

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**AĞ TRAFİĞİ TAHMİNİNDE MAKİNE ÖĞRENMESİ ALGORİTMALARININ
KARŞILAŞTIRMALI ANALİZİ**

YÜKSEK LİSANS TEZİ

Buse Dilan USLAN

İşletme Mühendisliği Anabilim Dalı

İşletme Mühendisliği Programı

HAZİRAN 2025

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**AĞ TRAFİĞİ TAHMİNİNDE MAKİNE ÖĞRENMESİ ALGORİTMALARININ
KARŞILAŞTIRMALI ANALİZİ**

YÜKSEK LİSANS TEZİ

**Buse Dilan USLAN
507211041**

İşletme Mühendisliği Anabilim Dalı

İşletme Mühendisliği Programı

Tez Danışmanı: Prof. Dr. Ferhan ÇEBİ

HAZİRAN 2025

ISTANBUL TECHNICAL UNIVERSITY ★ GRADUATE SCHOOL

**A COMPARATIVE ANALYSIS OF MACHINE LEARNING ALGORITHMS ON
NETWORK TRAFFIC FORECASTING**

M.Sc. THESIS

**Buse Dilan USLAN
(507211041)**

Department of Management Engineering

Management Engineering Programme

Thesis Advisor: Prof. Dr. Ferhan ÇEBİ

JUNE 2025

İTÜ, Lisansüstü Eğitim Enstitüsü'nün 507211041 numaralı Yüksek Lisans Öğrencisi Buse Dilan USLAN, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “AĞ TRAFİĞİ TAHMİNİNDE MAKİNE ÖĞRENMESİ ALGORİTMALARININ KARŞILAŞTIRMALI ANALİZİ” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Prof. Dr. Ferhan ÇEBİ**
İstanbul Teknik Üniversitesi

Doç. Dr. Tuncay ÖZCAN
İstanbul Teknik Üniversitesi

Doç. Dr. Ersin NAMLI
İstanbul Üniversitesi - Cerrahpaşa

Teslim Tarihi : 26 Mayıs 2025
Savunma Tarihi : 25 Haziran 2025





Gelecekteki kendime,



ÖNSÖZ

Tüm eğitim yolculuğumu destekleyen sevgili aileme teşekkür ederim. Bu tezin hayata geçmesi için bana zaman tanıyan tüm iş arkadaşlarıma teşekkür ederim. Her türlü zorluğa rağmen yılmadan çalışmaya devam eden, hayallerinin peşinden giden, imkansızları olduran kendime teşekkür ederim.

Ders aşamasındaki emeklerimin boşa gitmemesini sağlayan sevgili hocam Prof. Dr. Ferhan Çebi'ye süreçteki tüm yardımları, desteği ve ilgisi için teşekkür ederim.

Haziran 2025

Buse Dilan USLAN
(Veri Bilimci)

İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	ix
İÇİNDEKİLER	xi
KISALTMALAR	xiii
ÇİZELGE LİSTESİ.....	xv
ŞEKİL LİSTESİ.....	xvii
ÖZET.....	xix
SUMMARY	xxi
1. GİRİŞ...	1
1.1 Tezin Amacı	1
1.2 Literatür Araştırması	2
2. AĞ TRAFİK TAHMİNİNİN ÖNEMİ	19
2.1 Zaman Serisi Tahminleme Yöntemleri	20
2.1.1 İstatistiksel yöntemler	20
2.1.1.1 ARIMA	20
2.1.1.2 SARIMA	21
2.1.1.3 Üssel düzeltme	22
2.1.2 Makine öğrenmesi yöntemleri	22
2.1.2.1 Karar ağaçları	23
2.1.2.2 Rastgele ormanlar.....	23
2.1.2.3 Destek vektör makineleri	23
2.1.2.4 Gradyan artırma makineleri	23
2.1.3 Derin öğrenme yöntemleri	24
2.1.3.1 Tekrarlayan sinir ağları (recurrent neural networks)	24
2.1.3.2 Uzun kısa süreli bellek (long short-term memory)	24
2.1.4 Diğer yöntemler	25
2.1.4.1 Prophet	25
2.2 Performans Ölçme Metrikleri.....	26
2.2.1 R^2 skoru	26
2.2.2 Ortalama mutlak hata (mean absolute error).....	27
2.2.3 Ortalama kare hata (mean squared error).....	27
2.2.4 Karekök ortalama kare hata (root mean squared error)	28
3. UYGULAMA.....	29
3.1 Veri Setinin Tanıtımı.....	29
3.2 Model Sonuçları	30
3.2.1 Prophet	31
3.2.2 SARIMA	31
3.2.3 LSTM	32
3.2.4 Hibrit model	34
3.2.5 Karşılaştırma	34
4. SONUÇ VE ÖNERİLER.....	37

KAYNAKLAR.....	39
ÖZGEÇMİŞ.....	43



KISALTMALAR

MAE	: Ortalama mutlak hata
MSE	: Ortalama hata karesi
RMSE	: Kök ortalama kare hatası
LSTM	: Uzun kısa süreli bellek
SARIMA	: Mevsimsel otoregresif entegre hareketli ortalama
ARIMA	: Ototregresif entegre hareketli ortalama
IoT	: Nesnelerin internet
AIC	: Akaike ölçütü
5G	: Beşinci nesil



ÇİZELGE LİSTESİ

Sayfa

Çizelge 1.1 : Literatür araştırması için taksonomi.....	16
Çizelge 2.1 : Üssel düzeltme algoritmalarının kullanım durumlarının özeti.....	22
Çizelge 2.2 : Makine öğrenmesi algoritmalarının özellik kıyaslaması.....	22
Çizelge 2.3 : Derin öğrenme yöntemlerinin kıyaslaması.....	24
Çizelge 3.1 : SARIMA modelinin seçtiği parametreler.....	32
Çizelge 3.2 : Tüm modellerin performans metriklerine göre kıyaslanması.....	35





ŞEKİL LİSTESİ

Sayfa

Şekil 3.1: Prophet modelinin tahminleri ile gerçek değerlerin kıyaslanması.	31
Şekil 3.2: SARIMA modelinin tahminleri ile gerçek değerlerin kıyaslanması.	32
Şekil 3.3: LSTM modelinin tahminleri ile gerçek değerlerin kıyaslanması.	33
Şekil 3.4: Hibrit modelin tahminleri ile gerçek değerlerin kıyaslanması.	34





AĞ TRAFİĞİ TAHMİNİNDE MAKİNE ÖĞRENMESİ ALGORİTMALARININ KARŞILAŞTIRMALI ANALİZİ

ÖZET

Günümüzde dijitalleşmenin hız kazanması ve teknoloji kullanımının yaygınlaşması, veri trafiğinde önemli bir artışa neden olmuştur. Akıllı telefonların, nesnelerin interneti (IoT) cihazlarının ve 5G teknolojisinin yaygınlaşması gibi faktörler, telekomünikasyon ağlarındaki yükü önemli ölçüde artırmıştır. Bu nedenle, ağ yönetiminin verimli hale getirilmesi ve kapasite planlamasının doğru bir şekilde yapılması, artan veri trafiğiyle başa çıkmak için hayati bir öneme sahiptir.

Telekomünikasyon şirketleri, gelecekteki ağ ihtiyaçlarını öngörerek kapasite yatırımlarını optimize etmek ve rekabet avantajı elde etmek için ileri tahmin yöntemlerine başvurmaktadır. Tahmin hataları, gereğinden fazla yatırım maliyetine neden olabileceği gibi karşılanmayan taleplere ve dolayısıyla müşteri memnuniyetinin azalmasına da neden olabilir.

Telekomünikasyon sektöründe en geniş müşteri tabanı mobil teknolojilere (2G, 3G, 4G) dayanmaktadır. Bu nedenle, mobil kapasite ihtiyaçlarının doğru tahmin edilmesi, kesintisiz ve kaliteli hizmet sunmak açısından büyük önem taşımaktadır. Her şebeke kendine özgü olduğu için şebekenin sezonsal trafik değişikliklerini en iyi tahminleyecek modelin kurulması gerekmektedir. Bu bağlamda, bu çalışmanın amacı, farklı makine öğrenmesi algoritmalarını karşılaştırmalı bir şekilde değerlendirerek ağ trafiği tahmini için en uygun yaklaşımları belirlemektir. Araştırma kapsamında SARIMA, Prophet, LSTM ve hibrit bir model (Prophet+LSTM) detaylı olarak incelenmiştir.

Çalışma için gerçek veri kullanma konusunda bazı kısıtlamalarla karşılaşmıştır. Bundan dolayı sektör uzmanlarının yardımı ile 2023-2024 yıllarının ortalama trafik değeri üzerine günlük ve aylık sezonsallık eklenerek iki yıllık bir veri seti elde edilmiştir. 24 aylık verinin 18 ayı eğitim, 6 ayı ise test için kullanılmıştır.

Çalışmada kullanılan modellerin her biri farklı yaklaşımlara dayanmaktadır. SARIMA, istatistiksel yöntemlerin klasik bir temsilcisi olarak, lineer trendleri ve sezonsal bileşenleri tahmin etmekte etkilidir. Prophet modeli, özellikle sezonsallık, trend ve tatil etkilerini modelleyebilme kapasitesiyle kullanıcı dostu bir araç olarak öne çıkmaktadır. LSTM modeli ise derin öğrenme tabanlı bir yöntem olarak, karmaşık zaman serisi desenlerini öğrenme kapasitesine sahiptir ve uzun vadeli tahminlerde yüksek doğruluk sağlayabilmektedir. Hibrit model ise Prophet'in trend analizi gücü ile LSTM'in yüksek doğruluk sağlayan tahmin yeteneklerini birleştirerek daha güçlü bir tahmin aracı oluşturmuştur.

Modellerin her biri için hiperparametre optimizasyonu yapılmıştır. SARIMA için AIC (Akaike ölçütü), Prophet için Grid Search, LSTM için Keras Tuner kullanılmıştır.

Hibrit modelde de Prophet ve LSTM için belirlenen en iyi parametreler kullanılmıştır. Bu algoritmaların detayları uygulama bölümünde verilmiştir.

Modellerin performansı, ortalama mutlak hata (MAE), ortalama karesel hata (MSE), kök ortalama hata karesi (RMSE) ve R^2 skoru gibi metriklerle ölçülmüştür. Sonuçlar, her bir modelin avantaj ve dezavantajlarını açıkça ortaya koymuştur. SARIMA ve LSTM'in tek başlarına yeterince iyi tahminleme yapamadığı, Prophet'in sezonsallığı çok iyi öğrendiği görülmüştür. Hibrit modelin ise diğer modellerden daha yüksek doğruluk oranlarına ulaştığı gözlemlenmiştir. Bu durum, hibrit modellerin, farklı algoritmaların güçlü yanlarını bir araya getirerek üstün performans sağlayabileceğini göstermektedir.

Sonuç olarak, bu çalışma, makine öğrenmesi algoritmalarının telekomünikasyon sektöründe ağ trafiği tahmini üzerindeki potansiyelini ve önemini vurgulamaktadır. Doğru tahmin modellerinin kullanımı, şirketlerin kaynaklarını daha verimli bir şekilde yönetmesini, maliyetlerini optimize etmesini ve kullanıcı deneyimini geliştirmesini mümkün kılmaktadır.

Çalışmanın sonuçları, yalnızca akademik bir katkı sağlamakla kalmayıp, aynı zamanda sektör profesyonellerine yönelik pratik bir rehber niteliği taşımaktadır. Gelecekte, makine öğrenmesi tabanlı modellerin daha geniş bir ölçekte kullanılması ve bu alanda yeni hibrit yaklaşımların geliştirilmesi, telekomünikasyon şirketlerinin stratejik karar alma süreçlerinde önemli bir rol oynayacaktır.

A COMPARATIVE ANALYSIS OF MACHINE LEARNING ALGORITHMS ON NETWORK TRAFFIC FORECASTING

SUMMARY

In recent years, the increasing demand for internet services and the rapid growth of digital transformation have significantly impacted telecommunication networks. As data consumption continues to increase, ensuring efficient network capacity planning has become a crucial challenge for network providers due to the introduction of 5G, the growth of IoT devices, and the growing dependence on cloud-based apps.

Accurate forecasting of network traffic plays a vital role since it helps businesses to predict future demand, optimize network infrastructure, make well-informed investment decisions and improving overall network performance. Through my research, I aimed to explore how different machine learning algorithms can improve the accuracy and reliability of network traffic predictions. Therefore, this paper examines the effectiveness of various algorithms with a focus on SARIMA, Prophet, LSTM, and a hybrid Prophet-LSTM model.

Time series forecasting techniques have been widely applied in various domains, including finance, energy, and telecommunications. In the context of network traffic forecasting, traditional statistical models such as Seasonal AutoRegressive Integrated Moving Average (SARIMA) and Prophet have been commonly used due to their interpretability and efficiency in handling seasonality. However, as deep learning has advanced, models like Long Short-Term Memory (LSTM) networks have demonstrated encouraging outcomes in capturing complicated temporal dependencies. Additionally, hybrid models that combine the strengths of both statistical and deep learning approaches have showed up as a potential solution for enhancing forecasting accuracy.

The study focused on the usefulness of these models for the telecom sector in addition to quantitative assessments. Wide-ranging advantages of accurate network traffic forecasting include increased customer satisfaction, lower operating costs and improved service quality for operators. For example, operators can proactively allocate resources to avoid congestion and maintain optimal performance by forecasting peak traffic periods. In a similar way, long-term forecasts can direct strategic network expansion investments, guaranteeing that infrastructure expansion matches with the expected demand.

Due to data privacy laws in Türkiye and the fact that the telecommunications sector contains a lot of critical and confidential information, some restrictions were encountered in using real data for the study. Therefore, with the help of industry experts, a two-year data set was obtained by adding daily and monthly seasonality to the average traffic value of 2023-2024. With 18 months of data set aside for training and the remaining 6 months set aside for testing, the study used a standard data

partitioning technique. By simulating actual forecasting conditions, this approach made sure the models were tested on unobserved data. Hyperparameter tuning was performed for all four models.

Four different forecasting models, each with its own advantages and disadvantages, were used. Based on statistical principles, the SARIMA model is excellent at detecting seasonality and linear trends. However, it assumes data stationarity, which frequently requires for transformation methods like logarithmic scaling or differencing. Despite being simple and easy to understand, SARIMA has downsides when working with datasets that contain complex, non-linear patterns or long-term dependencies.

Prophet, developed by Facebook, addresses several of SARIMA's shortcomings. Its ability to model holidays, handle missing data, and incorporate custom seasonality makes it particularly well-suited for business applications. Prophet's flexibility in adjusting to irregular intervals and its user-friendly interface contribute to its popularity among practitioners. However, like SARIMA, it struggles with short-term irregular fluctuations and lacks the capacity to model complex non-linear relationships.

A new approach in time series forecasting is represented by LSTM, a type of recurrent neural network. It is an effective tool for complex datasets because of its architecture, which is made to learn non-linear patterns and capture long-term dependencies. In contrast to SARIMA and Prophet, LSTM requires a large amount of processing power and careful adjustment of hyperparameters like batch size, learning rate, and layer count. Despite these difficulties, LSTM performed well in simulating both long-term trends and short-term fluctuations.

