



Comparison of automated machine learning (AutoML) libraries in time series forecasting

Nagihan Akkurt*^{ID}, Servet Hasgül^{ID}

Department of Industrial Engineering, Faculty of Engineering and Architecture, Eskişehir Osmangazi University, 26480, Eskişehir, Turkey

Highlights:

- Advantages of the AutoML approach, its success in model and hyper-parameter optimization
- Using the AutoML approach on a univariate time series data
- Evaluation of forecasting results of different AutoML libraries with performance metrics

Keywords:

- AutoML
- AutoML libraries
- Time series forecasting

Article Info:

Research Article
Received: 23.04.2023
Accepted: 25.08.2023

DOI:

10.17341/gazimmfd.1286720

Acknowledgement:

The first author of this study is supported by TÜBİTAK 2211-A Domestic Doctoral Scholarship Program

Correspondence:

Author: Nagihan Akkurt
e-mail: 503220191002@ogrenci.ogu.edu.tr
phone: +90 538 011 8208

Graphical/Tabular Abstract

Studies include various data and methodologies, such as artificial intelligence and machine learning, along with concepts, such as developing data technologies. In such an environment, decision-making, training, and analyzing the factors that make up the solution, such as the method, model, and hyperparameter, can be challenging. It is not always possible for researchers to have detailed information for every model training, design, or analysis. In this direction, Automated Machine Learning (AutoML), which aims to automate machine learning steps to achieve the best performance on a data set, forms the basis of this study. This approach was used to forecast univariate time series data. Figure A shows the training, testing, and forecasting results of Auto_ARIMA, an AutoML library, on the selected dataset. The blue line in the graph shows the training data, the orange line is the test data, and the green line is the forecasting result of the relevant library.




Figure A. Forecasting plot of Auto_ARIMA library

Purpose:

With the developments in data science, accessing expert knowledge can take time and effort. Instead, it is more accessible and easier to use a method that does not require specialist knowledge, applies a large number of models, and automatically performs the optimum selection of model parameters. For this reason, in this study, it is planned to use an AutoML approach in the forecasting of a univariate time series.

Theory and Methods:

AutoML automates all machine learning steps, such as data preprocessing, feature engineering, model selection, hyperparameter optimization, and forecasting result analysis. In the study, different AutoML libraries (Auto_ARIMA, FLAML, FEDOT, Prophet, Auto_TS, EvalML) were coded using Python programming language for time series forecasting, and the results were compared.

Results:

Forecasting graphs of each library were created using the Python programming language. In addition, forecasting successes of AutoML libraries were measured using Mean Squared Error (MSE), Root Mean Squared Error (RMSE), Mean Absolute Error (MAE), and Mean Absolute Percent Error (MAPE) performance metrics. According to the results obtained, it is seen that the library with the highest forecast value is Auto_ARIMA.

Conclusion:

The forecasting successes of 6 different AutoML libraries were compared on performance metrics. According to the results obtained, each library can be an alternative that can be used for forecasting studies, and Auto_ARIMA is the library with the highest forecasting success.



Zaman serisi tahminlemede otomatikleştirilmiş makine öğrenmesi (AutoML) kütüphanelerinin karşılaştırılması

Nagihan Akkurt*^{ID}, Servet Hasgül^{ID}

Eskişehir Osmangazi Üniversitesi, Mühendislik Mimarlık Fakültesi, Endüstri Mühendisliği Bölümü, 26480, Eskişehir, Türkiye

Ö N E Ç I K A N L A R

- AutoML yaklaşımının avantajları, model ve hiper-parametre optimizasyonundaki başarısı
- Tek değişkenli bir zaman serisi verisi üzerinde AutoML yaklaşımının kullanılması
- Farklı AutoML kütüphanelerinin tahminleme sonuçlarının performans metrikleri ile değerlendirilmesi

Makale Bilgileri

Araştırma Makalesi

Geliş: 23.04.2023

Kabul: 25.08.2023

DOI:

10.17341/gazimmfd.1286720

Anahtar Kelimeler:

AutoML,
AutoML kütüphaneleri,
zaman serisi tahminleme

ÖZ

Firmaların bulunduğu konumu koruması veya geliştirebilmesi, ileride meydana gelebilecek durumlara karşı önceden tedbir alabilmesi ve diğer firmalar ile rekabet edebilmesi açısından geleceğe yönelik tahminleme gerçekleştirmesi gereklidir. Gelişen veri teknolojileri ile anlamlı veriye ulaşabilmek kolaylaşmıştır ve yapay zekâ, makine öğrenmesi, derin öğrenme gibi yöntemlerle birlikte bu verilerin analiz edilmesiyle geleceğe yönelik tahminlemede oldukça başarılı sonuçlar elde edilebilmektedir. Ancak literatürde birçok farklı yöntemin bulunması, araştırmacıların hangi yöntemi kullanacağı, model ve hiper-parametre seçimi için hangi teknikleri kullanacağı gibi birçok problem oluşturabilmektedir. Model ve hiper-parametre seçimde farklı değerlerin karşılaştırılması zahmetli ve uzun süreli olabilir. Bu doğrultuda gerçekleştirilen çalışmanın amacı, makine öğrenmesinin gelişmiş bir versiyonu olan AutoML yöntemini kullanmaktır. AutoML, makine öğrenmesi modellerini otomatikleştirerek bu alanda uzmanlık gerektirmeden makine öğrenmesi algoritmalarının kullanımına ve geliştirilmesine olanak tanır. Çalışmada, tek değişkenli bir zaman serisi verisi üzerinde 6 farklı AutoML kütüphanesi ile tahminleme çalışması gerçekleştirilmiştir ve tahminleme başarıları çeşitli performans metrikleri üzerinden karşılaştırılmıştır. Kullanılan veri seti üzerinde elde edilen sonuçlara göre seçilen kütüphanelerden tahminleme başarısı en yüksek olanın Auto_ARIMA kütüphanesi olduğu gözlemlenmiştir.

Comparison of automated machine learning (AutoML) libraries in time series forecasting

H I G H L I G H T S

- Advantages of the AutoML approach, its success in model and hyper-parameter optimization
- Using the AutoML approach on a univariate time series data
- Evaluation of forecasting results of different AutoML libraries with performance metrics

Article Info

Research Article

Received: 23.04.2023

Accepted: 25.08.2023

DOI:

10.17341/gazimmfd.1286720

Keywords:

AutoML,
AutoML libraries,
time series forecasting

ABSTRACT

Companies must make forecasts for the future to take necessary precautions, as well as to guard or expand their position and remain competitive. The development of data technologies has made it easier to reach meaningful data. Analyzing these data with methods such as artificial intelligence, machine learning, and deep learning makes it possible to obtain highly accurate results in future forecasts. However, the presence of numerous methods in the literature poses several challenges for researchers, including selecting the most suitable method and determining the appropriate techniques for model and hyper-parameter selection. Moreover, comparing different values in the model and making hyper-parameter selections can be tedious and time-consuming. Therefore, this study aims to use the AutoML method, which is an advanced version of machine learning. AutoML automates machine learning models, allowing the use and development of machine learning algorithms without requiring expertise in this field. The study carried out forecasts using 6 different AutoML libraries on univariate time series datasets, and forecasting successes were compared over various performance metrics. According to the results obtained on the data set used, it was observed that the Auto_ARIMA library had the highest forecasting success rate among the selected libraries.

