

BOR SEKTÖRÜNDE AUTO ML VE AĞIRLI KLANDIRMA YÖNTEMİ İLE TALEP TAHMİNİ UYGULAMASI

Arzu ÇAKIROĞLU *^{ID}
Pınar ÖZEN **^{ID}

Alınma: 28.05.2025 ; düzeltme: 17.11.2025 ; kabul: 18.01.2026

Öz: Bu çalışmada, bir kurumun sevkiyat verileri kullanılarak talebi doğru tahmin etmeyi amaçlayan bir model önerisi sunulmuştur. AutoML (Otomatik Makine Öğrenmesi) yaklaşımı kapsamında AutoTS (Otomatik Zaman Serisi) kütüphanesi ile yedi farklı zaman serisi modeli test edilmiş ve performansları çeşitli hata metrikleriyle değerlendirilmiştir. Modelleme sürecinde ürün adı, torbalama türü ve şekli esas alınarak oluşturulan 5 farklı grup için ayrı tahminler yapılmıştır. Tahmin sonuçları ağırlıklandırma yöntemiyle birleştirilerek nihai tahminlere ulaşılmıştır. Çalışma, AutoML temelli zaman serisi tahminlerinin karar destek süreçlerinde etkin bir biçimde kullanılabileceğini göstermektedir. Ayrıca önerilen ağırlıklı modelleme yaklaşımı, dinamik yapısıyla tahmin doğruluğunu artırmaya katkı sağlamaktadır. Kurumun birden fazla ürünü için yapılan tahminler değerlendirilmiş; ancak bu makalede bir ürün üzerinden dört çeyrek dönemlik tahminler ile gerçekleşen değerler karşılaştırılmıştır. Seçilen ürün için çeyrek sonlarında sırasıyla %33, %-82, %-15 ve %0,63 oranlarında sapmalar gözlemlenmiştir. Sonuçlar, modelin bazı dönemlerde sapmalar gösterdiğini, bazı dönemlerde tahmin doğruluğu yüksek olduğunu göstermektedir.

Anahtar Kelimeler: Talep Tahmini, Zaman Serisi Analizi, AutoML, AutoTS, Lojistik, Makine Öğrenmesi

Demand Forecasting Application Using Automl and Weighting Method

Abstract: In this study, a model is proposed to accurately forecast demand based on the shipment data of a public institution. Within the scope of the AutoML (Automated Machine Learning) approach, seven different time series models were tested using the AutoTS (Automated Time Series) library, and their performances were evaluated using various error metrics. During the modeling process, five different groups were created based on variables such as product name, packaging type, and shape, and separate forecasts were generated for each group. The forecasting results were then combined using a weighting method to obtain final predictions. The study demonstrates that AutoML-based time series forecasting can be effectively used in decision support processes. Furthermore, the proposed weighted modeling approach contributes to improving forecast accuracy with its dynamic structure. Although forecasts were generated for multiple products, this paper compares forecasted and actual values for a single product over four quarters. For the selected product, deviations of 33%, -82%, -15%, and 0.63% were observed at the end of each quarter, respectively. The results show that while the model exhibited significant deviations in some periods, it achieved high forecast accuracy in others.

Keywords: Demand Forecasting, Time Series Analysis, AutoML, AutoTS, Logistics, Machine Learning

1. GİRİŞ

İşletmelerin rekabetçi ortamda güçlü kalabilmeleri için lojistik ve tedarik zinciri kritik öneme sahiptir. Küreselleşen Pazar ortamı ve müşteri beklentilerinin giderek artması, işletmelerin lojistik ve tedarik süreçlerini daha verimli ve düşük maliyetli yönetmelerini zorunlu

* Evliya Çelebi Yerleşkesi Tavşanlı Yolu 10.km 43100 Kütahya / Türkiye

** Evliya Çelebi Yerleşkesi Tavşanlı Yolu 10.km 43100 Kütahya / Türkiye

İletişim Yazarı: Arzu Çakıroğlu (arzucakiroglu19@gmail.com)

kılmaktadır. Talep tahmini bahsedilen bu süreçlerin en önemli adımlarından biridir. Talep tahmini İşletmelerin stok yönetimi, üretim ve dağıtım planlaması, müşteri hizmetleri gibi birçok alanda stratejik kararlar almasını sağlar. Hatalı tahminler ise stok fazlası veya eksikliği gibi sorunlara yol açarak maliyetlerin ve müşteri şikayetlerinin artmasına sebep olabilir.

Bu çalışma, bir kamu kurumunda karşılaşılan operasyonel bir sorunun çözümüne yönelik gerçekleştirilmiştir. Kurumda üretilen ürünler toz ürün olarak üretilmekte, üretim bandından çıktığı anda paketlenmekte ve paketli olarak depolanmaktadır. Ancak, müşteriden sipariş geldiğinde eğer depoda müşterinin talebine uygun paket türü mevcut değilse, mevcut paketler değiştirilerek yeniden paketlenme işlemi yapılmaktadır. Bu süreç, hem zaman hem de maliyet açısından kayıplara yol açmaktadır. Yeniden paketlenme işlemi, paket zayıflığına, iş gücü maliyetlerinin artmasına ve zaman kaybına sebep olmaktadır. Bu problem, depo yönetimi ve lojistik süreçlerde verimliliği düşürmektedir.

Talep tahmini, tarihsel verileri kullanarak gelecekteki ürün veya hizmet talebini tahmin etmeyi amaçlayan stratejik bir süreçtir. Talep, müşterilerin belirli bir mal veya hizmeti belirli bir fiyat üzerinden satın almayı planladıkları miktar olarak tanımlanmakta ve olası satış hacmini ifade etmektedir. Bir ürüne yönelik talebin büyüklüğü ve bunun doğru şekilde ölçülmesi, işletmeler açısından büyük öneme sahiptir (Alpay ve Yüzüğüllü, 2005). Özellikle üretim planlaması süreçleri için gelecekte talebin ne düzeyde oluşacağını kestirilmesi büyük önem taşımaktadır. Talebin doğru tahmin edilmesi, hammadde tedarik süreçleri, kapasite planlaması gibi süreçlerin etkin yönetilmesi için zorunludur. Ürüne pazarda oluşacak talebin yöneticiler tarafından bilinmesi, üretim ve lojistik yönetimi süreçlerinde stratejik kararlar alınmasında, hazırlıkların yapılmasında ve eyleme geçilmesinde önemlidir (Top ve Yılmaz, 2009). Geleneksel istatistiksel yöntemlerle yürütülen talep tahmini süreçleri son yıllarda yerini makine öğrenmesi ve yapay zeka tekniklerine bırakmaktadır. Makine öğrenmesi modelleri, büyük, çok boyutlu ve karmaşık veri setlerindeki örüntüleri otomatik olarak öğrenebilme yetenekleri sayesinde, talep tahmininde daha yüksek doğruluk sağlamaktadır (Cerqueira ve diğ., 2022).

