara Göre CNN, Polinom Regresyon, Ortalama Yöntemi Ortalama MAPE Değerleri

Şekil 5.24'te CNN, Polinom Regresyon ve Ortalama Yöntemi sonucu tüm algılayıcıların ay bazında tahmin sonucuna göre ortalama MAPE değerleri verilmiştir. CNN modeli ve Ortalama yöntemi MAPE sonuçlarının ay bazında birbirine yakın olduğu gözlemlenmektedir. CNN modelinin, Polinom Regresyona göre ay bazında %3-4 arasında daha doğru sonuç ürettiği görülmektedir. 44 algılayıcı için en doğru tahmin edilen ay 13,96 ile Kasım ayı olurken, en kötü tahmin edilen ay 21,65 ile Eylül ayı olmuştur. Eylül ayındaki tahmin sonucunun diğerlerinden daha kötü olmasını okulların açılış zamanına denk gelmesiyle yorumlanabilmektedir. Aynı zamanda Ağustos ayı da 14,64 ile en doğru sonuçlar arasında yer almaktadır. Ağustos ayının yaz tatili sebebiyle daha doğru tahmin edilebilir bir zaman olduğu söylenebilir.



Şekil 5.25 Tüm Algılayıcıların Aylara Göre CNN, Polinom Regresyon, Ortalama Yöntemi Ortalama MAE Değerleri


Şekil 5.25'te CNN, Polinom Regresyon ve Ortalama Yöntemi sonucu tüm algılayıcıların ay bazında tahmin sonucuna göre ortalama MAE değerleri verilmiştir. CNN modeli ve Ortalama yöntemi MAE sonuçlarının ay bazında birbirine yakın olduğu gözlemlenmektedir. CNN modelinin, Polinom Regresyona göre ay bazında 1-2 arasında daha doğru sonuç ürettiği görülmektedir. 44 algılayıcı için en doğru tahmin edilen ay 7,02 ile Aralık ayı olurken, en kötü tahmin edilen ay 9,1 ile Eylül ayı olmuştur. Eylül ayındaki tahmin sonucunun diğerlerinden daha kötü olmasını okulların açılış zamanına denk gelmesiyle yorumlanabilmektedir. Temmuz, Ağustos, Ekim, Kasım, Aralık aylarının en doğru sonuçlarla tahmin edilebileceği görülmektedir. Haziran ve Eylül aylarında sonuca yansıyan daha az doğru sonuç elde etme sebebi okulların açılış ve kapanış aylarına denk gelmesinden kaynaklanmaktadır.

5.5 Tüm Algılayıcılar Saat Bazında Tahmin Değerlendirmesi

Uzun vadeli trafik yoğunluk tahmini için en uygun değişken parametrelerle, 15 dakika ileri geri gidilip aynı 5 dakikaların yan yana gelmesi ile oluşturulan veri seti kullanılarak kurulan CNN modelinin; tüm algılayıcılarda, gün içindeki saatlere göre tahmin gücü bu kısımda incelenmiştir.

Şekil 5.26'da 15 dakika ileri geri gidilerek aynı 5 dakikalar yan yana gelecek şekilde oluşturulmuş veri seti kullanılarak en doğru sonuç veren değişken parametrelerle CNN

modeli kurulması sonucu 44 farklı algılayıcı ve 7 farklı ay verisi için saat bazında MAPE ve MAE değerleri verilmiştir. Saat bazında tahmin sonucu elde edilirken sadece hafta içi günler değerlendirilmiştir. Şekilde x ekseninde 1 den 24'e kadar saat bilgisi verilmiştir. Burada 1; 00:00-01:00 saatleri arasını, 2; 01:00-02:00 saatleri arasını temsil edecek şekilde 24 değerine kadar sembolize edilmiştir. En kötü sonuç veren MAPE ve MAE değerlerinin iş çıkış saati olan 18, 19, 20 saatlerinde elde edildiği gözlemlenmektedir. Trafiğin en az yoğun olduğu 1, 2, 3, 4, 5, 6, 7, 8, 22, 23, 24 saatlerinde ise daha doğru sonuç elde edildiği gözlemlenmektedir.




Şekil 5.26 CNN Modeli Tüm Algılayıcılar Tüm Aylar için Saat Bazında MAPE ve MAE Sonuçları

5.6 Tüm Algılayıcılar Haftanın Günü Bazında Tahmin Değerlendirmesi

Uzun vadeli trafik yoğunluk tahmini için en uygun değişken parametrelerle, 15 dakika ileri geri gidilip aynı 5 dakikaların yan yana gelmesi ile oluşturulan veri seti kullanılarak kurulan CNN modelinin; tüm algılayıcılarda, haftanın gününe göre tahmin gücü bu kısımda incelenmiştir.

