

# Ticari Havayolu Taşımacılığı Sektöründe Makine Öğrenmesi Uygulamalarının İncelenmesi

## Investigation of Machine Learning Applications in Commercial Air Transportation Industry

Eyüp Bayram ŞEKERLİ\*

### ÖZ

Karmaşıklığın oldukça fazla olduğu, dinamik bir çevrede operasyonlarını sürdüren havayolu işletmelerinin birçok kısıta rağmen doğru karar almaları oldukça önemlidir. Bugün çok çeşitli veri ve büyük miktarda veri üreten havayolu işletmelerinin bu verileri en doğru şekilde değerlendirebilme becerileri kararlarının etkinlik derecesini belirleyebilecektir. Bu nedenle, bu çalışma kapsamında Yapay Zeka (YZ) uygulaması olan Makine Öğrenmesinin (MÖ) havayolu işletmelerinin hangi süreçlerinde, hangi algoritmalar ile kullanılabileceği alanyazında yer alan çalışmalar incelenerek tespit edilmeye çalışılmıştır. Elde edilen sonuçlar, özellikle son yıllarda MÖ'nün "dispeç güvenilirliği", "uçuş emniyeti", "gelir yönetimi/fiyatlama" ve "müşteri davranışları" konularına uygulanmasında bir artış olduğunu ortaya koymaktadır.

### ANAHTAR KELİMELER

Havayolu Taşımacılığı, Yapay Zeka, Makine Öğrenme

### ABSTRACT

It is very important that the airlines that carry out operations in a dynamic and complex environment struggle to make the right decision despite many limitations. Today, a wide range of data and a large amount of data generated by airline companies and their ability of data evaluation will determine the effectiveness of the decisions. For this reason, in this study, it has been tried to determine the applications of Artificial Intelligence (AI) and Machine Learning (ML) algorithms in airline processes of by examining previous literature. The results show that there has been an increase in the application ML algorithms in "dispatch reliability", "flight safety", "yield management/pricing" and "customer behavior" issues especially in recent years.

### KEYWORDS

Air Transportation, Artificial Intelligence, Machine Learning

Makale Geliş Tarihi / Submission Date	Makale Kabul Tarihi / Date of Acceptance
07.03.2019	24.05.2019
Atıf	Şekerli, E.B. (2019). Ticari Havayolu Taşımacılığı Sektöründe Makine Öğrenmesi Uygulamalarının İncelenmesi. Selçuk Üniversitesi Sosyal Bilimler Meslek Yüksekokulu Dergisi, 22 (2), 405-419.

\* Dr. Öğretim Üyesi, Muğla Sıtkı Koçman Üniversitesi, eyupbs@mu.edu.tr, ORCID: 0000-0003-1562-4716

## GİRİŞ

Ticari havayolu taşımacılığı sektörü teknolojinin yoğun olarak kullanıldığı sektörlerdendir. Kullanılan teknolojiler, genellikle operasyonel verimliliğin (Rosenberg vd., 1978; Lee ve Mo, 2011), uçuş emniyeti ve güvenliğinin sağlanmasına yöneliktir. Özellikle, tarihsel süreçte incelendiğinde havaaraçlarının daha emniyetli hale getirilmesi için önemli teknolojik geliştirmelerin yapıldığı görülmektedir (AU Department of Transport, 1998; Hansman, 2005). Seyrüsefer esnasında karar vermeyi kolaylaştıracak, ekip üyelerine daha az iş yükü yükleyecek otomatik sistemler havaaraçlarını robotik sistemler haline getirmiştir. Diğer yandan, uçuş güvenliği de teknolojinin yoğun bir biçimde kullanıldığı alanlardan birisidir. Büyük oranda havalimanı emniyetine bağlı olan uçuş emniyetinin sağlanmasında şüpheli olan ya da yetkisiz girişlerin engellenmesine ve tehlikeli maddelerin tespit edilmesine yönelik girişimleri engellenmesine yönelik teknolojiler sürekli geliştirilmektedir.