Özellikle AutoML kütüphaneleri bu süreci hızlı ve kolay hale getirmektedir. AutoML, veri ön işleme, model seçimi, model eğitimi, hiperparametre optimizasyonu gibi süreçleri otomatikleştirerek, kullanıcıların uzmanlık gereksinimlerini en aza indirmektedir (Wang ve diğ., 2022).

(He ve diğ., 2019) tarafından yapılan kapsamlı çalışmada, AutoML'in temel bileşenleri (örneğin meta-öğrenme, Bayesian optimizasyon) tanımlanmış ve bu teknolojinin özellikle zaman serisi gibi karmaşık veri tiplerinde nasıl verimlilik sağladığı ortaya konmuştur. Araştırma, AutoML sistemlerinin yalnızca zaman ve maliyet tasarrufu sağlamakla kalmayıp aynı zamanda daha yüksek model doğruluğu elde edilmesine de katkı sunduğunu vurgulamaktadır. AutoML, zaman serisi verilerinde özellikle veri hazırlama, model seçimi ve hiperparametre optimizasyonu gibi işlemleri otomatikleştirerek süreci hızlandırmakta ve doğruluğu artırmaktadır.

Zaman serisi tahmini için geliştirilen özel AutoML araçları, literatürde giderek daha fazla ilgi görmektedir. Meisenbacher ve diğ. (2022), otomatik zaman serisi tahmin sistemlerini detaylı şekilde incelemiş ve bu sistemlerin özellikle büyük veri setlerinde hızlı ve güvenilir sonuçlar ürettiğini göstermiştir. Çalışmada, AutoML sistemlerinin manuel model kurulumlarına göre zaman kazandırdığı ve hiperparametre ayarlamalarında insan hatasını minimize ettiği belirtilmektedir. Ayrıca, zaman serisi verilerine özgü AutoML araçlarının, geleneksel yöntemlere göre daha iyi genelleme performansı sergilediği vurgulanmaktadır.

AutoML teknolojilerinin gelişiminde temel yapı taşlarından biri olan scikit-learn kütüphanesi (Pedregosa ve diğ., 2011), Python ekosisteminde standart hale gelmiş bir makine öğrenmesi aracıdır. Scikit-learn, veri ön işleme, modelleme ve değerlendirme aşamalarında sunduğu modüllerle, kullanıcıların hem klasik hem de otomatik makine öğrenmesi uygulamaları geliştirmesine imkan tanımıştır. Bu kütüphane üzerinde inşa edilen Auto-Sklearn ve TPOT (Tree-Based Pipeline Optimization Tool – Ağaç Tabanlı Boru Hattı Optimizasyonu Aracı) gibi

araçlar, zaman serisi tahmini dahil olmak üzere birçok alanda AutoML projelerine öncülük etmiştir. AutoML sistemleri, scikit-learn'ün sağladığı esneklik ve kapsamlı modüller sayesinde, hem veri hazırlık hem de modelleme aşamalarında daha hızlı ve doğru sonuçlar elde edilmesine olanak tanımaktadır.

Zaman serisi tahmininde ve genel olarak makine öğrenmesi uygulamalarında, tek bir modelin sınırlamalarını aşmak için ensemble yöntemleri sıklıkla kullanılmaktadır. (Dietterich, 2000), ensemble öğrenmenin temel prensiplerini açıklamış; bagging (örnekleme ile birleştirme), boosting (güçlendirme) ve stacking (katmanlı öğrenme) gibi tekniklerin modelin genelleme yeteneğini artırarak overfitting (aşırı uyum) riskini azalttığını belirtmiştir. Bu teknikler sayesinde, farklı modellerin güçlü yönleri bir araya getirilmekte ve daha dengeli sonuçlar elde edilmektedir. Özellikle zaman serisi verilerinde, birden fazla modelin çıktılarının entegrasyonu, farklı modellere ait hataları dengeleyerek daha doğru tahminler yapılmasını sağlamaktadır.

(Opitz ve Maclin, 1999), farklı ensemble yöntemlerini deneysel olarak karşılaştırmış ve bu yaklaşımların bireysel modellere kıyasla belirgin doğruluk artışı sağladığını göstermiştir. Özellikle bagging ve boosting gibi yöntemlerin, veri setindeki gürültüye karşı daha dayanıklı sonuçlar üretebildiği bulunmuştur. Bu çalışmalar, ensemble öğrenmenin farklı alanlardaki uygulanabilirliğini açıkça desteklemektedir. Ensemble yöntemlerinin, özellikle zaman serisi gibi karmaşık verilere dayalı tahminlerde model hatalarını minimize etmede önemli bir rol oynadığı gösterilmiştir.

Son olarak, (Park ve diğ. 2021) tarafından geliştirilen Self-Weighted Ensemble yöntemi, farklı modellerin çıktılarının güvenilirliğine göre ağırlıklandırılarak birleştirilmesini önermektedir. Bu yöntem sayesinde, güvenilirliği düşük modellerin etkisi azaltılmakta ve genel tahmin doğruluğu artırılmaktadır. Özellikle değişken veri kalitesine sahip veri setlerinde, bu tip ağırlıklandırılmış yaklaşımlar önemli performans kazançları sağlamaktadır. Self-Weighted Ensemble yöntemi, ensemble tekniklerinin doğruluğunu artırmada daha güvenilir ve sağlam bir yaklaşım sunmakta, zaman serisi verilerinde ise modelin genelleme gücünü artırmaktadır.

Bu çalışmada, zaman serisi tahmini için özel olarak tasarlanmış bir AutoML kütüphanesi olan AutoTS kullanılmıştır. AutoTS, hem ARIMA gibi geleneksel algoritmaları hem de Prophet, LSTM (Long-Short Term Memories – Uzun Kısa Süreli Bellek) gibi yeni nesil makine öğrenmesi algoritmalarını birlikte otomatik olarak test eder, karşılaştırır ve en iyi performans gösteren modeli seçer (Wang ve diğ.,2022). Ayrıca AutoTS'ten elde edilen sonuçlar ağırlıklandırma yöntemi ile birleştirilerek modelin gücünün artırılması hedeflenmiştir.

Bu çalışmanın temel amacı, müşteri taleplerini önceden tahmin ederek uygun paketleme türlerinin depoda hazır bulunmasını sağlamaktır. Bu sayede, yeniden paketleme işlemlerinin önüne geçilerek zaman ve maliyet kayıpları minimize edilebilir. Ayrıca, bu yaklaşım, lojistik süreçlerin optimizasyonuna ve müşteri memnuniyetinin artırılmasına katkıda bulunacaktır.