Şekil 5.27’de 15 dakika ileri geri gidilerek aynı 5 dakikalar yan yana gelecek şekilde oluşturulmuş veri seti kullanılarak en doğru sonuç veren değişken parametrelerle CNN modeli kurulması sonucu 44 farklı algılayıcı ve 7 farklı ay verisi için haftanın günü bazında MAPE ve MAE değerleri verilmiştir. MAPE ve MAE değerleri incelendiğinde en kötü MAPE sonuçlarının 17.74 ve 18.06 değerleri ile Pazartesi ve Perşembe günlerinde alındığı gözlemlenmektedir. En doğru sonucu ise 11.77 MAPE değeri ile Cumartesi günü alındığı gözlemlenmektedir. MAE değerleri de gün bazında MAPE değerleri ile doğru orantılı olacak şekilde sonuç verdiği gözlemlenmektedir.




Şekil 5.27 CNN Modeli Tüm Algılayıcılar Tüm Aylar için Haftanın Günü Bazında MAPE ve MAE Sonuçları

5.7 Algılayıcı Trafik Hız Değerleri Ortalama ve Standart Sapmasının CNN Tahmin Sonuçlarına Etkisi


Uzun vadeli trafik yoğunluk tahmini için en uygun değişken parametrelerle, 15 dakika ileri geri gidilip aynı 5 dakikaların yan yana gelmesi ile oluşturulan veri seti kullanılarak kurulan CNN modeli ile elde edilen tahmin sonucu MAPE değerleri ile eğitimde kullanılan hız verilerinin ortalama ve standart sapma değerleri arasındaki ilişki incelenecektir.

Şekil 5.28 ve Şekil 5.29'da 15 dakika ileri geri gidilerek aynı 5 dakikalar yan yana

gelecek şekilde oluşturulmuş veri seti kullanılarak en doğru sonuç veren değişken parametrelerle CNN modeli kurulması sonucu 44 farklı algılayıcı tüm aylar ortalama hız değerine karşılık tahmin sonucu elde edilen MAPE ve MAE değerleri verilmiştir. Ortalama hız ile tahmin sonucu arasında bir ilişki bulunmadığı gözlemlenmiştir.




Şekil 5.28 44 Algılayıcı Tüm Aylar Ortalama Hız Değerine Karşılık CNN ile Elde Edilen MAPE Değerleri




Şekil 5.29 44 Algılayıcı Tüm Aylar Ortalama Hız Değerine Karşılık CNN ile Elde Edilen MAE Değerleri

Şekil 5.30 ve Şekil 5.31’de 15 dakika ileri geri gidilerek aynı 5 dakikalar yan yana gelecek şekilde oluşturulmuş veri seti kullanılarak en doğru sonuç veren değişken parametrelerle CNN modeli kurulması sonucu 44 farklı algılayıcı tüm aylar ortalama standart sapma değerine karşılık tahmin sonucu elde edilen MAPE ve MAE değerleri verilmiştir. Algılayıcı tüm aylar ortalama standart sapma değeri arttıkça tahmin sonucu elde edilen MAPE ve MAE değerlerinin arttığı gözlemlenmektedir.



Şekil 5.30 44 Algılayıcı Tüm Aylar Standart Sapma Değerine Karşılık CNN ile Elde Edilen MAPE Değerleri



Şekil 5.31 44 Algılayıcı Tüm Aylar Standart Sapma Değerine Karşılık CNN ile Elde Edilen MAE Değerleri

6 SONUÇ VE ÖNERİLER

Uzun vadeli trafik yoğunluk tahmini için haftanın aynı günlerinde benzer örüntülerde hız verisi bulunduğu tespit edilerek, tahmin edilecek günden k hafta ($k=2,3,4,5$, ve 6 olmak üzere) geriye gidilerek veri setleri oluşturulmuştur.

Tahmin edilecek günden k hafta geriye gidilerek haftanın aynı gün ve dakikalarındaki hız verileri ortalaması alınarak uzun vadeli trafik yoğunluk tahmini yapılmış ve 44 farklı algılayıcı için 7 ayda ortalama %17,0036 MAPE değeri ile 7 güne kadar uzun vadeli trafik yoğunluk tahmini yapılmıştır. Ayrıca elde edilen geçmiş k hafta ortalama hız verileri kullanılarak 5. dereceden polinom regresyon eğrisi oluşturulmuş ve 44 farklı algılayıcı için 7 ayda ortalama %20,1602 MAPE değeri ile uzun vadeli trafik tahmini yapılmıştır.

