

İŞLETMELER İÇİN MAKİNE ÖĞRENİMİ HİZMET STRATEJİSİNE GENEL BAKIŞ OVERVIEW OF MACHINE LEARNING SERVICE STRATEGY FOR BUSINESS

Hasan Tahsin AYTEKİN

Ufuk Üniversitesi, İ.İ.B.F.,

Yönetim Bilişim Sistemleri

hasan.aytekin@ufuk.edu.tr

ORCID: 0000-0002-5632-7825

ÖZ

ABSTRACT

Geliş Tarihi:

24.07.2024

Kabul Tarihi:

07.10.2024

Yayın Tarihi:

29.12.2024

Anahtar Kelimeler

Makine Öğrenimi
Hizmet Olarak Makine
Öğrenimi
Hizmet Olarak Makine
Öğrenimi Platformları
Makine Öğrenimi
Hizmetleri

Keywords

Machine Learning
Machine Learning as a
Service
Machine Learning as a
Service Platforms
Machine Learning
Services

Artan makine öğrenimi talebi ve veri analizine olan ihtiyaç nedeniyle birçok işletme, yüksek teknolojiye sahip çözümleri süreçlerine dahil ederek kendi altyapılarını geliştirmenin maliyetini düşürmeyi amaçlamakta ve bulut tabanlı çözümlere yönelmektedir. Bu nedenle hizmet olarak makine öğrenimi (MLaaS) platformları hem maliyet avantajları hem de teknik gereksinimler açısından önemli hale gelmiştir. Bu bağlamda çalışmada, karşılaştırmalı analiz yaklaşımı benimsenerek Amazon SageMaker, Google AI Platform, Microsoft Azure Machine Learning ve IBM Watson Studio platformları incelenmektedir. Bu platformlar, kullanıcı tabanlı ve sundukları geniş hizmet seçenekleri nedeniyle seçilmiştir. Veriler, platform sağlayıcılarının sunduğu açık veri kaynaklarından elde edilmiştir. Bulgular, her bir platformun kendine özgü avantajları olduğunu, ancak maliyet ve teknik gereksinimlerin işletmelerin platform seçiminde önemli rol oynadığını göstermektedir. Ayrıca bulut tabanlı MLaaS çözümlerinin, küçük ekiplerle büyük verisetleri üzerinde çalışmayı mümkün kılarak maliyet avantajı sağladığı bulunmuştur. Sonuçlar, MLaaS platformlarının işletmelere maliyet etkin, ölçeklenebilir ve esnek çözümler sunduğunu göstermektedir. Ancak, veri gizliliği ve güvenliği gibi konular platform seçiminde önemli bir rol oynamaktadır. İşletmelerin makine öğrenimi projelerinde başarılı olabilmesi için, doğru platformun seçimi ve mevcut sistemlerle entegrasyonun sağlanması kritik öneme sahiptir.

Due to the increasing demand for machine learning and the need to analyse data, many companies are looking to reduce the cost of developing their own infrastructure by incorporating high-tech solutions into their processes and are turning to cloud-based solutions. As a result, machine learning as a service (MLaaS) platforms have become important in terms of both cost benefits and technical requirements. In this context, the study adopts a comparative analysis approach and examines the Amazon SageMaker, Google AI Platform, Microsoft Azure Machine Learning and IBM Watson Studio platforms. These platforms were selected based on their user base and the breadth of services they offer. Data was obtained from open data sources provided by the platform vendors. The findings show that each platform has its own advantages, but cost and technical requirements play an important role in organisations' choice of platform. Cloud-based MLaaS solutions were also found to offer cost benefits by enabling small teams to work on large datasets. The results show that MLaaS platforms offer enterprises cost-effective, scalable and flexible solutions. However, issues such as privacy and security play an important role in platform selection. Choosing the right platform and ensuring integration with existing systems is critical to the success of enterprise machine learning projects.

DOI: <https://doi.org/10.30783/nevsosbilen.1521972>

Atf/Cite as: Aytekin, H. T. (2024). İşletmeler için makine öğrenimi hizmet stratejisine genel bakış. *Neşehir Hacı Bektaş Veli Üniversitesi SBE Dergisi*, 14(4), 1901-1923.

Giriş

Yapay zekâ çerçevesi altında ele alınan makine öğrenimi modelleri ve bu modellere bağımlı uygulamaların geliştirilmesi için kullanılabilir yollardan biri açık kaynak gücünden de yararlanan geleneksel geliştirme ortamlarından (genellikle Python) faydalanarak oluşturulan duruma, kuruma ve kişiye özel sistemlerdir. Bu tür özel sistemler, mutlak gerekli olan özel durumlar dışında oldukça karmaşık ve pahalı sistemlerdir. Bu karmaşık ve pahalı sistemlerin yanı sıra, daha konvansiyonel insan kaynakları (endüstri mühendisleri, yazılım mühendisleri, vs.) ile geliştirilmiş olan, geliştirilen veya geliştirilebilecek birçok işleme ait uygulamaların verilerini ve sonuçlarını kullanarak, var olan veya yeni geliştirilecek sistemlere makine öğrenimi modelleri ekleyerek yapay zekâ özelliği kazandırmak mümkündür.

Nesnelerin interneti, siber uzay, mobil cihazlar, işletmeler, sosyal medya platformları, sağlık sistemleri ve benzeri çevrimiçi ortamda çok fazla veri vardır. Makine öğrenimi, bu verilerin akıllı analizlerini yapmak ve bunları kullanan akıllı, otomatik uygulamalar geliştirmek için kullanılmaktadır. Farklı türde birçok makine öğrenimi algoritması vardır (Tufail, Riggs, Tariq, & Sarwat, 2023).

Makine öğrenimi algoritmaları klasik yazılım geliştirmede olduğu gibi kodlanarak kullanılmaz, büyük miktardaki ilgili veriler ile eğitilen ve örneklerden öğrenen bir yazılımdır (Aytekin, 2021). Makine öğrenimi, her türlü iş ve araştırma alanındaki birçok işletme için iyi eğitilmiş insan kaynağı ve yüksek teknoloji ürünü donanım ve altyapı kaynağı gereksinimi nedeniyle pahalı ve yetenek gerektiren bir çalışma olarak görülmektedir. Her boyuttaki kurumda kaynaklar sınırlı olduğu için, makine öğrenmesi teknolojisinin kullanımının kuruma ekonomik bir değer katacağının ispatlanması çok önemlidir (Costa-Climent, Haftor, & Staniewski, 2024).

Klasik sistemlerde kullanılan bütün veri ve işlemlerin, bir hizmet olarak her türlü otomasyon sistemine sağlanması özelliği sayesinde hem eğitim hem de sanayi sektörleri oldukça başarılı projeler gerçekleştirmiştir. Hizmet odaklı ve yönelimli projeler maliyet, performans ve gerekli eğitimli insan kaynağının bu yöntemlere yönelik bilgi birikimi sayesinde her türlü sanayide sıkça kullanılan başarılı bir yaklaşım olmuştur. Elde ettiği başarılı sonuçlar neticesinde, hizmet odaklılık yaklaşımı, her türlü çalışma ortamında bilinen, kullanılan ve güvenilmesi için gerekli olan bilgi ve donanım altyapısını hali hazırda sunmaktadır (Lee, Shim, & Kim, 2010). Organizasyonel süreçler, algoritmik süreçler, veriler, verisetleri, veri nesnelere gibi bilgi süreçlerine erişim amacıyla geliştirilen bilgi teknolojileri hizmetlerinin dijitalleştirilmesi ve istekte bulunan yetkili uç noktası işlemlere sunulması olarak tanımlayabileceğimiz hizmet odaklı mimari yaklaşımı, oldukça karmaşık olan yapay zekâ özelinde makine öğrenimi alanını da etkilemiştir. Eğer bir işletme veri biliminde yeniyse ve hedeflediği makine öğrenmesi projesini çok fazla yatırım yapmadan hızlı bir şekilde başlatabilmeyi amaçlıyorsa, bir bulut hizmeti olan hizmet olarak makine öğrenimini kullanabilme imkanını değerlendirebilir. Bulut hizmeti olarak tasarlanan bir makine öğrenimini ortamını kullanarak bu amaca ulaşmak hem maliyet hem de yetenek olarak veri bilimi projelerinin olanaklı hale gelmesini sağlamaktadır. Makine öğrenimi bulut hizmetlerini kullanarak, nispeten küçük bir ekiple çalışılabilir ve bu çalışmaların sonucunda oluşturulacak tahminlerden değerli öngörüler elde edilerek ilk çalışan modeller oluşturulabilir (Xie, Xue, Zhu, & Wang, 2022).

Bu çalışmadaki amaç, hizmet olarak makine öğrenimi (MLaaS) platformlarının etkinliğini ve kullanılabilirliğini değerlendirmektir. Çalışma, karşılaştırmalı analiz yaklaşımını benimsemektedir. Çalışmada incelenen MLaaS platformları Amazon SageMaker, Google AI Platform, Microsoft Azure Machine Learning ve IBM Watson Studio'dur. Bu platformlar, geniş kullanıcı tabanları ve sağladıkları kapsamlı hizmetler nedeniyle seçilmiştir. Analiz için kullanılan veriler, ilgili MLaaS platform sağlayıcıları tarafından sağlanan açık veri kaynaklarından alınmıştır.

Çalışmanın sınırlamaları, MLaaS platform sağlayıcılarının sunduğu açık veri kaynaklarından elde edilen verilerin çeşitliliği ve platformların belirli özelliklerinin tam olarak incelenememesi olarak belirlenmiştir. Ayrıca, çalışma belirli bir zaman diliminde gerçekleştirilmiş olup, platformların sürekli güncellenen özellikleri göz önünde bulundurulmamıştır.

Bu çalışmada, makine öğrenimi modellerinin sanayide geliştirilen projelere nasıl dahil edilebileceği, bu konudaki yetişmiş eğitimli insan kaynağı eksikliğinin nasıl en aza indirebileceği ve bu amaca ulaşmak için kullanılabilir yöntem ve kaynaklar tartışılacaktır. Bu amaçla önce hizmet olarak makine öğrenimi kavramı ele alınacak ve kavram ortaya konduktan sonra, bu kavramın gerekliliklerini sağlayan ürün platformları gözden geçirilecek ve birbirleri ile ilgili güçlü ve zayıf yönleri karşılaştırılarak farklılıkları ortaya konacaktır. Son olarak ise hizmet olarak

makine öğreniminin kuruluşlara yapacağı katkı tartışılarak eğitilmiş ve deneyimli insan kaynağı ile oluşturulabilecek bir sistem ortaya konacaktır.

Temel Kavramlar

Makine Öğrenimi

Makine Öğrenimi, bilgisayar biliminde en hızlı büyüyen alanlardan biridir. Veri örneklerinden (eğitim seti olarak da adlandırılır) çıkarımlar yapabilen matematiksel modeller oluşturmaya yönelik istatistiksel tekniklerin bir koleksiyonudur. Makine öğrenimi, yapay zekânın bir parçasıdır ve kendisini değişen ortama devamlı olarak uyarlamalıdır (Alpaydın, 2020).

Çeşitli özelliklerine göre sınıflandırılmış birçok farklı makine öğrenimi sistemi vardır (Géron, 2023). Bu kategoriler, farklı makine öğrenimi sistemlerini birbirinden ayırt etmemize ve işimize en uygun olanı seçmemize yardımcı olur. Aşağıda, bu sistemlerin üç ana kategorisi ve her birinin temel özellikleri özetlenmiştir:

1. Gözetimli ve Gözetimsiz Öğrenme:
 - a. *Gözetimli Öğrenme*: Bu sistemler, önceden etiketlenmiş ve kategorize edilmiş örneklerle eğitilerek çalışmaktadır.
 - b. *Gözetimsiz Öğrenme*: Bu sistemler, etiketlenmemiş verilerden öğrenerek çalışmaktadır. Verilerdeki doğal kalıpları ve ilişkileri keşfetmek için kullanılmaktadır.
2. Çevrimiçi ve Toplu Öğrenme:
 - a. *Çevrimiçi Öğrenme*: Bu sistemler, yeni veriler geldikçe bunlardan öğrenerek ve modellerini sürekli güncelleyerek çalışmaktadır. Gerçek zamanlı veri işleme ve tahminlerde kullanılmaktadır.
 - b. *Toplu Öğrenme*: Bu sistemler, tüm eğitim verileri toplandıktan sonra tek seferde eğitilerek çalışmaktadır. Büyük veri kümeleri üzerinde çalışırken daha uygun olmaktadır.
3. Örnek Tabanlı ve Model Tabanlı Öğrenme:
 - a. *Örnek Tabanlı Öğrenme*: Bu sistemler, benzer örneklerle karşılaştırma yaparak yeni veriler için tahminlerde bulunmaktadır. K-en yakın komşu algoritması buna örnektir.
 - b. *Model Tabanlı Öğrenme*: Bu sistemler, verilerdeki kalıpları ve ilişkileri modellemek için matematiksel modeller kullanmaktadır. Regresyon ve sinir ağları buna örnektir.