Havayolu işletmeleri istenilen kalitedeki ürünleri düşük fiyatlara sunmak için optimizasyon temelli karar destek sistemlerine başvurmak durumundadırlar. Optimizasyon ile yeterli miktarda kâr sağlamaya imkân verecek ücret sınıflarının belirlenmesi, uçuş programları, ekip eşleştirmeleri, bakım programları, uçuş planları, uçuş rotaları, kapı-uçak eşleştirmeleri ve eğitimlerin programlanması gibi alanlarda karar verme süreçlerinin etkinleştirilmesi sağlanmaktadır. Özellikle, havayolu taşımacılığı sektöründeki yoğun rekabet yapısı, büyük operasyonel hacim, birbirine yüksek seviyeli bağımlılık ve etkileşim içinde olan kaynaklar/süreçler (havaaracı, ekip, bakım faaliyetleri, havalimanı gibi), karmaşık operasyonel planlamalar, oldukça dinamik çevre, karmaşık müşteri davranışları, birçok sektöre göre daha yoğun yasalar, kurallar ve düzenlemelerin oluşturduğu hukuksal çevre süreçlerin optimizasyonu ile ilgili çabaları desteklemektedir (Yu & Yang, 1998:1383).

Günümüzde, örgütler; farklı yapılar, önemli miktarda ve sürekli olarak artan veriyle karşı karşıyadırlar. Büyük veri olarak tanımlanan bu veri yığınları havayolu işletmeleri içinde karar vermede kullanabilecekleri önemli bir kaynak niteliğindedir. Uçuş rotaları, yolcu bilgileri, havalimanı operasyonları, havadurumu verileri, emniyet raporları, havaaracı, havayolu ve pazara dair bilgiler havayolu işletmelerinin sürekli olarak ulaşabildikleri büyük verilerdir (Andronie, 2015:153-154). Büyük veri aynı zamanda bilgisayarlar teknolojileri ile karar vermek için kullanılan Yapay Zeka (YZ) ve Makine Öğrenmesi (MÖ) uygulamalarının etkin bir biçimde çalışmasına ihtiyaç duymaktadır (Bhatnagar, 2018: 469). YZ ve MÖ uygulamaları farklı sektörlerde yer alan işletmeler için süreçlerin verimliliği ve karar verme etkinliğinin sağlanmasında giderek daha fazla gündeme gelmektedir. Bu anlamda, operasyonel süreçlerin etkinliğini belirleyecek konularda havayolu işletmeleri sahip oldukları verileri YZ ile değerlendirebilirler. Diğer yandan, havayolu işletmelerinin YZ'den hangi süreçlerde ve ne kapsamda yararlanabilecekleri incelenebilir. Özellikle, YZ'nin ticari havayolu sektörünün bir takım problemlerine uygulayan akademik çalışmaların incelenmesi faydalı olabilecektir. Bu nedenle, çalışma kapsamında ticari havayolu taşımacılığı sektöründe YZ ve MÖ yöntemlerinin uygulama alanları araştırılmaktadır.

### 1. YAPAY ZEKÂ VE MAKİNE ÖĞRENME KAVRAMLARI

İnsan zihninin kapsamlı yeteneklerinin gerekli olduğu görevleri yerine getiren tüm bilgisayar temelli araçlar YZ olarak tanımlanmaktadır. Bilgisayarların işlem performanslarındaki önemli gelişmeler ve yüksek miktarda veriye ulaşmanın kolaylaşması YZ'ye olan ilginin artmasını sağlamıştır. MÖ ise, yapay zekânın alt bir uygulaması olarak kullanılmaktadır (Financial Stability Board, 2017:4). En temel düzeyde, MÖ, bir insan tarafından kapsamlı programlanmasına gerek kalmadan kendi başına “öğrenebilen” her türlü bilgisayar programını ifade etmektedir (Wehle, 2017:2). MÖ, istatistik ve bilgisayar bilimlerinin ortak uygulandığı bir alan olarak kabul edilmektedir. MÖ kapsamında yönetilmesi oldukça zor olan veri setleri, oluşturulan matematiksel modeller ile anlamlandırılmaktadır (Boelaert & Ollion, 2018). MÖ; insan zekasının konuşma, olgusallaştırma, çıkarım yapma ve problem çözümü gibi yönlerini simüle etmektedir (Buchanan, 2005; Deloitte, 2017). MÖ, verilerin analizinde kullanılan bir matematiksel prosedürü (algoritma) ifade etmektedir. MÖ ile farklı veri bileşenleri arasındaki örüntülerin (ilişkiler) keşfedilmesi amaçlanmaktadır. Olgular arasındaki ilişkilerin belirlenmesinden sonra çıkarımlar yapılarak oluşabilecek yeni durumlardaki davranış örüntüleri anlaşılmasına çalışılmaktadır (Finlay, 2017: 5). MÖ, çok çeşitli algoritmaları kullanarak mevcut verilerden sürekli öğrenerek kendisini geliştirmekte ve öngöründe bulunabilmektedir. MÖ kapsamında kullanılan algoritmalar sayesinde veriler arasındaki ilişkilerin öğrenilmesi (eğitim) ile daha kesin öngörüler yapılabilmektedir (Hurwitz ve Kirsch, 2018). MÖ kapsamında büyük veriler kullanılarak sürekli öğrenme ve geliştirme sağlanmaktadır (Deloitte, 2017).