1. Giriş (Introduction)

Endüstri 4.0 ile yaygınlaşan yapay zekâ ve makine öğrenmesi gibi kavramların kullanımı her alanda artış göstermektedir. IoT ve sensör teknolojilerinin gelişmesiyle birlikte çeşitli ve hacmi hızla artan büyük veri setleri oluşmaktadır. Bulut teknolojileri ile birlikte de verilerin saklanabilir ve kolay erişilebilir olması veri analizinde büyük faydalar sağlamaktadır. Makine öğrenmesi, derin öğrenme, yapay sinir ağları gibi kavramların hayatımıza girmesiyle birçok çözüm yöntemi de literatürde yerini almıştır. Bu kadar veri ve yöntemin bulunduğu bir ortamda araştırmacılar, hangi yöntem ve tekniği kullanacağı konusunda bilinçli ya da bilinçsiz bir şekilde karar verebilir. Farklı yöntemlerin denenmesi, karşılaştırılması, farklı model ve hiper-parametrelerin değerlendirilmesi zaman ve maliyet açısından oldukça zor olabilmektedir. Bunların yanı sıra veri bilimcilerin her modele aşına ve her modeli uygulayabilir olması, modellerin eğitimi için detaylı bilgiye sahip olması, bu modelleri tasarlayabilmesi ve optimize edebilmesi, verilerin farklı boyut ve özelliklerini analiz edebilmesi gibi gereksinimleri karşılayabilmeleri her zaman mümkün değildir. Bu niteliklere sahip veri bilimciler olsa bile sayıca az olmaları muhtemeldir. Bu doğrultuda bir veri seti üzerinde en iyi performansı yakalamak için veri ön işleme, özellik seçimi, model seçimi ve hiper-parametre optimizasyonu gibi makine öğrenmesi adımlarını otomatikleştirmeyi hedefleyen AutoML, bu çalışmanın temelini oluşturmaktadır. AutoML mevcut veriler için en iyi özelliklere sahip modeli ve hiper-parametreleri bulma sürecini otomatikleştirir. AutoML'in amacı insan faktörünün yerini almak değil, aksine onların zorlu, tekrarlayan görevlerinin yerini alarak kullanılan çabayı azaltmak, klişe seçim, önyargı veya inisiyatif kullanımının önüne geçebilmek ve makine öğrenmesi süreçlerini otomatikleştirerek makine öğrenmesini daha erişilebilir hale getirmektedir. Veri teknolojisinin gelişmesi zaman serisi analizlerinde daha anlamlı sonuçlar elde edilmesini sağlamış ve zaman serisi analizinin de önemini artırmıştır. Aynı zamanda gelecek dönemlere yönelik daha doğru tahminlerin yapılması kolaylaşmıştır. Zaman serisi tahmini, zaman serisinin gelecekteki değerlerini tahmin etmek için aynı değişkenin geçmiş gözlemlerinin analiz edildiği önemli bir veri modelleme disiplini [1]. Tek değişkenli zaman serisi tahmini ise aynı değişkenin geçmişi, zaman sıralı gözlemlerine dayalı olarak tek bir değişken için ekstrapolasyonların oluşturulmasıdır [2]. Zaman serisi tahminlemede geleneksel yöntemler dışında yapay sinir ağları, makine öğrenmesi, derin öğrenme gibi yöntemler kullanılmaktadır [3-5]. Makine öğrenmesi, bir makinenin eldeki verilerden kendi kendine öğrendiği ve elde ettiği deneyimlerden performansını iyileştirerek doğruluğunu kademeli şekilde artırdığı bir yapay zekâ alt kümesidir. Tahminleme, sınıflandırma, kümeleme, öneri sistemleri, ses ve görüntü işleme gibi birçok alanda makine öğrenmesi yöntemlerinin kullanımı mevcuttur. Makine öğrenmesinin halen birçok alanda kullanılan ve geliştirilen popüler bir yöntem olmasına ek olarak endüstri ve yapay zekâ araştırmalarında daha yeni bir yöntem olan AutoML yönteminin kullanımı son yıllarda artmaya başlamıştır.

AutoML, makine öğrenmesinin tüm adımlarını otomatikleştirmeye yönelik bir fikirdir. AutoML, belirli bir görevde en iyi performansı elde etmek için makine öğrenmesi algoritmalarını otomatik olarak seçmeyi, oluşturmayı ve parametrelerini belirlemeyi [6], makine öğrenmesini makine öğrenmesini bilmeyen uzmanlar (alan uzmanları) için erişilebilir kılmayı, makine öğrenmesinin verimliliğini artırmayı ve makine öğrenmesi araştırmalarını hızlandırmayı amaçlar [7]. Makine öğrenmesi uygulamalarında yoğun iş yükü insan üzerindeyken AutoML'de işlerin çoğu bilgisayar programları ile yapılabilmektedir [8]. Makine öğrenmesi uzmanlarının hem bulunması zor hem de pahalı olduğundan AutoML'in önemli miktarda zaman ve para tasarrufu sağlamanın yanı sıra gelişmiş performans da sağlar [9]. Çünkü, gelişen makine

öğrenmesi tekniklerinin karmaşıklığı arttıkça, bir makine öğrenmesi uzmanının bile en son en iyi uygulamaların tümünü modellemelerine dahil etmesi giderek daha zor hale gelmektedir [10]. AutoML'e olan ticari ilgi de son yıllarda çarpıcı bir şekilde artmaktadır. ReportLinker'in bir raporuna göre [11] AutoML pazarı, 2020'de 346,2 milyon dolar gelir elde ederken, tahmin döneminde (2020-2030) %45,6'lık bir yıllık bileşik büyüme oranı ile ilerleyerek 2030'a kadar 14.830,8 milyon dolara ulaşması beklenmektedir.