Yukarıdaki birinci kategoride bahsedilen insan gözetimi ile yapılan dört ana öğrenme türü vardır:

1. *Denetimli Öğrenme*: Bu öğrenme algoritması, etiketli verileri kullanarak modeli eğitmektir. Veriler, bir gözetim sinyali ve bu sinyale ilişkin verilerden oluşan çiftlerden oluştuğu için etiketli olarak adlandırılır ve bir vektör olarak ifade edilebilir. Denetimli öğrenme, doğru sonuç önceden bilindiğinde gerçekleşir (Taye, 2023).
2. *Denetimsiz Öğrenme*: Verileri görselleştirmenin bilgilendirici bir yolu var mı? Değişkenler veya gözlemler arasında alt gruplar keşfedebilir miyiz? Denetimsiz öğrenme, bu gibi soruları yanıtlamaya yönelik çeşitli teknikleri ifade eder (James, Witten, Hastie, Tibshirani, & Taylor, 2023). Bu yaklaşım, denetimli öğrenmenin aksine, etiketli çıktılardan yoksun bir girdi veri kümesi kullanarak öğrenme algoritmasını eğitir. Her bir girdi ögesi için doğru veya yanlış çıktı yoktur ve denetimli öğrenmenin aksine, düzeltmek veya uyarlamak için insan müdahalesi yoktur.
3. *Yarı Denetimli Öğrenme*: Geleneksel denetimsiz öğrenme yaklaşımlarının performansını artırmak için yeni geliştirilmiş olan bir teknolojidir ve etiketlenmemiş verileri kendi oluşturduğu sözde etiketler altında denetimli olarak öğrenmek için tasarlanmıştır (Zhao, Alzubaidi, Zhang, Duan, & Gu, 2024). Bu teknik, bir kısmı etiketlenmiş çok sayıda girdi verisi kullanırken geri kalanı etiketsizdir ve denetimli ve denetimsiz öğrenme arasında yer alır. Makine öğreniminin bu dalı, daha az insan etkileşimi gerektirdiği için çeşitli gerçek dünya öğrenme sorunlarıyla ilgilenir.
4. *Pekiştirmeli Öğrenme*: Çevre ile etkileşim yoluyla öğrenmeye pekiştirmeli öğrenme denir. Pekiştirmeli öğrenme temsilcisi ne yapması gerektiği konusunda açıkça talimat almak yerine, kendi faaliyetleri yoluyla öğrenir. Önceki kullanım ve yeni seçeneklere dayalı olarak kullanacağı bir eylem rotası seçer. Bu nedenle, deneme yanılmaya dayalı bir öğrenme süreci olarak nitelendirilebilir (Taye, 2023). Deneme-yanılma tabanlı insan/hayvan öğrenmesinden esinlenmiştir. Stokastik dinamik bir ortamdan sürekli etkileşim yoluyla elde edilen bilgi ile otonom olarak optimal bir politika geliştirerek öğrenebilen bir makine

öğrenimi tekniğidir. Temel olarak karmaşık problemlerde sıralı karar vermeyi öğrenir (Shakya, Pillai, & Chakrabarty, 2023).

Makine öğrenimi tekniklerinin çalışma yöntemleri çok benzerdir. Genel çalışma prensibi olarak, geliştirilen model bir eğitim kümesinden öğrenmekte ve ardından yeni bir veri kümesi için çıkarımlar yapabilir hale gelmektedir. Bu soyutlama, herhangi bir makine öğrenimi algoritmasını desteklemek için genel bir mimarinin oluşturulmasını sağlamaktadır.

Makine Öğrenimi, teknolojideki gelişmeler ve büyük verisetlerinin kullanılabilirliği nedeniyle son yıllarda önemli ilerlemeler kaydetmiştir. Bununla birlikte, makine öğrenimi modellerinin başarısı büyük ölçüde modelleri eğitmek ve değerlendirmek için kullanılan verisetlerinin kalitesine bağlıdır. Yüksek kaliteli bir veriseti, gerçek dünyadaki olguları doğru bir şekilde temsil eden, kapsamlı ve önyargılardan arındırılmış bir verisetidir. Verisetinin kalitesi, makine öğrenimi modelinin doğruluğu ve etkinliği üzerinde önemli bir etkiye sahiptir (Gong, Liu, Xue, Li, & Meng, 2023).

Makine öğrenimi modellerinin geliştirilmesinde kullanılan algoritmaların seçimi büyük oranda verisetinin yapısına bağlıdır. Herhangi bir algoritma için tahmin doğruluğu yüksek olan verisetleri olduğu gibi, tahmin doğruluğu düşük olan verisetleri de vardır. Aynı veriseti için, farklı algoritmalar kendi yapıları gereği farklı doğruluk oranları ile tahminde bulunmaktadırlar. Hizmet olarak makine öğrenimi, kullanıcının birden çok algoritmayı çalıştırmasına ve performanslarını karşılaştırmasına yardımcı olmakta ve böylece en uygun algoritma seçilebilmektedir.

Hizmet Bileşeni Mimarisini

Hizmet Bileşeni Mimarisini (HBM) (Chapman & Edwards, 2011), Servis Odaklı Mimari (SOA) ilkelerine göre sistemler oluşturmak için bir modelleme özelliğidir.

Hizmet bileşeni mimarisini, uygulamaları üç farklı bölüme ayırır:

- a) İş ile ilgili fonksiyonları gerçekleştiren bileşenler,
- b) İş ile ilgili çözümler üretmek için çeşitli bileşenleri bir araya getiren birleşikler ve
- c) Hizmetler, bileşenleri ve birleşikleri oluşturan fonksiyonlara uzaktan erişim için oluşturulan hizmetlerin arabirimleri.

Hizmet bileşeni mimarisini, Servis Odaklı Mimari üzerine inşa edildiğinden, Servis Odaklı Mimarinin tüm avantajlarına sahiptir (Erl, 2006). Bu avantajlar ile beraber, Ek olarak, Servis Odaklı Mimari tek tek bileşenleri tasarlamak için bir mimari oluşturmaya odaklanırken, HBM, birden çok bileşeni tek bir komposit yapıya birleştirmeye ve bu yolla tasarımı, uygulamayı ve devreye almayı kolaylaştırmaya odaklanmaktadır.

Hizmet Olarak Makine Öğrenimi

Hizmet olarak makine öğrenimi, bulut mimarisinde üretilmiş olan bir üründür. Hizmet olarak İşlevler (FaaS) ve Hizmet Olarak Yazılım (SaaS) çözümü için bir temel oluşturan kapsayıcılardan ve kubernetes'lerden oluşmaktadır. Hizmet olarak makine öğrenimi ürünlerini sağlayan şirketler genel olarak tüm araç setini sağlamak yerine, tek bir hizmetten ince ayarlı bir makine öğrenimi modeli sağlamaktadırlar. Yeni verileri tahmin etmeye yardımcı olan bu modeller ile oluşturulan matematiksel modellerin algoritmaları, verilerdeki kalıpları aramak için kullanılmaktadır.

Makine öğrenimine yönelik artan talep, yeni çözümlerin ortaya çıkmasına neden olmaktadır. Makine öğrenimi araçları çok çeşitli iş sorunlarına uygulanabilir hale gelirken, çoğu şirket kendi makine öğrenimi sistemlerini oluşturmak için deneyim, anlayış ve/veya altyapıdan yoksundur (Ribeiro, Grolinger, & Capretz, 2015).

Hizmet olarak makine öğrenimi, kullanıcıların bilgi işlem kaynaklarına odaklanmaya gerek kalmadan makine öğrenimini kullanmalarına olanak tanıyan yeni bir paradigmadır. Veri depolama, model eğitimi ve dağıtımın karmaşıklığını azaltarak makine öğrenimi sürecini daha da basitleştirmektedir (Yao, ve diğerleri, 2017).

Hizmet olarak makine öğrenimi, veri ön işleme, model eğitimi ve model değerlendirme gibi makine öğreniminin altyapı sorunlarının çoğunu kapsayan çeşitli bulut tabanlı platformların bir şemsiye tanımıdır. Bu platformlardan elde edilecek tahmin sonuçları, iki bilgisayar sisteminin internet üzerinden güvenli bir şekilde bilgi alışverişi

yapmak için kullandığı (Amazon AWS Machine Learning, 2024) bir arabirim olan REST API'leri aracılığıyla yeni geliştirilen veya var olan dahili bilgi teknolojileri altyapısı ile birleştirilebilmektedir (Mira, Moreno, Bardisbanian, & Gorroñogoitia, 2024).

Birçok şirketin sunduğu platformların ortak özelliği, müşterinin ihtiyaçlarına göre özelleştirilmiş iş akışının yapılabileceği farklı yöntemler ile oluşturulan hem örutü tanıma hem de olasılıksal akıl yürütme özelliklerinin sunulmasıdır.

DevOps (Development and Operations)

DevOps, yazılım geliştirme (Dev) ve BT operasyonlarını (Ops) birleştiren bir dizi uygulamadır. Sistem geliştirme yaşam döngüsünü kısaltmayı ve yüksek yazılım kalitesi ile sürekli teslimat sağlamayı amaçlamaktadır (Loukides, 2012).

MLOps (Machine Learning Operations)

DevOps'un yazılım geliştirme topluluğu arasındaki popüleritesi, "MLOps" terimini doğurmuştur. DevOps, kısa ve hızlı sürümlere odaklanarak yazılım geliştirme süreçlerini optimize etmek için geliştiriciler ve operasyon ekiplerinin birleştirilmesini öneren bir yazılım geliştirme yaklaşımıdır. Önerilen bu yazılım geliştirme yaklaşımı, rutin görevlere yüksek düzeyde otomasyon uygulanarak elde edilir. MLOps da, aynı şekilde, otomatik veri yönetimi, model eğitimi/dağıtım ve izleme süreçlerinin optimizasyonu amacıyla geliştiriciler ve operasyon ekiplerinin birleştirilmesini öneren bir yaklaşım ve üretimde makine öğrenimi modellerini güvenilir ve verimli bir şekilde dağıtmayı ve sürdürmeyi amaçlayan bir dizi uygulamadır (Breuel, 2020).

API (Application Programming Interface)

API, uygulama yazılımı oluşturmak ve entegre etmek için bir dizi tanım ve protokoldür (Red Hat, 2024). Bazen bilgi sağlayıcı ile bilgi kullanıcısı arasındaki içerikleri (tüketiciden istenen içerik: çağrı; üretici tarafından istenen içerik: yanıt) belirleyen bir sözleşme olarak da anılır. Örnek olarak, bir hava durumu hizmeti için API tasarımı, kullanıcının bir posta kodu sağlamasını ve üreticinin, birincisi yüksek sıcaklık ve ikincisi düşük olmak üzere 2 parçalı bir yanıtla cevap vermesini gerektirmektedir.

REST (REpresentational State Transfer)

REST, bir protokol veya standart değil, bir dizi mimari kısıtlamadır ve temsili durum aktarımı anlamına gelmektedir. Her türlü ağ üzerindeki bilgisayar sistemleri arasında standartlar sağlamaya yönelik bir mimari stildir ve sistemlerin birbirleriyle iletişim kurmasını kolaylaştırmaktadır. API geliştiricileri, REST'i çeşitli şekillerde uygulayabilmektedir (Red Hat, 2024).