MÖ; gözetimli (supervised learning), gözetimsiz (unsupervised learning) ve pekiştirmeli öğrenme (reinforcement learning) olarak adlandırılan algoritmaları kullanılmaktadır. Gözetimli öğrenme algoritmaları ile “eğitim” aşamasında etiketlenmiş, bazı özellikleri belirtilmiş olan veri setleri analiz edilmektedir (Financial

Stability Board, 2017; Raschka ve Mirjalili, 2017). Gözetimli öğrenmenin en temel görevi verileri ortak özelliklerine göre sınıflandırmaktır. Verileri sınıflandırmasının yanısıra gözetimli öğrenme öngörüsül hedef nümerik değerler de yaratmaktadır. Örneğin, bir otomobilin yapmış olduğu mesafe (km), markası ve yaşı gibi verilerden yola çıkarak aracın değeri ile ilgili bir değer oluşturulabilmektedir (Géron, 2017).

**Tablo 1: Makine Öğrenmesi Türleri**

Gözetimli Öğrenme	Gözetimsiz Öğrenme	Pekiştirmeli Öğrenme
Etiketli veriler kullanılır.	Etiketli olmayan veriler kullanılır.	Ödül sistemine göre karar verilir.
Çıktı, eğitim veri setine dayanmaktadır. Sınıflandırma yapılır.	Çıktı, verinin kümelenmesini temel almaktadır.	Çıktı aracı-ajan (agent)'ın çevreyle olan etkileşimi sayesinde oluşmaktadır.
Öncül bir veri seti gereklidir.	Öncül bir veri setinin olması gerekli değildir.	Öncül bir veri setine ihtiyaç duyulur.
Aynı girdiler her zaman aynı çıktılar üretir.	Aynı girdiler için her bir tekrarda farklı sonuçlar üretilebilir.	Eğer çevre değişiyor ise aynı girdiler için çıktılar da değişir.
Geleceğe yönelik çıktılar, öngörüler üretilir.	Veri setindeki gizli ilişkiler tespit edilir.	Eylem serileri oluşturulur.

**Kaynak:** Dasgupta & Nath, 2016; Raschka ve Mirjalili (2017)

Gözetimsiz öğrenme algoritması ise etiketlenmemiş veriler üzerinden çalışmaktadır (Financial Stability Board, 2017:4-5). Gözetimsiz öğrenme; temel olarak verinin sınıflandırılması, boyutlarının belirlenmesi ve verideki düzensizliklerin belirlenmesi amaçları ile kullanılmaktadır. Özellikle verideki düzensizliklerin tespit edilmesine yönelik olan gözetimsiz algoritmalar normal olmayan kredi kartı harcamalarının tespit edilerek hırsızlık girişimlerinin engellenmesinde ve üretim hatalarının tespit edilmesinde yoğun olarak tercih edilmeye başlanmıştır. Bu kapsamda, sistem normal veriler ile eğitildiğinden normalin dışında bir veri hemen ayırt edilmektedir. Bunların yanı sıra sistem içerisinde var olan fakat kolayca tespit edilemeyecek ilişkiler de gözetimsiz öğrenme algoritmaları ile öngörülmektedir. Örneğin, bir markette bir ürün tercih eden müşterilerin aynı zamanda tercih ettiği ürünlerin belirlenerek fiyat, promosyon ve mağaza düzenlemelerinin yapılması gözetimsiz öğrenme ile mümkün olabilmektedir (Géron, 2017).