A hybrid model was created to take advantage of Prophet and LSTM's complementary strengths. First, Prophet was used to extract seasonality components and long-term trends from the data. The residuals, which represent the error rate for each prediction, were then fed into the LSTM model for further analysis. This combination performed very well, achieving increased accuracy since the errors have been learned and fine-tuned.

Hyperparameter tuning was performed for each model. AIC (Akaike Information Criterion) was used for SARIMA, Grid Search for Prophet, and Keras Tuner for LSTM. The hybrid model also used the best parameters determined for Prophet and LSTM. Details of these algorithms are provided in the application section.

The models' performance was evaluated using key metrics, including Mean Absolute Error (MAE), Mean Squared Error (MSE), Root Mean Squared Error (RMSE) and R^2 score. MAE measures the average absolute difference between actual and predicted values. MSE penalizes larger errors more heavily. RMSE provides a more interpretable measure of prediction errors and does not penalize larger errors as much as MSE. R^2 score is a statistical measure that represents the proportion of the variance for a dependent variable that's explained by an independent variable. R^2 score is a metric frequently used to interpret the performance of regression and time series problems.

SARIMA delivered reliable results for stationary data and short-term forecasts but struggled with dynamic, non-linear datasets. However, it exhibited limitations in capturing short-term irregularities. Prophet outperformed both SARIMA and LSTM in scenarios requiring long-term predictions, achieving lower error rates and greater adaptability.

The hybrid Prophet-LSTM model emerged as the best-performing approach, combining the interpretability of Prophet with the predictive power of LSTM to deliver consistently accurate results. It offers significant potential for real-world applications. Its ability to balance interpretability and predictive accuracy makes it an ideal choice for scenarios where both short-term adjustments and long-term planning are critical. Moreover, the modular nature of the hybrid approach allows for further enhancements, such as integrating external data sources. For example, incorporating football game schedules, special dates and holidays, campaign periods, weather data, social media trends, or regional demographic information could improve the model's performance by providing additional context for traffic patterns.

To summarize, each of the models used in the study is based on different approaches. SARIMA, as a classic representative of statistical methods, is effective in estimating linear trends and seasonal components. The Prophet model stands out as a user-friendly tool, especially with its capacity to model seasonality, trend and holiday effects. The LSTM model, on the other hand, is a deep learning-based method, has the capacity to learn complex time series patterns and can provide high accuracy in long-term forecasts. The hybrid model combines the trend analysis power of Prophet with the high accuracy forecasting capabilities of LSTM to create a more powerful forecasting tool.

This study also clarifies the larger effects of machine learning in network management. In addition to forecasting, these algorithms can be applied to tasks such as capacity optimization, anomaly detection, and user behavior analysis. For example, customer segmentation models can help operators customize their services to specific user groups, enhancing customer churn rates and revenue growth.

This study recognizes several limitations and potential future research areas despite its promising results. Despite being comprehensive, the dataset's daily granularity may have covered more subtle details that could be seen in weekly or hourly data. The applicability of these models for high-frequency datasets may be investigated in future research, offering more detailed information for operational decision-making. Furthermore, even though the hybrid Prophet-LSTM model performed better, the need for more efficient methods is highlighted by its computational complexity and heavy reliance on preprocessing. The usability and scalability of the model could be further improved by creating automated pipelines for feature engineering, data preparation, and outlier detection.

In conclusion, from my observations throughout this research, this study underscores the critical role of machine learning in network traffic forecasting, demonstrating the unique strengths and limitations of SARIMA, Prophet, LSTM, and hybrid Prophet-LSTM models. While SARIMA and LSTM are effective for quick, interpretable forecasts, Prophet and hybrid models excel in capturing complex, long-term patterns. The hybrid Prophet-LSTM model, in particular, represents a significant advancement in forecasting methodology, offering a balanced solution for diverse use cases. As the telecommunications industry continues to evolve, leveraging advanced machine learning techniques will be essential in addressing emerging challenges and unlocking new opportunities for growth and innovation.



1. GİRİŞ

Telekomünikasyon sektörü, dijital dönüşümün itici gücü olarak günümüzde stratejik bir öneme sahiptir. Ericsson'un 2024 tarihli Mobilite Raporu'na göre, küresel mobil veri trafiği her yıl yaklaşık %30 oranında artmakta ve 5G aboneliklerinin 2029 yılına kadar toplam mobil aboneliklerin %60'ını oluşturması beklenmektedir (Ericsson, 2024). Bu hızlı büyüme, yalnızca bireysel kullanıcıların değil, aynı zamanda nesnelerin interneti (IoT), akıllı şehirler ve endüstriyel otomasyon gibi alanlarda da artan veri talebini beraberinde getirmektedir.

Türkiye'de ise halihazırda 2G, 3G ve 4G teknolojileri yaygın olarak kullanılmaktadır ancak yakın gelecekte 5G teknolojisinin devreye girmesiyle beraber çok daha yüksek veri hızları, düşük gecikme süreleri ve daha güvenilir bağlantıların mümkün olacağı öngörülmektedir. Bu gelişmeler sayesinde, kullanıcıların gerçek zamana yakın bir iletişim deneyimi yaşamaları sağlanacaktır. 5G'nin sunduğu bu yüksek kapasiteli yapı, aynı zamanda operatörler için de ciddi bir planlama ve kaynak yönetimi gereksinimi doğurmaktadır.

Artan kapasite ve hız talepleri, telekomünikasyon şirketlerini geleceğe yönelik tahminleme sistemleri geliştirmeye ve altyapı yatırımlarını veri odaklı bir şekilde yönlendirmeye zorlamaktadır. Bu bağlamda, makine öğrenmesi temelli tahminleme modelleri, ağ trafiğini öngörme ve kaynakları etkin bir şekilde dağıtma açısından önemli bir rol oynamaktadır.

1.1 Tezin Amacı

Bu tez, telekomünikasyon trafiği verileri üzerinden yapılan zaman serisi analizlerinde farklı modelleme tekniklerinin karşılaştırmalı performansını değerlendirmeyi amaçlamaktadır. Zaman serisi tahmini (time series forecasting), geçmişe ait zaman damgalı verilerdeki desenleri ve eğilimleri analiz ederek gelecekteki değerlerin öngörülmesini sağlayan önemli bir veri bilimi yaklaşımıdır. Artan veri trafiği karşısında, ağ kaynaklarının etkin şekilde planlanması ve potansiyel tıkanıklıkların

önceden tespit edilebilmesi için doğru tahmin modellerine ihtiyaç duyulmaktadır. Bu bağlamda hem klasik hem de modern yaklaşımlar kullanılarak trafik tahmininde en başarılı yöntemin belirlenmesi hedeflenmiştir.

Çalışma kapsamında istatistiksel kökenli SARIMA, zaman serisi tahmininde sezonsallıkları tespit etmekte oldukça başarılı olan Prophet, derin öğrenme tabanlı LSTM ve bu iki modelin hibrit versiyonu olan Prophet + LSTM değerlendirilmiştir. Her bir model, aynı veri seti üzerinde eğitilmiş ve MAE, MSE, RMSE ve R^2 skoru gibi yaygın performans metrikleri ile test edilmiştir.

Mobil trafik verilerinin hazırlanması, analiz edilmesi, farklı makine öğrenmesi algoritmalarından oluşturulan modellerin uygulanması, karşılaştırılması, hibrit bir model önerisi ve performans analizlerinin yapılması ve geleceğe yönelik öneriler sunmak bu tezin kapsamını oluşturmaktadır.

Bu çalışma yalnızca tarihsel trafik verilerini kullanmaktadır, ani değişiklikler (örneğin doğal afetler, maçlar, sosyal olaylar, vb.) gibi dış faktörler kapsam dışı bırakılmıştır. Ayrıca, model performansı yalnızca seçilen metrikler çerçevesinde değerlendirilmiştir.

1.2 Literatür Araştırması

Ağ trafiği tahmini günümüzde telekomünikasyon sektörünün verimliliği, ağ servisinin kalitesi ve müşteri deneyimi için kritik öneme sahiptir. Geçmişten günümüze tahminleme algoritmaları gelişerek farklı zaman serisi problemlerine uyumlu hale gelmişlerdir ve özellikle ağ trafiği gibi ardışık, hacimli ve istatistiksel olarak bağımlı verilerin analizinde sıklıkla tercih edilmektedirler. Geçmişte birçok farklı algoritmanın farklı zaman serisi problemlerinde veya ağ trafiğinde kıyaslamalı analizi yapılmıştır.

Katwal ve arkadaşlarına göre, internet sitesi trafik tahmininde doğru modellerin kullanılması, özellikle gelecekteki trafik yoğunluğunu doğru bir şekilde tahmin edebilmek için kritik öneme sahiptir. Bu tür tahminler, geçmiş verilerin ve mevcut trendlerin gelecekteki trafik üzerindeki etkisini anlamaya dayanır. ARIMA, Prophet ve LSTM gibi yöntemler, internet sitesi trafiğini tahmin etmek için yaygın olarak kullanılmaktadır ve her birinin kendine has avantajları ve sınırlamaları vardır. ARIMA'nın zaman serisi verilerindeki lineer ilişkileri iyi modellediği, ancak karmaşık sezonluk ve trend değişikliklerini hesaba katmada yetersiz kaldığı belirtilmiştir. Prophet ise sezonluk değişiklikleri ve tatil etkilerini başarılı bir şekilde modelleyebilir,

ancak yine de bazı veri setlerinde doğruluk sorunları yaşanabilir. LSTM ise derin öğrenme temelli bir yaklaşım olarak, karmaşık ve uzun dönemli bağımlılıkları öğrenme kapasitesine sahip olmakla birlikte, yeterli eğitim verisi ve hesaplama gücü gerektirebilir. Bu araştırmada, tek başına her bir modelin sınırlamaları nedeniyle, daha doğru tahminler elde edebilmek için hibrit modellerin kullanılması gerektiği vurgulanmıştır (Katwal, 2023).

Prajam ve arkadaşlarına göre, ağ trafiği tahmini, ağ yönetiminde önemli bir yer tutmaktadır çünkü doğru tahminler, ağ kaynaklarının daha verimli kullanılmasını ve hizmet kalitesinin iyileştirilmesini sağlar. Çalışmalarında, ağ trafiği tahmininde kullanılan çeşitli yöntemleri incelemişler ve özellikle makine öğrenmesi (ML) ve istatistiksel modellerin karşılaştırılmasına odaklanmışlardır. Yazarlar, özellikle derin öğrenme tabanlı yöntemlerin, geçmiş verilerden öğrenme kapasitesinin yüksek olduğunu ve karmaşık ağ trafiği desenlerini daha doğru bir şekilde modelleyebildiğini vurgulamaktadır. ARIMA gibi geleneksel zaman serisi tahmin teknikleri, doğrusal ilişkilerle sınırlı kalırken, yapay zeka tabanlı yöntemler daha doğru sonuçlar elde etmek için potansiyel sunmaktadır. Çalışma, ağ trafiği tahmininde bu iki yaklaşımın birleşimi ile daha doğru sonuçlar alınabileceğini savunmaktadır. Ayrıca, makine öğrenmesi tekniklerinin daha karmaşık ağ yapılarında ve daha büyük veri setlerinde etkili bir şekilde kullanılabileceği belirtilmiştir (Prajam, 2022).

Ertürk (2024) çalışmasında İstanbul Büyükşehir Belediyesi'nden alınan metro ulaşım verileri kullanılarak, akıllı ulaşım sistemlerinde (ITS) zaman serisi tahmin modellerinin performansını değerlendirmektedir. Özellikle, Dijital İkiz (Digital Twin - DT) mimarisi çerçevesinde kamu ulaşım altyapısının gerçek zamanlı izlenmesi ve yönetimi amaçlanmıştır. DT; fiziksel sistemlerin sanal bir yansıması olup, IoT ve makine öğrenmesi (ML) teknikleri ile desteklenerek ulaşım sistemlerinin etkinliğini artırmada kullanılmaktadır. Çalışmada üç farklı zaman serisi tahmin yöntemi karşılaştırılmıştır: Long Short-Term Memory (LSTM) sinir ağları, Facebook Prophet ve ARIMA. Elde edilen sonuçlara göre, tek değişkenli senaryolarda Prophet modeli diğer iki yöntemle göre hafif bir üstünlük göstermiştir. LSTM ise daha karmaşık senaryolar için potansiyel sunmaktadır ancak eğitim süreci daha fazla kaynak gerektirmektedir. Gelecek çalışmalarda çok değişkenli zaman serisi modellerinin gerçek zamanlı simülasyon ortamlarında uygulanması ve federated learning yaklaşımları ile gizlilik odaklı tahmin sistemlerinin geliştirilmesi hedeflenmektedir.

Gao (2022) çalışmasında, zaman serisi tahmin modellerinin pratik uygulamalardaki önemini vurgulayarak, özellikle karmaşık ve doğrusal olmayan yapıya sahip zaman serileri için tek bir modelin yetersiz kaldığını belirtmektedir. Facebook tarafından geliştirilen açık kaynaklı Prophet modeli, zaman serisi tahmininde basitlik, esneklik ve sağlamlık açısından öne çıkmaktadır. Ancak Prophet gibi tekil modeller, karmaşık örüntüleri ve ilişkileri tam olarak yakalamakta zorlanabilir. Bu soruna çözüm olarak, Prophet modelinin uzun-kısa vadeli bellek ağı olan LSTM ile birleştirildiği Prophet-LSTM hibrit modeli önerilmektedir. Çalışmada öncelikle klasik zaman serisi modelleri ve bu modellerin eksiklikleri tartışılmış, ardından Prophet-LSTM modelinin prensipleri ve avantajları açıklanmıştır. Shanghai bölgesine ait beş yıllık sıcaklık verileriyle yapılan deneylerde, modelin önümüzdeki 60 gün için gerçekleştirdiği tahminlerin yüksek doğrulukla sonuçlandığı ve genel geçerlik (genelleme) kapasitesinin güçlü olduğu gösterilmiştir. Sonuçlar, Prophet-LSTM modelinin zaman serisi tahmininde gelişmiş bir çözüm sunduğunu ve uygulama potansiyelinin yüksek olduğunu ortaya koymuştur. Gelecek çalışmalarda, farklı iş senaryolarından elde edilecek veri setleriyle modelin performansının daha da artırılması hedeflenmektedir.