REST API

REST API (RESTful API olarak da bilinmektedir), REST mimari stiline kısıtlamalarına uyan ve RESTful web hizmetleriyle etkileşime izin veren bir uygulama programlama arayüzüdür (API veya web API) (Red Hat, 2024). Farklı sistemlerin sorunsuz bir şekilde iletişim kurmasını ve veri alışverişinde bulunmasını sağlayarak çok çeşitli hizmet ve işlevlerin entegre edilmesini kolaylaştırmaktadır (Kim, Stennett, Shah, Sinha, & Orso, 2024).

Yöntem

Bu çalışmada, hizmet olarak makine öğrenimi (MLaaS) platformlarının etkinliği ve kullanılabilirliği değerlendirilmektedir. Çalışmada, karşılaştırmalı analiz yaklaşımını benimsemektedir. Analiz için kullanılan veriler, ilgili MLaaS platform sağlayıcıları olan Amazon, Google, Microsoft ve IBM tarafından sunulan açık veri kaynaklarından alınmıştır.

MLaaS platform sağlayıcılarının sunduğu açık veri kaynaklarından elde edilen veriler tematik analiz yöntemi kullanılarak yorumlanmıştır. Bu amaçla, elde edilen veriler karşılaştırma amacıyla gruplanarak tablolandırılmıştır.

Karşılaştırma grupları bulut makine öğrenimi, konuşma ve metin işleme API'leri, görüntü analizi API'leri ve video Analiz API'leri özellikleri kullanılarak oluşturulmuştur.

Hizmet Olarak Makine Öğrenimi Platformları ve Özellikleri

Amazon Machine Learning, Azure Machine Learning, Google AI Platform ve IBM Watson Machine Learning hızlı model eğitimi ve dağıtımına olanak tanıyan dört lider bulut hizmet olarak makine öğrenimi hizmetidir. Bu platformların özellikleri ve platform üreticilerinin desteklediği makine öğrenimi API'lerini karşılaştırılması bu bölümde yapılacaktır.

Hizmet Olarak Makine Öğrenimi Platformları

İlgili platformların makine öğrenimi çerçevesindeki API'leri ve özellikleri aşağıdaki alt bölümlerde anlatılmaktadır.

Amazon Makine Öğrenimi (Amazon ML) ve SageMaker

Amazon, makine öğrenimine adanmış iki ana ürüne sahiptir. Bunlar Amazon Machine Learning ve SageMaker platformudur.

Amazon Makine Öğrenimi

Amazon Makine Öğrenimi, tahmine dayalı analitik odaklı otomatikleştirilmiş çözümlerden biridir ve zaman sınırı olan işlemler için en uygun çözümdür (Amazon AWS Machine Learning, 2024). Hizmet, Amazon RDS, Amazon Redshift, CSV dosyaları vb. dahil olmak üzere birden çok kaynaktan veri yükleyebilir. Tüm veri ön işleme işlemleri otomatik olarak gerçekleştirilmektedir.

Amazon ML'nin sadece üç tahmin yöntemi vardır. Bunlar ikili sınıflandırma, çok sınıflı sınıflandırma ve regresyon yöntemlerinden oluşmaktadır. Amazon ML hizmeti, denetimsiz öğrenme yöntemlerini desteklememektedir ve bundan dolayı kullanıcının eğitim setinde herhangi bir etiketleme yapmak için mutlaka bir hedef değişken seçmesi gerekmektedir. Ayrıca, Amazon sağlanan verilere baktıktan sonra bunları otomatik olarak seçtiğinden, kullanıcının herhangi bir makine öğrenimi yöntemini bilmesine gerek yoktur.

2021 yılı itibarıyla Amazon Makine Öğrenimi platformu güncellenmemektedir. Hizmet hala çalışmakta ancak yeni kullanıcı kabul edilmemektedir. Bunun nedeni, SageMaker ve ilgili tüm hizmetlerinin Amazon Makine Öğrenimi platformu ile aynı işlevselliği sağlamasıdır.

SageMaker

SageMaker, bir veri bilimcisinin işini basitleştirmesi amacıyla hızlı model oluşturma ve devreye alma amacıyla gerekli araçları sağlayan bir makine öğrenimi ortamıdır (Amazon SageMaker, 2024). Örneğin, sunucu yönetimi zorluğu olmadan veri keşfini ve analizini basitleştirmek amacıyla Jupyter Notebook desteği sunmaktadır.

2021'de Amazon, makine öğrenimi için ilk IDE olan SageMaker Studio'yu piyasaya sürmüştür. Bu araç, tüm makine öğrenimi model eğitim testlerini tek bir ortamda gerçekleştirebilmeyi sağlayan web tabanlı bir arayüz sağlamaktadır. Defterler, hata ayıklama araçları, veri modelleme ve otomatik oluşturma dahil tüm geliştirme yöntemleri ve araçları SageMaker Studio aracılığıyla kullanılabilir.

Amazon ayrıca, dağıtılmış sistemlerdeki büyük veri kümeleri ve hesaplamalar için optimize edilmiş yerleşik algoritmalara sahiptir. Bunlar şunları içerir (Amazon SageMaker, 2024):

- *Doğrusal öğrenen* (Linear Learner), sınıflandırma için denetimli bir yöntemdir.
- Faktoring makineleri, seyrek veri kümeleri için tasarlanmış sınıflandırma ve regresyon için kullanılmaktadır.
- *XGBoost*, daha basit algoritmaların tahminlerini birleştirerek sınıflandırma, regresyon ve sıralamada tahmin doğruluğunu artıran, denetimli, güçlendirilmiş bir ağaç algoritmasıdır.
- *Görüntü sınıflandırması*, transfer öğrenimi için de uygulanabilen ResNet'e dayanmaktadır.

- Seq2seq, dizileri tahmin etmek için denetimli bir algoritmadır (örneğin, cümleleri tercüme etmek, kelime dizilerini özet olarak daha kısa olanlara dönüştürmek, vb.).
- *K-means*, kümeleme için denetimsiz bir öğrenme yöntemidir.
- *Temel bileşen analiz*, boyutsallığı azaltmak için kullanılmaktadır.
- *Gizli Dirichlet tahsisi*, belgelerdeki kategorileri bulmak için kullanılan denetimsiz bir yöntemdir.
- *Nöral konu modeli* (NTM), belgeleri araştıran, en çok kullanılan kelimeleri ortaya çıkaran ve konuları tanımlayan (kullanıcılar konuları önceden tanımlayamaz, ancak konunun beklenen sayısını ayarlayabilirler) denetimsiz bir yöntemdir.
- *DeepAR tahmini*, tekrarlayan sinir ağlarını (RNN) kullanan zaman serilerini tahmin etmek için kullanılan denetimli bir öğrenme algoritmasıdır.
- *BlazingText*, Word2vec temelinde oluşturulmuş bir doğal dil işleme (NLP) algoritmasıdır ve büyük metin koleksiyonlarındaki sözcüklerin vektör temsilleriyle eşleşmesine olanak tanımaktadır.
- *Random Cut Forest*, her veri noktasına anormallik puanları atayabilen, denetimsiz bir anormallik algılama algoritmasıdır.
- *Sıralamayı Öğrenme* (LTR), Amazon Elasticsearch arama sonuçları sorgularının makine öğrenimi sıralama yöntemlerinde kullanımına izin veren bir eklentidir.
- *K-en yakın komşu* (k-NN), özel öneri hizmetleri oluşturmak için Nöral Konu Modeli ile birlikte kullanılabilen dizin tabanlı bir algoritmadır. Ayrıca, Amazon.com'un kendisi tarafından kullanılan gerçek zamanlı öneriler için ayrı bir Amazon Kişiselleştirme motoru vardır.

Yerleşik SageMaker yöntemleri, Amazon'un önerdiği ML API'leriyle büyük ölçüde keşişir, ancak burada veri bilimcilerin onlarla oynamasına ve kendi veri kümelerini kullanmasına olanak tanır.

Büyük veri kümeleri ve hesaplamalar için optimize edilmiş yerleşik algoritmaların kullanılması istenmiyorsa, dağıtım özelliklerinden yararlanarak SageMaker aracılığıyla her veri bilimci kendi yöntemlerini oluşturabilir ve bu yöntemleri kullanarak oluşturulacak modelleri çalıştırabilir. Aynı zamanda SageMaker'ı TensorFlow, Keras, Gluon, Torch, MXNet ve diğer makine öğrenimi kitaplıkları ile entegre edebilmek mümkündür.

Genel olarak, Amazon makine öğrenimi hizmetleri hem deneyimli veri bilimcileri hem de veri kümesi hazırlıkları ve modellemesi konusunda daha derine inmeden işlerin yapılmasına ihtiyaç duyanlar için yeterli olmaktadır.

Amazon, MLOps altyapısını oluşturmak ve yönetmek için ortak AWS hizmetlerini içeren bir şablon mimarisine birlikte kendi MLOps çerçevelerini yayınlamıştır. Kuruluşlar kendi MLOps çerçevelerini oluşturmak için bu çerçeveyi temel olarak kullanabilmektedirler.

Microsoft Azure AI platformu

Azure AI platformu, API'leri ve altyapı hizmetleriyle makine öğrenimi için birleşik bir platformu temsil etmektedir (Microsoft, 2024). Bu bölümde, makine öğrenimi çözümleri açısından Azure'un içerdiği hizmetler gözden geçirilecektir.

Azure Machine Learning

Azure Machine Learning, veri kümesi yönetimi, model eğitimi ve dağıtım için ana ortamdır. Platform, makine öğrenimi işlemlerini ve işlem hatlarını hızlı bir şekilde yapılandırmak için kod geliştirme ihtiyacı en alt seviyede olan Azure Machine Learning Studio (ML Studio) adlı web tabanlı bir makine öğrenimi ortamı sağlamaktadır.

ML Studio genel olarak, veri keşfi, ön işleme, yöntem seçme ve modelleme sonuçlarını doğrulama araçlarına sahiptir. Makine öğrenmesi alanında sınıflandırma, anormallik algılama, regresyon, öneri ve metin analizini ele alan yaklaşık 100 farklı yöntemi desteklemektedir. Platform aynı zamanda bir kümeleme algoritmasına (K-means) da sahiptir. Bu yetenekler, Azure ML'nin inovasyon ve verimliliği artırırken belirli iş ihtiyaçlarını karşılayan özel yapay zekâ çözümleri sunarak sektörleri dönüştürme potansiyelini de vurgulamaktadır (Borra, Advancing Data Science and AI with Azure Machine Learning: A Comprehensive Review, 2024).

Amazon'da olduğu gibi Azure platformu da Jupyter ile entegrasyon imkanına sahiptir ve bu sayede geliştirilen kodlar ML Studio ortamına taşınmadan önce Jupyter ortamında çalıştırılıp denenebilir. Ayrıca, çeşitli işletim

sistemlerinde, donanım platformlarında ve çerçevelerde makine öğrenimi modellerini çalıştırabilmek için ONNX Runtime ortamını da sağlar. ONNX Runtime, farklı ML çerçeveleri arasında birlikte çalışabilirliği sağlamak amacıyla TensorFlow, PyTorch, scikit-learn ve benzeri çerçeveleri de desteklemektedir.