Üçüncü bir öğrenme algoritması olan pekiştirmeli (takviyeli) öğrenme yönteminde ise, hedef çıktıyı vermek için bir danışman yerine, elde edilen çıkışın verilen girişe karşılık iyi ya da kötü olarak değerlendirilen bir kriter kullanılmaktadır (Atalay ve Çelik, 2017). Pekiştirmeli öğrenmede öğrenen sistem aracı-ajan (agent) olarak tanımlanmakta ve çevreyi gözlemleyerek, eylemlerini belirlemekte ve harekete geçmektedir. Bu hareket sonucu karşılaşılan olumlu (ödül) ya da olumsuz durum (ceza) aracının öğrenmesinde etkili olmaktadır. Benimsenen eyleme karşı çevreden gelen geribildirimde göre aracı tarafından politika (policy) olarak adlandırılan bir davranış yolu belirlenmektedir. Böylece, şartlar benzer olduğunda aracı, nasıl davranışlar sergileyeceğini öğrenmiş olmaktadır (Géron, 2017). Aracının çevre ile etkileşiminde deneme yanılma yaklaşımı ya da bilinçli bir planlama ile ödülleri maksimize edecek eylemler serisi öğrenilmektedir (Raschka ve Mirjalili, 2017).

## 2. YAPAY ZEKÂ VE MAKİNE ÖĞRENMENİN İŞLETMELERDEKİ UYGULAMALARI

İstatistiksel yöntemleri öngörü yapacak şekilde bir araya getirmesinin yanı sıra tarihsel verilere dayanarak öngöründe bulunan MÖ, modeller oluşturmakta ve veriler değiştiğinde bu modelleri güncellemektedir. Yeni veri akışları sayesinde öğrenerek öngörü yapmaya yarayan modelleri sürekli güncelleyebilen MÖ, veri akışının sürekli ve büyük miktarlarda olduğu günümüz iş dünyasında veri bileşenleri arasındaki ilişkileri dinamik bir biçimde tanımlayarak öngörü de bulunması, bu suretle çevresel belirsizliği azaltabilmesi örgütler için oldukça önemlidir (Bramer vd., 2015). Bu nedenle, MÖ, örgütlerin performanslarını ve pazardaki pozisyonlarını iyileştirmelerinde kullanılabilir. YZ, her büyüklükteki işletmede uygulama alanı bulabilme potansiyeline sahiptir. İşletmeler; dolandırıcılık girişimlerinin tespitinde, güvenliğin artırılmasında, ses ve görüntü tanıma ile daha etkin insan-makine ara yüzlerinin oluşturulması, araçların kullanımına ve medikal operasyonlara destek sağlanması gibi alanlarda YZ uygulamalarını kullanabilmektedirler (Azoff, 2015).

**Tablo 2: Makine Öğrenmesinin İşletmeler İçin Faydaları**

Gelir Artışı	Verimlilik Artışı	Sermaye Tasarrufu Artışı	Yatırım Maliyetlerinin Azaltılması
İşletme çıktılarının sonuçlarının tahmin edilmesi	Süreç verimliliği sağlanması	Üretim girdilerinin optimize edilmesi	Veri maliyetinin azaltılması
Müşteri ilişkilerinin bireyselleştirilmesi	Çalışan verimliliğinin sağlanması	Sabit sermayenin devamlılığının sağlanması	İnsan kaynağı maliyetinin azaltılması
Daha iyi pazar araştırması ile işletme stratejisinin geliştirilmesi	Değer zinciri verimliliğinin sağlanması	Kalite kontrolünün etkinleştirilmesi	Üçüncü kişi tedarikçi maliyetlerinin azaltılması
Rekabetçi avantaj elde etme			

**Kaynak:** Deloitte, 2017.

İşletmeler ellerinde bulunan sınıflandırılmış ya da sınıflandırılmamış verilerin işlenmesi ve buna dayanarak karar verilmesinde YZ önemli bir araç niteliğindedir. Birçok işletme, müşterileri ile ilgili ellerindeki çok geniş veri tabanlarını MÖ uygulamaları ile işleyerek müşteri profili belirleme ve pazar bölümlenme çalışmalarını daha etkin hale getirebilirler. Pazarlama alanında; pazar bölümlenme (Florez-Lopez ve Ramon-Jeronimo, 2009; Grau vd., 2009; Dullaghan ve Rozaki, 2017; Kamthania vd., 2018;) tüketici davranışlarının belirlenmesinde (Badea, 2014; Ravnik vd., 2014), müşteri ilişkilerinin analizinde (Emtiya ve Keyvanpour, 2011; Cioca vd., 2013; Amnur, 2017; Sabbeh, 2018) işletmelerin MÖ'den yararlanabileceği görülmektedir. MÖ'nün, pazarlama süreçlerinin yanı sıra fiyat belirleme (Narahari vd., 2005; Tulabandhula ve Rudin, 2013; Spedicat vd., 2018), gelir yönetimi (Shin ve Park, 2000; Rana ve Oliveira, 2014; Gosavi, 2004; Bayoumi vd., 2013), üretim süreçlerinin planlanması (Song vd., 2005; Gyulai vd., 2014; Müller vd., 2018), insan kaynakları planlamaları (Aytug vd., 1994; Punnoose ve Ajit, 2016; Serengil ve Ozpinar, 2017), süreç yönetimi-kalite kontrolü (Yang, Lu, & Lin, 1992; Escoba ve Morales-Menendez, 2018; Bai vd., 2018;), dağıtım hatlarının planlanması (Min, 2010; Mei ve Doomernik, 2017) gibi işletmecilik alanlarında kullanılabileceği görülmektedir.