Literatürde AutoML yöntemi kullanılarak gerçekleştirilen birçok çalışma bulunmaktadır. Bunlardan AutoML'i tahminleme aracı olarak kullanan çalışmalar ise şu şekilde örneklendirilebilir; Ahlgren vd. [12] gemilerdeki dinamik yakıt tüketimini tahmin etmek için AutoML algoritmalarını kullanmıştır. Zhang vd. [13] Bayes optimizasyonu ve AutoML kullanarak tünel açma makinesinin performans tahminine yönelik bir çalışma gerçekleştirmiştir. Zeineddine vd. [14] geçmiş zaman verilerini kullanarak öğrenci performansını tahmin etmenin doğruluğunu artırmak için AutoML kullanılmasını önermektedir. Zhang ve Ye [15], su borusu arıza risklerini tahmin etmek için AutoML yöntemi kullanmıştır. Bender vd. [16] sipariş üzerine üretim yapan küçük ve orta ölçekli iki işletmeden alınan verilerle yüksek düzeyde özelleştirilebilir ürünler için doğru teslim sürelerini AutoML yaklaşımı ile tahmin etmiştir. AutoML yaklaşımı tarafından oluşturulan modellerin manuel tahminlerden daha iyi performans gösterdiği tespit edilmiştir. Duan ve Zhang [17] ABD'deki kuraklıkları tahmin etmek için AutoML tabanlı bir çerçeveyi araştırmıştır. Yaygın olarak kullanılan zamansal derin öğrenme modelleriyle karşılaştırıldığında, AutoML modeli daha az eğitim verisi ve zaman gerektirmektedir. Gomathi vd. [18] COVID-19 vakalarına ait verileri analiz etmek ve hastalığı tahmin etmek için en iyi algoritmayı bulmak amacıyla AutoML yöntemini kullanmıştır. Muniz Do Nascimento ve Gomes-Jr [19] tarafından gerçekleştirilen çalışma, bölge ölçüm alanlarından gelen su akışı verileri üzerinde aykırı değer algılama tekniklerinin ve AutoML kaynaklarının yarı denetimli bir uygulamasını sunmaktadır. Sistem, model yapılandırması için uzmanlara veya eğitim için derlenmiş verilere ihtiyaç duymaz.

Yapay zekâ, büyük veri, bulut bilişim vb. alanlardaki gelişmeler sürekli olarak güncellenmeye ve artmaya devam etmektedir. Veri bilimdeki bu hızlı gelişmelerle birlikte uzman bilgisine erişebilmek zaman ve maliyet açısından bazı zorluklar doğurabilmektedir. Bunun yerine uzmanlık bilgisi gerektirmeyen, çok sayıda modelin uygulanması ve model hiper-parametrelerinin optimum şekilde seçilmesini otomatik bir şekilde gerçekleştiren bir yöntemin kullanılması daha ulaşılabilir ve daha kolaydır. Bu yaklaşımdan yola çıkılarak bu çalışmada AutoML yaklaşımının kullanılması planlanmıştır. Tek değişkenli bir zaman serisi verisi üzerinde AutoML yöntemi kullanılarak bir tahminleme gerçekleştirilmiş ve farklı AutoML kütüphaneleri karşılaştırılarak analiz edilmiştir.

Çalışmanın ikinci bölümünde AutoML yönteminin adımları ve kullanılan AutoML kütüphaneleri açıklanmıştır. Üçüncü bölümünde kullanılan veri seti ve gerçekleştirilen çalışma detaylandırılmış, AutoML kütüphanelerin tahminleme sonuçları grafiksel olarak verilmiş ve belirli performans metrikleri üzerinden karşılaştırılmıştır. Dördüncü bölümde elde edilen sonuçlar tartışılmıştır.

2. Materyal ve Metot (Material and Method)

2.1. AutoML Adımları (AutoML Steps)

Veri bilimcilerin varsayımlarına ve deneyimlerine dayanarak en iyi performans gösteren modeli seçmek ve karşılık gelen optimum hiper-parametre değerlerini düzeltmek için birkaç algoritmayı

değerlendirmesi ve farklı hiper-parametreleri ayarlaması gerekebilir. Bu gerçekten pahalı ve sıkıcı bir iştir [20]. Hiper-parametreleri manuel olarak optimize etmek yalnızca daha fazla kaynağa mal olmakla kalmaz, aynı zamanda klişeleri takip eden hiper-parametreler ayarlama olasılığını da artırır. Bu da mantıksız hiper-parametre ayarlarına ve zayıf model performansına neden olabilir [21].

AutoML, veri ön işleme, özellik mühendisliği, model seçimi, hiper-parametre optimizasyonu ve tahmin sonucu analizi gibi makine öğrenmesi ardışık düzenlerinde tekrarlanan görevlerde zamandan ve emekten tasarruf etmenin bir yolu olarak ortaya çıkmıştır [22]. Şekil 1, bir makine öğrenmesi sürecindeki özellik mühendisliği, model seçimi ve hiper-parametre optimizasyonu adımlarının AutoML kapsamında optimizasyonunu görselleştirmektedir ve [23]'ten uyarlanmıştır.

İlk adım, veri kümesini hazırlamak için kullanılan veri ön işleme adımıdır. İkinci adım, modelin oluşturulmasında kullanılacak özelliklerin seçilmesini ve/veya yeni özelliklerin oluşturulmasını içeren özellik mühendisliğidir. Özellik mühendisliği, model için girdi olarak kullanılan verilerin daha anlamlı ve etkili hale getirilmesi sürecini içerir. Sonraki adım ise seçilen problem için kullanılacak modelin belirlendiği ve eğitildiği, modele ait hiper-parametrelerin optimize edildiği adımdır. Optimize edilecek hiper-parametreler için değer aralıkları ve optimizasyon için kullanılacak algoritma (ızgara arama, rastgele arama, Bayes optimizasyonu vb.) belirlenir. Farklı değerlerin ve modellerin işlenmesi süreci sonrasında seçilen performans metriklerine göre en iyi performansı gösteren model ve hiper-parametre değerleri belirlenir. En iyi değerler kullanılarak modelin tekrar eğitildiği yinelemeli bir süreç devam eder. Son olarak da modelin doğrulanması, seçilmesi ve uygulanması ile süreç tamamlanmaktadır. İzleyen başlıklarda bu adımlar hakkında ayrıntılı bilgiler mevcuttur.

2.1.1. Veri ön işleme (Data preprocessing)

Ön işleme, tahmin modellerinin doğruluğunu etkileyen en önemli görevlerden biridir, çünkü çoğu veri seti eksik değerler, farklı özellik ölçekleri ve aykırı değerlere sahip gürültülü veriler içermektedir [24]. Veri ön işleme; veri toplama ve veri temizleme, veri dönüştürme ve veri küçültme gibi adımları içerir. Veri temizleme (data cleaning) ile verideki tutarsızlıklar ve gürültüler giderilir. Veri birleştirme (data integration), çeşitli kaynaklardan gelen bilgilerle tek bir veri seti oluşturmaktır. Veri dönüştürme (data transformations) ise düzeltme, birleştirme ve normalleştirme gibi işlemleri içerir. Veri küçültme (data reduction), bazı değişkenlerin birleştirilmesi, atılması veya kümeleme ile veri büyüklüğünün azaltılmasıdır.

Veri ön işleme, makine öğrenmesi ardışık düzeninde temel bir aşamadır. Şu anda, hiçbir AutoML tekniği bu görevi doğru bir şekilde ele alacak kadar olgun değildir ve önemli ölçüde insan müdahalesi gerektirmektedir [25]. Bu görev, AutoML araçları arasında yaygın olarak desteklenmeyen veri türü ve şema algılama gerektirir. Ancak, veri türleri tanımlandıktan sonra araçlar, ardışık düzendeki bir sonraki bileşen için uygun özellik mühendisliği sağlar [22].