Madan ve Mangipudi (2018) tarafından gerçekleştirilen bu çalışmada, bilgisayar ağ trafiği tahmini için geliştirilmiş hibrit bir model önerilmektedir. Çalışmada, Dalgalı Dönüşüm (DWT), ARIMA (AutoRegressive Integrated Moving Average) ve Tekrarlayan Sinir Ağları (RNN) yöntemlerinin kombinasyonu kullanılarak ağ trafiği tahmin edilmeye çalışılmaktadır. Yazarlar, ağ trafiği tahminini iki ana bölümde ele almaktadırlar: ön işleme ve modelleme. İlk adımda, Dalgalı Dönüşüm (DWT) kullanılarak sinyalden gürültü ve karmaşıklık ayrıştırılmakta, böylece zaman serisinin daha düzgün ve anlamlı bir şekilde analiz edilmesi sağlanmaktadır. Bu, zaman serisinin çok boyutlu ve karmaşık yapısını azaltarak, tahminlerin doğruluğunu artırmaya yardımcı olmaktadır. İkinci adımda, ARIMA ve RNN modelleri kombinlenerek tahminler yapılmaktadır. ARIMA, geleneksel bir zaman serisi modelidir ve geçmiş verilere dayalı olarak gelecekteki değerleri tahmin eder. Ancak, ARIMA'nın sınırlamaları doğrusal ilişkilerle sınırlı olmasıdır. Bununla birlikte, RNN (Recurrent Neural Networks) daha karmaşık, doğrusal olmayan ilişkileri öğrenebilme yeteneğine sahiptir ve zaman serisi verilerindeki derin desenleri keşfetme potansiyeline sahiptir. Bu iki yöntemin birleştirilmesi, doğrusal ve doğrusal olmayan unsurları aynı anda işleyerek daha doğru ve güvenilir tahminler yapılmasını

sağlamaktadır. Çalışmanın sonuçlarına göre, önerilen hibrit model, tek başına kullanılan ARIMA ve RNN modellerine göre daha yüksek doğruluk ve güvenilirlik sunmaktadır. Ayrıca, modelin performansı, ağ trafiği tahmini gibi karmaşık ve yüksek boyutlu verilere sahip uygulamalarda önemli ölçüde iyileşmiştir. Yazarlar, bu hibrit yaklaşımın, ağ kapasite planlaması, trafik yoğunluğu tahmini ve ağ güvenliği gibi kritik alanlarda etkili bir araç olarak kullanılabileceğini vurgulamaktadırlar (Madan, 2018).

Shi ve arkadaşlarının (2021) çalışması, ağ trafiğinin tahmininde kullanılan hibrit modelleri kapsamlı bir şekilde incelemektedir. Ağ trafiği, zamanla değişen ve karmaşık desenler gösteren doğrusal olmayan bir zaman serisi olduğundan, geleneksel tek yöntemler yeterli olmayabilmektedir. Bu nedenle, farklı yöntemlerin birleşimi olan hibrit modeller, daha doğru ve güvenilir tahminler sunmaktadır. Optimizasyon tabanlı hibrit modeller, belirli sürü optimizasyonu (PSO) ve kuantum genetik algoritmalar gibi tekniklerle, model parametrelerini optimize ederek tahmin doğruluğunu artırmayı hedefler. Örneğin, PSO tabanlı modeller, ekstrem öğrenme makinelerinin (ELM) ağırlıklarını optimize ederek daha iyi sonuçlar elde etmektedir. Dekompozisyon tabanlı hibrit modeller ise ağ trafiği verileri dalgalı dönüşüm (WT), ampirik mod dekompozisyonu (EMD) veya varyasyonel mod dekompozisyonu (VMD) gibi tekniklerle bileşenlerine ayrılır. Her bir bileşen daha sonra ayrı ayrı modellenir ve tahmin edilir, bu da genel tahmin performansını artırır. Örneğin, DWT-DBN-SCS modeli, dalgalı dönüşüm ve derin inanç ağlarını birleştirerek bu yaklaşımı kullanmaktadır. Çalışma, optimizasyon ve dekompozisyon tekniklerinin hibrit modellerde nasıl kullanıldığını detaylı bir şekilde incelemekte ve her bir yaklaşımın avantajlarını ve sınırlamalarını tartışmaktadır. Bu sayede, ağ trafiği tahmini için en uygun modellerin geliştirilmesine katkı sağlamaktadır (Shi, 2021).

Subashini ve arkadaşlarının (2019) çalışmasında, web trafiği tahmininde Facebook tarafından geliştirilen Prophet zaman serisi modelinin etkinliği incelenmiştir. Web sitesi trafiği tahmini, internet sitelerinin kaynaklarını verimli bir şekilde planlaması ve reklam gelirlerini artırması için kritik bir öneme sahiptir. Geleneksel tahmin yöntemleri, genellikle basit modellere dayanmakta ve bu modeller büyük veri setlerini işleme konusunda yetersiz kalmaktadır. Bu nedenle, Prophet modelinin kullanılabilirliği bu çalışmada araştırılmıştır. Çalışmada, günlük web sayfası görüntülenme verileri toplanmış ve Prophet modelinin gereksinimlerine uygun şekilde

tarikh ve g r nt lenme sayısı olmak  zere iki s tun halinde d zenlenmiřtir. Ardından, hazırlanan veri seti Prophet modeline eęitilmiř ve gelecekteki web trafięi tahmin edilmiřtir. Modelin tahmin performansı, ger ek verilerle karřılařtırılarak deęerlendirilmiřtir. Sonu lar, Prophet modelinin web trafięi tahmininde olduk a etkili bir ara  olduęunu g stermiřtir. Elde edilen tahminler, web sitesi sahiplerinin trafik trendlerini anlamalarına ve kaynaklarını daha etkin bir řekilde planlamalarına yardımcı olabilir. Ayrıca, bu tahminler reklam ve i erik stratejilerinin optimize edilmesinde de  nemli bir rol oynayabilir (Subashini, 2019).

Cembaluk ve arkadaşlarının (2022)  alıřmasında, aę trafięi tahmini i in Facebook tarafından geliřtirilen Prophet modelinin etkinlięi incelenmiřtir. Prophet, doęrusal olmayan trendleri, yıllık, haftalık ve g nl k mevsimsellikler ile tatil etkilerini hesaba katabilme yeteneęine sahiptir. Bu  zellikleri sayesinde, aę trafięi gibi karmařık veriler  zerinde etkili bir tahmin aracı olarak kullanılabilir.  alıřmada, Prophet modelinin    ana parametresinin aę trafięi tahmini  zerindeki etkileri deęerlendirilmiřtir. Bu parametreler arasında deęiřim noktası  ncelik  l eęi, mevsimsellik  ncelik  l eęi ve otomatik deęiřim noktası sayısı yer almaktadır. Deęiřim noktası  ncelik  l eęi, modelin trenddeki b y k deęiřimlere duyarlılıęını belirlerken, mevsimsellik  ncelik  l eęi mevsimsel etkilerin modeldeki aęırlılıęını kontrol eder. Otomatik deęiřim noktası sayısı ise, modelin veriye dayalı olarak belirledięi deęiřim noktalarının sayısını ifade eder. Deneysel tasarımıda, Seattle Internet Exchange Point'ten (SIX) 22 Ekim 2019 ile 23 Aralık 2019 arasında, 5 dakikalık aralıklarla toplanan veriler kullanılmıřtır. Orijinal verilere rastgele dalgalanmalar eklenerek    farklı trafik profili oluřturulmuřtur: d ř k dalgalanmalı trafik, orta d zeyde dalgalanmalı trafik ve y ksek dalgalanmalı trafik. Bu trafik profilleri, modelin farklı veri t rleri  zerindeki performansını incelemek i in kullanılmıřtır. Ayrıca, modelin tahmin doęruluęu MAPE gibi hata  l  tleriyle deęerlendirilmiřtir. Prophet modelinin performansı, geleneksel doęrusal regresyon modeli ile karřılařtırılmıřtır. Doęrusal regresyon modeli, g n n saati, dakikası, saniyesi ve haftanın g n  gibi  zellikler kullanılarak uzun vadeli trafik tahminleri i in uyarlanmıřtır. Sonu lar, Prophet modelinin  zellikle y ksek dalgalanmalı trafik profillerinde daha iyi performans g sterdięini ortaya koymuřtur. Parametrelerin doęru ayarlanması, modelin tahmin doęruluęunu  nemli  l  de artırmıřtır. (Cembaluk, 2022).

Zaraket ve arkadaşları (2024) yaptıkları çalışmada trafik akışı tahmini için Prophet modelini ve Uzun Kısa Vadeli Bellek (LSTM) yapay sinir ağlarını birleştiren "Hyper-Flophet" adlı hibrit bir model önerilmektedir. Bu model, zaman serileri verilerini daha etkili bir şekilde işleyerek tahmin doğruluğunu artırmayı amaçlamaktadır. Prophet modeli, Facebook tarafından geliştirilen bir zaman serisi tahmin aracıdır ve mevsimsel etkiler, tatil günleri ve trend değişikliklerini dikkate alarak verileri modelleyebilir. Özellikle günlük ve haftalık mevsimsellik gibi düzenlilikleri yakalama konusunda etkili olduğu bilinir. LSTM ise, uzun vadeli bağımlılıkları öğrenme yeteneğine sahip bir yapay sinir ağı türüdür. Bu özellik, zaman serisi verilerindeki geçmiş bilgileri kullanarak gelecekteki değerleri tahmin etmede büyük bir avantaj sağlar. Hyper-Flophet modeli, Prophet'in mevsimsel ve trend bileşenlerini LSTM'nin öğrenme kapasitesiyle birleştirerek daha hassas ve doğru tahminler yapmayı hedefler. Böylece, her iki modelin avantajlarından faydalanarak trafik akışı tahminlerinde yüksek doğruluk oranları elde edilmektedir. Deneysel sonuçlar, Hyper-Flophet modelinin tek başına kullanılan Prophet veya LSTM modellerine kıyasla daha iyi performans gösterdiğini ortaya koymaktadır. Bu bulgu, hibrit modellerin trafik akışı tahminlerinde ne kadar etkili ve potansiyel taşıdığını göstermektedir (Zaraket, 2024).

Kong ve arkadaşları (2021) yaptıkları çalışmada Facebook kullanıcı etkileşimini tahmin etmek amacıyla Prophet ve Uzun Kısa Vadeli Bellek (LSTM) modellerini birleştiren hibrit bir yaklaşım önerilmektedir. Zaman serileri verilerinin doğrusal ve doğrusal olmayan bileşenlerini ayrı ayrı ele alarak daha doğru tahminler elde etmeyi hedefleyen bu hibrit model, Prophet'in mevsimsel ve trend bileşenlerini LSTM'nin öğrenme kapasitesiyle birleştirmektedir. Çalışmada, 2018 Haziran ile 2019 Mart arasında üç popüler markanın Facebook sayfalarından toplanan veriler kullanılmıştır. Modelin doğruluğu hem Prophet hem de LSTM modelleriyle karşılaştırılmış ve hibrit modelin daha yüksek doğruluk sağladığı görülmüştür. Ayrıca, tatil günlerinin kullanıcı etkileşimi üzerindeki etkisi de incelenmiştir. Tatil günlerinin, etkileşimdeki artışa neden olduğu ve bu bilginin tahmin doğruluğunu artırmada önemli bir rol oynadığı bulunmuştur. Tatil günlerini dikkate alarak kampanya tarihlerini belirlemek, reklamların daha geniş bir kitleye ulaşmasına olanak tanıyabilir. Bu çalışma, zaman serisi tahminlerinin doğruluğunu artıran hibrit modellerin önemini ve uygulamalı olarak nasıl fayda sağladığını vurgulamaktadır. Böylece, pazarlama stratejileri için daha güvenilir tahminler yapılabilmektedir (Kong, 2021).

Ma ve arkadaşları (2020), yazdıkları makalede, ağ genelindeki trafik durumu tahmini için yenilikçi bir yaklaşım sunulmaktadır. Önerilen yöntem, temel makine öğrenimi algoritması olan Çok Katmanlı Algılayıcı (MLP) tarafından elde edilen kalıntıları işlemek üzere istatistiksel bir zaman serisi modeli olan ARIMA'yı kullanmaktadır. Bu birleşim, "NN-ARIMA" olarak adlandırılmıştır. MLP, tüm trafik akışlarının ağ ölçeğindeki ortak hareket desenlerini yakalamak için kullanılır. ARIMA, MLP'nin kalıntılarındaki konumlara özgü trafik özelliklerini daha da ayrıştırmak için devreye girer. Deneyler, ARIMA ile işlenen MLP kalıntıları, ortalama kare hata (MSE) açısından %8,9–13,4 oranında bir iyileşme sağladığını göstermektedir. Ayrıca, Çok Boyutlu Destek Vektör Regresyonu (MSVR) modeli de karşılaştırma için kullanılmış ve benzer sonuçlar elde edilmiştir. Bu yöntem, hem ağ genelindeki trafik akışlarının ortak hareket desenlerini hem de belirli konumlardaki trafik özelliklerini dikkate alarak tahmin doğruluğunu artırmaktadır.

Bashir ve arkadaşları (2022) makalelerinde, kısa vadeli elektrik yükü tahmini için yenilikçi bir yaklaşım sunmaktadır. Elektrik yükü tahmini, enerji üretim ve dağıtım sistemlerinin verimli çalışması için kritik bir öneme sahiptir, çünkü enerji talebinin doğru tahmin edilmesi, enerji üretim planlamasında önemli rol oynar. Bu çalışma, elektrik yükü tahmininde doğruluğu artırmak amacıyla, Prophet ve Long Short-Term Memory (LSTM) modellerini birleştiren hibrit bir model öneriyor. Prophet, zaman serisi verilerindeki mevsimsellik ve tatil etkilerini iyi bir şekilde modelleyen bir araçtır. Özellikle günlük, haftalık ve yıllık döngüsel değişimlerin tahmin edilmesinde güçlüdür. Bu model, elektrik yükü gibi mevsimsel veri içeren sistemlerde genellikle iyi sonuçlar verir. Prophet, kullanıcıların verileri hızlıca işleyip sezonsal özellikleri daha iyi anlayabilmelerine olanak tanır. Diğer taraftan, LSTM (Long Short-Term Memory), derin öğrenme tabanlı bir model olup, zaman bağımlılıklarını öğrenme konusunda oldukça etkilidir. LSTM, özellikle uzun vadeli bağımlılıkları modellemek için geliştirilmiş bir yapıdır ve elektrik yükü gibi değişken verilerin gelecekteki değerlerini tahmin etmek için idealdir. LSTM'nin güçlü yanlarından biri, geçmişteki olayların etkilerini uzun süre hatırlayabilmesi ve böylece daha hassas tahminler yapabilmesidir. Bu makalede, Prophet modelinin elde ettiği tahmin sonuçları, LSTM tarafından daha da iyileştirilmiş ve her iki modelin gücü birleşerek daha doğru tahminler ortaya çıkarmıştır. Ayrıca, modelin optimizasyonu için Backpropagation Neural Network (BPNN) algoritması da kullanılmıştır. Bu optimizasyon, modelin

öğrenme sürecini hızlandırarak daha yüksek doğruluk elde edilmesini sağlamaktadır. Yapılan deneysel çalışmalar, hibrit modelin geleneksel yöntemlere göre daha iyi sonuçlar verdiğini ve elektrik yükü tahmininde önemli iyileşmeler sağladığını ortaya koymuştur. Özellikle enerji sektöründe, elektrik yükü tahminlerinin doğruluğu ne kadar yüksek olursa, enerji arzı o kadar verimli ve güvenli bir şekilde sağlanabilir. Sonuç olarak, bu çalışma, kısa vadeli elektrik yükü tahmini için hibrit bir yaklaşımın kullanılmasının, daha doğru ve güvenilir sonuçlar elde etmek için etkili bir yöntem olduğunu göstermektedir (Bashir, 2022).