### 3. TİCARİ HAVAYOLU SEKTÖRÜNDE YAPAY ZEKÂ-MAKİNE ÖĞRENMESİ UYGULAMA ALANLARI

1980'li yıllarda serbestleşmeye başlayan ticari havayolu taşımacılığı sektöründe giriş engelleri kalkmış, sektöre yeni girişlerin kolaylaşması ile rekabet de artmıştır. Rekabetin artması ile birlikte fiyatlar düşmüş ve kar marjları azalmaya başlamıştır. Bu nedenle, yoğun rekabet ortamında gelirlerini artırabilmek için verimlilik havayolu işletmelerinin en önemli stratejisi haline gelmiştir (Odoni, 2009; Doganis, 2006).

Ticari havayolu taşımacılığı sektöründe maliyetler yoluyla rekabet etmek oldukça önemli bir strateji haline gelmiştir. Özellikle, serbestleşme hareketiyle ortaya çıkan düşük maliyetli iş modelini uygulayan havayolu işletmeleri, büyük ağa sahip olan, büyük merkezlerde topladıkları çok sayıda yolcu küresel çapta taşıyan büyük network tipi bayrak taşıyıcıları için kısa-orta hatlarda rekabet baskısının daha da artmasına neden olmuşlardır. Ayrıca, ticari havayolu taşımacılığı sektöründe oldukça yüksek olan yakıt, personel, bakım-onarım, havalimanı, sigorta giderlerinin baskısını azaltmak için yöntemlerin geliştirilmesi havayolu işletmelerini meşgul etmektedir. Bunların yanı sıra, havalimanı sıkışıklıkları, yüksek sermaye gereksinimleri, güvenlik ve emniyet ile ilgili gereklilikler, karmaşık ve büyük sistemin yönetimi ile ilgili zorluklar optimizasyon araçlarının/modellerinin kullanımının ön plana çıkmasına neden olmaktadır (Barnhart ve Cohn, 2004).

Bahsedilen konuları çözmek üzere akademik kapsamda rasyonel modellerin oluşturulmasını ele alan birçok çalışma bulunmaktadır. Çalışmaların yapıldığı alanlar aynı zamanda YZ ve MÖ uygulamaları ile çözüm aranabilecek alanlardır. Bu çalışmaların kapsamı aşağıdaki gibidir:

- Yakıt Yönetimi:** Yakıt giderlerinin havayolu işletmelerinin operasyonel maliyetleri arasında birinci sırada bulunmaktadır (Zouein vd., 2002; Belobaba, 2016). Nash (1981)'e göre, havayolu işletmeleri için petrol krizinin yaşandığı 1974 yılından itibaren matematiksel formülasyonlar ve bilgisayar yardımı ile yakıt giderlerini azaltmaya çalışmaktadırlar. Yakıt giderlerinin azaltılması için uçuş planlamanın sürecinin etkinliğinin sağlanmasına yönelik bir çok çalışma (Zouein vd., 2002 ; Naumann ve Suhl, 2013; Belkin, 2017; Legrand vd., 2018 ) bulunmaktadır.
- Ekip Planlama:** Yakıt giderlerinden sonra havayolu işletmelerinin en yüksek maliyetleri personel giderleridir (Belobaba, 2016). Bu nedenle, personelin en verimli şekilde kullanılması gerekmektedir. Personelin çalışma saatlerine getirilen kanuni kısıtlamalar ve havaaracı tipine uygunluk gibi kısıtlamalar personel planlamasında kısıtlardan bazılarıdır. Bu nedenle, ekip