Tahmin edilecek günden k hafta geriye gidilerek aynı 5 dakika dilimindeki hız verileri yan yana dizilerek veri seti oluşturulmuş ve CNN modeli filtre sayısı, kernel boyutu, düğüm sayısı, katman sayısı, optimizasyon algoritması, öğrenme oranı, aktivasyon fonksiyonu, batch boyutu, epoch sayısı gibi farklı değişken parametreler değiştirilerek çalıştırılmış ve model başarısı karşılaştırılmıştır. Bu veri setinde en doğru sonucun; filtre sayısı 2, kernel boyutu 4, düğüm sayısı 10, katman sayısı 1, optimizasyon algoritması Adagrad, aktivasyon fonksiyonu Relu, batch boyutu 256, epoch sayısı 15 ile elde edildiği gözlemlenmiştir.

CNN modeli için en doğru tahmin üreten değişken parametreler kullanılarak; geçmiş k hafta hız verilerine 15 dakika ileri ve geri hız verilerinin eklenmesi ile oluşturulmuş 2 farklı veri seti için de CNN modeli çalıştırılmış ve sonuçlar elde edilmiştir. CNN modeli en başarılı sonucu 44 farklı algılayıcı için 7 ayda ortalama 16,6006 MAPE değeri ile; geçmiş k hafta hız verisine 15 dakika ileri ve geri hız verisinin aynı 5 dakikalar yan yana gelecek şekilde dizilimi ile oluşturulmuş veri setinde elde etmiştir.

CNN yöntemi algılayıcı bazında MAPE değeri %3-10 arası, Polinom Regresyon yönteminden daha doğru sonuç üretmektedir. CNN yöntemi 44 farklı algılayıcı için

7 ay verileri tahmin sonucu MAPE ortalamasında, Ortalama yönteminden yaklaşık %1 daha iyi tahmin başarısı elde etmektedir.

Çalışmada kullanılan tüm yöntemlerin başarıları algılayıcı ve ay bazında değişmektedir. İstanbul 1. ve 2. köprüde bulunan 443, 444, 445, 1749 algılayıcıları hız verisi ile oluşturulan tahmin sonuçları diğer algılayıcılara göre daha az başarı elde etmiştir.

Tahmin sonuçları, 44 farklı algılayıcı 7 farklı ay için saat bazında değerlendirilmiştir. En kötü sonuç veren MAPE ve MAE değerlerinin iş çıkış saati olan 18, 19, 20 saatlerinde elde edildiği gözlemlenmektedir. Trafiğin en az yoğun olduğu 1, 2, 3, 4, 5, 6, 7, 8, 22, 23, 24 saatlerinde ise daha doğru sonuç elde edildiği gözlemlenmektedir. Tahmin sonuçları haftanın günü bazında değerlendirildiğinde en doğru sonuç cumartesi günü alınmıştır. Aynı zamanda 44 farklı algılayıcı için ortalama hız ve standart sapma değerleri elde edilerek tahmin sonucuna etkisi incelenmiştir. Hız ortalaması tahmin sonucuna etki etmezken, standart sapma arttıkça tahmin doğruluğunun düştüğü gözlemlenmiştir.

Ay bazında tahmin sonuçlarında Haziran ve Eylül ayları verisi kullanılarak elde edilen tahmin sonuçlarının başarısı diğer aylara göre düşük çıkmıştır. Haziran ve Eylül aylarındaki trafik yoğunluğunu okulların açılış ve kapanış tarihi olması etkilemektedir.

Elde edilen sonuçlarla standart sapması yüksek algılayıcılar için, trafik yoğunluğu fazla olan saatler, özel günler ve aylar için farklı derin öğrenme modellerinin oluşturulması gelecekteki çalışmalar için önerilmektedir. Ayrıca kurulan derin öğrenme modeline hava durumunun eklenmesi de gelecek çalışmalarda başarıyı arttıracakını düşündüğümüz özelliklerden biridir.