Ning ve arkadaşları (2022) yazdıkları makalede, zaman serileri analizinde kullanılan üç farklı makine öğrenimi modelinin karşılaştırmasını sunmaktadır: ARIMA (Auto-Regressive Integrated Moving Average), LSTM (Long Short-Term Memory) ve Prophet. Bu modeller, özellikle petrol üretimi gibi dalgalı ve karmaşık zaman serisi verilerinin tahmininde kullanılır. Çalışmada, Denver-Julesburg (DJ) Havzası'nda yer alan bir kuyudan elde edilen petrol üretim verileri kullanılmıştır. Verilerin %70'i model eğitimi için, geri kalan %30'u ise model performansını değerlendirmek için ayrılmıştır. ARIMA, LSTM ve Prophet modelleri, petrol üretim verileri üzerinde uygulanmış ve performansları karşılaştırılmıştır. Sonuçlar, makine öğrenimi modellerinin, geleneksel yöntemlere göre daha doğru tahminler sağladığını göstermiştir. Makine öğrenimi modelleri, basit bir iş akışına sahip olup, rezervuar türüne dair ön varsayımlara ihtiyaç duymadan hızlı ve güvenilir tahminler sunar. Özellikle Prophet modeli, kış mevsimi etkisi gibi üretim dalgalanmalarını yakalama konusunda başarılıdır.

Wang ve arkadaşlarının (2023) çalışması trafik yoğunluğu ve yol kapasitesi sınırlamaları gibi günümüz ulaşım sistemlerinde karşılaşılan temel sorunlara çözüm üretmeyi amaçlamaktadır. Özellikle kısa vadeli trafik akışı tahmini, etkin trafik yönetimi ve kontrol stratejileri açısından kritik bir rol oynamaktadır. Literatürde yaygın olarak kullanılan tek noktalı tahmin yöntemleri, farklı yol bölümleri arasındaki karşılıklı etkileşimleri ve sistem genelindeki eş zamanlı değişimleri yeterince modelleyememektedir. Ayrıca, geniş yol ağlarında kullanılan geleneksel makine öğrenmesi algoritmaları, yüksek hesaplama maliyeti ve düşük ölçeklenebilirlik gibi sınırlamalara sahiptir. Bu makalede, tarihsel trafik verileri ile yol ağı yapısını bütünleştiren hibrit bir tahmin yöntemi önerilmektedir. Model, yol ağındaki topolojik ilişkileri kullanarak, coğrafi olarak bağlantılı noktalar arasındaki veri etkileşimini

dikkate almaktadır. Gerçek dünya verileri üzerinde yapılan deneyler, önerilen yöntemin geleneksel makine öğrenimi tabanlı modellere göre daha yüksek doğruluk ve daha iyi ölçeklenebilirlik sunduğunu göstermiştir. Sonuç olarak, çalışma; trafik akışı tahmininde hem mikro düzeyde (tekil yollar) hem de makro düzeyde (yol ağı) daha etkili karar destek mekanizmaları geliştirilmesine katkı sunmaktadır. Bu yaklaşım sayesinde trafik tıkanıklıkları daha önceden öngörülebilir, enerji tüketimi azaltılabilir ve çevresel etkiler minimize edilebilir.

Zhou ve arkadaşları (2020) bu çalışmada, son yıllarda toplumsal endişeye neden olan hava kirliliğine odaklanmakta ve Nanjing şehri örneği üzerinden Hava Kalitesi İndeksi (AQI) değişimlerini analiz edip tahmin etmeyi amaçlamaktadır. Haziran 2014 - Mayıs 2019 dönemine ait hava kalitesi verileri kullanılarak Prophet modeli kurulmuş ve bu modelle Haziran 2019 - Nisan 2020 arasındaki AQI değerleri tahmin edilmiştir. Prophet modelinin tahmin doğruluğunu artırmak amacıyla iki hibrit model önerilmiştir: Prophet-SVR ve Prophet-LSTM. Bu modellerde Prophet'in kalıntı (residual) serileri alınarak, bu hata serileri SVR ve LSTM modellerine eğitim verisi olarak sunulmuştur. Böylece Prophet'in ilk tahminlerine, öğrenilmiş kalıntı tahminleri eklenerek daha hassas sonuçlar elde edilmiştir. Deneysel sonuçlara göre Prophet-LSTM hibrit modeli, özellikle aşırı değerlerin tahmininde en yüksek doğruluğu sağlamış ve tekli modellere göre belirgin avantaj göstermiştir. Ancak çalışma, mevcut makine öğrenimi algoritmalarının meteorolojik faktörleri göz ardı ettiğini de belirtmekte ve gelecekte hava kalitesini etkileyen dışsal faktörlerin de modellere dahil edilmesiyle daha evrensel ve isabetli tahmin sistemlerinin geliştirilebileceğini önermektedir.

Arslan (2022) bu çalışmada, zaman serisi tahmin doğruluğunu artırmak amacıyla Prophet modeli ile tekrarlayan sinir ağı (RNN) tabanlı bir hibrit tahmin modeli önermiştir. Yüksek frekanslı, mevsimsellik ve düzensiz dalgalanmalar içeren zaman serisi verilerinde tek bir model yeterli performans göstermediğinden, Prophet modeli mevsimsel desenleri korumak için, istiflenmiş çift yönlü LSTM ağı ise STL algoritmasıyla mevsimsellikten arındırılmış verileri işlemek için kullanılmıştır. Bu sayede model, hem mevsimsellik desenlerini koruyabilmekte hem de bu desenlerin tahmin üzerindeki etkisini azaltabilmektedir. Elde edilen tahminler, her iki alt modelin çıktıları birleştirilerek elde edilmektedir. Model, yedi ülkenin on yılı aşkın süreye ait aylık enerji tüketimi verisi üzerinde test edilmiştir. Tek başına Prophet, orijinal veriyle

eđitilen LSTM ve mevsimsellikten arındırılmıř veriyle eđitilen LSTM gibi modellerle karřılařtırıldıđında, hibrit yaklařım daha ylık dođruluk sađlamıřtır. Ayrıca, ARIMA, SVR, Holt-Winters, EMD-LSTM ve EMD-GRU gibi gyncel yontemlerle kıyaslandıđında bazı lklelerde daha iyi, bazılarında ise rekabetçi sonuqlar vermiřtir. Gelecekte farklı RNN turleri ve veri kaynaklarıyla modelin genellenebilirliđi ve optimizasyonu arařtırılacaktır.

Prasad ve arkadaşları (2023) alıřmalarında, Hindistan'ın ozellikle Andhra Pradesh (AP) bolgesinde sık gorulen řiddetli yađıřların yol aabileceđi sel felaketlerine karřı onlem alabilmek amacıyla, yıllık yađıř tahmini uzerine odaklanmaktadır. AP, Telugu konuřulan eyaletlerin yonetim ve hizmet merkezlerinden biri olduđundan, bu bolgedeki dođal afet risklerinin analitik olarak ongorulmesi buyuk onem tařımaktadır. alıřmada, gemiř meteorolojik veriler kullanılarak řiddetli yađıř, ruzgar hızı ve sıcaklık gibi deđiřkenleri tahmin etmek amacıyla, LSTM (Long Short-Term Memory) ve Neural Prophet (NP) modelleri birleřtirilerek yeni bir hibrit zaman serisi modeli (LSTM+NP) onerilmiřtir. Yazarlar, bu hibrit modelin klasik yontemlerle kıyaslandıđında daha iyi performans gosterdiđini belirtmiř ve modelin dođruluđunu RMSE (Root Mean Square Error) 0.25 ve MAE (Mean Absolute Error) 0.16 deđerleriyle ortaya koymuřtur. Elde edilen sonuqlar, ozellikle LSTM ve Neural Prophet birleřiminin zaman serisi verilerinde gulu tahmin yeteneklerine sahip olduđunu gostermektedir. alıřma, gelecekte bu tur hibrit modellerin yađıř tahmininde ve afet risk yonetiminde yaygın řekilde kullanılabileceđini one surmekte ve literat ure yeni bir arařtırma yonu sunmaktadır.

Aladag ve arkadaşları (2009) yaptıkları alıřmada, zaman serisi tahmininde dođrusal ve dođrusal olmayan yapıları birlikte modelleyebilmek amacıyla ARIMA ve Elman Tekrarlayan Sinir Ađı (ERNN) tabanlı yeni bir hibrit yontem onermiřtir. Yapay sinir ađları (ANN), zaman serilerindeki karmařık desenleri ođrenebilme kapasitesiyle son yıllarda tahmin alıřmalarında yaygın řekilde kullanılmaktadır. Ancak ANN'ler hem dođrusal hem de dođrusal olmayan yapıları aynı derecede iyi modelleyemediđinden, ARIMA gibi dođrusal modellerle hibrit biimde kullanılması daha iyi sonuqlar dođurabilmektedir. Bu alıřmada onerilen ARIMA-ERNN hibrit modeli, ozellikle dođrusal yapıları ARIMA, dođrusal olmayan yapıları ise ERNN ile modelleyerek bu soruna ozum sunmayı amalamaktadır. Model, Canadian Lynx veri seti uzerinde test edilmiř ve hem Zhang'ın ARIMA-FNN hibrit modelinden hem de diđer tekil

modellerden daha başarılı tahmin sonuçları vermiştir. ERNN'nin bağlam katmanına sahip olması, önceki zamana ait bilgileri daha etkin kullanmasını sağlayarak tahmin doğruluğunu artırmaktadır. Çalışma sonuçları, hibrit yöntemlerin potansiyelini ortaya koymakta ve gelecekte farklı tekrarlayan sinir ağı türleri (örneğin Jordan ağları) ile daha da geliştirilerek tahmin başarımının artırılabilceğini göstermektedir.

Khashei ve Bijari (2011) çalışmalarında, zaman serisi tahmininde doğruluğu artırmak amacıyla yeni bir hibrit model önermektedir. Zaman serisi tahmini, özellikle yatırım karar destek sistemlerinde kritik bir rol oynamaktadır ve tahmin doğruluğunu artırmak çoğu zaman oldukça zordur. Literatürde, tek bir modelin yetersizliklerini gidermek amacıyla farklı tahmin modellerini birleştiren çok sayıda hibrit yaklaşım önerilmiştir. Bu çalışmanın özgün yanı, geleneksel hibrit modellerden farklı olarak bir zaman serisi modeli ile bir sınıflandırıcıyı bir araya getirerek yeni bir hibrit model sınıfı önermesidir. Önerilen yöntemde, ilk aşamada temel bir zaman serisi modeli kullanılarak tahminler üretilmekte, ardından ikinci aşamada bu tahminler, modelin kalıntıların (residuals) eğilimine göre düzeltilmektedir. Kalıntıların eğilimleri bir olasılıksal sinir ağı (PNN) sınıflandırıcısı tarafından analiz edilirken, bu düzeltelerin uygulanacağı optimum adım uzunluğu ise matematiksel programlama kullanılarak hesaplanmaktadır. Bu sayede, temel modelin eksik kaldığı noktalar sistematik biçimde tanımlanarak düzeltilmekte ve daha doğru tahmin sonuçları elde edilmektedir. Üç farklı ve yaygın şekilde kullanılan gerçek veri kümesi üzerinde yapılan deneysel sonuçlar, önerilen modelin tek başına kullanılan zaman serisi modellerine kıyasla daha yüksek tahmin doğruluğu sağladığını göstermektedir. Dolayısıyla, bu yöntem, özellikle yüksek doğruluk gerektiren zaman serisi tahmin problemleri için etkili ve uygun bir alternatif olarak sunulmaktadır. Ayrıca, modelin yapısı farklı sınıflandırıcı ve temel modellerle genişletilerek daha da geliştirilebilir.

Dangi ve Lalwani (2022) çalışmalarında 5G ağ kaynaklarını daha verimli ölçeklendirmek amacıyla, ağ trafiği dalgalanmalarını tahmin etmek için CNN ve LSTM'nin birleşiminden oluşan hibrit bir model (CNN+LSTM) önermektedir. 5G sadece akıllı telefon ve tabletler değil, aynı zamanda akıllı evler, otonom araçlar ve endüstri 4.0 gibi birçok bağlantılı teknolojiyi destekleyerek ağ trafiğinde büyük artışa neden olmaktadır. Bu artışı karşılamak için ağ işlevlerinin sanallaştırılması (NFV) ve yazılım tanımlı ağlar (SDN) kullanılarak dinamik ve ölçeklenebilir bir 5G mimarisi gereklidir. Mevcut derin öğrenme modelleri genellikle normal trafik koşullarını

tahmin etmede başarılı olsa da, festival gibi ani ve beklenmedik trafik artışlarında yetersiz kalmaktadır. Bu sorunu aşmak için geliştirilen CNN+LSTM modeli, hem normal hem de anormal trafik koşullarında daha doğru trafik tahmini yaparak 5G kaynaklarının etkin kullanımını sağlamaktadır. İki aylık trafik verisi kullanılarak yapılan testlerde bu model, 1D-CNN, LSTM ve ARIMA gibi yaygın kullanılan modellerle karşılaştırılmış ve en iyi tahmin performansını göstermiştir. Sonuçlar, modelin 5G ağlarının ölçeklendirilmesinde güçlü bir çözüm sunduğunu kanıtlamaktadır.

Zhang ve arkadaşları (2018) makalelerinde kısa vadeli trafik akışı tahmininde Support Vector Regression (SVR), Genetic Algorithm (GA) ve Random Forest (RF) yöntemlerini bir araya getiren yeni bir tahmin çerçevesi önermektedir. Önerilen çerçeve, SVR modelinin hem özellik seçimi hem de parametre optimizasyonu problemlerini çözmeyi hedeflemektedir. İlk bileşen olarak, RF tabanlı bir özellik seçimi yöntemi geliştirilmiştir; bu yöntem, klasik çapraz doğrulama veya bireysel özellik sıralaması yerine, öğrenme süreci sırasında en önemli özellikleri belirlemektedir. İkinci bileşen, SVR parametrelerini optimize etmek için geliştirilen modifiye edilmiş kaotik genetik algoritma (CGA)dır. CGA, kromozom oluşturma ve mutasyon stratejilerinde yapılan değişikliklerle, standart GA'nın yerel optimumlara takılma sorununu azaltmaktadır. Üçüncü bileşen ise CGA ve RF sonuçlarının entegre edilmesiyle oluşturulan optimize SVR tabanlı tahmin modelidir. California Ulaştırma Departmanı'na ait gerçek trafik verileri üzerinde yapılan deneysel değerlendirmeler, önerilen modelin daha az sayıda özellik kullanarak, klasik SVR (grid search ile), Back-Propagation Neural Network (BPNN) ve ARIMA gibi yöntemlere göre daha yüksek doğruluk ve etkinlik sağladığını göstermiştir. Çalışmanın temel katkıları; RF tabanlı öğrenme süreci içinde özellik seçimi yöntemi, geliştirilmiş CGA ile SVR parametre optimizasyonu ve bu yöntemlerin entegre edilmesiyle elde edilen geliştirilmiş kısa dönem trafik tahmin modeli olarak özetlenebilir.