- planlamasının etkinleştirilmesine yönelik çalışmalar (Rubin, 1973; Vance vd., 1997; Yen ve Birge, 2006; Rauf vd., 2016) bulunmaktadır.
- c) **Gelir Yönetimi/Fiyatlama:** Havayolu işletmelerinin karşılamaya çalıştıkları talebin birçok sektöre göre değişken olması fiyatlamayı zorlaştırmaktadır. Gün, hafta, ay ve yılın belirli zamanlarına göre değişen talebe uygun bir fiyatlama yapmak uçakların doluluklarını artırırken gelirleri maksimize etmek hedeflemektedir. Bu nedenle, dinamik bir fiyatlama sürecinde doğru karar verebilmeyi amaçlayan matematiksel modellemeler önplana çıkarılmıştır (Belobaba, 1987). Matematiksel modellemeleri kullanan çalışmalar (Belobaba ve Farkas, 1999; Lautenbacher vd., Stidham, 1999; Subramanian vd., 1999; Coughlan, 1999) temel olarak talep değişimlerinde dolululuğu ön görmeye çalışmakta, fazla satış ve ek satışları da dikkate alarak fiyatlama için karar modelleri oluşturmaktadır.
- d) **Filo Yönetimi:** Havayolu işletmeleri için filodaki en uygun hava aracının uçuşlara atanması üzerinde çaba gösterilmesi gereken bir problemdir (Barnhart vd., 2009). Bu anlamda, filo yönetimi, hem hedeflenen hizmet kalitesinin sağlanması hem karlı operasyonlar için oldukça kritik öneme sahiptir (Khoo ve Teoh, 2014). Bu anlamda belirsizlik yaratan farklı koşullarda filo planlama süreçlerinin etkinliğinin sağlanmasına dair bir çok çalışma bulunmaktadır (Sherali ve Zhu, 2008; Yan vd., 2008; Lohatepanont ve Barnhart, 2004, Khoo ve Teoh, 2014). Bahsedilen çalışmalarda; filo ile ekip, hat ve talep eşleştirmelerine en etkin çözümler birtakım matematiksel modeller ile aranmaktadır.
- e) **Network Planlama:** Havayolu işletmelerinin yeterli talep düzeyinin olduğu pazarlara, talebin olduğu zaman dilimlerinde, uygun miktarda uçuş sunmaları gerekmektedir. Network geliştirme tarife oluşturma (nerelere, ne zaman uçulacağı) ve filo atamasını içermektedir. Bu anlamda, doğru bir uçuş networkünün oluşturulması gelirle üzerinde etkili olmaktadır (Caetano vd., 2017). Bu kapsamda geliştirilen modeller ile gelirleri maksimize edecek şekilde hatların ve uçuş frekanslarının belirlenmesine yönelik matematiksel karar verme modelleri üzerinde alanyazında çalışılmaktadır (Yan ve Wang, 2010).

Günümüzde havayolu işletmelerinin yakıt, uçuş hatları, filo, bakım ve network gibi alanlarda elde ettiği büyük veriler yöneylem çalışmalarının yanı sıra YZ-MÖ ile araştırma yapmayı da mümkün hale getirmektedir.

#### 4. ARAŞTIRMANIN AMACI VE YÖNTEMİ

Akademik alanda havayolunun yukarıda bahsedilen problemlerinin (yakıt yönetimi, ekip planlama, gelir yönetimi/fiyatlamaya, filo yönetimi ve network gelişimi) yöneylem kapsamında çok fazla incelenmiştir. Diğer yandan, yöneylem araçları ile cevap aranmaya çalışılan her problem aynı zamanda YZ uygulamaları ile incelenebilen problemlerdir. Bu çalışmada nispeten yeni ve giderek ilgi yaratan bir alan olan YZ uygulamalarının hangi havayolu problemlerine uygulandığı anlaşılmasına çalışılacaktır. Bu kapsamda, Business Source Complete, IEEE Xplore Digital Library, Scopus, Jstor Journals, EBSCOHOST, Science Direct ve Academic Search Complete veri tabanlarında yer alan çalışmalar bir doküman taramasından geçirilmiştir. Araştırma sürecinde YZ-MÖ'nün kullanıldığı ve havayolu taşımacılığı sektörünü konu alan araştırmalar tespit edilmiştir. İncelenen çalışmaların araştırma soruları ve kullanılan algoritmaları görmeyi kolaylaştıracak bir sınıflandırma formu kullanılmıştır.