2. MATERYAL VE METOD

2.1. Problem Tanımı

Çalışılan kurumda ürünler, üretim bandından çıktığı anda paketlenmekte ve paketli bir şekilde depolanmaktadır. Ancak, müşteri siparişi geldiğinde eğer depoda müşterinin talebine uygun paket türü mevcut değilse, mevcut paketler değiştirilerek yeniden paketleme işlemi yapılmaktadır. Bu süreç, hem zaman hem de maliyet açısından kayıplara yol açmaktadır. Yeniden paketleme işlemi, paket zayıflığına, iş gücü maliyetlerinin artmasına ve zaman kaybına sebep olmaktadır. Bu problem, depo yönetimi ve lojistik süreçlerde verimliliği düşürmektedir.

2.2. Yöntem

Bu çalışmada lojistik sektöründe talep tahmini problemi ele alınmıştır. Lojistik süreçler kapsamına giren stok yönetimi, tedarik planlaması ve operasyonel verimlilik gibi konularda

doğru kararlar verilebilmesi için doğru talep tahmini büyük önem taşımaktadır. Bu çalışmada kullanılan veri, bor sektöründe faaliyet gösteren bir kuruma ait sevkiyat verileridir. Gizlilik gerekçesiyle ürünlerin adı bu çalışmada belirtilmemiştir. 43 farklı ürün A, B, ..., AP, AR şeklinde şifrelenmiştir. Çalışma kapsamında kullanılan veri seti 33.477 gözlem ve 16 değişken içermektedir (Tablo 1).

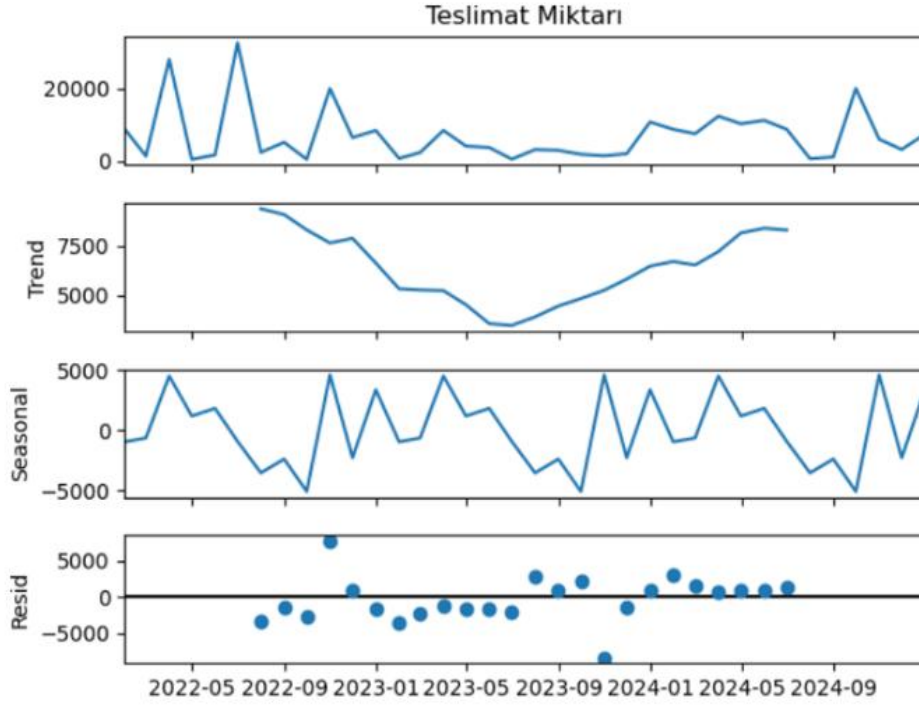
Tablo 1: Veri Seti Değişken İsimleri Tablosu

No	Sütun Adı	No	Sütun Adı
1	Malzeme	10	Yükleme Limanı
2	Torbalama Şekli	11	Boşaltma Limanı
3	Torbalama Türü	12	Boşaltma Limanı Ülke
4	Fiili Mal Çıkış Tarihi	13	Navlun Birim Fiyat
5	Sipariş Belgesi	14	Incoterms (*) - Anahtar
6	Teslimat	15	Birim Fiyat
7	Sipariş Oluşturma Tarihi	16	Birim Fiyat Para Birimi
8	İstenen Teslimat Tarihi		
9	Teslimat Miktarı		

(*)*Incoterms, Uluslararası Ticaret Odası (ICC) tarafından yayınlanan ve uluslararası işlemlerde malların satışı için satıcıların ve alıcıların sorumluluklarını tanımlayan 11 ayrı kuraldan oluşan bir settir.*

Veri setindeki her bir satır kurumdan çıkan ürün taşıyan her bir kamyonun kaydını içermektedir. Kurumun üretim tesislerinde 43 çeşit ürün üretilmektedir. Veri seti Ocak 2022 ile Aralık 2024 tarihleri arasındaki verileri içermektedir. 2022 ve 2023 yılı verileri tahmin modeli eğitimleri için kullanılmış; 2024 yılı verileri sonuçları değerlendirmek ve ağırlıklandırma sistemini uygulamak amacıyla kullanılmıştır.

Veri seti analizinde Şekil 1 de görüldüğü üzere belirgin bir mevsimsellik ve trend bileşeni olduğu görülmektedir. Özellikle, hedef değişken olan teslimat miktarında genel bir artış eğilimi gözlemlenmektedir. Bununla birlikte belirli dönemlerde teslimat miktarları tekrarlayan bir şekilde artış ve azalış göstermiştir ve mevsimsel dalgalanmalar belirgindir. Artık bileşenin büyük çoğunluğunun sifıra yakın ve dengeli dağılmış olması modelin veriyi iyi ayrıştırdığını göstermektedir. Sonuç olarak Şekil 1 incelendiğinde veri setinin zaman serisi analizine uygun olduğu görülmektedir.



Şekil 1:
Teslimat Miktarının Zaman Serisi Dekompozisyonu

Bu çalışmada zaman serisi modelleme süreci için tercih edilen AutoTS Kütüphanesi model seçimi, veri ön işleme, hiperparametre optimizasyonu ve modelin değerlendirilmesi gibi adımların tamamını manuel müdahaleye gerek kalmadan zaman serisi verilerine özel olarak uygular. Bu algoritma farklı zaman serisi modellerini eğitebilir, karşılaştırabilir ve en iyi sonuç veren algoritmayı seçerek sonuç üretebilir. Aynı zamanda hem klasik hem de modern zaman serisi modellerini kullanması ve karşılaştırması da avantajlarından biridir. Ayrıca hiperparametre optimizasyonu yeteneği sayesinde model performansını artırabilir. Çok sayıda ürün ve kategoriye ait zaman serilerini ayrı ayrı modellemek gereken bu çalışmada, AutoTS tüm bu özelliklere sahip olması sayesinde önemli bir avantaj sunmuştur.