2.1.2. Özellik mühendisliği (Feature engineering)


Özellik mühendisliği süreci genellikle bir uzman insan tarafından manuel olarak gerçekleştirilen kapsamlı alan bilgisi gerektiren ve makine öğrenmesinde en çok zaman alan adımlardan biridir [26]. Ham verileri, hesaplamalı tahmine dayalı modeller için altta yatan bir sorunu daha iyi temsil edebilecek özelliklere dönüştürme sürecidir ve bu da görünmeyen veriler üzerinde gelişmiş model doğruluğu sağlar. Daha sonra bu özellikler, onları eğitmek ve tahminler yapmak için doğrudan makine öğrenmesi modellerini besleyebilir [7]. Özellik mühendisliği üç alt konudan oluşur: özellik seçimi (feature selection), özellik çıkarma (feature extraction) ve özellik oluşturma (feature generation). Özellik çıkarma ve oluşturma, yeni bir özellik kümesinin yaratıldığı özellik dönüşümünün çeşitleridir. Özellik seçiminin amacı, önemli özellikleri seçerek özellik fazlalığını azaltmaktır. Otomatikleştirilmiş özellik mühendisliğinin özü, bir dereceye kadar, bu üç sürecin dinamik bir kombinasyonudur [27].

Otomatikleştirilmiş özellik mühendisliği, makine öğrenme araçlarının performansının iyileştirilebileceği yeni bir özellik seti oluşturmayı amaçlar. Bu sayede yoğun insan bilgisinden ve emeğinden tasarruf edilebilmektedir [8]. Otomatik yaklaşımın en önemli avantajları şunlardır; çok az alan bilgisi gereklidir, yalnızca belirli bir uzman tarafından tanımlananlar yerine çok çeşitli olası özellikler değerlendirilir, kodlama bakımından daha kısa ve temizdir [28].

2.1.3. Model ve hiper-parametre optimizasyonu (Model and hyperparameter optimization)

Yüksek kaliteli bir makine öğrenmesi modeli oluşturma süreci, hiper-parametrelerini etkili bir şekilde ayarlama konusunda iyi bir deneyime sahip olmanın yanı sıra farklı algoritma ve teknikleri denemeyi içeren yinelemeli, karmaşık ve zaman alan bir süreçtir [29]. Model seçiminin amacı, bir dizi makine öğrenmesi modeli ve bir veri kümesi verildiğinde, veri kümesi üzerinde eğitilip test edildiğinde en yüksek doğruluğa sahip modelleri bulmaktır. AutoML, insan müdahalesi olmadan verileri göz önünde bulundurarak en uygun modeli seçmeye çalışır. Aynı girdi verileri üzerinde eğitilmek üzere farklı modeller arasında yineleme yapabilir ve en iyi performansı gösteren modeli seçebilir [1].

Hiper-parametreler model eğitime başlamadan önce geliştirici tarafından belirlenen ve genellikle eğitim süreci boyunca sabit kalan değerlerdir. Bu değerler modelin performansını önemli ölçüde etkilemektedir. Hiper-parametre optimizasyonu, sinir ağı yapıları ve model eğitim süreci için optimum hiper-parametrelerin aranmasında AutoML'nin önemli bir bileşenidir. Hiper-parametre optimizasyonun amacı üç yönlüdür: yapay zekâ uzmanlarının maliyetli basit işlerini azaltmak, araştırma ve geliştirme eşiğini düşürmek; sinir ağı eğitiminin doğruluğunu ve verimliliğini artırmak; hiper-parametre seti seçimini daha ikna edici ve eğitim sonuçlarını daha tekrarlanabilir hale getirmektedir [30]. Hiper-parametre optimizasyonu, temel olarak ızgara arama (grid search), rastgele arama (random search), Bayes optimizasyonu (Bayesian optimization) ve gradyan tabanlı optimizasyonu (gradient-based optimization) içerir [21].



Şekil 1. AutoML optimizasyonu (AutoML optimization)

2.2. AutoML Kütüphaneleri (AutoML Libraries)

AutoML kütüphaneleri, makine öğrenmesi uygulayıcılarının veriler için dikkatlice seçilmiş birkaç algoritmayı deneyerek ve hiper-parametre ayarlaması gerçekleştirilerek en iyi performans gösteren makine öğrenmesi veya derin öğrenme algoritmalarını bulmalarına yardımcı olur [31]. Zaman serisi tahminleme, sınıflandırma gibi problemleri çözmek için farklı programlama dilleriyle oluşturulmuş birçok farklı AutoML kütüphanesi bulunmaktadır. Bu kütüphaneler makine öğrenmesi modellerini otomatik, hızlı ve etkin bir şekilde sunmaktadır. Bu çalışma kapsamında tek değişkenli bir zaman serisi verisi üzerinde tahminleme gerçekleştirmek amacıyla seçilmiş 6 farklı AutoML kütüphanesi bulunmaktadır.

2.2.1. Auto_ARIMA (Auto_ARIMA)

ARIMA modeli, verilerdeki korelasyonları modelleyerek zaman serisi verilerini ayrıştırmak ve tahmin etmek için kullanılan istatistiksel bir yöntemdir [32]. En iyi parametre kombinasyonunu bulmak için AIC ve BIC değerlerini dikkate alır. Bu değerler, farklı modelleri karşılaştırmak için kullanılır. ARIMA modeli genellikle (p, d, q) mertebesine göre görülür; burada p, d ve q sırasıyla AR, fark ve MA kısmının mertebelerini ifade eder [33]. Mevsimsel bir ARIMA modeli ARIMA (p, d, q) × (P, D, Q)S olarak gösterilir, burada P mevsimsel AR sırası, D mevsimsel fark, Q mevsimsel MA sırası ve S sırasıyla mevsimsel örtüntüyü tekrar eden zaman aralığıdır [34].

Auto_ARIMA, otomatik bir şekilde ARIMA modeli oluşturmak için kullanılır. Auto_ARIMA işlevi, bir ARIMA modeli için en uygun parametreleri belirlemeye çalışır ve uygun bir ARIMA modeli döndürür [35]. Auto_ARIMA p, d, q gibi uygun parametreleri bulur. Durağanlık testi için fark d gibi parametrelere karar vermede Artınlmış Dickey-Fuller, Phillips-Perron veya Kwiatkowski-Phillips-Schmidt-Shin testleri kullanılır. Auto_ARIMA, Canova-Hansen testi gibi mevsimsellik testleri için ideal p ve q değerlerini de belirleyebilir [36].

Al-Qazzaz ve Yousif [37], petrol fiyatlarını tahmin etmek için Auto_ARIMA modelinin kullanımını araştırmıştır. Çalışma, bir uzman dikkati gerektirmeden uygun ARIMA parametrelerini belirlemek için Auto_ARIMA kullanımının faydalarını göstermektedir. Gupta ve Sharma [38], COVID-19 verilerinin analizini için Auto_ARIMA modelini kullanmıştır. Analitik ve mevcut sonuçlardaki yakınlık, Auto_ARIMA modelinin doğruluğunu göstermektedir.

2.2.2. FLAML (FLAML)

FLAML, kaynak açısından verimli ve kolayca uyarlanabilir olacak şekilde tasarlanmış en yeni algoritmaları kullanarak doğru makine öğrenmesi modellerini verimli ve ekonomik bir şekilde bulan Microsoft Research'in bir Python kütüphanesidir [39].