ML Studio'daki özelliklerden bazıları şunlardır (Microsoft, 2024):

- *Azure Machine Learning tasarımcısı*, platformun özelliklerine erişim ve denetimler sağlayan ML stüdyosu için bir grafik sürükle ve bırak kullanıcı arabirimidir. Bu arabirim kullanılarak veriler üzerinde değişiklik yapılabilir, makine öğrenimi yöntemleri uygulanabilir ve elde edilen sonuçların ilgili sunuculara yüklenmesi (dağıtım) yönetilmektedir.
- *Veri Hazırlama* amacıyla Apache Spark kümeleri üzerinde veri hazırlama işlemlerini hızlı bir şekilde yineleyebilmekte ve Microsoft Fabric ile uyumlu çalışabilmektedir.
- *Automated ML*, kodsuz ve düşük kodlu model eğitimi sağlayan bir SDK'dır. Automated ML, ML stüdyosunu rutin görevler için yüksek derecede otomasyon ve veri keşfi, model özelleştirme ve dağıtım desteği ile tamamlamaktadır. Azure, otomatikleştirilmiş makine öğrenimi araçlarını kullanarak eğitim için uygun olan sınıflandırma, regresyon ve zaman serisi tahmin görevlerini yerine getirmektedir.
- *Azure ML Python ve R dili SDK'ları*, ML Studio ile tam olarak tümleştirilmiştir.
- PyTorch, TensorFlow ve scikit-learn gibi *makine öğrenimi çerçeveleri* için destek sağlamaktadır. Ayrıca, ONNX Runtime kullanan çerçeveler arasında birlikte çalışabilirlik imkânı vardır.
- *Modüler işlem hatları* yerleşiktir ve bu sayede makine öğrenimi projesi için özel bir veri işlem hattı oluşturulmaktadır.
- Veri ve ekip yönetimi, etiketleme ilerlemesi, eksik etiketleme takibi ve etiketli veri araçlarını dışa aktarma dahil olmak üzere *veri etiketleme projeleri için destek* sağlanmaktadır.
- *Özelleştirilebilir işlem bedelleri*, model dağıtım için, Azure Kubernetes hizmetleri, Container örnekleri ve işlem kümeleri gibi çeşitli bulut hizmetlerini desteklemektedir.
- *Özellik Mağazası* ile, geliştirilmiş olan modellerin daha hızlı bir şekilde dağıtılabilmesi için özelliklerin keşfedilebilir ve yeniden kullanılabilir olmasını sağlamaktadır.
- *MLOps* araçları ile otomatikleştirilmiş işlem hatları içindeki modellerin yönetimini, dağıtımını ve izlenmesini sağlamaktadır.
- *Yapay Zekâ Altyapısı*, en güncel GPU'lar ve InfiniBand ağları ile tasarlanmış özel AI altyapısından yararlanmaktadır.
- *Otomatik Makine Öğrenimi (AutoML)* ile sınıflandırma, regresyon, görüntü işleme ve doğal dil işleme gibi görevler için hızlı ve doğru makine öğrenimi modelleri oluşturur.
- *Model Kataloğu* ile Microsoft, OpenAI, Hugging Face, Meta, Cohere gib hizmet sunucuların temel modellerini keşfetme, ince ayar yapma ve dağıtma imkânı sağlamaktadır.
- *Yerleşik Güvenlik ve Uyumluluk* özelliği ile güvenlik ve uyumluluk özellikleri ile veri ve AI yönetimini birleştirmektedir.

Hem ML Designer hem de Automated ML, deneyimsiz kullanıcıların makine öğrenimi çözümleri oluşturması için araçlar sağlamaktadır. Buna karşılık ML Studio, teknoloji konusunda bilgili veri bilimcileri ve kurumsal düzeydeki çözümler tarafından kullanılacak bir dizi özellik de içermektedir.

Makine öğrenimi amacıyla Azure ortamını kullanmak için tüm ana tekniklerin daha önceden öğrenilmiş olması gerekmektedir. Azure ML grafik arabirimi, iş akışındaki her adımı görselleştirmekte ve yeni adımların eklenebilmesini desteklemektedir. Azure ML ortamını kullanmanın en öne çıkan kazanımlarından birisi ise, üzerinde oynanabilecek ve test edilebilecek birçok algoritmanın bu ortamda hazır olarak sunulmasıdır.

Azure AI Galerisi

Azure ML'nin bir başka önemli bölümü de Azure AI Gallery'dir. Veri bilimcileri tarafından araştırma ve yeniden kullanabilme amacıyla ilgili topluluk tarafından sağlanan bir makine öğrenimi çözümleri koleksiyonudur.

Azure AI Gallery, geliştiricilerin ve veri bilimcilerin araştırma ve yeniden kullanabilme amacıyla ilgili analiz ve çözümlerini paylaşmalarını ve keşfetmelerini sağlayan topluluk odaklı bir çözüm koleksiyonu platformudur. En temel işlevleri (Microsoft, 2024):

- *Çözümleri Paylaşma ve Keşfetme*: Kullanıcılar, ML Studio'da geliştirilmiş çeşitli çözüm veya deneylerinin Jupyter Notebooks dosyalarını, çözüm şablonlarını ve referans mimarilerini paylaşabilmektedirler.
- *Eğitim ve Öğrenme*: Galeride bulunan makine öğrenimi teknolojileri ve kavramları hakkında eğitim materyalleri ve ileri düzey yöntemleri açıklayan öğreticiler barındırmaktadır.
- *Projeler ve Modeller*: Veri bilimi topluluğunun deneyimli üyeleri tarafından geliştirilmiş olan projeler ve makine öğrenim modelleri incelenebilmekte ve gerektiğinde kullanılabilir.
- *Özelleştirilebilir Modeller*: Galeride bulunan önceden oluşturulmuş makine öğrenimi modelleri ve şablonları, kullanılacak verilere ve ihtiyaçlara göre özelleştirilebilmektedir.

Bu özellikler, Azure AI Gallery'yi makine öğrenimi çözümleri geliştirmek ve paylaşmak için güçlü bir kaynak haline getirmektedir.

Google AI Platformu

Google AI Platform (Birleşik), daha önce ayrı olarak var olan makine öğrenimi araçlarını birleştirmiştir. Platform, AI Platform Unified başlığı altındaki AI Platform (Vertex), AutoML, çerçeveler ve API'lerden oluşur (Google Cloud Machine Learning, 2024).

AI Platformu (Vertex)

AI Platform (Vertex), makine öğrenimi uzmanları ve veri bilimcileri için bir dizi özellik içeren bir araçtır. AI Platform Classic, özel modeller oluşturmak için aşağıdaki hizmetleri sunmaktadır (Vlisthttps, Helmondhttps, & Ferrarhttps, 2024):

- *Eğitim Hizmeti*, yerleşik algoritmaları veya veri bilimcilerin kendi algoritmalarını kullanarak modeller oluşturabilmesi için bir ortamı sağlamaktadır. Kullanıcılar, eğitim uygulamasını yüklemek için kendi eğitim yöntemlerini ilgili ortama yükleyebilir veya istedikleri şekilde özelleştirebilecekleri bir ortam oluşturulabilmektedir.
- *Tahmine Dayalı Hizmet*, oluşturulan tahminleri iş uygulamalarına veya başka herhangi bir hizmete entegre etmeye olanak tanımaktadır.
- *Veri Etiketleme Hizmeti*, verilerin etiketlenmesi için insan(lar)dan oluşan bir ekibin oluşturulması ve çalışmasını destekleyen bir araçtır. Hizmet, veri bilimcilerin yönlendirmesi ile işlenecek video, metin ve resimler için etiketlemeyi desteklemektedir.
- *Deep Learning Image*, derin öğrenme amacıyla bir sanal makine görüntüsü sağlar. Görüntü, popüler çerçeveler ve önceden yüklenmiş araçlarla makine öğrenimi ve veri bilimi görevleri için önceden yapılandırılmış olarak gelmektedir.
- *AI Platform Notebooks*, bir kullanıcının sanal makine örnekleri oluşturabileceği veya yönetebileceği ve veri işleme belleği türlerini (CPU veya GPU) yapılandırabileceği bir ortamdır. Ayrıca TensorFlow ve PyTorch kütüphaneleri, derin öğrenme paketleri ve Jupyter not defteri ile önceden entegre edilmiş olarak gelmektedir.

Modellerin, işlerin ve uç noktaların yönetimi, özel bir REST API, gcloud komut satırı veya Google Cloud Console aracılığıyla yapılmaktadır. AI Platform Classic, deneyimli kullanıcılar için tasarlanmıştır.

Google Cloud AutoML

Google Cloud AutoML, veriye dayalı çözümler oluşturmaya kodsuz bir yaklaşım öneren bulut tabanlı bir makine öğrenimi platformudur. AutoML, hem yeni başlayanlar hem de deneyimli makine öğrenimi mühendisleri için özel modeller oluşturmak üzere tasarlanmıştır. Ancak platform, bir dizi API aracılığıyla kullanılabilen önceden oluşturulmuş bir dizi model de önermektedir. Önerilen modeller görüntü, video, metin ve tablo verilerini

desteklemektedir ve kullanıcıların birleşik bir API, istemci kütüphanesi ve web arayüzü aracılığıyla modelleri eğitmelerine ve dağıtmalarına olanak tanımaktadır (Oliveira, Topsakal, & Toker, 2024).

Google platformunun ana fikri, AI yapı taşları aracılığıyla açıklanmaktadır. Bunlar, ML çözümleri oluşturmak için birlikte kullanılması amaçlanan AutoML, TensorFlow ve API'ler gibi temelde farklı araçlardır. Bu platform ile, hem özel olarak geliştirilmiş bir modelin, hem de önceden eğitilmiş modellerin tek bir üründe birleştirilebileceği anlamına gelmektedir.

Ayrıca, geliştirilen makine öğrenimi çözümleri web sitene veya GPU veya CPU üzerinde farklı veri işleme yöntemleri içeren özel bir AI Altyapısına dağıtılabılır. AutoML tüm Google hizmetleriyle tamamen entegre olarak çalışmaktadır ve verileri bulutta depolamaktadır. Eğitilen modeller, REST API arabirimi aracılığıyla dağıtılabilmektedir.

Dolayısıyla, bir platformu bir bütün olarak düşünülürse, farklı kullanıcılar tarafından kullanılması amaçlanan iki tür çözüm vardır. AI Platform (Klasik), özel modeller oluşturmak ve algoritmaları ve eğitim süreçlerini manuel olarak yönetmek için birçok seçenek sunmaktadır ve daha çok deneyimli makine öğrenimi geliştiricileri için uygundur. Buna karşılık, AutoML ihtiyaç olduğunda modeller oluşturmak, verileri uygulamak ve tahminleri entegre etmek için kod geliştirmeyi gerektirmeyen bir yol sağlamaktadır (Google Cloud Machine Learning, 2024).

TensorFlow Çerçevesi

TensorFlow, çeşitli veri bilimi araçlarından oluşan ve hizmet olarak makine öğrenimi yerine kullanılacak açık kaynak kodlu bir makine öğrenimi kitaplığıdır. Görsel bir arayüzü yoktur ve TensorFlow için öğrenme eğrisi oldukça zordur. TensorFlow, çoğunlukla derin sinir ağı görevleri için kullanılmaktadır (Google Cloud Machine Learning, 2024). Temel olarak, TensorFlow ve Google Cloud hizmetinin birleşimi, üç katmanlı bulut hizmetleri modeline göre hizmet olarak altyapı ve hizmet olarak platform çözümleri önermektedir (Borra, The Evolution and Impact of Google Cloud Platform in Machine Learning and AI, 2024).

Google AI MLOps

Google AI MLOps araçları, yapay zekâ ekipleri arasındaki işbirliği ve tahmine dayalı model izleme, uyarı, tanımlama ve eyleme dönüştürülebilir açıklamalar aracılığıyla modellerin iyileştirilmesine yardımcı olmaktadır. Google'ın MLOps çözümü, makine öğrenimi ardışık düzenleri oluşturmak ve yönetmek için AWS'ye benzer özellikler sunmaktadır (Moutaouakal & Baïna, 2023).

IBM Watson Machine Learning Studio

IBM Machine Learning platformu, teknik olarak otomatik ve manuel (uzman kullanıcılar için) olmak üzere kullanıcılara iki farklı yaklaşım sunmaktadır (IBM Watson Machine Learning, 2024).