Veri AutoTS Kütüphanesi ihtiyaçlarına göre yapılandırıldıktan sonra modelleme sürecine geçilmiştir. Bu kapsamda, yukarıda belirtildiği gibi veri seti her bir satırı bir kamyon kaydına denk geldiği için teslimat miktarları gün bazında toplanmış, tarih sütunu standart hale getirilmiş ve zaman serisi frekansı günlük olacak şekilde indekslenmiştir. Veri dönüşümleri, aykırı değer analizleri gibi diğer veri ön işleme adımlarını AutoTS kütüphanesi otomatik olarak yapabilmektedir ve bu durum veri ön işleme ihtiyacını en aza indirmiştir.

Kurum müşterileri ürün talep ederken kendi proseslerine uygun torbalama türü ve torbalama şeklinde sipariş oluşturmaktadır. Bu nedenle kurum için hangi ürünün ne kadar sipariş edildiği kadar hangi ürün, hangi torbalama türü ve hangi torbalama şeklinde sipariş edildiği önemlidir. 43 farklı ürün için 5 farklı torbalama türü ve 28 adet farklı torbalama şekli bulunmaktadır. Stok ve lojistikten sorumlu personelin doğru ve verimli şekilde süreç yönetimi yapabilmesi için tahminler ürün, torbalama türü ve torbalama şekli kombinasyonları için yapılmıştır.

Bu çalışmada, otomatik zaman serisi tahmini için tasarlanmış AutoTS kütüphanesi kullanılarak, Tablo 2'de açıklanan alternatif durumlara göre ayrı ayrı beş farklı tahmin modeli oluşturulmuştur. Elde edilen beş model, başlangıçta ayrı ayrı AutoTS ile eğitilmiş ve ardından her bir modelin tahmin çıktıları ağırlıklandırılarak birleştirilmiştir. Model ağırlıkları, başlangıçta

dengeli bir şekilde belirlenmiştir, sistemin adaptif olması amacıyla model ağırlıkları her üç ayda bir güncel sonuçlar kullanılarak güncellenmiştir. Bu periyodik güncelleme ile modellerin değişen talep eğilimlerine uyum göstermesi sağlanmıştır.

Tablo 2: Farklı Değişkenlere ve Değişken Kombinasyonlarına Göre Kurulan Zaman Serisi Tahmin Modelleri

Model No	Tahmin Kriteri	Açıklama
1	Sadece Ürün Adı	Her ürünün tarihsel talebi analiz edilerek AutoTS ile en uygun zaman serisi modeli seçilmiştir. Her ürün için döngüyle ayrı model kurulmuştur.
2	Sadece Torbalama Türü	Her torbalama türünün tarihsel talebi analiz edilmiştir. AutoTS, her bir torbalama türü için en uygun modeli döngüyle kurmuştur.
3	Sadece Torbalama Şekli	Torbalama şekillerinin geçmiş talebi analiz edilmiştir. Her torbalama şekli için AutoTS döngüyle model seçimi yapılmıştır.
4	Torbalama Türü + Torbalama Şekli	Tür ve şekil kombinasyonları dikkate alınmıştır. Her kombinasyon için AutoTS uygun modeli döngüyle belirlemiştir.
5	Ürün Adı + Torbalama Türü + Torbalama Şekli	Tüm değişkenlerin birleşimi kullanılmıştır. Her kombinasyon için AutoTS ayrı model oluşturmuştur.

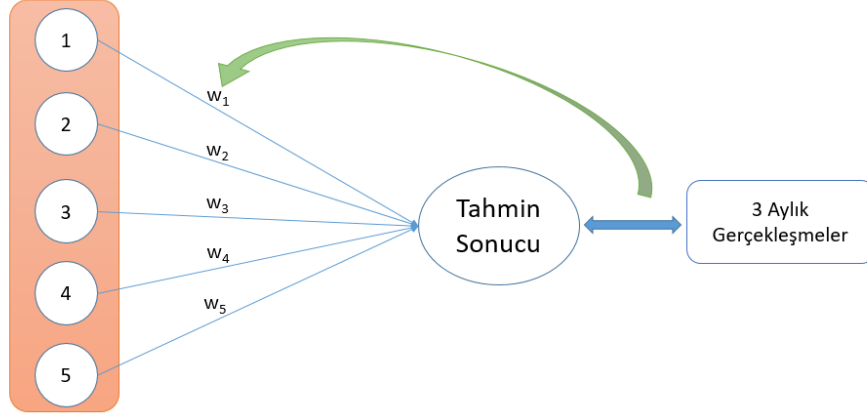
Bu çalışmada, AutoTS Kütüphanesinin, geleneksel zaman serisi modellerinin yanı sıra makine öğrenmesi ve derin öğrenme tekniklerini de içeren geniş bir yelpazede model sunması esnekliğinden yararlanılarak, talep tahmini için uygun model alternatifleri değerlendirilmiştir. Çalışmada 'AverageValueNaive', 'NeuralProphet', 'ARIMA', 'FBProphet', 'GLM', 'GLS' ve 'FFT' modelleri kullanılmıştır. Bu modellerin seçilme gerekçeleri Tablo 3'te özetlenmiştir. Her bir model, paketleme talebinin özelliklerine (örneğin, mevsimsellik, trend, doğrusal/doğrusal olmayan ilişkiler) en uygun yaklaşımı sunmak üzere belirlenmiştir. Örneğin, ARIMA ve Prophet, mevsimsellik ve trend etkilerini yakalamak için tercih edilirken, NeuralProphet derin öğrenme kullanarak karmaşık desenleri modelleyebilmektedir. Bu modeller, veri setine göre en iyi tahmin performansını elde etmek amacıyla AutoTS ile test edilmiş ve sonuçları karşılaştırılmıştır. Model, 90 günlük (forecast_length=90) bir tahmin periyodu belirler ve veri setinin günlük (frequency='D') frekansa sahip olduğunu varsayar. Ayrıca, transformer_list='all' parametresi ile normalizasyon, log dönüşümü gibi veri ön işleme adımları otomatik olarak uygulanır. Modelin performansını değerlendirmek için validation_method='backwards' yöntemi kullanılır; bu yöntem, zaman serisi verilerini geçmişe dönük olarak böler ve modelin gerçekçi bir şekilde değerlendirilmesini sağlar. ensemble='all' parametresi, farklı modellerin birleştirilerek ensemble yöntemleriyle daha güçlü tahminler yapılmasını sağlar. Son olarak, verbose=2 parametresi, modelin eğitim ve değerlendirme süreçlerinde detaylı bilgilerin ekrana yazdırılmasını sağlayarak, kullanıcıya süreç hakkında daha fazla bilgi sunar. Bu yapı, AutoTS'in zaman serisi tahmini süreçlerini otomatikleştirme ve kullanıcı dostu bir deneyim sunma yeteneğini gösterir.