Diğer AutoML araçları ve kitaplıklarıyla karşılaştırıldığında FLAML, hızlı, ekonomik ve özelleştirilmesi kolay olmasıyla dikkat çekmektedir. FLAML, üstün model tahmin performansı elde ederken makine öğrenmesi ve veri bilimi uygulayıcılarının üretkenliğini artırabilir. Esneklik ve özelleştirilebilirlik, onu Ar-Ge için güçlü bir araç haline getirmektedir [40]. Minimum özelleştirmeden tam özelleştirmeye kolay genişleme, geniş arama alanlarını yönetme ve uygun maliyetli hiper-parametre optimizasyonu bu kütüphanenin avantajları arasında bulunmaktadır [41].

2.2.3. FEDOT (FEDOT)

FEDOT, otomatik modelleme ve otomatikleştirilmiş makine öğrenmesi için açık kaynaklı bir kütüphanedir. Evrimsel bir yaklaşım

kullanarak otomatik bir şekilde farklı gerçek dünya süreçleri için özel modelleme oluşturabilir. FEDOT, ikili ve çoklu sınıflandırma, regresyon, kümeleme ve zaman serisi tahmin görevlerini destekler [42].

2.2.4. Prophet (Prophet)

Prophet, otomatik zaman serisi tahmini için geliştirilmiştir [43]. Python ve R'de bulunan açık kaynaklı bir kütüphanedir. Prophet, zaman serilerini ve mevsimselliği kolayca ele almak için kendi özel veri çerçevesine sahiptir. Trenddeki değişimleri ve büyük aykırı değerleri yakalayarak eksik veriye karşı güçlüdür [44]. Prophet modelinin uygulanması oldukça az sayıda koddan oluşur ancak aynı zamanda kullanıcıların daha düşük seviyeli parametreler üzerinde kontrol sahibi olmalarına da izin verir [43]. Prophet tahmin modeli üç ana özelliği nedeniyle kaliteli bir tahmin oluşturabilir; trend, mevsimsellik ve tatiller (holiday). Model Eş. 1'deki gibi ifade edilebilir [45].

$$y(t) = g(t) + h(t) + s(t) + \epsilon_t \quad (1)$$

Burada, y(t) hedef yapıyı veya zaman serisini temsil eder, g(t) zaman serisinin değerindeki periyodik olmayan değişimleri modelleyen trend fonksiyonudur, s(t) periyodik değişimleri (örneğin haftalık ve yıllık mevsimsellik) temsil eder ve h(t), potansiyel olarak düzensiz programlarda bir veya daha fazla gün boyunca meydana gelen tatillerin etkilerini temsil eder, ϵ_t ise hata terimini gösterir.

2.2.5. EvalML (EvalML)

EvalML, özellik seçimi, model seçimi, hiper-parametre optimizasyonu vb. otomatik olarak yürüten açık kaynaklı bir AutoML kütüphanesidir. Özellik seçimi için rastgele orman sınıflandırıcı/regresör ve hiper-parametreleri optimize etmek için Bayes optimizasyonu kullanır. Zaman serisi tahmini durumunda MSE gibi bir nesnel işlev parametresine bağlı olarak makine öğrenmesi modelini oluşturur ve optimize eder. Regresyon, sınıflandırma, zaman serisi regresyonu ve zaman serisi sınıflandırması dahil olmak üzere çeşitli denetimli makine öğrenmesi problem türlerini destekler [46].

EvalML, gerekli veri ön işleme konusunda önerilerde bulunabilir, son teknoloji veri ön işleme, özellik mühendisliği, özellik seçimi ve diğer modelleme teknikleri dahil olmak üzere yüksek düzeyde optimize edilmiş bir model oluşturmaya yardımcı olur, bir model oluşturmak ve bu modelleri doğru tahminler yapmak için basit, kullanımı kolay, düşük kodlu bir arayüz sağlar [1].

2.2.6. AutoTS (AutoTS)

AutoTS, zaman serilerinde yüksek doğrulukta tahminler üretmek için tasarlanmış bir Python kütüphanesidir. Çok değişkenli zaman serisi çıktıları tahmin etmeyi desteklemektedir. İçerisinde bulunan modeller genetik algoritmalar aracılığıyla belirli bir veri kümesi için en iyi modelleri, ön işlemeyi ve birleştirmeyi otomatik olarak bulan bir AutoML entegrasyonu için tasarlanmıştır.

Kütüphane, optimum zaman serisi tahmin modelini bulmak için genetik programlama optimizasyonunu kullanır. Alt ve üst güven aralığı tahmin değerleri sağlar. Hem tek değişkenli hem de çok değişkenli zaman serilerini çalıştırabilir [47].

3. Deneysel Sonuçlar (Computational Results)

Çalışmada kullanılan veri seti [48], Ocak 1985 ile Eylül 2022 tarihleri arasında ölçülen Amerika Birleşik Devletleri'nde aylık olarak elektrik ve gaz tesislerinin endüstriyel üretimini (İndeks 2017=100) ele

almaktadır. İndeksler, bir olayın (üretilen mal veya hizmetlerin) zaman veya mekân itibarıyla gösterdiği oransal değişimleri ifade eder. Bu veri setinde, elektrik ve gaz tesislerinin endüstriyel üretimini özetlemek amacıyla 2017 yılı baz alınarak indekslenmiştir. AutoML kütüphanelerinin kodlanmasında Python programlama dili kullanılmıştır. Veri seti %80'i eğitim, %20'si test verisi olmak üzere ikiye ayrılmıştır ve Şekil 2'deki gibidir.

AutoML kütüphanelerinin tahmin performanslarını ölçmek için MSE, RMSE, MAE ve MAPE metrikleri kullanılmıştır. Bu tür ölçümler birimden bağımsızdır, verilerde küçük değişiklikler olduğunda iyi bir duyarlılığa sahiptir ve veri asimetrisi göstermezler [49]. Burada X_i , i . nokta tahminini ve Y_i , i . dönem için sonucu temsil eder. Eş. 2, MSE'yi gösterir. Tahmindeki hataların kareleri toplamının ortalamasını ölçer.

$$MSE = \frac{1}{m} \sum_{i=1}^m (X_i - Y_i)^2 \quad (2)$$

Eş. 3'teki RMSE, hataların standart sapmasını gösterir.