Thakur ve arkadaşları (2025) çalışmalarında, web trafiği analizinde tahmin doğruluğunu artırmak amacıyla ARIMA, LSTM ve Prophet modellerini birleştiren hibrit bir yaklaşımı ele almaktadır. ARIMA modeli doğrusal eğilimler ve mevsimsel döngülerde başarılı olurken; LSTM, karmaşık ve doğrusal olmayan örüntüleri yakalamada güçlüdür. Prophet modeli ise eksik verilerle başa çıkma ve mevsimsel dalgalanmaları modelleme konusunda etkilidir. Üç modelin entegrasyonu ile

oluşturulan hibrit sistem, web trafiği tahmininde %93 doğruluk oranı sağlamıştır. Bu sonuç, hem klasik hem de ileri düzey makine öğrenmesi yöntemlerinin bir araya getirilmesinin güçlü bir öngörü performansı sağladığını ortaya koymaktadır. Araştırma, özellikle LSTM'nin zamansal ve mekânsal örüntüleri yakalama kabiliyeti sayesinde ARIMA'dan daha iyi sonuçlar verdiğini göstermiştir. Hibrit modelin, kullanıcı davranışlarını anlama, kaynakları verimli yönetme, etkileşimi artırma ve gelir elde etme gibi işlevsel katkıları vurgulanmıştır. Gelecek çalışmalarda, pazarlama kampanyaları veya dış mevsimsel etkiler gibi yeni özelliklerin de eklenerek bu hibrit modellerin daha da geliştirilmesi hedeflenmektedir. Bu yönüyle çalışma, dijital platform yönetimi ve kullanıcı deneyiminin iyileştirilmesi için güçlü bir temel sunmaktadır.

Karthika ve arkadaşları (2017) tarafından gerçekleştirdikleri çalışmada, kısa vadeli elektrik yük tahmini (STLF) için ARIMA ve SVM modellerinden oluşan hibrit bir yöntem önermişlerdir. Çalışmanın amacı, yalnızca geçmiş yüklere dayalı tahmin yapan geleneksel zaman serisi modellerinin özellikle ARIMA'nın sınırlılıklarını, SVM gibi yapay zeka teknikleri ile tamamlayarak tahmin doğruluğunu artırmaktır. Model iki aşamada geliştirilmiştir. İlk aşamada ARIMA modeli kullanılarak ilk tahmin yapılır, ardından yüzde hata (PE) yöntemine göre aykırı değerler (outlier) tespit edilir ve düzeltilir. İkinci aşamada ARIMA tahminlerinin artık hataları (residuals) ve dışsal etkenler (sıcaklık, haftanın günü) SVM modeline giriş olarak verilerek nihai tahmin oluşturulur. Sonuçlar, yalnızca ARIMA (MAPE: %5.16) veya yalnızca SVM (MAPE: %4.97) kullanımı yerine, ARIMA–SVM hibrit modelinin (MAPE: %4.15) daha yüksek doğruluk sağladığını göstermiştir. Ayrıca, aykırı değer düzeltimi ile birlikte hibrit modelin hata oranını daha da düşürdüğü belirtilmiştir. Bu çalışma, tahmin doğruluğunu artırmak amacıyla zaman serisi modellerinin yapay zeka yöntemleriyle birleştirilmesi fikrine güçlü bir katkı sağlamaktadır.

Vijayaraghavan ve arkadaşları (2025) çalışmalarında yapay zeka uygulamalarının hızla yaygınlaştığı ve cihazların giderek daha fazla birbirine bağlandığı günümüz dünyasında, geleneksel bant genişliği tahmin yöntemlerinin yetersiz kaldığını ortaya koymaktadır. AI tabanlı teknolojilerin artışı ve birbirine bağlı cihaz sayısındaki patlama, ağ trafiğinde büyük bir yükselişe neden olmuş, bu da mevcut tahmin yaklaşımlarını zorlamaktadır. Ağ yöneticileri, kaynakları verimli kullanmak ve ağların kesintisiz çalışmasını sağlamak için bant genişliği taleplerini doğru bir şekilde

öngörmek zorundadır. Bu bağlamda araştırma, makine öğrenimi ve derin öğrenme algoritmalarının entegrasyonu ile yenilikçi bir tahmin modeli geliştirmeyi amaçlamaktadır. Geliştirilen model, geleneksel yöntemlerin dikkate almada zorlandığı karmaşık kullanıcı davranışlarını ve AI etkilerini daha isabetli analiz ederek ağ yöneticilerine anlamlı içgörüler sunmayı hedeflemektedir. Modellerin performansı RMSE, MAE, MSE, MAPE ve R^2 gibi metriklerle değerlendirilmiştir. Geleneksel zaman serisi modelleri arasında ETS, ARIMA'dan daha iyi sonuçlar vermiştir. Prophet ise hem ARIMA hem de ETS'ye göre daha düşük hata oranları ve daha yüksek R^2 değerleri sunmuştur. Prophet ile LSTM'in birleşimi, tüm modeller içinde en düşük RMSE ve MAE değerlerini sağlayarak dikkat çekmiştir. Derin öğrenme modellerinde ise LSTM, en düşük hata oranlarıyla en başarılı model olarak öne çıkmıştır. LSTM ile GRU'nun birleşimi de güçlü bir performans sergilemiştir. SVM+RF ve LightGBM+CatBoost gibi ansambl modeller de iyi sonuçlar vermekle birlikte, LSTM tabanlı yaklaşımların gerisinde kalmıştır. Sonuç olarak, özellikle LSTM ve Prophet ile hibritleştirilen modellerin, zaman serisi tahmininde yüksek doğruluk ve güvenilirlik sunduğu kanıtlanmıştır.

Su ve arkadaşları (2023) çalışmalarında, havacılıkta yaşanan "incident" türü olayların (kazaya dönüşmeyen, ancak güvenliği etkileyen durumlar) öngörülmesi için Prophet ve LSTM modellerini birleştiren hibrit bir algoritma önermektedir. Havacılık kazaları düşük olasılıklı ancak yüksek etkili olaylardır ve bu nedenle, kazaların habercisi olabilecek incident verilerinin analizi büyük önem taşımaktadır. Geleneksel yöntemler (örneğin ARIMA, Exponential Smoothing) doğrusal ve kısa vadeli eğilimleri iyi yansıtsa da, olaylardaki dalgalı ve karmaşık desenleri tam olarak yakalayamamaktadır. LSTM gibi derin öğrenme modelleri bu doğrusal olmayan yapıları daha iyi modelleyebilse de, tek başına kullanıldığında zaman serisinin tüm bileşenlerini yeterince iyi analiz edemez. Bu nedenle Prophet-LSTM modeli geliştirilmiştir: Prophet modeli veriyi eğilim, mevsimsellik ve rastgele bileşenlere ayırırken, LSTM bu bileşenleri kullanarak gelecekteki olay sayısını tahmin eder. 2002-2022 Çin sivil havacılık verisi üzerinde yapılan testlerde Prophet-LSTM, ARIMA, SVM, yalnız Prophet ve yalnız LSTM gibi modellere kıyasla daha düşük RMSE/MAE ve daha yüksek R^2 değerleri göstermiştir. Model, havayollarına proaktif güvenlik yönetimi için etkili bir araç sunmaktadır.

Genel olarak literatür, tek bir model yerine hibrit yaklaşımların daha başarılı sonuçlar verdiğini ortaya koymaktadır. Özellikle Zaraket, Kong ve Katwal'ın çalışmalarından ilham alınarak bu tez hayata geçirilmiştir. Taksonomi tablosu Çizelge 1.1'de verilmiştir.

Çizelge 1.1: Literatür araştırması için taksonomi.

Yıl	Yazarlar	Alan / Veri	Kullanılan Modeller	Hibrit Yaklaşım
2023	Katwal ve ark.	Web trafiği	ARIMA, Prophet, LSTM	Prophet + LSTM
2022	Prajam ve ark.	Ağ trafiği	ML modelleri, ARIMA	ML + ARIMA karşılaştırması
2024	Ertürk	Ulaşım	ARIMA, Prophet, LSTM	-
2022	Gao	Sıcaklık (Shanghai)	Prophet, LSTM	Prophet-LSTM hibrit
2018	Madan & Mangipudi	Ağ trafiği	DWT, ARIMA, RNN	DWT + (ARIMA + RNN)
2021	Shi ve ark.	Ağ trafiği	PSO-ELM, DWT-DBN-SCS, EMD/VMD tabanlı	Optimizasyon ve ayrıştırma bazlı hibrit
2019	Subashini ve ark.	Web trafiği	Prophet	—
2022	Cemaluk ve ark.	Ağ trafiği	Prophet, Doğrusal Regresyon	—
2024	Zaraket ve ark.	Trafik akışı	Prophet, LSTM	Prophet + LSTM ("Hyper-Flophet")
2021	Kong ve ark.	Facebook etkileşim verisi	Prophet, LSTM	Prophet + LSTM
2020	Ma ve ark.	Ağ trafiği	ARIMA, MLP	MLP kalıntısı + ARIMA
2022	Bashir ve ark.	Elektrik yükü	Prophet, LSTM, BPNN	Prophet + LSTM + BPNN
2022	Ning ve ark.	Petrol üretimi	ARIMA, LSTM, Prophet	—
2023	Wang ve ark.	Trafik akışı (yol ağı)	ML modelleri + grafik-topoloji	Topoloji + geçmiş veri hibriti
2020	Zhou ve ark.	Hava Kalitesi (Nanjing)	Prophet, SVR, LSTM	Prophet artığı + SVR/LSTM
2022	Arslan	Enerji tüketimi (7 ülke)	Prophet, BiLSTM	STL + Prophet + BiLSTM

Çizelge 1.1 (devam): Literatür araştırması için taksonomi.

Yıl	Yazarlar	Alan / Veri	Kullanılan Modeller	Hibrit Yaklaşım
2023	Prasad ve ark.	Yağış tahmini (AP, Hindistan)	LSTM, Neural Prophet	Prophet–LSTM hibrit
2009	Aladag ve ark.	Canadian Lynx veri seti	ARIMA, ERNN	ARIMA + ERNN
2011	Khashei & Bijari	Genel zaman serisi	Temel model + PNN	Kalıntılara PNN ile düzeltme
2022	Dangi & Lalwani	Ağ trafiği	CNN, LSTM, ARIMA	CNN + LSTM
2018	Zhang ve ark.	Trafik akışı (California)	SVR, GA, RF	GA ile SVR parametre optimizasyonu
2025	Thakur ve ark.	Web trafiği	ARIMA, LSTM, Prophet	ARIMA + LSTM + Prophet
2017	Karthika ve ark.	Elektrik yükü (STLF)	ARIMA, SVM	ARIMA + SVM
2025	Vijayaraghavan ve ark.	Ağ trafiği	ETS, LSTM, Prophet, GRU, SVM, CatBoost, LightGBM, RF	Prophet + LSTM, SVM + RF, LightGBM + CatBoost
2023	Su ve ark.	Havacılık kaza verileri	Prophet, LSTM	Prophet + LSTM



2. AĞ TRAFİK TAHMİNİNİN ÖNEMİ

Trafik tahminlerinin önemini anlamak için, öncelikle kapasite planlamasının ne denli kritik olduğunu vurgulamak gerekmektedir. Ağ operatörleri, kullanıcı taleplerini doğru bir şekilde tahmin ederek altyapı yatırımlarını optimize edebilirler. Bu maliyetleri doğru yönetmeyi sağlarken aynı zamanda kullanıcı deneyimi üzerinde de doğrudan etki yaratır. Doğru zamanlama ile yapılan tahminler sayesinde, ağda oluşabilecek yoğunluklar veya tıkanıklıklar önceden belirlenebilir ve gerekli iyileştirmeler yapılabilir. Bunun yanı sıra, trafik tahminlerinin ağ mühendisliği açısından başka bir avantajı da kapasite yönetimi sırasında kritik ağ noktalarındaki kaynakların etkin bir şekilde dağıtılmasına olanak tanımasıdır. Ağ üzerinde kritik noktaların yoğun olduğu zamanlarda, yük dengeleme stratejileri devreye alınarak, sistemin denge ve verimliliği korunabilir.

Bir diğer önemli konu ise, maliyet optimizasyonudur. Telekomünikasyon altyapısı, yüksek maliyetli kaynaklara sahiptir; dolayısıyla, ağ kaynaklarının verimli kullanımı, operatörlerin finansal sürdürülebilirliği açısından büyük bir önem taşır. Trafik tahminlerinin doğru yapılması, gereksiz yatırımları ve fazla kapasite harcamalarını engeller. Operatörler, tahminler doğrultusunda sadece ihtiyaç duyulan kapasiteyi sağlamak üzere stratejiler geliştirebilirler. Bu durum, özellikle büyük veri merkezlerinin ve ağ yönetim sistemlerinin maliyetlerini ciddi şekilde düşürebilir. Ayrıca, tahminlere dayalı ağ planlaması, servis sağlayıcılarının yeni hizmetler sunarken mevcut altyapı üzerinde aşırı yük yaratmaktan kaçınmalarını sağlar.

Trafik tahminleri, ağ yönetiminde sadece kapasite yönetimi değil, aynı zamanda acil durum yönetimi, trafik yoğunlukları, ağ güvenliği ve hizmet sürekliliği açısından da büyük önem taşır. Bu tür sistemler, ağ yöneticilerine, yüksek yoğunluklu trafik dönemlerinde ağ performansını sürdürme veya kriz anlarında hızlı çözüm önerileri sunma kapasitesi sağlar. Örneğin, ağ üzerinde ani trafik artışları meydana geldiğinde, tahminler sayesinde bu artışlar önceden belirlenebilir ve gerekli önlemler alınabilir.

Son olarak, doğru trafik tahminlerinin yapılması, ağıın geleceğe dönük evrimini şekillendirmek için de kritik rol oynamaktadır. Ağlar, kullanıcı talepleri ve yeni teknolojilerin gereksinimleri doğrultusunda sürekli olarak evrimleşir. Bu nedenle, trafik tahminlerinin yalnızca mevcut durumu değil, gelecekteki eğilimleri de dikkate alarak yapılması gerekmektedir. Gerçek zamanlı trafik tahminleri, ayrıca operasyonel verimliliği artırarak, ağ operatörlerinin hızlı ve doğru kararlar almasını sağlar.

Bu bağlamda, derin öğrenme tabanlı modeller ve hibrit yaklaşımlar, geçmiş veriler ve mevcut eğilimler üzerinde yapılan analizler ile gelecekteki trafik durumlarını doğru bir şekilde öngörebilir. Bu tür tahminler, operatörlerin daha sağlam ve esnek altyapılar inşa etmelerini sağlayarak, gelecekteki ağ taleplerine uyum sağlamalarına olanak tanır. Trafik tahminlerinin yalnızca teknik değil, aynı zamanda ekonomik ve stratejik bir araç olarak kullanılabilirliği giderek daha fazla önem kazanmaktadır.