- [1] E. Bolshinsky R. Friedman, “Traffic flow forecast survey,” Computer Science Department, Technion, Tech. Rep., 2012.
- [2] *Google haritalar*. [Online]. Available: <https://www.google.com/maps> (visited on 07/03/2019).
- [3] *Yandex haritalar*. [Online]. Available: <https://yandex.com.tr/harita> (visited on 01/03/2020).
- [4] *Yandex haritalar*. [Online]. Available: https://yandex.com.tr/company/press_center/infographics/istanbul_traffic (visited on 07/03/2019).
- [5] M. G. Karlaftis E. I. Vlahogianni, “Statistical methods versus neural networks in transportation research: Differences, similarities and some insights,” *Transportation Research Part C: Emerging Technologies*, vol. 19, no. 3, pp. 387–399, 2011.
- [6] J. Van Lint C. Van Hinsbergen, “Short-term traffic and travel time prediction models,” *Artificial Intelligence Applications to Critical Transportation Issues*, vol. 22, no. 1, pp. 22–41, 2012.
- [7] E. I. Vlahogianni, M. G. Karlaftis, J. C. Golias, “Short-term traffic forecasting: Where we are and where we’re going,” *Transportation Research Part C: Emerging Technologies*, vol. 43, pp. 3–19, 2014.
- [8] S. Wong, W. Szeto, Q. Ye, “Short-term traffic speed forecasting based on data recorded at irregular intervals,” in *13th International IEEE Conference on Intelligent Transportation Systems (ITSC 2010) Institute of Electrical and Electronics Engineers (IEEE)*, 2010.
- [9] F. G. Habtemichael M. Cetin, “Short-term traffic flow rate forecasting based on identifying similar traffic patterns,” *Transportation research Part C: emerging technologies*, vol. 66, pp. 61–78, 2016.
- [10] X. Ma, Z. Tao, Y. Wang, H. Yu, Y. Wang, “Long short-term memory neural network for traffic speed prediction using remote microwave sensor data,” *Transportation Research Part C: Emerging Technologies*, vol. 54, pp. 187–197, 2015.
- [11] Y. Lv, Y. Duan, W. Kang, Z. Li, F.-Y. Wang, “Traffic flow prediction with big data: A deep learning approach,” *IEEE Transactions on Intelligent Transportation Systems*, vol. 16, no. 2, pp. 865–873, 2014.
- [12] H. Yu, Z. Wu, S. Wang, Y. Wang, X. Ma, “Spatiotemporal recurrent convolutional networks for traffic prediction in transportation networks,” *Sensors*, vol. 17, no. 7, p. 1501, 2017.

- [13] X. Ma, Z. Dai, Z. He, J. Ma, Y. Wang, Y. Wang, "Learning traffic as images: A deep convolutional neural network for large-scale transportation network speed prediction," *Sensors*, vol. 17, no. 4, p. 818, 2017.
- [14] X. Luo, D. Li, Y. Yang, S. Zhang, "Spatiotemporal traffic flow prediction with knn and lstm," *Journal of Advanced Transportation*, vol. 2019, 2019.
- [15] W. Jin, Y. Lin, Z. Wu, H. Wan, "Spatio-temporal recurrent convolutional networks for citywide short-term crowd flows prediction," in *Proceedings of the 2nd International Conference on Compute and Data Analysis*, ACM, 2018, pp. 28–35.
- [16] Z. Hou X. Li, "Repeatability and similarity of freeway traffic flow and long-term prediction under big data," *IEEE Transactions on Intelligent Transportation Systems*, vol. 17, no. 6, pp. 1786–1796, 2016.
- [17] N. G. Polson V. O. Sokolov, "Deep learning for short-term traffic flow prediction," *Transportation Research Part C: Emerging Technologies*, vol. 79, pp. 1–17, 2017.
- [18] H. Özbek S. Keskin, "Standart sapma mı yoksa standart hata mı?" *Van tıp dergisi*, vol. 14, no. 2, pp. 64–67, 2007.
- [19] S. K. Köse, *Korelasyon ve regresyon analizi*, 2008. [Online]. Available: <https://www.scribd.com/document/2066772/korelasyon-analizi> (visited on 03/05/2019).
- [20] J. Schmidhuber, "Deep learning in neural networks: An overview," *Neural networks*, vol. 61, pp. 85–117, 2015.
- [21] M. Längkvist, L. Karlsson, A. Loutfi, "A review of unsupervised feature learning and deep learning for time-series modeling," *Pattern Recognition Letters*, vol. 42, pp. 11–24, 2014.
- [22] P. Swietojanski, A. Ghoshal, S. Renals, "Convolutional neural networks for distant speech recognition," *IEEE Signal Processing Letters*, vol. 21, no. 9, pp. 1120–1124, 2014.
- [23] B. Zhao, H. Lu, S. Chen, J. Liu, D. Wu, "Convolutional neural networks for time series classification," *Journal of Systems Engineering and Electronics*, vol. 28, no. 1, pp. 162–169, 2017.

TEZDEN ÜRETİLMİŞ YAYINLAR

İletişim Bilgileri: fethiyyasli@gmail.com

Konferans Bildirisi

1. YASLI, Fethiye; TÜRKMEN, H. İrem; GÜVENSAN, M. Amaç. Long-term Traffic Speed Estimation via Regression using Weekly Day Patterns. In: 2019 Innovations in Intelligent Systems and Applications Conference (ASYU). IEEE. p. 1-6.