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (X_i - Y_i)^2} \quad (3)$$

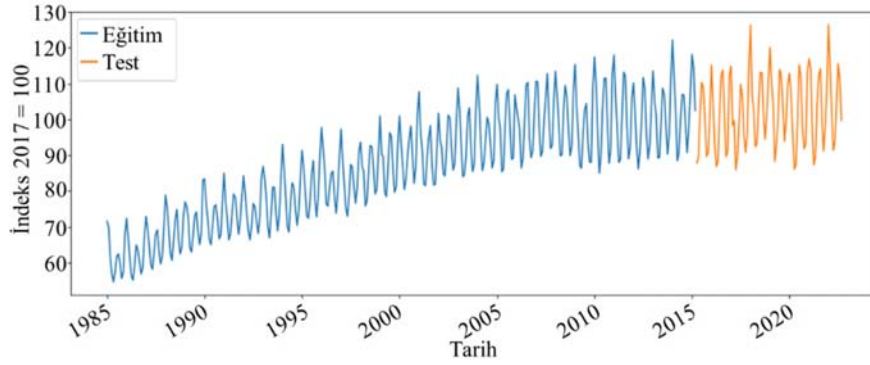
Eş. 4, MAE'yi gösterir. Mutlak değerlerdeki tahmin hatalarının ortalama değeri olarak tanımlanır.

$$MAE = \frac{1}{m} \sum_{i=1}^m |X_i - Y_i| \quad (4)$$

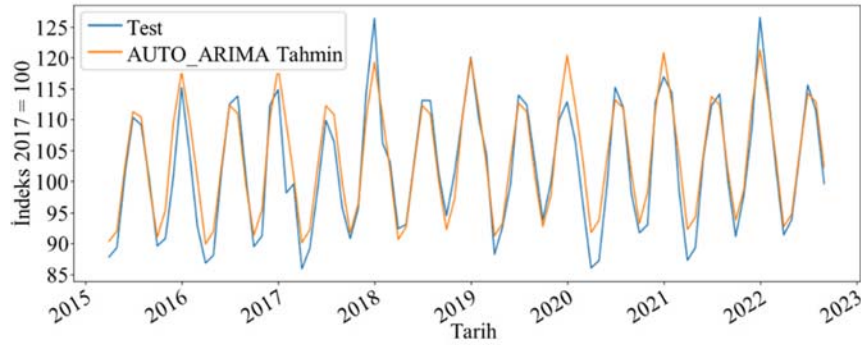
Eş. 5, MAPE'yi gösterir. Doğruluğu hatanın yüzdesi olarak ölçer [50].

$$MAPE = \frac{1}{m} \sum_{i=1}^m \left| \frac{Y_i - X_i}{Y_i} \right| \cdot 100\% \quad (5)$$


Şekil 3-Şekil 8, test verisini ve kullanılan AutoML kütüphanelerinin (Auto_ARIMA, FLAML, FEDOT, Prophet, EvalML ve AutoTS) tahminleme sonuçlarını göstermektedir. Veri setinin son 90 gününe




Şekil 2. Veri setinin zamana bağlı grafiği (Time graph of dataset)




Şekil 3. Auto_ARIMA kütüphanesinin tahminleme grafiği (Estimation plot of Auto_ARIMA library)



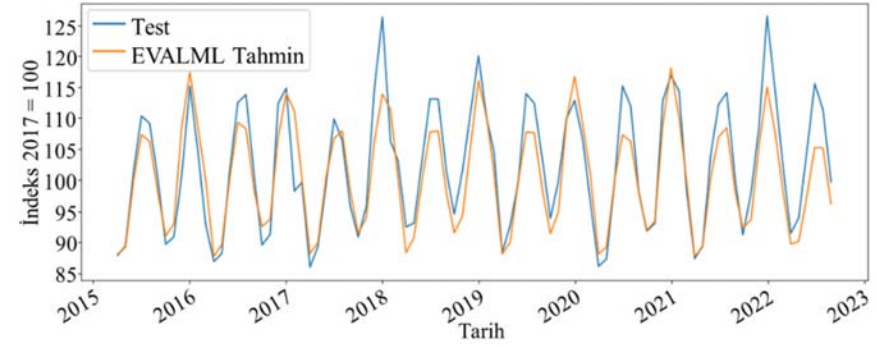
Şekil 4. FLAML kütüphanesinin tahminleme grafiği (Estimation plot of FLAML library)



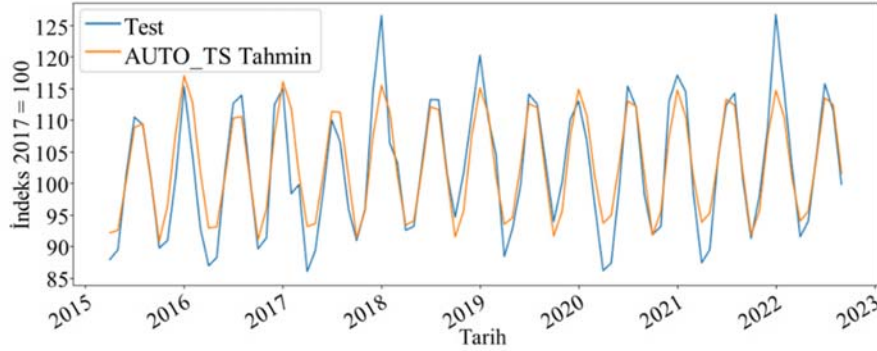
Şekil 5. FEDOT kütüphanesinin tahminleme grafiği (Estimation plot of FEDOT library)



Şekil 6. Prophet kütüphanesinin tahminleme grafiği (Estimation plot of Prophet library)



Şekil 7. EvalML kütüphanesinin tahminleme grafiği (Estimation plot of EvalML library)



Şekil 8. AutoTS kütüphanesinin tahminleme grafiği (Estimation plot of AutoTS library)

ait değerlerin tahmini gerçekleştirilmiştir. Grafikteki mavi çizgi test verisini, turuncu çizgi ilgili kütüphanenin tahmin değerini temsil etmektedir.

Witt ve Witt [51], MAPE değerleri %10'un altında olan tahmin modellerini "yüksek doğruluk" derecesine sahip, %10 ile %20 arasında olan modelleri ise "doğru tahminler" olarak sınıflandırmıştır.

Lewis [52], MAPE değerleri %10'un altında olan modelleri "çok iyi", %10 ile %20 arasında olan modelleri "iyi", %20 ile %50 arasında olan modelleri "kabul edilebilir" ve %50'nin altında olan modelleri ise "yanlış ve hatalı" olarak sınıflandırmıştır.

AutoML kütüphanelerinin belirlenen metrikler bazında tahmin performansları Tablo 1'deki gibidir. Elde edilen sonuçlara göre her bir AutoML kütüphanesinin MAPE değeri %10'un altında olduğundan yüksek doğrulukta bir tahminleme gerçekleştiği söylenebilir. Tahminleme grafiklerine ve performans metriklerine bakıldığında en yüksek tahminleme doğruluğunu Auto_ARIMA kütüphanesinin verdiği görülmektedir. Bu sıralamayı Prophet ve AutoTS kütüphaneleri takip etmektedir.