Watson Studio ve AutoAI

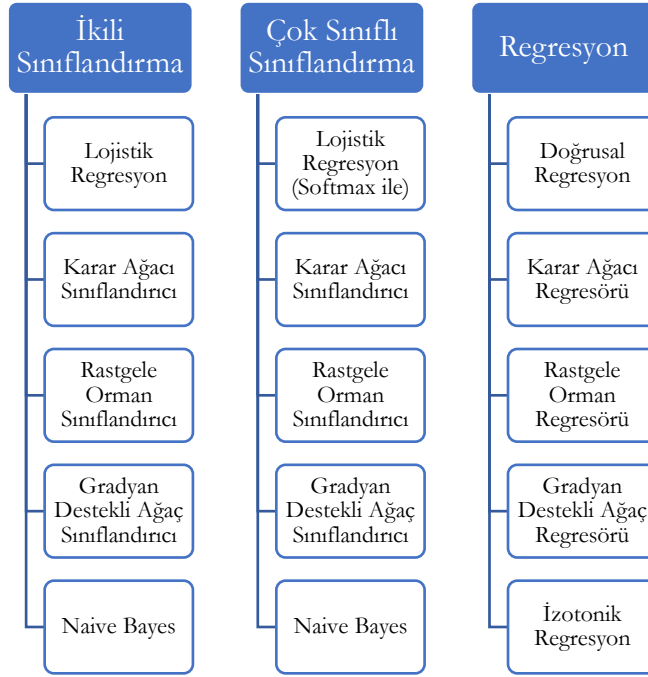
Watson Studio, verileri işlemek, modeller hazırlamak ve hazırlanan modelleri üretimde devreye almak için çok az eğitim gerektiren veya hiç eğitim gerektirmeyen tam otomatik bir veri işleme ve model oluşturma arabirimi sağlayan bir AutoAI'ye sahiptir (IBM Watson Machine Learning, 2024). Watson Studio'daki AutoAI grafik aracı ise verileri analiz ederek tahmine dayalı modelleme problemi için en iyi sonucu veren veri dönüşümlerini, algoritmaları ve parametre ayarlarını keşfetmektedir (Nirmala, ve diğerleri, 2022).

Watson Studio'nun otomatikleştirilmiş bölümü, üç ana görev türünü çözmek üzere tasarlanmıştır: ikili sınıflandırma, çok sınıflı sınıflandırma ve regresyon. Kullanılacak makine öğrenimi yöntemi ya tam otomatik ya da manuel olarak seçilebilmektedir. IBM Watson Machine Learning Studio, bu üç görev grubunu da kapsayabilmek için aşağıdaki on yönteme sahiptir (IBM Watson Machine Learning, 2024):

- Lojistik regresyon
- Karar ağacı sınıflandırıcı
- Rastgele orman sınıflandırıcı

- Gradyan destekli ağaç sınıflandırıcı
- Naive Bayes
- Doğrusal regresyon
- Karar ağacı regresörü
- Rastgele orman regresörü
- Gradyan destekli ağaç regresörü
- İzotonik regresyon

Bu yöntemlerin ilgili görev türleri ile ilişkileri ise Şekil 1’de verilmiştir.



Şekil 1. IBM Watson ML Studio ile Sunulan Yöntemlerin Görev Grupları

Not: Şekil yazar tarafından oluşturulmuştur.

AutoAI'nin yanı sıra, model oluşturmak için kullanılabilir SPSS modelleyici ve sinir ağı temelli iki hizmet daha bulunmaktadır.

IBM SPSS Modeller

IBM SPSS Modeller, verileri istatistiksel iş bilgilerine dönüştürmek için kullanılan bir yazılım paketidir. 2009'da IBM tarafından satın alınan ve bağımsız bir makine öğrenimi hizmeti olarak entegre edilen bu ürün, veri bilimcilerin kullanımı için hazırlanan, görsel bir veri bilimi ve makine öğrenimi çözümüdür. Makine öğrenimi projelerinde veri hazırlama ve keşif, tahmine dayalı analitik, model yönetimi, model dağıtımı ve varlıkların her türlü analizi için kullanılmaktadır (SPSS, 2024).

Veri madenciliği sürecinde kullanılan IBM SPSS Modeller araçları, kullanıcıların programlama yapmadan istatistiksel ve veri madenciliği algoritmalarından yararlanmalarını sağlama (Insani, Nasrullah, Azizah, & Raygrandi, 2023) ve verisetlerinin niteliklerini anlamlandırmak ve istatistiksel olarak tanımlama amacıyla kullanılmakta (Abuhaija, ve diğerleri, 2023) ve makine öğrenimi alanında kullanılan sınıflandırma yöntemlerini de içermektedir (Wendler & Gröttrup, Classification Models, 2021). İstatistiksel modeller oluşturmak için çok çeşitli algoritmalar, prosedürler ve seçenekler sunmasının yanı sıra, kullanıcılara analizlerinde R işlevlerini kullanma seçeneği de sağlamakta (Wendler & Gröttrup, Using R with the Modeller, 2021) ve zaman serisi verileriyle gerçek zamanlı endüstriyel tahmin analizinde de kullanılabilir (Nykyri, Kuisma, Hallikas, Immonen, & Silventoinen, 2020).

Sinir Ağı ve Derin Öğrenme

Yapay zekâ, makine öğrenimi, derin öğrenme ve sinir ağları, her biri bir sonrakini kapsayan bir dizi yapay zekâ sistemi olarak düşünülmelidir. Makine öğrenimi yapay zekanın bir alt kümesidir. Derin öğrenme, makine öğrenmesinin bir alt alanıdır ve sinir ağları derin öğrenme algoritmalarının bel kemiğini oluşturmaktadır. Sinir ağını derin öğrenme algoritmasından ayıran şey, sinir ağlarının düğüm katmanlarının sayısı veya derinliğidir (IBM Deep Learning - Articles, 2024).

IBM, insan beyninin çalışma prensibini taklit eden ve büyük miktarda veriyi işleme hızını önemli ölçüde azaltabilen yeni bir derin öğrenme teknolojisi geliştirmiştir (Chang, Tsai, & Lin, 2023). Derin öğrenme büyük sinir ağı modelleri tarafından yönlendirilmektedir. Geleneksel makine öğrenimi yöntemleri ile konuşma, metin ve görüntü gibi yapılandırılmamış ve algısal veri alanlarını ifade edebilmek ve işleyebilmek mümkün değildir. Aynı zamanda, bulut üzerinde kullanıma sunulan “hizmet olarak” tabanlı iş modelleri, bilgi teknolojisi endüstrisini temelden dönüştürmektedir. Sinir ağı, derin öğrenme ve “hizmet olarak” tabanlı iş modeli, IBM tarafından tek bir çatı altında "bulutta hizmet olarak derin öğrenme (DLaaS)" hizmeti olarak sunulmaktadır. DLaaS, geliştiricilere Caffe, Torch ve TensorFlow gibi popüler derin öğrenme kütüphanelerini bulutta ölçeklenebilir ve esnek bir şekilde minimum çabayla kullanma esnekliği sağlamaktadır (Bhattacharjee, ve diğerleri, 2017).

Sinir ağı ve derin öğrenme hizmeti, SPSS Modeler'dan biraz farklıdır. Özel bir GUI aracılığıyla sinir ağlarını modellemek için kullanılan bir araçtır. Hizmet, Watson Studio'ya entegre edilmiştir ve yerleşik veri entegrasyon aracıyla veri yönetimine olanak tanımaktadır. Hizmetin ana odak noktası, derin öğrenme yetenekleri ve büyük veriler üzerinde eğitimidir. Ek olarak, sinir ağı hizmetleri Keras, PyTorch veya TensorFlow gibi bir dizi ML çerçevesi ile entegre edilmiştir. Ayrıca IBM Watson Machine Learning Studio, Azure ML Studio'da kullanılan benzer akış düzenleyici bir arabirim kullanarak derin sinir ağı eğitimi iş akışı da sunmaktadır. Bunun yanı sıra, TensorFlow, scikit-learn, PyTorch ve diğerleri gibi popüler çerçeveleri kullanarak modelleri manuel olarak programlamak için Jupyter Notebook ile entegre edilmiştir (IBM - Deep Learning, 2024).

Hizmet Olarak Makine Öğrenimi Platformlarının Genel Özellikleri

Hizmet Olarak Makine Öğrenimi, bulut bilgi işlem hizmetlerinin bir parçasıdır. Makine öğrenimi bulut hizmeti sağlayıcıları birçok gelişmiş araç ile birlikte kullanıcılarının oluşturdukları çözümleri bulutta dağıtma ve önceden hazırlanmış veri kümelerine (insan yüzlerinden oluşan bir veritabanı gibi) dayalı modeller oluşturma yeteneği sunmaktadır.

Google, Microsoft, Amazon ve IBM; makine öğrenimi araçları sunan en tanınmış bulut hizmeti sağlayıcılarıdır. Hepsi, müşterilerin ücretli bir hizmete geçmeden önce seçilen platformun yeteneklerini değerlendirebilmesi için deneme amaçlı makine öğrenimi çözümleri sunmaktadır.

Tüm bu platformlar, müşterilerinin sıfırdan yazılım geliştirmek ve kendi fiziksel sunucularını kurmak zorunda kalmadan, bulutta makine öğrenimine hızlı bir şekilde başlayabilmelerini amaçlamaktadır. Hizmet Olarak Makine Öğrenimi hizmeti sağlayıcılarının tamamı, müşterilerinin sadece kullandıkları hizmetler ve bulutta veri depolama için kullandıkları depolama alanlarının boyutları ile orantılı ücretlendirme yapmaktadırlar. Bu hizmetlerle oluşturulan tüm çözümler, REST API aracılığıyla mevcut BT altyapısıyla entegre edilebilmektedirler.

Tablo 1’de, bulut makine öğrenimi hizmet sağlayıcılarının sunduğu özelliklerin karşılaştırması sunulmaktadır.

Tablo 1. Bulut Makine Öğrenimi Hizmetleri Karşılaştırması

	Amazon ML ve SageMaker	Microsoft Azure AI Platform	Google AI Platform	IBM Watson ML
Sınıflandırma	✓	✓	✓	✓
Regresyon	✓	✓	✓	✓
Kümeleme	✓	✓	✓	×
Anomali tespiti	✓	✓	×	×
Öneri	✓	✓	✓	×

Sıralama	✓	✓	×	×
Veri Etiketleme	✓	✓	✓	✓
MLOps ardışık düzen desteği	✓	✓	✓	✓
Yerleşik algoritmalar	✓	✓	✓	×
Desteklenen Çerçeveler	TensorFlow, MXNet, Keras, Gluon, Pytorch, Caffe2, Chainer, Torch	TensorFlow, scikit-learn, PyTorch, Microsoft Cognitive Toolkit, Spark ML	TensorFlow, scikit-learn, XGBoost, Keras	TensorFlow, Keras, Spark MLlib, scikit-learn, XGBoost, PyTorch, IBM SPSS, PMML

Not: Tablodaki veriler ilgili platform sağlayıcılardan elde edilerek yazar tarafından oluşturulmuştur.

Amazon, Microsoft, Google ve IBM Makine Öğrenimi API'lerinin Karşılaştırması

Tam gelişmiş Hizmet Olarak Makine Öğrenimi platformlarının yanı sıra, makine öğrenimi hizmet sağlayıcılarının kullanıcılarına sundukları üst düzey API'ler de müşteriler tarafından bağımsız olarak kullanılabilir. API'ler, verilerin beslenebileceği ve sonuçların alınabileceği önceden eğitilmiş olan modellere sahip hizmetlerdir ve makine öğrenimi uzmanlığı gerektirmemektedir. Amazon, Microsoft, Google ve IBM makine öğrenimi API'leri genel olarak üç gruba ayrılabilir. Bunlar:

1. Metin tanıma, çeviri ve metin analizi (Tablo 2)
2. Görüntü (Tablo 3) ve video (Tablo 4) tanıma ve ilgili analizler
3. Belirli bir başlık altında kategorize edilmemiş hizmetler (Tablo 1)

Üçüncü grup olan hizmetler ile ilgili karşılaştırmalar Tablo 1'de, diğer ilk iki gruba ait API'lerin hizmetleri sunan şirketler bazında karşılaştırması ise aşağıdaki Tablo 2, Tablo 3 ve Tablo 4'te sunulduğu gibidir:

	Amazon	Microsoft	Google	IBM
Konuşma Tanıma (Metne Konuşma)	✓	✓	✓	✓
Metni Konuşmaya Dönüştürme	✓	✓	✓	✓
Varlık Çıkarma	✓	✓	✓	✓
Anahtar İfade Çıkarma	✓	✓	✓	✓
Dil Tanıma	100+ dil	120 dil	120+ dil	60+ dil
Konu Çıkarma	✓	✓	✓	✓
Yazım Denetimi	×	✓	×	×
Otomatik Tamamlama	×	✓	×	×
Ses Doğrulama	✓	✓	×	×
Niyet Analizi	✓	✓	✓	✓
Meta Veri Çıkarma	×	×	×	✓
İlişkiler Analizi	×	✓	×	✓
Duygu Analizi	✓	✓	✓	✓
Kişilik Analizi	×	×	×	✓
Sözdizimi Analizi	×	✓	✓	✓
Konuşmanın Bölümlerini Etiketleme	×	✓	✓	×
Uygunsuz İçeriği Filtreleme	×	✓	✓	×
Düşük Kaliteli Ses İşleme	✓	✓	✓	✓
Tercüme	6 dil	60+ dil	100+ dil	48 dil
Chatbot Araç Seti	✓	✓	✓	✓

Not: Tablodaki veriler ilgili platform sağlayıcılardan elde edilerek yazar tarafından oluşturulmuştur.