Tablo 3: Talep Tahmininde Kullanılan Modeller ve Seçilme Gerekçeleri

Yöntem	Açıklama	Neden Tercih Edildi
AverageValueNaive	Geçmiş gözlemlerin ortalamasını temel alarak temel bir tahmin sağlar ve daha karmaşık modellerin performansını karşılaştırmak için bir ölçüt sunar (Qui ve diğ.,2022)	Temel bir karşılaştırma noktası olarak kullanılır. Çok basit zaman serilerinde iyi sonuç verebilir.
NeuralProphet	Yapay sinir ağlarıyla geliştirilmiş daha esnek ve yüksek doğruluklu tahminler yapabilen modern bir derin öğrenme tabanlı modeldir (Triebe ve diğ.,2021)	Derin öğrenme ile karmaşık desenleri ve uzun vadeli bağımlılıkları yakalamak için.
ARIMA	Geçmiş değerler ve hatalar arasındaki otokorelasyonu modelleyen istatistiksel yöntemdir (Contreras ve diğ., 2003)	Doğrusal zaman serisi verilerinde trend ve mevsimsellik etkilerini modellemek için.
FBProphet	Additive modelleme yaklaşımıyla trend ve mevsimselliği ayırıştırarak zaman serisi modelidir (Taylor ve Letham, 2018)	Güçlü mevsimsellik, tatil etkileri ve trend değişiklikleri olan zaman serileri için.
GLM	Doğrusal regresyonu genişleterek farklı dağılım yapıları ve bağlantı fonksiyonlarıyla çalışabilen esnek bir modelleme yaklaşımıdır (McCullagh ve Nelder, 1989)	Farklı dağılımlara sahip (örneğin Poisson) verileri modellemek ve bağımlı değişken ile açıklayıcı değişkenler arasındaki ilişkiyi incelemek için.
GLS	Klasik regresyonun varsayımlarının bozulduğu (özellikle otokorelasyon ve değişen varyans gibi) durumlarda, daha doğru tahminler yapmak için hata yapısını dikkate alarak çalışan gelişmiş bir regresyon yöntemidir (Fox ve Weisberg, 2018)	Heteroskedastisite veya otokorelasyon olduğunda doğrusal regresyon modelinin verimliliğini artırmak için.
FFT	Zaman serisindeki tekrar eden desenleri (periyotları) frekans alanında analiz ederek ortaya çıkaran, çok hızlı çalışan bir algoritmadır. Bu sayede özellikle mevsimsellik içeren verilerde güçlü bir analiz aracıdır (Heckbert, 1995, revised 1998)	Zaman serisini frekans bileşenlerine ayırarak mevsimsel kalıpları analiz etmek ve tahmin etmek için.

Tablo 2’de belirtilen alternatifler için elde edilen her sonuç Şekil 2’de gösterildiği gibi, belli bir ağırlık ile çarpılarak nihai sonuca katkıda bulunur. Belirlenen tahmin dönemleri sonucunda bu ağırlıklar modelin doğruluk oranına göre ayarlanır. Bu çalışmada ürünlerin teslim süreleri 2-3 aylık periyotlar olduğu için tahmin dönemi 3 ay olarak belirlenmiştir. 3 aylık periyotlar ile yapılan ağırlık güncellemeleri modelin değişen talep örüntülerine uyumunu sağlar. Örneğin tahmin modeli pazar koşullarında ani değişiklik olduğunda veya müşteriler proses güncellemesi

yaparak farklı bir torba türü talep ettiğinde ağırlıklandırma modeli sayesinde değişikliklere uyum göstererek daha iyi sonuç verebilir.



Şekil 2:
Ensemble Modelleme Kapsamında Ağırlıklandırma Sürecinin İş Akışı

3. BULGULAR / SONUÇLAR

Bu bölümde, çalışmada kullanılan tahmin modellerinin performans sonuçları ve ağırlıklandırma model yapısı anlatılmakta ve karşılaştırmalı olarak değerlendirilmektedir.


AutoTS kütüphanesi kullanılarak lojistik sektörüne yönelik talep tahmini amacıyla beş farklı model alternatifi değerlendirilmiş ve bu modeller, dinamik bir ağırlıklandırma yöntemi ile birleştirilmiştir. AutoTS kütüphanesinin birden fazla modeli deneme yeteneği sayesinde elde edilen bulgular, ensemble modellerinin tekil modellere kıyasla daha yüksek doğruluk düzeyi sağladığını ortaya koymaktadır. Model performansları; MAE (Ortalama Mutlak Hata), RMSE (Kök Ortalama Kare Hata) ve Score gibi hata metrikleri aracılığıyla değerlendirilmiştir. AutoTS'te "Score" metriği, modelin genel başarımını özetleyen bileşik (composite) bir ölçüdür. Genellikle hata metriklerinin normalize edilip ağırlıklandırılarak bir araya getirilmesiyle hesaplanır. Bu süreçte MAE, RMSE, SMAPE ve zamansal ağırlıklı hata ölçütleri önce ortak bir ölçüğe indirgenir (normalize edilir) ve ardından her bir metrik tahmin doğruluğuna etkisine göre ağırlıklandırılarak toplam bir maliyet fonksiyonuna dönüştürülür. AutoTS ayrıca çalışma süresi ve model istikrarı gibi faktörler için küçük ceza terimleri ekleyerek nihai Score değerini oluşturur. Tablo 4'te, en başarılı altı modelin bu metrikler açısından karşılaştırmalı sonuçları sunulmaktadır.