2.1 Zaman Serisi Tahminleme Yöntemleri

Trafik tahmininde ve genel olarak zaman serisi analizlerinde yaygın olarak kullanılan bazı tahminleme yöntemleri bulunmaktadır.

2.1.1 İstatistiksel yöntemler

Zaman serisi tahminlemede istatistiksel yöntemler, geçmiş gözlemlerden elde edilen desenleri ve yapıları modelleyerek geleceğe yönelik öngörülerde bulunur. Bu yöntemler, genellikle verinin durağanlık, trend ve mevsimsellik gibi temel özelliklerini dikkate alır. Yüksek yorumlanabilirliğe sahip olmaları ve nispeten küçük veri setleriyle etkili çalışabilmeleri ile öne çıkarlar.

2.1.1.1 ARIMA

ARIMA ya da Türçe ismiyle Otoregresif entegre hareketli ortalama zaman serisi verilerinin tahmin edilmesinde kullanılan en yaygın yöntemdir. Geçmiş veriye dayalı bir regresyon modeli olup, veri noktalarının zaman içindeki ilişkilerini modellemeyi amaçlar. Bu model üç bileşenden oluşmaktadır.

Otoregresyon (AR), geçmiş değerlerin mevcut değerleri etkilemesi anlamına gelmektedir. Denklem (2.1)'deki gibi ifade edilmektedir. Formülde p kaç adet geçmiş değer modelde dahil edileceğini belirtmektedir.

$$y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t \quad (2.1)$$

Fark alma (I), veriyi durağan hale getirmek için farkların alınması işlemidir. Durağanlık, ortalama ve varyansı zamanla değişmeyen serileri ifade eder. d ile ifade edilir. Hareketli ortalama (MA) ise tahmin hatalarının geçmiş tahmin hatalarıyla modellenmesidir. Denklem (2.2)'deki gibi ifade edilmektedir. Formülde q kaç adet geçmiş hata teriminin modelde dahil edileceğini belirler. Özetle, ARIMA(p, d, q) şeklinde bir notasyonla ifade edilir.

$$y_t = c + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} \quad (2.2)$$

2.1.1.2 SARIMA

SARIMA, Türkçe adıyla sezonsal otoregresif entegre hareketli ortalama, ARIMA modelinin mevsimsel bileşenleri de dikkate alan bir genişletmesidir. Mevsimsellik yaz döneminde artan turizm verisi ya da kış aylarında azalan klima satış verisi gibi örneklendirilebilir. Mevsimsel paternlerin belirgin olduğu veri setlerinde, SARIMA modeli bu dönemsel etkileri modelleyerek daha doğru tahminler yapabilir.

SARIMA(p, d, q)(P, D, Q, s) şeklinde ifade edilir. p, d, q ARIMA modelindeki gibi tanımlanırken P, D, Q, s mevsimsellik parametreleridir ve aşağıdaki gibi tanımlanır: P: mevsimsel otoregresif terim, D: mevsimsel fark sayısı, Q: mevsimsel MA terimi, s: mevsimsellik periyodu.

SARIMA hem trendi hem sezonsallığı aynı anda modelleyebilir. İstatistiksel olarak güçlü ve açıklanabilir bir modeldir. Küçük ve orta boyutlu veri setleri için uygundur. Öte yandan parametre seçimi karmaşık ve zaman alıcı olabilir. Aşırı öğrenme riski taşır. Ani değişimlere karşı duyarsızdır. Karmaşık yapıları modelleme konusunda yetersizdir.

2.1.1.3 Üssel düzeltme

Exponential smoothing, Türkçe adıyla üssel düzeltme yöntemi zaman serisi verilerindeki trend ve mevsimsel bileşenleri modellemek için kullanılır. Bu yöntem, geçmiş verilere zamanla azalan ağırlıklar vererek geleceği tahmin eder. Model denklem (2.3)'teki gibi özetlenebilir. Formülde alfa 0 ve 1 arasında bir ağırlığı temsil eder.

$$Forecast_{t+1} = \alpha \cdot y_t + (1 - \alpha) \cdot Forecast_t \quad (2.3)$$

Toplamda üç adet farklı üssel düzeltme algoritması bulunmaktadır: Basit üssel düzeltme (SES), Holt'un lineer trend yöntemi ve Holt-Winters yöntemi. Holt-Winters yöntemi, hem toplamalı (sezonluk dalgalanmalar sabit) hem de çarpanlı (sezonluk etki büyüklüğü zamanla değişiklik gösteriyor) mevsimsel paternleri dikkate alabilir. Bu üç algoritmanın hangi durumlarda kullanılabildiği Çizelge 2.1'de özetlenmiştir.

Çizelge 2.1 : Üssel düzeltme algoritmalarının kullanım durumlarının özeti.

Yöntem	Trend	Mevsimsellik	Uygun Durumlar
SES	Hayır	Hayır	Durağan seriler
Holt	Evet	Hayır	Trendli ama sezonsuz seriler
Holt-Winters	Evet	Evet	Aylık satışlar, trafik gibi mevsimsel seriler

2.1.2 Makine öğrenmesi yöntemleri

Bu yöntemler, verinin geçmiş örüntülerini otomatik olarak öğrenerek gelecekteki değerleri tahmin etmeyi amaçlar. İstatistiksel modellere kıyasla karmaşık, doğrusal olmayan ilişkileri modelleme konusunda daha esnektir. Özellikle büyük veri setlerinde ve çok değişkenli zaman serisi problemlerinde güçlü performans sergilerler. Zaman serileri tahminlemede kullanılan en yaygın makine öğrenmesi algoritmalarının özellik kıyaslamaları Çizelge 2.2'deki gibi özetlenmiştir:

Çizelge 2.2 : Makine öğrenmesi algoritmalarının özellik kıyaslaması.

Özellik	Gradyan Artırma	Destek Vektör	Rastgele Orman	Karar Ağaçları
Doğruluk	Yüksek	Yüksek	Yüksek	Orta
Aşırı öğrenme riski	Az	Az	Az	Yüksek
Eğitim süresi	Orta	Orta	Hızlı	Hızlı
Yorumlanabilirlik	Düşük	Düşük	Orta	Yüksek

2.1.2.1 Karar ağaçları

Karar ağaçları, zaman serilerinde özellikle kategorik ve doğrusal olmayan değişkenleri modellemek için uygundur. Bir ağacın kökünden başlayarak dalları boyunca ilerleyip bir sonuca yani yapraklara ulaşılmaktadır. Yazılımda çok sık karşılaşılan eğer-ise yapısına uygun şekilde dallanmalar oluşturulur. Overfitting (aşırı öğrenme) problemi görülebilir.

2.1.2.2 Rastgele ormanlar

Birden çok karar ağacının bir araya gelip birlikte karar aldığı bir yöntemdir. Bu yöntemde birden çok karar ağacı oluşturulur ve her ağaç kendine göre tahmin yapar. Daha sonra eğer sınıflandırma problemiye en çok oyu alan sınıf seçilir, eğer regresyon problemiye tüm ağaçların ortalaması alınır. Her ağaç farklı rastgele örneklerle eğitilir. Overfitting (aşırı öğrenme) problemi riski bu modelde karar ağaçlarına göre daha düşüktür. Eğer çok fazla ağaç varsa modelin çalışma süresi uzayabilir ve bellekte çok fazla yer kaplayabilir.

2.1.2.3 Destek vektör makineleri

Support Vector Machines, yani Destek Vektör Makineleri, sınıflandırma ve regresyon problemleri için kullanılan bir algoritmadır. Sınıflandırma problemlerinde genellikle veri noktalarını iki sınıfa ayıran bir hiper düzlem bulur. Bu hiper düzlemin marjini, sınıflar arasındaki en geniş mesafedir. SVM'in amacı bu marjini maksimize etmektir. Bu model doğrusal olmayan veriler ile çalışabilmek için çekirdek yöntemini (kernel) kullanır. Çekirdek fonksiyonları veriyi daha yüksek boyutlu bir uzaya dönüştürerek sınıflandırma yapılmasını mümkün kılar. Bu modelde kullanılabilecek dört farklı çekirdek bulunmaktadır: lineer, polinom, radyal temel ve sigmoid.

Özetle SVM algoritması genellikle yüksek doğruluk gerektiren sınıflandırma problemlerinde tercih edilir, özellikle doğrusal olmayan verilerde kullandığı çekirdek yöntemi güçlü yönü olarak öne çıkar.

2.1.2.4 Gradyan artırma makineleri

Gradyan artırma, bir modelin hatalarını görüp öğrenmeye çalışır ve her seferinde daha iyi tahminler yapmayı hedefler. Bu süreç ardışık olarak bir dizi karar ağacı oluşturur ve her ağacın oluşturulmasında önceki ağaçların hatalarına odaklanılır. Başlangıçta

genellikle çok basit bir model oluşturulur ve her bir gözlem için modelin hataları (tahmin edilen değer ile gerçek değer arasındaki fark) hesaplanır. Daha sonrasında bu hataları düzeltmek için yeni bir karar ağacı eklenir, bu adım hataları düzeltme hedefiyle tekrar edilir.

Sonuçta tüm bu ağaçlar ile bir model oluşmuş olur ve son tahmin bu topluluğun birleşimi olur. Çok fazla ağaç oluşturulabildiği için eğitim süresi çok uzundur fakat yüksek doğruluk oranları sunar.

2.1.3 Derin öğrenme yöntemleri

Derin öğrenme yöntemleri, zaman serisi tahmininde verideki karmaşık, doğrusal olmayan ilişkileri ve uzun vadeli bağımlılıkları yakalamak için kullanılan güçlü yaklaşımlardır. Bu çalışmada ele alınan derin öğrenme yöntemleri Çizelge 2.3'teki gibi özetlenmiştir.

Çizelge 2.3 : Derin öğrenme yöntemlerinin kıyaslaması.

Özellik	RNN	LSTM
Eğitim Süresi	Orta	Yavaş
Kullanım Alanı	Zaman serileri	Uzun vadeli bağımlılıklar
Performans	Zayıf	Güçlü

2.1.3.1 Tekrarlayan sinir ağları (recurrent neural networks)

Tekrarlayan sinir ağları genellikle zaman serisi veya sıralı veri problemlerinde kullanılır. RNN geçmişteki durumu bilerek geleceği tahminleyen bir modeldir çünkü her adımda bir dönüş gerçekleştirerek önceki adımların çıktısı nasıl etkilediğini öğrenir. Buna aynı zamanda hafıza ya da gizli durum da denmektedir.

Model, zaman serisini aldıktan sonra bu veriyi zaman adımlarına böler. Her bir adımda, giriş verisini ve önceki durum verisini kullanarak gizli durumu hesaplar. Bu hesaplama için tanh veya ReLU (düzeltilmiş doğrusal birim) gibi aktivasyon fonksiyonları kullanılır. Gizli durumu hesaplamak için ağırlıklar ve eğilim (bias) terimleri kullanılır. Geri yayılım (backpropagation) ile öğrenme gerçekleşir.

2.1.3.2 Uzun kısa süreli bellek (long short-term memory)

LSTM, aslında RNN'in geliştirilmiş bir versiyonudur. LSTM uzun süreli bağımlılıkları öğrenme konusunda RNN'lere göre çok daha başarılı bir modeldir. Ayrıca bilgiyi daha uzun süre saklayabilme yeteneği vardır. İki model arasındaki en

büyük fark, LSTM’de gizli durum yerine hücre durumu (cell state) isimli bir yapı bulunmaktadır. Hücre durumu, modelin zamanla öğrendiği bilgiyi sakladığı bir bellektir.

LSTM’de üç ana yapı bulunmaktadır: Unutma kapısı (forget gate), güncelleme kapısı (input gate), çıktı kapısı (output gate). Unutma kapısı, ne tür bilgilerin unutulması gerektiğini ve önceki hücre durumunun ne kadarının saklanacağını belirler. Formülü denklem (2.4)’teki gibidir:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2.4)$$

Güncelleme kapısı modele ne kadar yeni bilgi ekleneceğini kontrol eder. Denklem (2.5)’teki gibi formülize edilir:

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2.5)$$

Çıktı kapısı ise hücre durumundan çıkacak bilgiyi belirler, denklem (2.6)’daki gibi gösterilir:

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (2.6)$$

LSTM doğrusal olmayan, karmaşık desenleri modelleyebilir. Sezonallık, trend ve ani değişimlere karşı esnektir. Veri boyutu büyüdükçe performansı artar. Diğer yandan çok sayıda hiperparametre içerdiği için eğitim süreci karmaşıktır. Büyük veri setlerine ve güçlü donanımına ihtiyaç duyar. Eğitim süresi uzundur ve modelin yorumlanabilirliği düşüktür.

2.1.4 Diğer yöntemler

Hem klasik modellere benzeyen hem de makine öğrenmesi öğeleri içeren modeller de mevcuttur. Hibrit modelleri de bu kategoride değerlendirmek doğru olur. Her hibrit model, modelleyen tercihiyle bağlı olarak geliştirildiği için bu kısımda detaylı olarak yer verilmemiştir.

2.1.4.1 Prophet

Prophet, Facebook tarafından geliştirilmiş güçlü bir zaman serisi modelidir ve sezonallığı yakalama konusunda oldukça başarılıdır. Günlük, haftalık, aylık, yıllık verilerle çalışan, sezonsal, döngüsel ve tatil/özel gün etkilerinin modellenbildiği bir

araçtır. Kullanımı esnek ve birçok modele göre basittir. Trend, verinin uzun dönemli yönelimini ifade eder.

Trendlerin zaman içinde nasıl değiştiğini Prophet kırılma noktaları (change points) ile takip eder. Kullanıcı tarafından özel gün ve tatil etkileri eklenebilmektedir. Prophet modelinin beş adet hiperparametresi bulunmaktadır.

Growth yani büyüme linear ya da logistic değerlerini alabilir. ‘changepoint_prior_scale’ verideki kırılma noktalarını ifade eder, daha büyük değerler daha esnek bir modeli daha küçük değerler daha düz bir trendi ifade eder. Sezonallık günlük, haftalık ya da aylık olarak tanımlanabilir. ‘seasonality_mode’ yani sezonallık modu additive ya da multiplicative değerlerini alabilir, eğer veri arttıkça sezonallığın etkisi artıyorsa multiplicative kullanılır. ‘seasonality_prior_scale’, sezonallığın modele etkisini ifade eden katsayıdır. Prophet az veriyle çalışabildiği gibi eksik olan verileri de tamamlayarak sorunsuz bir şekilde çıktı üretebilir. (“Outliers”, 2025) Yorumlanabilir bileşenlere sahiptir ve kullanıcı dostudur. Öte yandan karmaşık dönemsel yapılar için yetersiz kalabilir. Aykırı değerlere duyarlı olabilir ve bu sebeple çok uzun dönemli tahminlerde sapmalar artabilir.