##### 4.1.Bulgular

Çalışma kapsamında 34 adet araştırma incelenmiştir. İncelenen çalışmaların 2004-2018 yılları arasında kapsadığı görülmektedir. Havayolu taşımacılığı ile ilgili problemleri MÖ algoritmaları ile inceleyen çalışmaların özellikle son yıllarda artış gösterdiği görülmüştür. İncelenen çalışmaların önemli bir bölümünün 2018 yılında (%32'si) yapılmıştır. Diğer yandan, incelenen 34 çalışma içerisinde MÖ tekniği olarak en çok gözetimli öğrenme (%61'i) tercih edilmiştir.

**Tablo 3: İncelenen Çalışmalarda Yıllara Göre Kullanılan Algoritmalar**

	2002	2004	2009	2010	2012	2013	2014	2015	2016	2017	2018
Gözetimli Öğrenme			1		1		2	1	3	3	8
Gözetimsiz Öğrenme		1					1	1	1	1	1
Pekiştirmeli Öğrenme	1	1		1	1	1	1			1	2
Toplam	1	2	1	1	2	1	4	2	4	5	11

İncelenen çalışmalardan on dokuz âdeti gözetimli öğrenme ile yapılmıştır. Bu çalışmaların dokuzunda Destek Vektör Makineleri Algoritması kullanılmıştır. Diğer gözetimli öğrenme çalışmalarında ise çeşitli algoritmalar (Rasgele Orman, Gradyen Güçlendirme, Yapay Sinir Ağları, Regresyon Ağacı Modellemesi, Multinomial Logit (MNL), Bulanık Mantık) kullanılmıştır. Diğer yandan, altı adet gözetimsiz öğrenme çalışması incelendiğinde belirgin bir algoritmanın baskın olmadığı görülmektedir. Bunlara ek olarak dokuz adet pekiştirmeli öğrenme çalışmasının dördünde Q-Öğrenme algoritması kullanılmıştır. Geri kalan pekiştirmeli öğrenme çalışmalarında ise çeşitli algoritmaların (SARSA, P-Öğrenme, Monte Carlo Öğrenme, Otomatik Nesne Tespit, Thompson Örnekleme) kullanıldığı görülmüştür.

**Tablo 4 İncelenen Çalışmalarda Kullanılan MÖ Algoritmaları**

Gözetimli Öğrenme	Sıklık	Gözetimsiz Öğrenme	Sıklık	Pekiştirmeli Öğrenme	Sıklık
Dispeç Güvenilirliği	4	Dispeç Güvenilirliği	1	Dispeç Güvenilirliği	2
Güvenlik	1	Uçuş Emniyeti	2	Güvenlik	1
Müşteri Davranışları	5	Havaaracı Verimliliği	2	Talep Tahmini	1
Ekip Planlama	1	Ekip Planlama	1	Havayolu fiyatlama/ Gelir yönetimi	4
İnsan Kaynakları	1			Havaaracı Verimliliği	1
Süreç Planlama	1			Talep Tahmini	1
Talep Tahmini	1				
Uçuş Emniyeti	4				

İncelenen çalışmaların havayolu sektörünün hangi problemlerine yönelik olduğu değerlendirilmiştir. Buna göre, yapılan çalışmalar en çok dispeç güvenilirliğine yöneliktir. Genel olarak tarifede belirtilen saatlere göre kalkış yapabilmeyi ifade eden dispeç güvenilirliğinin sağlanması havayolu işletmelerinin verimlilik, müşteri memnuniyeti ve gecikmelerden kaynaklanan maliyetlerin önlenmesi adına önem verilen bir konudur (Fan vd. 2014). Bu kapsamda yapılan MÖ uygulamalarının en fazla kalkış-varış performansının ve gecikmelerin öngörülmesine yönelik çalışmalar olduğu anlaşılmaktadır. Çalışmaların önemli bir bölümü gözetimli öğrenme algoritmaları kullanılmıştır. Dispeç güvenilirliği ile ilgili çalışmalarda kullanılan gözetimli algoritmalar genellikle regresyon temelli karar ağaçları ve rasgele orman algoritmaları şeklindedir.