Tablo 1. AutoML kütüphanelerinin tahminleme performansları (Estimation performances of AutoML libraries)

	MSE	RMSE	MAE	MAPE
Auto_ARIMA	12,1652	3,4879	2,7502	2,7498
FLAML	20,2051	4,4950	3,6644	3,5998
FEDOT	24,8659	7,6563	4,1286	4,0162
Prophet	14,0279	3,7454	3,0309	2,9915
EvalML	19,6453	4,4323	3,4566	3,2690
AutoTS	17,6763	4,2043	3,2045	3,1845

Auto_ARIMA kütüphanesi ile elde edilen tahmin sonuçlarına göre seçilen performans metriklerini en küçükleyen ve en iyi tahminleme değerini veren model ARIMA(1,1,1)(2,1,2)[12]'dir. Model şu şekilde açıklanır; zaman serisinin bir önceki gözleminin üzerindeki etkisi vardır ($p=1$), zaman serisinin bir önceki dereceden farkı alınır ($d=1$), zaman serisindeki hataların bir önceki gözlemin üzerindeki etkisi vardır ($q=1$), mevsimsel olarak geçmişteki 2 adet gözlemin şu anki gözlem üzerindeki etkisi vardır ($P=2$), zaman serisinin bir önceki dereceden mevsimsel farkı alınır ($d=1$), mevsimsel olarak geçmişteki hataların, şu anki gözlem üzerindeki etkisi vardır ($Q=2$), zaman serisinde bir yıl boyunca tekrarlanan mevsimsel örüntüler bulunmaktadır ($m=12$). Mevsimsellik faktörünün ele alınması, Auto_ARIMA kütüphanesinin iyi sonuç vermesinin sebeplerinden biri olabilir.

4. Sonuçlar (Conclusions)

Bu çalışmada makine öğrenmesinin gelişmiş bir versiyonu olan AutoML yöntemi kullanılmıştır. AutoML, özellik seçimi, model ve hiper-parametre optimizasyonu gibi uzman bilgisi gerektiren makine öğrenmesi adımlarını otomatikleştirmek ve bir uzmana ihtiyaç duymadan çözümlenebilirlik amacıyla geliştirilmiştir. Amaç, insanı tamamen sürecin dışına almak değil, insandan kaynaklı oluşabilecek önyargı ve klişelerden kurtulmak, zaman ve maliyet açısından da tasarruf edebilmektir. Çalışmada, kullanılan tek değişkenli bir zaman serisi verisi üzerinde ileriye yönelik tahminleme için Auto_ARIMA, FLAML, FEDOT, Prophet, EvalML ve AutoTS olmak üzere 6 farklı AutoML kütüphanesi kullanılmış ve kütüphanelerin tahmin başarılarının karşılaştırılması yapılmıştır. MSE, RMSE, MAE ve MAPE metrikleri üzerinden elde edilen sonuçlara göre kullanılan veri seti özelinde tahmin başarısı en yüksek olan kütüphanenin Auto_ARIMA olduğu görülmektedir. Mevsimsel etkileri içeren tahminleme modelleri, zaman serilerinin gelecekteki değerlerini daha doğru bir şekilde tahmin edebilmektedir. AutoML, zaman serisi veri setlerindeki mevsimsellik, trendler ve diğer zaman bazlı desenlere dikkat ederek model performansını artırabilir. Gelecek çalışmalarda, özellikle mevsimsel etkilere sahip zaman serileri için AutoML kullanmak, mevsimsel etkileri ve gelecekteki değerleri daha doğru bir şekilde tahmin etmek için faydalı olabilir. Ancak veriye ve probleme özgü olarak, model başarısının değişkenlik gösterebileceği de dikkate alınmalıdır. Yine kullanılan AutoML kütüphaneleri, farklı veri setleri

üzerinde denenerek kütüphanelerin tahmin performansları karşılaştırılabilir.

5. Simgeler (Symbols)

AIC	: Akaike Bilgi Kriteri
ARIMA	: Otoregresif Entegre Hareketli Ortalama
BIC	: Bayes Bilgi Kriteri
FLAML	: Fast and Lightweight AutoML
IoT	: Nesnelerin İnterneti
MAE	: Ortalama Mutlak Hata
MAPE	: Mutlak Yüzde Hata Ortalaması
MSE	: Hata Kareleri Ortalaması
RMSE	: Hata Kareleri Ortalamasının Karekökü

Teşekkür (Acknowledgement)

Bu çalışmanın 1. Yazarı TÜBİTAK 2211-A Yurt İçi Doktora Burs Programı tarafından desteklenmektedir. Ancak yayın ile ilgili tüm sorumluluk yayının sahibine aittir. Yayının içeriğinin bilimsel anlamda TÜBİTAK tarafından onaylandığı anlamına gelmez.

Kaynaklar (References)

- Alsharif A., Aggarwal K., Sonia, Kumar M., Mishra A., Review of ML and AutoML solutions to forecast time-series data, Arch Computat Methods Eng, 29 (7), 5297-3111, 2022.
- Petropoulos F., Spiliotis E., The wisdom of the data: getting the most out of univariate time series forecasting, Forecasting, 3 (3), 478-97, 2021.
- Masini R.P., Medeiros M.C., Mendes E.F., Machine learning advances for time series forecasting, Journal of Economic Surveys, 37 (1), 76-111, 2023.
- Tealab A., Time series forecasting using artificial neural networks methodologies: a systematic review, Future Computing and Informatics Journal, 3 (2), 334-40, 2018.
- Torres J.F., Hadjout D., Sebaa A., Martínez-Álvarez F., Troncoso A., Deep learning for time series forecasting: a survey, Big Data, 9 (1), 3-21, 2021.
- Mohr F., Wever M., Hüllermeier E., ML-Plan: automated machine learning via hierarchical planning, Mach Learn, 107 (8), 1495-515, 2018.
- Karmaker S.K., Hassan M., Smith M.J., Xu L., Zhai C., Veeramachaneni K., AutoML to date and beyond: challenges and opportunities, Association for Computing Machinery, 54 (8), 175:1-175:36, 2021.
- Yao Q., Wang M., Chen Y., Dai W., Li Y.F., Tu W.W., Yang Q., Yu Y., Taking human out of learning applications: a survey on automated machine learning, arXiv preprint arXiv:1810.13306, 2018.
- Hutter F., Kotthoff L., Vanschoren J., Automated machine learning: methods, systems, challenges, Springer Nature, 219, 2019.
- Erickson N., Mueller J., Shirkov A., Zhang H., Larroy P., Li M., Smola A., Autogluon-tabular: robust and accurate automl for structured data, arXiv preprint arXiv:2003.06505, 2020.
- Prescient & Strategic Intelligence Private Limited. AutoML Market. <https://www.reportlinker.com/p06191010/AutoML-Market.html>. Yayın tarihi Kasım, 2021. Erişim tarihi Şubat 7, 2023.
- Ahlgren F., Mondejar M.E., Thern M., Predicting dynamic fuel oil consumption on ships with automated machine learning, Energy Procedia, 158, 6126-6131, 2019.
- Zhang Q., Hu W., Liu Z., Tan J., TBM performance prediction with Bayesian optimization and automated machine learning, Tunneling and Underground Space Technology, 103, 2020.
- Zeineddine H., Braendle U., Farah A., Enhancing prediction of student success: automated machine learning approach, Computers & Electrical Engineering, 89, 2021.
- Zhang C., Ye Z., Water pipe failure prediction using AutoML, Facilities, 39 (1/2), 36-49, 2021.
- Bender J., Trat M., Ovtcharova J., Benchmarking AutoML-supported lead time prediction, Procedia Computer Science, 200, 482-94, 2022.