2.2 Performans Ölçme Metrikleri

Makine öğrenmesi problemlerinde kullanılabilecek bazı performans ölçme metodları bulunmaktadır. Sınıflandırma problemleri özelinde, doğruluk (accuracy), gerçek pozitif oranı (recall), yanlış pozitif oranı, kesinlik (precision) ve F1 skoru gibi metrikler kullanılmaktadır. Bu tezde ele alınan problem bir zaman serisi problem olduğu için performans metriği olarak çeşitli hata oranları ve R^2 skoru kullanılmıştır. Bu metrikler detaylı olarak bu bölümde incelenecektir.

2.2.1 R^2 skoru

R^2 skoru, oluşturulan makine öğrenmesi modelinin kullanılan verinin ne kadarını açıklayabildiğini belirten bir metriktir. Determinasyon katsayısı da denir. Bu değer genelde 0 ile 1 arasında bir değer alır ve yüzde olarak ifade edilir, formülü ise denklem (2.7)’de belirtildiği gibidir.

$$R^2 = 1 - \frac{SS_{res}}{SS_{tot}} \quad (2.7)$$

SS (sum of squares) kareler toplamı anlamına gelmektedir. Burada SSres, model tarafından yapılan tahminlerle gerçek değerler arasındaki farkların karelerinin toplamıdır ve modelin açıklayamadığı varyansı ifade eder. SStot ise gözlemlenen değerlerin aritmetik ortalamadan sapmalarının karelerinin toplamıdır ve bağımlı değişkendeki toplam varyasyonu ifade eder. R² skorunun 1'e yakın olması modelin gözlemlenen veriye yüksek düzeyde uyum sağladığını gösterirken, 0'a yakın veya negatif değerler modelin yetersizliğini gösterir. Genellikle %60 ve yukarıdaki oranlar iyi bir modeli ifade eder.

2.2.2 Ortalama mutlak hata (mean absolute error)

Ortalama mutlak hata ya da İngilizce kısaltmasıyla MAE, bir regresyon modelinin tahmin ettiği değerler ile gözlemlenen gerçek değerler arasındaki farkların mutlak değerlerinin ortalamasını ifade eder. Denklem (2.8)'deki gibi gösterilir:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2.8)$$

Bu gösterimde ilk y gerçek değerleri, şapkalı y ise modelin tahminlediği değerleri göstermektedir. n ise gözlem sayısını ifade etmektedir. Bu hesaplamada yön önemli değildir, tahminin gerçeğin üstünde ya da altında olması önemsizdir. MAE değeri sıfıra yaklaştıkça modelin doğruluğunun arttığı söylenebilir.

2.2.3 Ortalama kare hata (mean squared error)

Ortalama kare hata, modelin tahmin hatalarının karelerini alarak ortalama hesabı yapan bir metriktir. Kare alma sayesinde büyük hatalar daha fazla cezalandırılır. Denklem (2.9)'daki gibi formüle edilir. Formülde n gözlem sayısını, ilk x gerçek değerleri, ikinci x ise modelin tahminlediği değerleri göstermektedir.

$$MSE = \frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2 \quad (2.9)$$

Düşük bir MSE değeri, modelin tahminlerinin gerçek değerlerle daha uyumlu olduğunu gösterir. Kare işleminden dolayı tahmin edilen değişkenin biriminden farklı bir değer hesaplanmaktadır.

2.2.4 Karekök ortalama kare hata (root mean squared error)

RMSE, MSE'nin karekökünün alındığı ve birim değişikliği probleminin çözüldüğü bir metriktir. Bu sayede hesaplanan değeri yorumlamak kolaylaşır. Denklem (2.10)'daki gibi ifade edilir:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2} \quad (2.10)$$

Düşük RMSE değeri modelin yüksek doğrulukla tahmin yaptığını gösterir. Özellikle yüksek hata değerlerini minimize etmeye odaklanan modellerin değerlendirilmesinde kullanılır.

3. UYGULAMA

Bu çalışmada, telekomünikasyon sektöründe faaliyet gösteren bir kurumun verisi taklit edilmiştir. Veri seti titizlikle oluşturulduktan sonra dört farklı makine öğrenmesi modeli çalıştırılmış ve performans kıyaslaması yapılmıştır. Uygulamada SARIMA, Facebook Prophet, LSTM ve Prophet ile LSTM algoritmalarının ortak kullanımından oluşturulan hibrit bir model kullanılmıştır. Son bölümde sonuçlar detaylı bir şekilde incelenmiş ve yorumlanmıştır.

3.1 Veri Setinin Tanıtımı

Bu çalışmada kullanılan veri seti, Türkiye’de aktif faaliyet gösteren bir telekomünikasyon şirketinin günlük trafik verilerinin bir benzerini içermektedir. Veri, 1 Ocak 2023 ile 31 Aralık 2024 arasındaki 730 günü kapsamaktadır ve tüm ağın toplam trafiğini ifade etmektedir. Veri, tarih ve trafik değerini gösterecek şekilde sadeleştirilmiş ve bu uygulamada seçilen tüm makine öğrenmesi modelleriyle kullanılabilecek hale getirilmiştir.

Başlangıçta telekomünikasyon sektöründe trafik tahmini tecrübesi olan profesyonellerden veri oluşturmaya dair fikir alınmıştır. Buna göre bir ortalama değer, yıllık bir artış oranı ve günlük bir artış oranı belirlenmiştir. Daha sonra önce günlük artış oranı ardından ise sezonsallık etkisi başlangıç değeri üzerine eklenerek veri seti oluşturulmuştur. Burada özellikle kış ayları ve yaz ayları, hafta içi ve haftasonları birbirinden ayırarak şekilde bir planlama yapılmıştır. Çünkü özellikle Türkiye’de kullanıcılar yaz döneminden eylül ayına yani okula dönüş dönemine geçerken ve haftasonu hafta içine göre daha fazla veri tüketimi yapmaktadır.

Her bir model için veri setinin ilk 547 günü eğitim, sonraki 184 günü test için kullanılmıştır. Prophet modelinde yıllık ve haftalık sezonsallık “True” olarak tanımlanarak veri setinde belirtilen davranış deseninin daha iyi yakalanması hedeflenmiştir.

Grid Search algoritması ile Prophet hiperparametreleri için en iyi değerlerin seçilmesi sağlanmıştır. Grid Search en iyi modeli bulmak için sağlanan hiperparametre değerlerinin her kombinasyonunu ayrıntılı olarak dener.

SARIMA modeli için en iyi parametreleri belirleyecek şekilde bir AIC (Akaike ölçütü) algoritması oluşturulmuştur. AIC, modelin eğitim verilerine uyumunu değerlendirerek ve modelin karmaşıklığına göre bir ceza terimi ekleyerek çalışır. İstenen sonuç, model uyumu ile genelleştirilebilirlik arasındaki en iyi dengeyi gösteren mümkün olan en düşük AIC değerini bulmaktır. (Zajic, 2025)

LSTM için tüm veri Min Max ölçekleme yöntemi ile [0,1] aralığına normalize edilmiştir. Keras Tuner, hiperparametre aramanın sorunlu noktalarını çözen, kullanımı kolay, ölçeklenebilir bir hiperparametre optimizasyon yöntemidir. (O'Malley, 2019) Bu yöntem ile her bir LSTM katmandaki nöron sayısı, aktivasyon fonksiyonu, öğrenme katsayısı, aşırı öğrenmeyi engelleme oranı için en iyi sonuçları veren değerler belirlenmiştir.

Hibrit modelde ise Prophet ile trend ve sezonsallık bileşenleri elde edildikten sonra tahminler ile gerçek değerler arasındaki hata (residual) hesaplanarak bu bileşenler LSTM ile tahminlenmiştir, böylelikle iki modelin güçlü yanlarının birleştirilmesi hedeflenmiştir. Burada modellerin hiperparametre optimizasyonları yalın hallerinde elde edilen değerler ile yapılmıştır.

Tüm modeller Python kullanarak oluşturulmuş, Jupyter geliştirme ortamında yazılmış ve çıktılar üretilmiştir. Pandas, numpy, sci-kit learn, matplotlib, statsmodels, tensorflow, prophet gibi veri biliminde çok sık kullanılan Python kütüphanelerinden faydalanılmıştır.


3.2 Model Sonuçları

Bu bölümde oluşturulan her bir modelin detaylarına ve belirlenen performans kriterlerine göre sonuçlarına yer verilecektir.

3.2.1 Prophet

Prophet algoritması girdi olarak tarihten ('ds') ve tahminlenecek değerden (y) oluşan bir veri ile çalışmaktadır. Oluşturduğumuz veri seti zaten buna göre oluşturulduğu için kolon isimleri değiştirildikten sonra model yıllık ve haftalık sezonsallık gözetilerek oluşturulmuştur. Günlük sezonsallık ise aktif edilmemiştir. Daha sonra eğitim seti ile model çalıştırılmıştır. Test veri setimizin boyutu kadar bir tahminleme periyodu belirlendikten sonra öğrenilen değerler ile gelecek tahminlenmiştir. Daha sonra tahminlenen değerler ile test setimizde bulunan değerler kıyaslanarak MAE, MSE, RMSE ve R^2 skoru hesaplanmıştır. Şekil 3.1'de görüldüğü üzere MAE sıfıra yakın, R^2 skoru %77 olduğu için kurulan modelin oldukça başarılı olduğunu söylemek mümkündür.

Prophet Modeli Performansı:
MAE: 1.6691
MSE: 5.4799
RMSE: 2.3409
 R^2 : 0.7709



Şekil 3.1: Prophet modelinin tahminleri ile gerçek değerlerin kıyaslanması.

3.2.2 SARIMA

Sezonsallığın trafik tahminindeki önemi vurgulandığı için sezonsal verilerle en uyumlu şekilde çalışan klasik modellerden biri olan SARIMA için toplamda yedi adet parametre seçilmesi gerekmektedir. SARIMA modeli için parametre seçimi sırasında en çok zorlandığım konu, mevsimsel bileşenlerin etkisini doğru şekilde modellemektir. Hem SARIMA'nın doğası gereği hem de en iyi parametreleri seçmek için Grid Search tercih etmem sebebiyle modelin çalışması çok uzun sürmüştür.

Aylık sezonsallığı belirlemek için sezonsal periyot 12 olarak tanımlanmıştır. En iyi parametreler belirlendikten sonra model buna göre oluşturulmuştur ve eğitim seti ile tahminler yapılmıştır. Modelin tahminleri ile test setine ayrılan veriler kıyaslanarak MAE, MSE, RMSE ve R^2 skoru hesaplanmıştır. Modelin belirlediği en iyi parametreler Çizelge 3.1'deki gibidir:


Çizelge 3.1: SARIMA modelinin seçtiği parametreler.

p	d	q	P	D	Q	S
2	1	2	2	0	2	12

Şekil 3.2'de de görüldüğü üzere SARIMA'nın hata oranları düşük olarak yorumlansa da R^2 skoru %17.6 ile beklentinin çok altındadır. Modelin verideki ani değişimleri yakalayamadığı görülmektedir. Diğer yandan bir modelin performansını değerlendirmek için tek bir metrik yeterli değildir ve birçok farklı açıdan bakmak gerekmektedir.

SARIMA Modeli Performansı:

MAE: 3.2538
MSE: 19.6843
RMSE: 4.4367
 R^2 : 0.1769



Şekil 3.2: SARIMA modelinin tahminleri ile gerçek değerlerin kıyaslaması.


3.2.3 LSTM

LSTM modeli için ilk adım olarak MinMaxScaler fonksiyonu ile verinin $[0,1]$ arasında normalizasyonu sağlanmıştır. Daha sonrasında modelin kullanacağı sekanslar için uzunluğu 12 olarak belirleyip (12 aylık sezonsallığı temsil eder) eğitim ve test setleri

de benzer şekilde ölçeklendirilmiştir. Modelde aktivasyon fonksiyonu olarak “relu” yani düzeltmeli doğrusal birim kullanılmıştır. Aktivasyon fonksiyonları yapay sinir ağını daha esnek ve güçlü hale getirmek için kullanılır. Bu sayede model, verilerdeki karmaşık ilişkileri öğrenebilir ve giriş ile çıkış arasında doğrusal olmayan bağlantılar kurabilir.

Bu çalışmada 3 katmanlı bir LSTM modeli kurularak ilk katmanda 128 nöron, ikinci katmanda 64 nöron, üçüncü katmanda ise 32 nöron kullanılmıştır. Dropout fonksiyonu ile aşırı öğrenmeyi engellemek adına bazı nöronların geçici olarak kapatılması sağlanmıştır. “Dense” fonksiyonu ile son adımda tek bir tahmin ile bir sonraki ayın trafik tahmini yapılmaktadır. Modelde devir (epoch) değeri 150 olarak belirlenmiştir yani 150 kez tüm veri üzerinden bir eğitim gerçekleştirilecektir. Verinin 8’li gruplar halinde modele verilebilmesi için batch_size parametresi buna göre ayarlanmıştır. Model 0-1 arasında çıktılar ürettiği için geri dönüştürme fonksiyonu kullanılarak gerçek değerlere dönüştürülmektedir. Test verisi ile tahminler kıyaslanarak diğer modellerde olduğu gibi MAE, MSE, RMSE ve R^2 skoru hesaplanmıştır. Şekil 3.3’te de görüldüğü üzere LSTM modelinin performansı Prophet modelinden düşük olsa da SARIMA’dan yüksektir. Verinin %52.8’ini açıklayabilmiştir.

🔴 Tuner ile En İyi LSTM Model Performansı:
MAE: 2.3789
MSE: 11.7708
RMSE: 3.4309
 R^2 : 0.5281



Şekil 3.3: LSTM modelinin tahminleri ile gerçek değerlerin kıyaslaması.


3.2.4 Hibrit model

Bu model sezonsallık ve trend içeren zaman serilerinde oldukça yeterli performans gösterdiği bilinen Prophet modelini daha da iyi hale getirmenin mümkün olup olmadığını keşfetmek amacıyla oluşturulmuştur.

İlk adım olarak Prophet'ın yaptığı tahminler ile gerçek değerler birbirinden çıkarılarak her bir tahmin için hata (residual) hesabı yapılır. Burada temel mantık Prophet tahmininin üzerine LSTM modelinin düzelttiği hata eklenerek daha az sapma gösteren sonuçlar elde etmektir.

Şekil 3.4'te de görüldüğü üzere hata oranları oldukça düşük hesaplanmıştır. Prophet modeli verinin %77'sini açıklayabiliyorken hibrit model verinin %84'ünü açıklayabilmiştir. Daha büyük ve gerçek veri setlerinde bu yüzdesel iyileşmenin daha da fazla olacağı öngörülmektedir.

Hibrit Prophet + LSTM Model Performansı:
MAE: 1.4399
MSE: 3.8140
RMSE: 1.9529
R²: 0.8405



Şekil 3.4: Hibrit modelin tahminleri ile gerçek değerlerin kıyaslaması.