Tablo 4: En İyi Performans Gösteren 6 Modelin Karşılaştırması

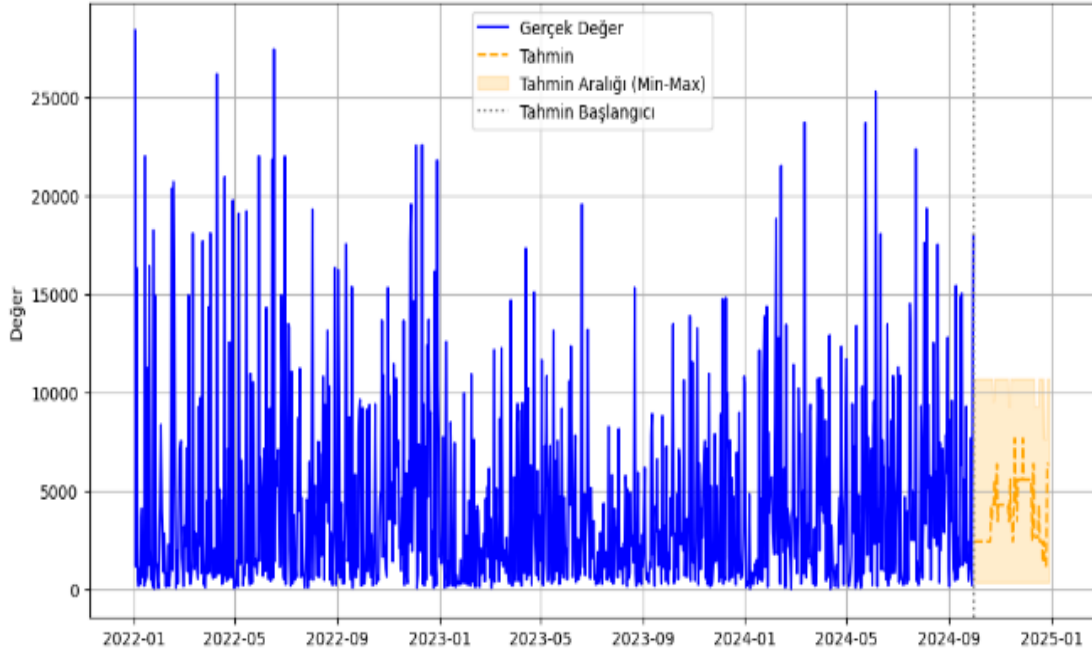
Sıra	Model Türü	MAE	RMSE	Score	Kullanılan Modeller
1	Ensemble 1	268,72	752,63	7,536	Mosaic yapılandırması altında toplam 31 alt model kullanılmış olup, bu modeller arasında GLM (Binomial, Gamma, Poisson dağılımları ile), GLS, ARIMA, FBProphet, FFT ve Ensemble (Dist tabanlı) modelleri yer almaktadır. Ensemble modeller ise kendi içinde yine GLM tabanlı tahminleyicileri içermektedir.
2	Ensemble 2	295,13	761,60	7,632	2 farklı GLM modelinin yapılandırması kullanılmıştır; birinci modelde Binomial familyası ve zaman değişkenleri ile regresyon yapılmıştır, ikinci modelde Gamma familyası kullanılmış ve zaman bileşenleri modelden çıkarılmıştır.
3	Ensemble 3	293,12	768,19	7,643	FBProphet ve Binomial dağılım temelli GLM modelinden oluşmaktadır. Prophet trend ve sezonsallık yapısını modellereken, GLM modeli geçmiş değerler ve anomali giderme temelli klasik yaklaşımla katkı sağlamaktadır.
4	Ensemble 4	293,12	768,19	7,646	FBProphet ve GLM (Binomial dağılım) modellerinin birleşiminden oluşmaktadır. Prophet modeli tatil etkilerini ve doğrusal trendleri hesaba katan modern bir yöntem sunarken, GLM modeli anomali giderme, detrend ve geçmiş değerler gibi klasik istatistiksel dönüşümlerle serinin yapısını desteklemektedir.

5	Ensemble 5	266,23	760,22	7,652	İki farklı GLM (Genelleştirilmiş Doğrusal Model) varyantının birleşiminden oluşmaktadır: biri Binomial dağılım ve tarih parçası (datepart) regresyonuyla, diğeri ise Gamma dağılım ile yapılandırılmıştır. Her iki model de geçmiş değerler, robust ölçekleme ve son değer hizalama gibi dönüşümlerle zaman serisinin yapısını dikkate alarak tahmin üretmektedir.
6	FFT	280,26	764,98	7,738	FFT

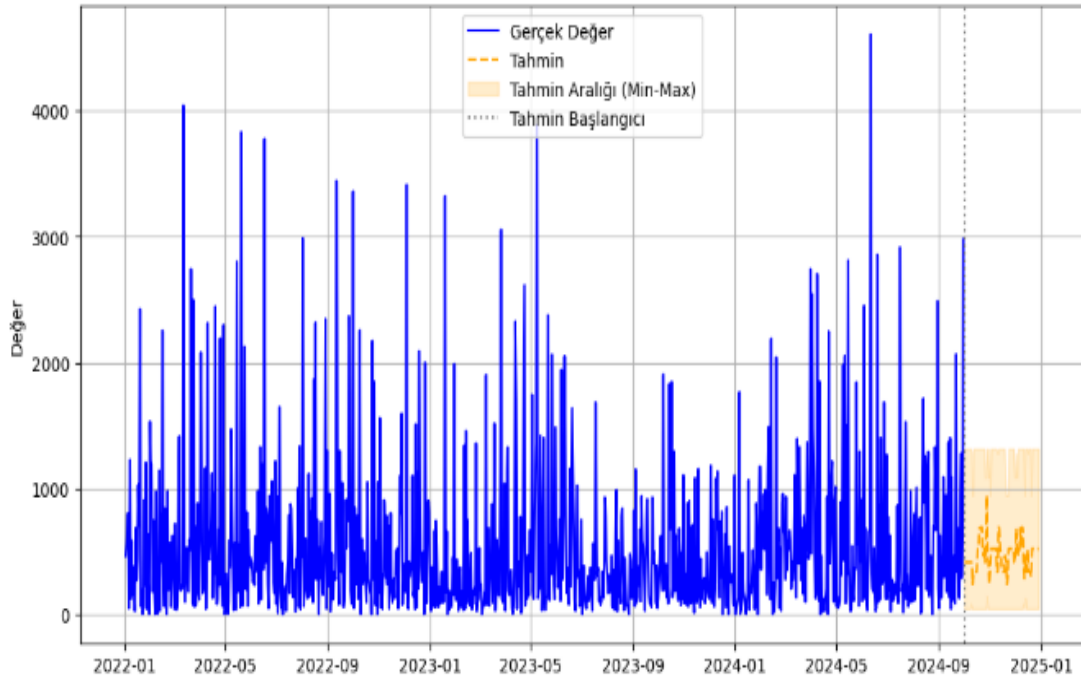
Şekil 3-7'deki grafikler, modelin farklı veri segmentasyon düzeylerindeki performansını göstermektedir. Şekil 3'te görüldüğü gibi, sadece ürün adına göre yapılan tahminler, genel trendi yakalamada başarılı olsa da, ani talep artışlarını öngörmeye yetersiz kalmıştır. Bu durum, ürün talebinin sadece ürün türüne değil, aynı zamanda diğer faktörlere (örneğin, mevsimsellik veya promosyonlar) de bağlı olduğunu göstermektedir. A ürünü için en iyi performans gösteren model (Şekil 7), ürün, torba türü ve torba şekli gibi tüm faktörleri birlikte değerlendirerek, zaman serisindeki karmaşık yapıyı daha iyi çözümlenmiş ve tahminlerdeki hatayı minimize etmiştir.