Tablo 3- Görüntü analizi API'leri karşılaştırması

	Amazon	Microsoft	Google	IBM
Nesne Algılama	✓	✓	✓	✓
Sahne Tespiti	✓	✓	✓	×
Yüz Bulma	✓	✓	✓	✓
Yüz Tanıma	✓	✓	×	×
Yüz Analizi	✓	✓	✓	✓
Uygunsuz İçerik Tespiti	✓	✓	✓	✓
Ünlü Tanıma	✓	✓	✓	×
Metin Tanıma	✓	✓	✓	✓
Yazılı Metin Tanıma	✓	✓	✓	×
Web'de Benzer Görseller Arama	×	×	✓	×
Logo Tespiti	×	×	✓	×
Önemli Nokta Tespiti	×	✓	✓	×
Gıda Tanıma	✓	✓	×	✓
Baskın Renk Tespiti	×	✓	✓	×

Not: Tablodaki veriler ilgili platform sağlayıcılardan elde edilerek yazar tarafından oluşturulmuştur.

Tablo 4- Video analiz API'leri karşılaştırması

	Amazon	Microsoft	Google	IBM
Nesne Algılama	✓	✓	✓	×
Sahne Tespiti	✓	✓	✓	×
Etkinlik Tespiti	✓	×	×	×
Yüz tanıma	✓	✓	×	×
Yüz ve Duygu Analizi	✓	✓	×	×
Uygunsuz İçerik Tespiti	✓	✓	✓	×
Ünlü Tanıma	✓	✓	×	×
Metin Tanıma	✓	✓	×	×
Videolarda Kişi Takibi	✓	✓	×	×
Ses Transkripsiyonu	×	✓	✓	×
Konuşmacı İndeksleme	×	✓	×	×
Anahtar Kare Çıkarma	×	✓	×	×
Video Çeviri	×	9 dil	×	×
Anahtar Kelime Çıkarma	×	✓	×	×
Marka tanıma	×	✓	×	×
Dipnot	×	✓	×	×
Baskın Renk Tespiti	×	×	×	×
Gerçek Zamanlı Analiz	✓	×	×	×

Not: Tablodaki veriler ilgili platform sağlayıcılardan elde edilerek yazar tarafından oluşturulmuştur.

Sonuç

Hizmet olarak makine öğrenimi (MLaaS) platformları algoritmalar, gerekli beceriler ve görevlerde farklılık göstermektedirler. Gözden geçirilen önde gelen dört çözüm (Amazon Machine Learning, Azure Machine Learning,

Google AI Platform ve IBM Watson Machine Learning) bile birbiriyle tam olarak rekabet edememektedir. Hizmet olarak makine öğrenimi pazarı daha yeni oluşmakta ve değişimin hızı çok etkileyicidir. Seçilen hizmet sunucunun ürünü ve özelliklerine mutlak olarak bağımlı kalınacaktır. İlgili seçimin çok geçerli nedenleri olsa da aniden başka bir hizmet sunucusunun beklenmedik bir şekilde gerekli gördüğünüz iş ihtiyaçlarını karşılayan yeni bir ürün ya da özellik ortaya çıkarma olasılığı her zaman yüksek olacaktır.

Doğru hareket, makine öğrenimiyle neyi başarmayı planladığınızı mümkün olduğunca erken ifade etmektir. Veri bilimi veya alan uzmanlığından herhangi biri eksik olduğunda, veri bilimi ile iş değeri arasında bir köprü oluşturmak zor olacaktır. Genellikle problemi doğru tanımlamak, ilgili ürünü seçmede büyük kolaylık sağlamaktadır.

Hizmet olarak makine öğrenimi, bir iş modeli olarak düşünüldüğünde, açık kaynak kodlu ürünleri kullanmak isteyen veri bilimciler ile problemleri çözmek için hazır araçlar satın almaya alışmış üst düzey yöneticilerin oluşturduğu alt ve üst sınırdaki yönetim modellerinin tam da ortasında yer almakta olduğu görülmektedir. Bununla birlikte, hizmet olarak makine öğrenimi sektörü henüz gelişme aşamasında olduğu ve ulaştığı organizasyon sayısı da sınırlı olduğu için, talepten çok daha az olan ve dolayısıyla çok pahalıya gelen veri bilimciler gibi yeteneklerden mümkün olduğunca kaçınmak amacıyla çok yönlü veri araçlarına yönelen çok fazla şirket olacaktır. Bu çok yönlü veri araçları ise MLaaS platformları olacaktır.

Uzman veri bilimcileri ve veri bilimi rollerinde çalışan diğer profesyoneller, verileri bulmak ve düzenlemek, modeller oluşturmak ve makine öğrenimi içgörülerini işler hale getirmek için birtakım yeteneklere ihtiyaç duymaktadır. Veri bilimi ve makine öğrenimi platformları, veri bilimi ve makine öğrenimi çözümleri (öncelikle tahmine dayalı ve kuralcı modeller) oluşturmak için gerekli olan temel ve gelişmiş işlevlerin bir karışımını sunmaktadır. Platformlar ayrıca bu çözümlerin iş süreçlerine, çevreleyen altyapıya, ürünlere ve uygulamalara dahil edilmesini de desteklemektedir. Bu platformlar, aşağıdaki alanların tümünde, veri ve analitik işlem hattındaki değişik bilgi ve becerilere sahip veri bilimcilerin ihtiyaçlarını desteklemektedir:

- Veri oluşturma
- Veri hazırlama
- Veri keşfi
- Özellik mühendisliği
- Model oluşturma ve eğitimi
- Model testi
- Dağıtım
- İzleme
- Bakım onarım
- İşbirliği

Tüm kuruluşlar, veri bilimi ve makine öğrenimi modellerini sıfırdan veya tamamen kendi başlarına oluşturamamaktadır. Çoğunun veri bilimi ve makine öğrenimi girişimlerini başlatmak veya genişletmek için yardıma ihtiyaçları vardır.

Son zamanlarda teknoloji, süreç ve yetenek geliştirmede çok sayıda gelişme olmuştur. Bununla birlikte, dağıtım ve kullanım niyetiyle geliştirilen modellerin endişe verici bir yüzdesi, hiçbir zaman fiilen çalıştırılmamaktadır. Bunun pek çok nedeni vardır, ancak en önemlisi, operasyonelleştirmeyi mümkün kılacak ve kolaylaştıracak araçların eksikliğidir. Operasyonelleştirme (genellikle MLOps olarak anılır), iş ve hedefleri değiştikçe zaman içinde uygunluklarını sağlamak için modellerin sürekli gözden geçirilmesine ve ayarlanmasına kadar birçok süreci içermektedir. MLOps ayrıca sapma algılama, kataloglar, yönetim, açıklanabilirlik ve iş etki analizi gibi temel işlevleri içermektedir.

Veri bilimi ve makine öğrenimi, yapay zekâ (AI) olarak sınıflandırılabilir, ancak tüm yapay zekâ kavramları veri bilimi ve makine öğrenimi olarak adlandırılmamalıdır. Yine de veri bilimi ve makine öğrenimi platformları, yapay zekâ etrafındaki sürekli ve bilinçli bir şekilde yapılan anlam saptırma içinde kaybolmaktan kaçınmamaktadır. Yapay zekâ üzerinden yapılan anlam saptırma ve algı yaratma, veri bilimi alanına doğru yönelen çok değerli bir ilgi ve coşku yaratmaktadır. Ancak eğitim, disiplin ve makul beklentiler olmadan, bu anlam saptırma ve algı yaratma süreci, yarardan çok zarar verebilmektedir.

Veri bilimi ve makine öğrenimi yetenekleri kuruluşlar arasında giderek daha fazla benimsendiğinden, aşırı parçalanmayı ve ortak standartların eksikliği için bölümler arası çalışma çok önemlidir. Aksi takdirde, bireysel departmanlar farklı platformlar ve süreçler benimseyebilir. Böyle bir durumla karşılaşıldığında ise işletim ve bakımla ilgili geri dönüşü olmayan ciddi sorunlarla karşılaşma olasılığı çok yüksektir.

Kuruluşlar, olgunlaşmış ve gelişmiş analitik yetenekler elde etmek için uçtan uca veri bilimi yaşam döngüsünü planlamalı ve buna yatırım yapmalıdır. Yaşam döngüsü, verilere erişme ve bunları dönüştürme, analiz yürütme ve analitik modeller oluşturma, modelleri operasyonelleştirme ve yerleştirme, alaka düzeylerini yeniden değerlendirmek için zaman içinde modelleri yönetip izleme ile birlikte veri ve iş ortamındaki değişiklikleri yansıtmak için modelleri ayarlama süreçlerini içermektedir.

Kuruluşların, veri bilimi ve makine öğrenimi alanındaki yolculuklarına başlarken veya devam ederken, içlerine kapanıp kendi kendilerine yetinmeye çalışmalarına gerek yoktur. Veri ve analitik hizmet sağlayıcıları rehberlik, yapılandırılmış bir yaklaşım ve azaltılmış arıza riski sunmaktadırlar.

Birçok kuruluş, bilgilerini geliştirmek ve olasılıkları keşfetmek için ücretsiz veya düşük maliyetli açık kaynak ve genel bulut hizmeti sağlayıcı tekliflerini kullanarak veri bilimi ve makine öğrenimi çalışmalarını başlatmakta veya devam ettirmektedir. Bu kuruluşların ilerleyen zamanlarda, daha geniş kullanım durumları ve ekip işbirliği için gereksinimlerin üstesinden gelmek ve modellerin dağıtımını ve yönetimini operasyonel hale getirmek için ticari yazılımları benimsemeleri olasılığı artmaktadır. Tamamen açık kaynaklı bir yığınla kurumsal veri bilimi başarısı mümkün olsa da olgun ve etkili veri bilimi ekiplerinin büyük çoğunluğunun ticari bir platforma yatırım yaptıkları gözlemlenmektedir.

Bulut hizmetlerinin altında Hizmet Olarak Makine Öğrenimi servislerinin hizmet sağlayıcılarının yanı sıra, açık kaynak ekosistemi ve topluluğu her zaman canlı ve hareketlidir. Python, veri bilimi ve makine öğreniminde baskın dil olarak sağlam bir şekilde yerini korumaktadır ve R topluluğu büyümeye devam etmektedir. Açık kaynak kodlu yazılımlar, kuruluşların çok az bir yatırımla veri bilimi ve makine öğrenimi girişimlerini hızlı bir şekilde başlatmasına veya genişletmesine olanak tanımaktadır. Algoritma yapı taşları genellikle model oluşturmak için kullanılmaktadır. Modeller belirli alan ve endüstri sorunları için soyutlanmaya ve paketlenmeye devam ettikçe bu eğilimin devam etmesi beklenmektedir.

Paketlenmiş modeller, uygulamalarla kolayca entegre edilebilen ve uygulamalarda kullanılabilen API'ler aracılığıyla giderek daha fazla kullanılabilir hale gelmektedir. Birçok bulut hizmeti API'si, belirli etki alanı ve sektör sorunlarına yüksek oranda odaklanmaktadır. Bu yaklaşım, kuruluşların kendi kendilerine modeller oluşturma ihtiyacını azaltabilmekte veya zamanla ortadan kaldırebilmektedir.