3.2.5 Karşılaştırma

Bu çalışmanın sonunda tüm modeller seçilen performans metriklerine göre kıyaslandığında hibrit modelin en başarılı model olduğu görülmektedir. Hibrit modeli sırasıyla Prophet, LSTM ve SARIMA takip etmektedir. Tüm modellerin performans metriklerine göre kıyaslanması Çizelge 3.2'de özetlenmiştir.

Çizelge 3.2: Tüm modellerin performans metriklerine göre kıyaslanması.

Modeller	MAE	MSE	RMSE	R ²
SARIMA	3.25	19.6	4.4	%17
LSTM	2.38	11.8	3.4	%52.8
Prophet	1.67	5.5	2.3	%77
Hibrit	1.44	3.8	1.9	%84



4. SONUÇ VE ÖNERİLER

Bu tez kapsamında, telekomünikasyon sektöründe zaman serisi tabanlı trafik tahminlemenin önemi vurgulanmış ve farklı modelleme yaklaşımlarının doğruluk, esneklik ve genel performans açısından karşılaştırmalı bir analizi gerçekleştirilmiştir. Özellikle 5G ve veri trafiğinde yaşanan ciddi artışla birlikte, ağ kapasitesinin etkin yönetimi, proaktif kaynak planlaması ve müşteri memnuniyetinin sürdürülebilirliği açısından güvenilir trafik tahmin sistemlerine olan ihtiyaç giderek artmaktadır. Bu bağlamda, yapılan çalışma telekomünikasyon sektörü başta olmak üzere, zaman serisi verisiyle çalışan diğer sektörler için de uygulanabilir nitelikte yöntemsel ve pratik bir rehber sunmaktadır.

Tezde değerlendirilen dört farklı model hem teorik temelleri hem de uygulamadaki başarıları açısından detaylı biçimde ele alınmıştır. Yapılan deneysel analizler sonucunda, hibrit modelin diğer modellere kıyasla daha düşük hata oranları ile en başarılı tahmin performansını sergilediği görülmüştür. Prophet modelinin trend ve sezonsallık analizi konusundaki güçlü yapısının, LSTM'in karmaşık zaman bağımlılıklarını öğrenme kapasitesiyle birleştirilmesi, modelin hem doğruluğunu hem de esnekliğini artırmıştır.

Modellerin genel performans sıralaması şu şekilde ortaya çıkmıştır: Hibrit model, Prophet, LSTM, SARIMA. Bu sıralama, geleneksel istatistiksel modellerin (SARIMA) trend ve sezonsallık içeren uzun vadeli serilerde sınırlı kaldığını; buna karşın modern, öğrenme temelli yaklaşımların (özellikle hibrit yapıların) daha etkili çözümler sunduğunu göstermektedir. Prophet modelinin sade parametre ayarları ve sezonsal yapılarla baş etmedeki başarısı, onu telekomünikasyon gibi döngüsel yoğunluk gösteren sektörlerde kullanışlı hale getirmektedir.

Bu çalışmanın telekomünikasyon sektörü için doğrudan bir uygulama potansiyeli mevcuttur. Ağ kapasitesi planlaması, bütçe optimizasyonu, yatırım planlarının zamanlaması gibi birçok kritik süreçte, geliştirilen modeller finansal karar destek sistemlerine entegre edilerek stratejik katkılar sağlayabilir.

Bu çalışmada tahminleme, yaklaşık iki yıllık günlük trafik verileri üzerinden gerçekleştirilmiştir. Gelecekteki araştırmalarda veri sıklığı saatlik düzeyde artırılarak modellerin daha hassas ve detaylı tahminlerde bulunması sağlanabilir. Bu tür granüler veriyle çalışmak, özellikle kısa dönemli operasyonel kararlar ve gerçek zamanlı trafik yönetimi gibi konularda önemli avantajlar sunar.

Mevcut modellemeler yalnızca geçmiş trafik verilerine dayanarak tahmin gerçekleştirmiştir. Ancak, veri bilimi literatüründe zaman serisi tahminlerinin başarısının, sadece geçmiş verilere değil, aynı zamanda dışsal (eksojen) faktörlerin de dikkate alınmasıyla önemli ölçüde arttığı gösterilmiştir. Telekomünikasyon trafiğini etkileyebilecek bazı dışsal faktörler; bayramlar ve tatiller, kampanya dönemleri, hava durumu koşulları, kullanıcı demografisi değişiklikleri, okul açılış/kapanış tarihleri olabilir. Bu değişkenler modele dahil edilerek daha isabetli tahminler elde edilebilir.

Özetle bu çalışma, telekomünikasyon alanında trafik tahmini gibi kritik bir problem için geliştirilen modellerin başarı düzeylerini karşılaştırmalı olarak inceleyerek önemli çıktılar sunmuştur. Özellikle Prophet tabanlı hibrit modelin, diğer yaklaşımlara kıyasla daha yüksek doğrulukla öngörü yapabildiği görülmüştür. Bu çalışmada yalnızca geçmiş veriler kullanıldığı için, gelecekte anlık trafik değişimlerini de içeren veri setleriyle çalışmanın, model başarısını daha da artırabileceğini düşünüyorum.

Gelecek çalışmalarda özellik seçimi (feature selection) ve aykırı değer tespiti (outlier detection) gibi daha gelişmiş ayrıştırma tekniklerinin, dışsal değişkenlerin etkisinin ve genetik algoritmalar gibi hiperparametre optimizasyon süreçlerinin modele entegre edilmesi, hem performansı artırabilir hem de modelin genellenebilirliğini güçlendirebilir. Özellikle çok değişkenli trafik verilerinin analiz edildiği senaryolarda, modele anlamlı katkı sağlayan değişkenlerin belirlenmesi, modelin hem doğruluğunu hem de yorumlanabilirliğini artıracaktır. Bu tür iyileştirmeler, özellikle gerçek zamanlı ağ trafiği tahmin uygulamalarında daha sağlam ve güvenilir sonuçlar elde edilmesini mümkün kılabilir. Böylelikle bu çalışma yalnızca telekomünikasyon sektörü için değil, enerji, ulaşım, e-ticaret ve finans gibi zaman serisi verisine dayanan diğer endüstrilerde de esnek ve kolaylıkla uygulanabilir bir çözüm önerisi sunmaktadır. Elde edilen bulguların, hem sektörel uygulamalarda hem de akademik literatürde gelecekteki çalışmalara sağlam bir temel oluşturma potansiyeli vardır. Telekomünikasyon sektöründe aktif olarak veri mühendisliği süreçlerinde yer alan biri olarak, bu tür modellerin gerçek hayat uygulamalarında pek çok zorluğu aşabileceğine inanıyorum.

KAYNAKLAR

- Aladag, C. H., Egrioglu, E., & Kadilar, C.** (2009). Forecasting nonlinear time series with a hybrid methodology. *Applied Mathematics Letters*, 22(9), 1467–1470. <https://doi.org/10.1016/j.aml.2009.02.006>
- Arslan, S.** (2022). A hybrid forecasting model using LSTM and Prophet for energy consumption with decomposition of time series data. *PeerJ Computer Science*, 8, e1001. <https://doi.org/10.7717/peerj-cs.1001>
- Bashir, T., Haoyong, C., Faizan Tahir, M., & Liqiang, Z.** (2022). Short-term electricity load forecasting using hybrid prophet-LSTM model optimized by BPNN. *Energy Reports*, 8, 1678-1686. <https://doi.org/10.1016/j.egyr.2021.12.067>
- Cembaluk, P., Aniszewski, J., Knapieńska, A., & Walkowiak, K.** (2022). Forecasting the network traffic with PROPHET. *Proceedings of the 3rd Polish Conference on Artificial Intelligence*, 215–218.
- Dangi, R., & Lalwani, P.** (2022). A novel hybrid deep learning approach for 5G network traffic control and forecasting. *Concurrency and Computation Practice and Experience*, 35(7). <https://doi.org/10.1002/cpe.7596>
- Ericsson** (2024). *Ericsson Mobility Report June 2024*. <https://www.ericsson.com/en/reports-and-papers/mobility-report>
- Ertürk, M. A.** (2024). Comparison of Time Series Forecasting for Intelligent Transportation Systems in Digital Twins. -. <https://doi.org/10.5152/electrica.2024.23200>
- Gao, J.** (2022). Time-series prediction research based on combined prophet-LSTM models. *2021 17th International Conference on Computational Intelligence and Security (CIS)*, 143–147. <https://doi.org/10.1109/cis58238.2022.00037>
- Karthika, S., Margaret, V., & Balaraman, K.** (2017, August). *Hybrid short term load forecasting using ARIMA-SVM*. 2017 Innovations in Power and Advanced Computing Technologies (i-PACT) (pp. 1–6). IEEE. <https://doi.org/10.1109/IPACT.2017.8245060>
- Katwal, S., Shrestha, R., & Sharma, G.** (2024). Analysis of Website Traffic Time Series Forecasting using ARIMA, Prophet, and LSTM RNN. *International Journal of Research Publications*, 146(1). <https://doi.org/10.47119/ijrp1001461420246271>
- Khashei, M., & Bijari, M.** (2011). A new class of hybrid models for time series forecasting. *Expert Systems With Applications*, 39(4), 4344–4357. <https://doi.org/10.1016/j.eswa.2011.09.157>

- Kong, Y. H., Lim, K. Y., & Chin, W. Y.** (2021). Forecasting Facebook user engagement using hybrid Prophet and long short-term memory model. *International Conference on Digital Transformation and Applications (ICDXA)*, October 25-26, 2021, Kuala Lumpur, Malaysia. https://www.tarc.edu.my/files/icdxa/proceeding_new/920C21C7-4E28-44B4-9E3A-ECB64CBB13CD.pdf
- Ma, T., Antoniou, C., & Toledo, T.** (2020). Hybrid machine learning algorithm and statistical time series model for network-wide traffic forecast. *Transportation Research Part C: Emerging Technologies*, 111, 352-372. <https://doi.org/10.1016/j.trc.2019.12.022>
- Madan, R., & Mangipudi, P. S.** (2018). Predicting computer network traffic: A time series forecasting approach using DWT, ARIMA and RNN. 2018 *Eleventh International Conference on Contemporary Computing (IC3)*, 1–6. <https://doi.org/10.1109/IC3.2018.8530608>
- Ning, Y., Kazemi, H., & Tahmasebi, P.** (2022). A comparative machine learning study for time series oil production forecasting: ARIMA, LSTM, and Prophet. *Computers & Geosciences*, 164, 105126. <https://doi.org/10.1016/j.cageo.2022.105126>
- O'Malley, T., Bursztein, E., Long, J., Chollet, F., Jin, H., Invernizzi, L.** (2019). *KerasTuner*. GitHub. <https://github.com/keras-team/keras-tuner>
- Outliers.** (2025, May 30). *Prophet*. <https://facebook.github.io/prophet/docs/outliers.html>
- Prajam, S., Wechtaisong, C., & Khan, A. A.** (2022). Applying machine learning approaches for network traffic forecasting. *Indian Journal of Computer Science and Engineering*, 13(2), 324–330. <https://doi.org/10.21817/indjcse/2022/v13i2/221302188>
- Prasad, G. L. V., Teja, B. R., Haribabu, T., Pavani, G. N., Karunamma, D., & Vivek, K.** (2023). A Hybrid Time Series Rainfall Prediction Model Using Neural Prophet and LS TM. -, 1582–1587. <https://doi.org/10.1109/icssas57918.2023.10331827>
- Shi, J., Leau, Y.-B., Li, K., & Obit, J. H.** (2021). A comprehensive review on hybrid network traffic prediction model. *International Journal of Electrical and Computer Engineering (IJECE)*, 11(2), 1450–1459. <https://doi.org/10.11591/ijece.v11i2.pp1450-1459>
- Su, S., Sun, Y., Zeng, Y., & Peng, C.** (2023). Aviation risk prediction based on Prophet–LSTM hybrid algorithm. *Aircraft Engineering and Aerospace Technology*, 95(7), 1054–1061. <https://doi.org/10.1108/aeat-08-2022-0206>
- Subashini, A., Sandhiya, K., Saranya, S., & Harsha, U.** (2019). Forecasting Website Traffic Using Prophet Time Series Model. *International Research Journal of Multidisciplinary Technovation*, 1(1), 56–63. <https://doi.org/10.34256/irjmt1917>
- Thakur, U., Singh, S. K., Kumar, S., Singh, H., Arya, V., Gupta, B. B., Attar, R. W., Alhomoud, A., & Chui, K. T.** (2025). Advanced Web Traffic

Modelling and Forecasting with a Hybrid Predictive Approach. *Journal of Web Engineering*. <https://doi.org/10.13052/jwe1540-9589.2434>

- Vijayaraghavan, N., Sundaram, K. K., Narasimhan, S., & Sankaradass, V.** (2025). An Extensive Analysis on Predictive Modeling for Network Traffic using Deep Learning Algorithms. 2025 International Conference on Data Science, Agents & Artificial Intelligence (ICDSAAI), Chennai, India, 2025, Pp. 1-6, <https://doi.org/10.1109/icdsaaai65575.2025.11011729>
- Wang, Z., Sun, P., Hu, Y., & Boukerche, A.** (2023). A novel hybrid method for achieving accurate and timeliness vehicular traffic flow prediction in road networks. *Computer Communications*, 209, 378–386. <https://doi.org/10.1016/j.comcom.2023.07.019>
- Zajic, A.** (2025, April 17). *What is Akaike Information Criterion (AIC)?* Built In. <https://builtin.com/data-science/what-is-aic>
- Zaraket, K., Harb, H., Bennis, I., Jaber, A., & Abouaissa, A.** (2024). Hyper-Flophet: A neural Prophet-based model for traffic flow forecasting in transportation systems. *Simulation Modelling Practice and Theory*, 134, 102954. <https://doi.org/10.1016/j.simpat.2024.102954>
- Zhang, L., Alharbe, N. R., Luo, G., Yao, Z., & Li, Y.** (2018). A hybrid forecasting framework based on support vector regression with a modified genetic algorithm and a random forest for traffic flow prediction. *Tsinghua Science & Technology*, 23(4), 479–492. <https://doi.org/10.26599/tst.2018.9010045>
- Zhou, L., Chen, M., & Ni, Q.** (2020). A hybrid Prophet-LSTM Model for Prediction of Air Quality Index. 2021 *IEEE Symposium Series on Computational Intelligence* (SSCI), 595–601. <https://doi.org/10.1109/ssci47803.2020.9308543>



ÖZGEÇMİŞ

Ad-Soyad

: Buse Dilan Uslan

ÖĞRENİM DURUMU:

- **Lisans** : 2021, İstanbul Teknik Üniversitesi, Bilgisayar ve Bilişim Fakültesi, Bilgisayar Mühendisliği
- **Yükseklisans** : 2025, İstanbul Teknik Üniversitesi, İşletme Mühendisliği Anabilim Dalı, İşletme Mühendisliği Tezli Yüksek Lisans Programı

MESLEKİ DENEYİM VE ÖDÜLLER:

- 2021 Eylül – Günümüz: Vodafone Network Veri Bilimcisi
- 2021 Mart-Eylül : Yapı Kredi Teknoloji Yazılım Mühendisi