17. Duan S., Zhang X., AutoML-based drought forecast with meteorological variables, arXiv preprint arXiv:2207.07012, 2022.
18. Gomathi S., Kohli R., Soni M., Dhiman G., Nair R., Pattern analysis: predicting COVID-19 pandemic in India using AutoML, World Journal of Engineering, 19 (1), 21-28, 2022.
19. Muniz Do Nascimento W., Gomes-Jr L., Enabling low-cost automatic water leakage detection: a semi-supervised, AutoML-based approach, Urban Water Journal, 1-11, 2022.
20. Bahri M., Salutari F., Putina A., Sozio M., AutoML: state of the art with a focus on anomaly detection, challenges, and research directions, International Journal of Data Science and Analytics, 14 (2), 113-126, 2022.
21. Wu D., Guan Q., Fan Z., Deng H., Wu T., AutoML with parallel genetic algorithm for fast hyperparameters optimization in efficient IoT time series prediction, IEEE Transactions on Industrial Informatics, 1-10, 2022.
22. Truong A., Walters A., Goodsitt J., Hines K., Bruss C.B., Farivar R., Towards automated machine learning: evaluation and comparison of AutoML approaches and tools, 2019 IEEE 31st International Conference on Tools with Artificial Intelligence (ICTAI), 1471-9, 2019.
23. Waring J., Lindvall C., Umeton R., Automated machine learning: review of the state-of-the-art and opportunities for healthcare, Artificial Intelligence in Medicine, 104, 101822, 2020.
24. Koc K., Gurgun A.P., Scenario-based automated data preprocessing to predict severity of construction accidents, Automation in Construction, 140, 104351, 2022.
25. Bilal M., Ali G., Iqbal M.W., Anwar M., Malik M.S.A., Kadir R.A., Auto-Prep: efficient and automated data preprocessing pipeline, IEEE Access, 10, 107764-84, 2022.
26. Bonidia R.P., Santos A.P.A., de Almeida B.L.S., Stadler P.F., da Rocha U.N., Sanches D.S., de Carvalho, A.C., BioAutoML: automated feature engineering and metalearning to predict noncoding RNAs in bacteria, Briefings in Bioinformatics, 23 (4), bbac218, 2022.
27. He X., Zhao K., Chu X., AutoML: a survey of the state-of-the-art, Knowledge-Based Systems, 212, 106622, 2021.
28. Adamczyk J., Malawski F., Comparison of manual and automated feature engineering for daily activity classification in mental disorder diagnosis, Computing & Informatics, 40 (4), 850-79, 2021.
29. Elshawi R., Maher M., Sakr S., Automated machine learning: state-of-the-art and open challenges, arXiv preprint arXiv:1906.02287v2, 2019.
30. Yu T., Zhu H., Hyper-parameter optimization: a review of algorithms and applications, arXiv preprint arXiv:2003.05689v1, 2020.
31. Akinci T.C., Topsakal O., Wernerbach A., Machine learning-based wind speed time series analysis, 2022 Global Energy Conference (GEC), 391-4, 2022.
32. Wadi S.A., Almasarweh M., Alsarairah A.A., Predicting closed price time series data using ARIMA model, Modern Applied Science, 12 (11), 181, 2018.
33. Choudhary A., Kumar S., Sharma M., Sharma K.P., A framework for data prediction and forecasting in WSN with auto ARIMA, Wireless Personal Communications, 123 (3), 2245-59, 2022.
34. Siami-Namini S., Tavakoli N., Siami Namin A., A comparison of ARIMA and LSTM in forecasting time series, 17th IEEE International Conference on Machine Learning and Applications (ICMLA), 1394-1401, 2018.
35. Chan W.N., Time series data mining: comparative study of ARIMA and prophet methods for forecasting closing prices of myanmar stock exchange, Journal of Computer Applications and Research, 1 (1), 2020.
36. Adiga R., Forecasting the spread of COVID-19 with prophet model using Belgium dataset, International Journal of Advances in Soft Computing and Intelligent Systems (IJASCIS), 1 (1), 36-41, 2022.
37. Al-Qazzaz R.A., Yousif S.A., High performance time series models using auto autoregressive integrated moving average, Indonesian Journal of Electrical Engineering and Computer Science (IJEECS), 27 (1), 422-430, 2022.
38. Gupta S., Sharma D., Prediction of COVID-19 spread in world using pandemic dataset with application of auto ARIMA and SIR models, International Journal of Critical Infrastructures 18 (2), 148-58, 2022.
39. Anyscale. Fast AutoML with FLAML + Ray Tune. <https://www.anyscale.com/blog/fast-automl-with-flaml-ray-tune>. Yayın tarihi Ağustos 24, 2021. Erişim tarihi Ocak 14, 2023.
40. Wang C., Wu Q., Liu X., Quintanilla L., Automated machine learning & tuning with FLAML, In Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining, 4828-4829, 2022.
41. Patil P.S., Kappuram K., Rumao R., Bari P., Development of AMES: automated ML expert system, International Conference on Machine Learning, Big Data, Cloud and Parallel Computing (COM-IT-CON), 208-13, 2022.
42. Derevitskii I.V., Mramorov N.D., Usoltsev S.D., Kovalchuk S.V., Hybrid bayesian network-based modeling: COVID-19-pneumonia case, Journal of Personalized Medicine, 12 (8), 1325, 2022.
43. Hoell N., A survey of open source automation tools for data science predictions, arXiv preprint arXiv:2208.11792v1, 2022.
44. Yenidoğan I., Çayır A., Kozan O., Dağ T., Arslan Ç., Bitcoin forecasting using ARIMA and PROPHET, 3rd International Conference on Computer Science and Engineering (UBMK), 621-4, 2018.
45. Taylor S.J., Letham B., Forecasting at scale, The American Statistician, 72 (1), 37-45, 2018.
46. Alsharaf A., Sonia, Kumar K., Iwendi C., Time series data modeling using advanced machine learning and AutoML, Sustainability, 14 (22), 15292, 2022.
47. Gandhi P. 7 libraries that help in time-series problems. <https://towardsdatascience.com/7-libraries-that-help-in-time-series-problems-d59473e48ddd>. Yayın tarihi Haziran 28, 2021. Erişim tarihi Ocak 24, 2023.
48. Board of Governors of the Federal Reserve System (US), Industrial Production: Utilities: Electric and Gas Utilities (NAICS=2211,2), retrieved from FRED. <https://fred.stlouisfed.org/series/IPG2211A2N>. Güncellenme tarihi Şubat 15, 2023. Erişim tarihi Kasım 24, 2022.
49. Cifuentes J., Marulanda G., Bello A., Reneses J., Air temperature forecasting using machine learning techniques: a review, Energies, 13 (16), 4215, 2020.
50. González-Sopeña J.M., Pakrashi V., Ghosh B., An overview of performance evaluation metrics for short-term statistical wind power forecasting, Renewable and Sustainable Energy Reviews, 138, 110515, 2021.
51. Witt S.F., Witt C.A., Modeling and forecasting demand in tourism, Londra: Academic Press., 1992.
52. Lewis C.D., Industrial and business forecasting methods, Londra: Butterworths Publishing, 1982.