Veri bilimi ekipleri, modelleri operasyonel hale getirmekten çok geliştirmekte daha iyi hale gelmişlerdir. Sonuç olarak, operasyonelleştirmede sorunlar yaşandığı için, yapılan işin değeri genellikle ölçülemez halde kalmaktadır. Veri bilimi platformlarındaki MLOps yetenekleri, yalnızca dağıtımın ötesine geçerek üretimdeki modellerin devam eden yönetimine ve bakımına kadar uzanmaktadır. Pek çok model geliştirilirken, çok azı sadece dağıtım değil, devam eden yönetim ve bakıma da yol açacak şekilde operasyonel hale getirilmektedir. Ayrıca, uygun şekilde yönetilmeyen ve izlenmeyen modeller, iş koşulları değiştikçe ilgisiz veya hatalı olma riskiyle karşı karşıya kalmaktadır.

Şirketlerin strateji olarak makine öğrenimi hizmeti kullanmasıyla ilgili olarak son akademik makaleler birkaç önemli sonucu vurgulamaktadır. Bunlar:

- *Gelişmiş Karar Alma*: MLaaS, şirketlerin büyük veri kümelerini analiz etmek için gelişmiş makine öğrenimi modellerinden yararlanarak daha bilinçli kararlar almasını sağlamakta ve optimize edilmiş süreçlere ve iyileştirilmiş iş sonuçlarına yol açmaktadır (Sarker, 2021).
- *Maliyet Verimliliği*: Şirketler, MLaaS kullanarak kendi makine öğrenimi altyapılarını geliştirme ve sürdürmeyle ilişkili maliyetleri azaltabilmekte ve böylece kaynaklarını temel iş faaliyetlerine odaklayabilmektedirler (Grigoriadis, Vrochidou, Tsiatsiou, & Papakostas, 2023).
- *Ölçeklenebilirlik ve Esneklik*: MLaaS, bir işletmenin değişen ihtiyaçlarını karşılamak için kolayca ayarlanabilen ölçeklenebilir esnek çözümler sunduğu için, pazar taleplerine hızlı bir şekilde uyum sağlamak isteyen şirketler için çok önemlidir (Grigoriadis, Vrochidou, Tsiatsiou, & Papakostas, 2023).

- *Veri Gizliliği ve Güvenliği*: MLaaS'in sunduğu avantajların yanı sıra veri gizliliği ve güvenliği konusunda endişelere de yol açmaktadır. Şirketler, verilerinin korunduğundan ve ilgili düzenlemelere uyduğundan emin olmalıdır (Grigoriadis, Vrochidou, Tsiatsiou, & Papakostas, 2023).
- *Rekabet Avantajı*: MLaaS'ı etkili bir şekilde kullanan şirketler, ürünlerini ve hizmetlerini geliştirmek için makine öğrenimi modellerini hızla devreye alarak rekabet avantajı elde etmektedirler (Enholm, Papagiannidis, Mikalef, & Krogstie, 2022).
- *Mevcut Sistemlerle Entegrasyon*: MLaaS'ın başarılı bir şekilde uygulanması, mevcut BT altyapısıyla sorunsuz entegrasyon gerektirmektedir. Bu zorlayıcı olabilir ancak makine öğreniminin faydalarını en üst düzeye çıkarmak için gereklidir (Enholm, Papagiannidis, Mikalef, & Krogstie, 2022).
- *Pazarlama Avantajı*: MLaaS'ın pazarlamada kullanımı ile veri odaklı bir çağda müşteri katılımını ve karar alma süreçlerini dönüştürme potansiyelini vurgulamaktadır (Pereira, ve diğerleri, 2024).

Şirketlerin strateji olarak makine öğrenimi hizmeti kullanmasıyla ilgili yayınlanan makalelerde vurgulanan önemli sonuçlara ek olarak; hizmet olarak makine öğrenimi platformlarının kurumsal makine öğrenimi projelerinin tasarım ve geliştirme ortamlarındaki etkinliğine ve kullanılabilirliğine odaklanan bu çalışma ile proje tasarım ve geliştirme ortamı ile ilgili konularda katkıda bulunulmuştur.

Öneriler

Şirketlerin strateji olarak makine öğrenimi hizmeti kullanmasıyla ilgili gelecekte ele alınabilecek potansiyel araştırma konu önerileri aşağıda sıralanmıştır:

- *MLaaS'ın Endüstri Spesifik Uygulamalarının İncelenmesi*: Farklı endüstrilerde MLaaS'ın etkisi üzerine daha ayrıntılı incelemeler yapılabilir. Örneğin, sağlık, finans, üretim gibi sektörlerde hizmet olarak makine öğrenimi platformlarının etkinliğini değerlendiren çalışmalar, bu teknolojinin sektörel farklılıklarına ışık tutabilir. Özellikle sağlıkta veri güvenliği ve hassasiyeti gibi konular önemli olabilir.
- *MLOps ve Operasyonelleştirme Sorunları*: Sonuç bölümünde belirtilen operasyonelleştirme (MLOps) eksiklikleri üzerine odaklanan çalışmalar, MLaaS platformlarının iş modellerine daha etkin entegrasyonu için yol gösterici öneriler ortaya koyabilir. Modellerin geliştirilmesinden ziyade, dağıtım sonrası yönetimi ve bakım süreçleri üzerine detaylı analizler yapılabilir.
- *Veri Gizliliği ve Güvenliği Araştırmaları*: MLaaS platformlarının veri gizliliği ve güvenliği konusundaki zorlukları üzerine yapılacak yeni araştırmalar, özellikle Avrupa parlamentosu tarafından 27 Nisan 2016 tarihinde yayınlanan Genel Veri Koruma Yönetmeliği (General Data Protection Regulation - GDPR), kuruluşları kişisel veri kullanma biçimlerine ilişkin sorumluluğunu düzenleyen çerçevelere uyum sağlayacak stratejiler geliştirilmesine yol gösterebilir. Bu bağlamda, MLaaS sağlayıcılarının veri güvenliği açısından daha şeffaf ve güvenilir olabilmesi için yönergeler oluşturulabilir.
- *Kurumsal Uygulamalar ve Standardizasyon*: Farklı platformlar ve süreçler kullanan departmanlar arasında ortaya çıkan parçalanma ve standart eksikliğine yönelik çözümler önerilebilir. Kurumlar arasında ortak standartların nasıl oluşturulacağı ve süreçlerin nasıl optimize edileceği konusunda yeni çalışmalar yapılabilir.
- *API Tabanlı Modellerin Kullanım Kolaylığı*: Paketlenmiş modellerin API'ler aracılığıyla kullanımı üzerine yapılacak araştırmalar, bu modellerin işletmelere nasıl daha etkin entegrasyon sağlayabileceği üzerine odaklanabilir. Özellikle şirketlerin kendi modellerini sıfırdan geliştirmeleri yerine bu hazır modellerden nasıl daha fazla faydalanabilecekleri incelenebilir.
- *MLaaS'ın KOBİ'ler Üzerindeki Etkisi*: MLaaS platformlarının küçük ve orta ölçekli işletmelere (KOBİ'ler) olan etkisini araştıran çalışmalar yapılabilir. Özellikle düşük maliyetli çözümlerin KOBİ'lerin rekabet gücünü nasıl artırabileceği değerlendirilebilir.

Bu araştırma önerileri, hizmet olarak makine öğrenimi kullanımını daha etkin kılmak için akademik literatüre önemli katkılar sağlayabilir.

Kaynakça

- Abuhaija, B., Alloubani, A., Almatari, M., Ghaith M. Jaradat, H. B., Abualkishik, A. M., & Alsmadi, M. K. (2023, 04). A comprehensive study of machine learning for predicting cardiovascular disease using Weka and SPSS tools. *International Journal of Electrical and Computer Engineering*, 13(2), s. 1891-1902. doi:10.11591/ijece.v13i2.pp1891-1902
- Alpaydın, E. (2020). *Introduction to Machine Learning, Fourth Edition*. Cambridge: MIT Press.
- Amazon AWS Machine Learning. (2024, 04 20). *Makine Öğrenimi ve Yapay Zeka*. Amazon AWS: <https://aws.amazon.com/tr/ai/machine-learning/> adresinden alındı
- Amazon SageMaker. (2024, 04 20). *Makine Öğrenimi - Amazon Web Services*. Amazon SageMaker: <https://aws.amazon.com/tr/sagemaker/> adresinden alındı
- Aytekin, H. T. (2021, 06 30). Makine Öğreniminin Araştırmacıların Veri Analizi Bağlamında Potansiyel Önemi. *Ufuk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 10(19), s. 85-106.
- Bhattacharjee, B., Boag, S., Doshi, C., Dube, P., Herta, B., Ishakian, V., . . . Mi, J. (2017, 09 08). IBM Deep Learning Service. *IBM Journal of Research and Development*, 4-5, s. 10:1 - 10:11. doi:10.1147/JRD.2017.2716578
- Borra, P. (2024, 06). Advancing Data Science and AI with Azure Machine Learning: A Comprehensive Review. *International Journal of Research Publication and Reviews*, 5(6), s. 1825-1831.
- Borra, P. (2024, 06). The Evolution and Impact of Google Cloud Platform in Machine Learning and AI. *International Journal of Advanced Research in Science, Communication and Technology*, 4(3), s. 72-77. doi:10.48175/IJARST-18908
- Breuel, C. (2020, Ocak 4). *ML Ops: Machine Learning as an Engineering Discipline*. Kasım 2022 tarihinde Towards Data Science: <https://towardsdatascience.com/ml-ops-machine-learning-as-an-engineering-discipline-b86ca4874a3f> adresinden alındı
- Chang, B. R., Tsai, H.-F., & Lin, Y.-C. (2023). Optimizing Big Data Retrieval and Job Scheduling Using Deep Learning Approaches. *Computer Modeling in Engineering & Sciences*, 2, s. 783-815. doi:10.32604/cmescs.2022.020128
- Chapman, M., & Edwards, M. (2011, 05 31). *Service Component Architecture Assembly Model Specification Version 1.1*. (M. Beisiegel, A. Karmarkar, S. Patil, & M. Rowley, Dü) 11 11, 2022 tarihinde OASIS: <https://docs.oasis-open.org/opencsa/sca-assembly/sca-assembly-spec-v1.1-csprd03.html> adresinden alındı
- Costa-Climent, R., Haftor, D. M., & Staniewski, M. W. (2024, 12). Using machine learning to create and capture value in the business models of small and medium-sized enterprises. *International Journal of Information Management*, 73, s. 102637. doi:10.1016/j.ijinfomgt.2023.102637
- Enholm, I. M., Papagiannidis, E., Mikalef, P., & Krogstie, J. (2022, 10). Artificial Intelligence and Business Value: a Literature Review. *Information Systems Frontiers*, 24, s. 1709–1734. doi:10.1007/s10796-021-10186-w
- Erl, T. (2006). *Service-Oriented Architecture: Concepts, Technology, and Design*. PEARSON INDIA.
- Géron, A. (2023). *Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow*. Boston: O'Reilly Media.
- Gong, Y., Liu, G., Xue, Y., Li, R., & Meng, L. (2023, 10). A survey on dataset quality in machine learning. *Information and Software Technology*, 162, s. 107268. doi:10.1016/j.infsof.2023.107268
- Google Cloud Machine Learning. (2024, 04 20). *Introduction to Vertex AI*. Google Cloud: <https://cloud.google.com/ai-platform/docs/technical-overview> adresinden alındı
- Grigoriadis, I., Vrochidou, E., Tsiatsiou, I., & Papakostas, G. A. (2023). Machine Learning as a Service (MLaaS) - An Enterprise Perspective. *Proceedings of International Conference on Data Science and Applications* (Cilt 2, s. 261–273). içinde doi:10.1007/978-981-19-6634-7_19
- IBM - Deep Learning. (2024, 09 25). *Deep Learning*. Deep learning - Resources and Tools - IBM Developer: <https://developer.ibm.com/technologies/deep-learning/> adresinden alındı