Şekil 3:
A Ürünü için Ürün Bazlı Tahmin Modeli – Gerçek ve Tahmin Değerleri




Şekil 4:
LAMINE PP Torbalama Türü için Torbalama Türü Bazlı Tahmin Modeli – Gerçek ve Tahmin Değerleri



Şekil 5:
25 kg'lık Torbalama Şekli için Torbalama Şekli Bazlı Tahmin Modeli – Gerçek ve Tahmin Değerleri



Şekil 6:
Torbalama Türü + Şekli Kombinasyonuna Göre Tahmin Modeli – Gerçek ve Tahmin Değerleri



Şekil 7:
Ürün + Torbalama Türü + Şekli Kombinasyonuna Göre Tahmin Modeli – Gerçek ve Tahmin Değerleri

Tablo 5, modelin adaptasyon yeteneğini açıkça göstermektedir. İlk çeyrekte %33'lük bir hata ile başlayan model, ağırlıkların güncellenmesiyle dördüncü çeyrekte %0.63'lük bir hataya ulaşmıştır. Bu durum, ağırlıklandırma yönteminin ve periyodik güncellenmenin modelin doğruluğunu önemli ölçüde artırdığını kanıtlamaktadır.

Tablo 5: Ağırlıklandırma Modeline Göre Sonuçların Değerlendirilmesi

A_LAMINE PP_25 KG			
	Tahmin	Gerçekleşme	Hata Oranı
1. Çeyrek	8.860,61	13.225,30	33,00
2. Çeyrek	20.050,09	11.014,55	-82,03
3. Çeyrek	10.678,26	9.245,70	-15,49
4. Çeyrek	9.462,12	9.521,73	0,63

4. TARTIŞMA

Bu çalışmada, lojistik sektöründe talep tahmini amacıyla AutoTS kütüphanesi kullanılarak beş farklı model alternatifi değerlendirilmiş ve sonuçlar doğrultusunda ağırlıklandırma yöntemiyle nihai tahmin performansı artırılmaya çalışılmıştır. Modellerin karşılaştırılmasında MAE, RMSE ve Score gibi hata metrikleri temel alınmış, performans analizleri bu ölçütler üzerinden gerçekleştirilmiştir.

Elde edilen bulgular, AutoTS kütüphanesinin birden fazla modeli değerlendirme ve ensemble yapılar kurabilme yeteneği sayesinde ensemble yapıların tekil modellere kıyasla daha yüksek doğruluk sunduğunu göstermektedir. Bu sonuç, Makridakis ve diğ. (2018) tarafından yapılan M4 yarışması bulgularıyla da uyumludur; söz konusu çalışmada ensemble yaklaşımlarının, hem istatistiksel hem de makine öğrenmesi tabanlı yöntemlere kıyasla daha istikrarlı ve yüksek başarımlı sonuçlar verdiği belirtilmiştir.

Mosaic yapılandırması altında bir araya getirilen 31 alt modelin oluşturduğu ensemble yapının, hem çeşitlilik hem de performans açısından güçlü bir sinerji yarattığı görülmüştür. Bu yapı içerisinde GLM, ARIMA, FBProphet, FFT gibi farklı model türlerinin birlikte kullanılması, modelin hem mevsimsel hem de ani değişimlere duyarlılığını artırmıştır. Bu yaklaşım, Hyndman ve Athanasopoulos (2018) tarafından vurgulanan “model çeşitliliğinin tahmin performansına katkısı” ilkesini de destekler niteliktedir.

Özellikle dinamik ağırlıklandırma yönteminin, farklı değişken kombinasyonlarında elde edilen modellerin etkisini artırarak, genel tahmin doğruluğunu olumlu yönde etkilediği gözlemlenmiştir. Bu bulgu, Montero-Manso ve diğ. (2020) tarafından önerilen ağırlıklı ensemble yaklaşımlarının veri setine adaptif olma kabiliyetiyle doğrudan örtüşmektedir. Statik ensemble yöntemlerine kıyasla dinamik ağırlıklandırma, talep değişkenliği yüksek sektörlerde daha anlamlı ve etkili sonuçlar vermektedir.

Birden fazla hata ölçütünün normalize edilerek bütünleştirilmesi ile elde edilen score metriği sayesinde modellerin genel başarımının daha sağlıklı bir şekilde değerlendirildiği düşünülmektedir. Hyndman ve diğ. (2006), tek bir metrik yerine çoklu metriklerin birleştirilmesinin model karşılaştırmalarında daha doğru içgörüler sağladığını belirtmiş ve bu tür birleşik skorların zaman serisi yarışmalarında sıklıkla tercih edildiğini vurgulamıştır.

Bununla birlikte, çalışmanın bazı sınırlılıkları da bulunmaktadır. Özellikle AutoTS'in model seçimi ve parametrik ayarlamaları büyük ölçüde otomatik olarak gerçekleştirdiğinden, bazı modellerin aşırı öğrenme (overfitting) riski taşıyabileceği göz ardı edilmemelidir. Ayrıca,

kullanılan veri setinin belirli bir dönem ve ürün grubuna ait olması, geliştirilen modelin genellenebilirliğini kısıtlayabilir. Bu nedenle, farklı veri setleri ve sektörlerde benzer yaklaşımların uygulanarak sonuçların test edilmesi, gelecekteki çalışmalar için önemli bir yön olacaktır.

Sonuç olarak, AutoTS temelli bu çalışmada elde edilen bulgular, otomatikleştirilmiş model seçimi ve ensemble yapıların, lojistik sektörü gibi yüksek değişkenlik gösteren alanlarda etkili tahmin sonuçları üretebildiğini göstermektedir. Uygulanan ağırlıklandırma stratejileri sayesinde modelin esnekliği artmış, bu da karar destek sistemleri açısından değerli bir katkı sunmuştur.

5. SONUÇ VE DEĞERLENDİRME

Sonuç olarak, bu çalışma, lojistik sektöründe talep tahmini için etkili bir yöntem sunmaktadır. Ensemble modellemesi ve dinamik ağırlıklandırma, tahmin doğruluğunu önemli ölçüde artırırken, AutoTS kütüphanesi model geliştirme sürecini hızlandırmıştır. Bu yaklaşım, işletmelerin stok yönetimini optimize etmelerine, maliyetleri azaltmalarına ve müşteri memnuniyetini artırmalarına yardımcı olabilir. Gelecekteki araştırmalar, bu yöntemin farklı sektörlerdeki uygulanabilirliğini ve diğer makine öğrenmesi algoritmalarıyla entegrasyonunu inceleyebilir.

Sonuçlar, beş farklı modelin ağırlıklandırılarak birleştirilmesi, tekil modellere kıyasla daha düşük tahmin hatası sağladığını göstermektedir. Ensemble yaklaşımı, her modelin zaaflarını dengeleyerek genel doğruluğu artırmayı başarmıştır. Ayrıca, model ağırlıklarının periyodik olarak güncellenmesi, sistemin pazar koşullarındaki değişimlere adaptasyonunu önemli ölçüde iyileştirmiştir. Bu bulgular, literatürdeki adaptif ağırlıklı ensemble yaklaşımlarının tahmin doğruluğunu artırmadaki etkinliğini bir kez daha doğrulamaktadır.

Model başarısının değerlendirilmesinde kullanılan MAE, RMSE ve Score gibi metrikler, farklı model yapılandırmalarının karşılaştırılması için güçlü araçlar sunmuştur. Ensemble modellerinin elde ettiği düşük hata metrikleri ve daha yüksek Score başarısı, bu yaklaşımın lojistik sektöründe talep tahmini uygulamaları için oldukça uygun bir çözüm sunduğunu göstermektedir.

ÇIKAR ÇATIŞMASI

Yazarlar, bilinen herhangi bir çıkar çatışması veya herhangi bir kurum/kuruluş ya da kişi ile ortak çıkar bulunmadığını onaylamaktadırlar.

YAZAR KATKISI

Yazar A, çalışmanın kavramsallaştırılmasını ve metodolojisini gerçekleştirdi, veri analizlerini yürüttü ve yazılım geliştirme sürecinde katkı sağladı, literatür taramasını yaptı ve ilk taslağı yazdı. Yazar B, kavramsallaştırmaya katkıda bulundu, yazıyı gözden geçirdi ve düzenledi, danışmanlık etti. Tüm yazarlar nihai versiyonu okudu ve onayladı.

KAYNAKLAR

1. Alpay, H., & Yüzügüllü, B. (2005). *Eskişehir ve çevresindeki üretim işletmelerinde üretim yönetimi uygulamaları*. Eskişehir Osmangazi Üniversitesi.
2. Cerqueira, V., Torgo, L., & Soares, C. (2022). A case study comparing machine learning with statistical methods for time series forecasting: Size matters. *Journal of Intelligent Information Systems*, 59(2), 415–433. <https://doi.org/10.1007/s10844-022-00713-9>
3. Contreras, J., Espinola, R., Nogales, F. J., & Conejo, A. J. (2003). ARIMA models to predict next-day electricity prices. *IEEE Transactions on Power Systems*, 18(3), 1014–1020. <https://doi.org/10.1109/TPWRS.2002.804943>
4. Dietterich, T. G. (2000). Ensemble methods in machine learning. In J. Kittler & F. Roli (Eds.), *Multiple classifier systems* (pp. 1–15). Springer. https://doi.org/10.1007/3-540-45014-9_1
5. Fox, J., & Weisberg, S. (2018). *Time-series regression and generalized least squares in R: An appendix to An R companion to applied regression* (3rd ed.). SAGE Publications
6. He, X., Zhao, K., & Chu, X. (2019). AutoML: A Survey of the State-of-the-Art. arXiv. <https://doi.org/10.48550/arXiv.1908.00709>
7. Heckbert, P. S. (1998). *Fourier transforms and the fast Fourier transform (FFT) algorithm*. (Revize edilmiş basım). [Yayınlanmamış çalışma veya Teknik Rapor]. Carnegie Mellon University.
8. Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: Principles and practice* (2nd ed.). OTexts. <https://otexts.com/fpp2/>
9. Hyndman, R. J., & Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22(4), 679–688. <https://doi.org/10.1016/j.ijforecast.2006.03.001>
10. Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2018). The M4 competition: Results, findings, conclusion and way forward. *International Journal of Forecasting*, 34(4), 802–808. <https://doi.org/10.1016/j.ijforecast.2018.06.001>
11. McCullagh, P., & Nelder, J. A. (1989). *Generalized linear models* (2nd ed.). Chapman and Hall/CRC. <https://doi.org/10.1201/9780203753736>
12. Meisenbacher, S., Turowski, M., Phipps, K., Rätz, M., Müller, D., Hagenmeyer, V., & Mikut, R. (2022). Review of automated time series forecasting pipelines. *Sensors*, 22(19), 7247. <https://doi.org/10.3390/s22197247>
13. Montero-Manso, P., Athanasopoulos, G., Hyndman, R. J., & Talagala, T. S. (2020). FFORMA: Feature-based forecast model averaging. *International Journal of Forecasting*, 36(1), 86–92. <https://doi.org/10.1016/j.ijforecast.2019.02.011>
14. Opitz, D., & Maclin, R. (1999). Popular ensemble methods: An empirical study. *Journal of Artificial Intelligence Research*, 11, 169–191. <https://doi.org/10.1613/jair.614>
15. Park, Y., Lee, J., & Park, W. (2021). Self-weighted ensemble method to adjust the influence of individual models based on reliability. In *2021 International Conference on Information and Communication Technology Convergence (ICTC)* (pp. 1195–1197). IEEE. <https://doi.org/10.48550/arXiv.2104.04120>

16. Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., & Duchesnay, É. (2011). Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, 12, 2825–2830. <https://doi.org/10.5555/1953048.2078195>
17. Qiu, X., Hu, J., Zhou, L., & Wu, X. (2022). TFB: Towards comprehensive and fair benchmarking of time series forecasting methods. *IEEE Transactions on Knowledge and Data Engineering*, 34(8), 3918–3932. <https://doi.org/10.48550/arXiv.2403.20150>
18. Taylor, S. J., & Letham, B. (2018). Forecasting at scale. *The American Statistician*, 72(1), 37–45. <https://doi.org/10.1080/00031305.2017.1380080>
19. Top, S., & Yılmaz, C. (2009). *Üretim yönetimi*. İstanbul Ticaret Üniversitesi.
20. Triebe, O., Hewamalage, H., & Seeger, M. (2021). NeuralProphet: Explainable forecasting at scale. *arXiv preprint arXiv:2101.02118*. <https://doi.org/10.48550/arXiv.2111.1539>
21. Wang, C., Chen, X., Wu, C., & Wang, H. (2022). AutoTS: Automatic Time Series Forecasting Model Design Based on Two-Stage Pruning. *IEEE Transactions on Knowledge and Data Engineering*, 34(8), 3848–3862. <https://doi.org/10.48550/arXiv.2203.14169>