- IBM Deep Learning - Articles. (2024, 09 25). *Deep Learning - Articles*. Deep Learning - Articles - IBM Developer: <https://developer.ibm.com/technologies/deep-learning/articles/> adresinden alındı
- IBM Watson Machine Learning. (2024, 04 20). *IBM Watson Studio*. IBM Watson Machine Learning: <https://www.ibm.com/cloud/watson-studio> adresinden alındı
- Insani, R., Nasrullah, M., Azizah, A. F., & Raygrandi, E. I. (2023). Application of Data Mining for the Selection Process of Prospective Students at ITTelkom Surabaya by Using the SPSS Modeler. *Proceedings of the 3rd International Conference on Advanced Information Scientific Development (ICAISD 2023)* (s. 289-294). Jakarta, Indonesia: Science and Technology Publications. doi:10.5220/0012448600003848
- James, G., Witten, D., Hastie, T., Tibshirani, R., & Taylor, J. (2023). Unsupervised Learning. *An Introduction to Statistical Learning: with Applications in Python* (s. 503–556). içinde Cham: Springer International Publishing. doi:10.1007/978-3-031-38747-0_12
- Kim, M., Stennett, T., Shah, D., Sinha, S., & Orso, A. (2024). Leveraging Large Language Models to Improve REST API Testing. *Proceedings of the 2024 ACM/IEEE 44th International Conference on Software Engineering: New Ideas and Emerging Results* (s. 37–41). Lisbon, Portugal: Association for Computing Machinery. doi:10.1145/3639476.3639769
- Lee, J. H., Shim, H.-J., & Kim, K. K. (2010, 04 14). Critical Success Factors in SOA Implementation: An Exploratory Study. *Information Systems Management*, 27(2), s. 123-145. doi:10.1080/10580531003685188
- Loukides, M. (2012). *What is DevOps?* Sebastopol, CA 95472: O'Reilly Media, Inc.
- Microsoft, A. M. (2024, 04 20). *Microsoft Azure Machine Learning Hizmeti - Hizmet Olarak ML*. Microsoft Azure Machine Learning Studio: <https://azure.microsoft.com/products/machine-learning/#product-overview> adresinden alındı
- Mira, J., Moreno, I., Bardisbanian, H., & Gorroñogoitia, J. (2024). Chapter 4 Machine Learning (ML) as a Service (MLaaS): Enhancing IoT with Intelligence, Adaptive Online Deep and Reinforcement Learning, Model Sharing, and Zero-knowledge Model Verification. R. Sofia, & J. Soldatos içinde, *Shaping the Future of IoT with Edge Intelligence: How Edge Computing Enables the Next Generation of IoT Applications* (s. Chapter 4). Abingdon (UK): River Publishers. doi:10.1201/9781032632407-6
- Moutaouakal, W. E., & Baïna, K. (2023). Comparative Experimentation of MLOps Power on Microsoft Azure, Amazon Web Services, and Google Cloud Platform. *2023 IEEE 6th International Conference on Cloud Computing and Artificial Intelligence: Technologies and Applications (CloudTech)* (s. 1-8). Marrakech, Morocco: IEEE. doi:10.1109/CloudTech58737.2023.10366138
- Nirmala, M., Saravanan, V., Jayasudha, A. R., John, P. M., Privietha, P., & Mahalakshmi, L. (2022, 08). Clinical Implication of Machine Learning Based Cardiovascular Disease Prediction Using IBM Auto AI Service. *International Journal for Research in Applied Science & Engineering Technology*, 10(8). doi:10.22214/ijraset.2022.46087
- Nykyri, M., Kuisma, M., Hallikas, J., Immonen, M., & Silventoinen, P. (2020). Modeling and Predicting an Industrial Process Using a Neural Network and Automation Data. *2020 IEEE 29th International Symposium on Industrial Electronics* (s. 505-509). Delft, Netherlands: IEEE. doi:10.1109/ISIE45063.2020.9152407
- Oliveira, S. d., Topsakal, O., & Toker, O. (2024, 01 21). Benchmarking Automated Machine Learning (AutoML) Frameworks for Object Detection. *Information*, 15(1), s. 63. doi:10.3390/info15010063
- Pereira, I., Madureira, A., Bettencourt, N., Coelho, D., Rebelo, M. Â., Araújo, C., & Oliveira, D. A. (2024, 04 15). A Machine Learning as a Service (MLaaS) Approach to Improve Marketing Success. *Informatics*, 11(2), s. 19. doi:10.3390/informatics11020019
- Red Hat. (2024, 04 20). *What is a REST API*. Red Hat: <https://www.redhat.com/en/topics/api/what-is-a-rest-api> adresinden alındı
- Ribeiro, M., Grolinger, K., & Capretz, M. A. (2015). MLaaS: Machine Learning as a Service. *IEEE 14th International Conference on Machine Learning and Applications (ICMLA)* (s. 896-902). Miami: IEEE. doi:10.1109/ICMLA.2015.152

- Sarker, I. H. (2021, 03 22). Machine Learning: Algorithms, Real-World Applications and Research Directions. *SN Computer Science*, 2(3), s. 160. doi:10.1007/s42979-021-00592-x
- Shakya, A. K., Pillai, G., & Chakrabarty, S. (2023, 11 30). Reinforcement learning algorithms: A brief survey. *Expert Systems with Applications*, 231, s. 120495. doi:10.1016/j.eswa.2023.120495
- SPSS, I. (2024, 09 25). *IBM SPSS Modeler*. IBM SPSS Modeler: <https://www.ibm.com/products/spss-modeler> adresinden alındı
- Taye, M. M. (2023, 04 25). Understanding of Machine Learning with Deep Learning: Architectures, Workflow, Applications and Future Directions. *Computers*, 12, s. 91. doi:10.3390/computers12050091
- Tufail, S., Riggs, H., Tariq, M., & Sarwat, A. I. (2023, 04 10). Advancements and Challenges in Machine Learning: A Comprehensive Review of Models, Libraries, Applications, and Algorithms. *Electronics*, 12(8), s. 1789. doi:10.3390/electronics12081789
- Vlisthttps, F. v., Helmondhttps, A., & Ferrarihttps, F. (2024, 03 12). Big AI: Cloud infrastructure dependence and the industrialisation of artificial intelligence. *Big Data & Society*, 11(1). doi:10.1177/2053951724123263
- Wendler, T., & Gröttrup, S. (2021). Classification Models. *Data Mining with SPSS Modeler*. içinde Springer, Cham. doi:10.1007/978-3-030-54338-9_8
- Wendler, T., & Gröttrup, S. (2021). Using R with the Modeler. *Data Mining with SPSS Modeler*. içinde Springer, Cham. doi:10.1007/978-3-030-54338-9_9
- Xie, S., Xue, Y., Zhu, Y., & Wang, Z. (2022). Cost Effective MLaaS Federation: A Combinatorial Reinforcement Learning Approach. *IEEE INFOCOM 2022 - IEEE Conference on Computer Communications* (s. 2078 - 2087). IEEE Press. doi:10.1109/INFOCOM48880.2022.979670
- Yao, Y., Xiao, Z., Wang, B., Viswanath, B., Zheng, H., & Zhao, B. (2017). Complexity vs. Performance: Empirical Analysis of Machine Learning as a Service. *17th Internet Measurement Conference (IMC)* (s. 384-397). London: ACM Inc. New York. doi:10.1145/3131365.3131372
- Zhao, Z., Alzubaidi, L., Zhang, J., Duan, Y., & Gu, Y. (2024, 05 15). A comparison review of transfer learning and self-supervised learning: Definitions, applications, advantages and limitations. *Expert Systems with Applications*, 242, s. 122807. doi:10.1016/j.eswa.2023.122807

EXTENDED SUMMARY

Machine learning has become one of the most important components of modern data science and is becoming increasingly important in many industries. As the applications of this technology has become more widespread, the cost of developing and managing machine learning systems for organizations has also increased. Training, implementing and tuning machine learning models requires a high level of technical expertise and is often associated with high hardware costs. However, cloud-based solutions offer new opportunities to overcome these barriers. At this point, Machine Learning as a Service (MLaaS) offers an important alternative by providing businesses with cost-effective, flexible and easy-to-use machine learning solutions.

This study aims to evaluate the effectiveness and usability of Amazon SageMaker, Google AI Platform, Microsoft Azure Machine Learning and IBM Watson Studio MLaaS platforms by comparing them. These platforms were chosen because they are widely used and offer a wide range of services worldwide.

The main definitions of the ideas behind this study are as follows:

- *Machine Learning* is a collection of statistical techniques for building mathematical models that can make inferences from samples of data, which is part of artificial intelligence and must continually adapt to the changing environment.
- *Service Oriented Architecture* focuses on building an architecture to design individual components.
- *Service Component Architecture* is a modelling specification for building systems according to the principles of Service Oriented Architecture. It divides applications into three distinct parts: a) components that perform business-related functions, b) composites that bring together different components to create business-related solutions, and c) interfaces of services that are created to remotely access the functions that make up the components and composites.
- *Machine Learning as a Service* is an umbrella definition for various cloud-based platforms that cover many of the infrastructure issues of machine learning, such as data pre-processing, model training and model evaluation. It consists of containers and Kubernetes, which form the basis of a *Functions as a Service* (FaaS) and *Software as a Service* (SaaS) solution. Companies offering machine learning as a service product typically provide a fine-tuned machine learning model from a single service, rather than the full toolset. The algorithms of the mathematical models created with these models are used to look for patterns in the data. The common feature of the platforms offered by many companies is that they offer both pattern recognition and probabilistic reasoning capabilities, built using different methods, where a customized workflow can be created according to the needs of the customer.

Machine learning systems typically require high hardware costs and expertise. To overcome these barriers, cloud-based services have come into play, and this is where 'Machine Learning as a Service' platforms play an important role. MLaaS facilitates the processes of managing data science processes, creating, training and deploying

machine learning models. These services allow users to use machine learning applications without having to invest in their own infrastructure.

The study used the comparative analysis method and considered many technical features such as API diversity, algorithms, model training and deployment capabilities, cost structures, user interfaces and user experience. It also looks at whether these platforms simplify machine learning processes and the cost benefits they offer to businesses. The data is taken from open sources made available by the platform providers. The four platforms analyzed in the study are the most widely used MLaaS solutions worldwide.

The results of the analyses show that each platform has its own advantages. Amazon SageMaker has a wide range of uses for data scientists and engineers with its integrated development environment, built-in algorithms and user-friendly interface. SageMaker's tools are specifically optimized for deep learning models and its broad API support is noteworthy. The Google AI Platform, on the other hand, offers great convenience for non-data scientists by providing code-free machine learning modelling with the AutoML framework. In addition, Google's extensive data processing and analysis ecosystem is one of the platform's greatest strengths. Microsoft Azure Machine Learning is characterized by its flexible structure and broad framework support. Its flexibility and strong MLOps capabilities make it suitable for large-scale projects. Azure's customizable pipelines and multi-framework support, such as ONNX Runtime, are features that set it apart from the competition. IBM Watson Studio, on the other hand, offers effective results especially for projects that work with large datasets, with powerful tools especially for data processing and integration processes. IBM's AutoAI tool stands out for its ability to automatically optimize machine learning models.

All four platforms can serve a wide range of users, from small businesses to large organizations. The flexibility, scalability and ease of use offered by MLaaS platforms enable organizations to implement machine learning projects with less technical expertise and at lower cost. However, data privacy and security are an important factor in selecting these platforms.

The results of the study show that MLaaS platforms offer significant benefits to businesses. Cloud-based machine learning solutions stand out for their cost-effectiveness, scalability and flexibility. Small and medium-sized businesses in particular can develop and deploy machine learning models quickly without having to invest in their own infrastructure. However, data security and privacy issues should not be overlooked. Especially with cloud-based systems, data protection and regulatory compliance are critical.

The effectiveness of MLaaS platforms provides organizations with great flexibility in the tools and services they offer. However, the constantly updated features and changing service policies of these platforms require organizations to be in a continuous process of evaluation and improvement.

In conclusion, machine learning as a service (MLaaS) offers an important opportunity for businesses to facilitate access to machine learning technologies. Choosing the right platform is a critical factor for businesses to

successfully implement machine learning projects. As each platform has its own strengths and weaknesses, it is important for businesses to choose the platform that best suits their needs.