**Tablo 5. Dispeç Güvenilirliği İle İlgili Çalışmaların Kapsamı**

Konu	MÖ Tipi	MÖ Algoritması
Havaaraçlarının varış zamanlarının ön görülmesi.	Gözetimli Öğrenme	Rasgele Orman
Zamanında kalkış ve varış performansının tahmin edilmesi.	Gözetimli Öğrenme	Rasgele Orman, Ekstra-Ağaç Regresyonu (Extra-Trees Regressor), Gradyen Güçlendirme, Çok Katmanlı Algılayıcı (Multilayer Perceptron (MLP))
Zamanında kalkış ve varış performansının tahmin edilmesi.	Gözetimli Öğrenme	Gradyen Güçlendirme, Ekstra-Ağaç Regresyonu (Extra-Trees Regressor)
Havaaracıdan kaynaklanan gecikmelerin öngörülmesi, havaaracı bileşenlerine dair bakım incelemelerini temel alan gecikme analizi.	Gözetimli Öğrenme	Regresyon Ağacı Modellemesi
Gecikme tiplerinin sınıflandırılması.	Gözetimsiz Öğrenme	Apriori Algoritması
Taksi Sürelerinin kısaltılması.	Pekiştirmeli Öğrenme	Eşzamanlı Pertürbasyon Stokastik Yaklaşım (SPSA)
Dispeç güvenilirlik düzeyinin analizi.	Pekiştirmeli Öğrenme	Monte Carlo Öğrenme

Havayolu işletmeleri için uçuş emniyeti önemli bir hizmet bileşeni olarak kabul edilmektedir (Elliott & Roach, 1993; Lambert & Luiz, 2011). Yapılan çalışmaların uçuş emniyeti ile ilgili belirli bir odağı bulunmamaktadır. Çalışmaların konuları; uçuşun çeşitli aşamalarının gerçekleştirildiği bölgelerde çevresel risklerin öngörülmesi, pilotların emniyet odaklı davranışlarının ve olağandışı durumlarda karar verme eğilimlerinin öngörülmesi şeklindedir. Uçuş emniyeti ile ilgili çalışmaların gözetimli ve gözetimsiz algoritmaları tercih ettiği, pekiştirmeli öğrenmeye yer vermedikleri görülmektedir.

**Tablo 6. Uçuş Emniyeti İle İlgili Çalışmaların Kapsamı**

Konu	MÖ Tipi	MÖ Algoritması
ASRS ve ASAP veri tabanlarının incelenerek kaza/kırım nedenlerinin sınıflandırılması.	Gözetimli Öğrenme	Destek vektör makineleri (Support Vector Machines)
Pilotların beklenmedik olaylara tepkileri, elektroensefalografik sinyallerin pilotların performansını geliştirmek için kullanılması.	Gözetimli Öğrenme	K-En Yakın Komşu Algoritması, Destek Vektör Makineleri (Support Vector Machines), Rastgele Karar Ağaçları, Yapay Sınır Ağları, Doğrusal ve Radyal Temelli Kernel Fonksiyonları
Türbülanslı sahaların öngörülmesi	Gözetimli Öğrenme	Rasgele Orman (random forest)
Uçuşun iniş aşamasında oluşan sıradışı durumların incelenmesi	Gözetimli Öğrenme	Destek vektör makineleri (Support Vector Machines)
Değişik seviyelerdeki yorgunluğun ve iş yükünün pilotun performans ve psikolojik tepkileri üzerindeki etkilerinin eş zamanlı olarak tespiti.	Gözetimsiz Öğrenme	Kümeleme
Olağandışı durumların yönetilmesi ve karar vermenin etkinleştirilmesi.	Gözetimsiz Öğrenme	Parçacık Sürüşü Optimizasyon Algoritması
Olağandışı durumların yönetilmesi ve karar vermenin etkinleştirilmesi	Gözetimsiz Öğrenme	Parçacık Sürüşü Optimizasyon Algoritması

Müşteri davranışlarının tespit edilerek havayolu hizmetinin uyarlanması havayolu işletmelerinin performansı için önemlidir (Shaw, 2007; Belobaba vd., 2009). İncelenen çalışmalarda havayolu müşterilerin davranışlarının sınıflandırılmasına ve öngörülmesine çalışıldığı görülmektedir. Bu kapsamda, çalışmaların odağı müşterilerin satın alma süreçlerindeki karar verme davranışları ve hizmeti değerlendirmelerinin anlaşılmasına yönelik olduğu görülmektedir. İncelenen çalışmalarda müşteri davranışlarının anlaşılması için sadece gözetimli öğrenme algoritmaları tercih edildiği görülmektedir. Gözetimli öğrenme kapsamında en çok Destek Vektör Makineleri (Support Vector Machines) algoritmasından faydalanılmıştır.

**Tablo 7. Müşteri Davranışları İle İlgili Çalışmaların Kapsamı**

Konu	MÖ Tipi	MÖ Algoritması
Duygu analizi ile müşterilerin havayolu ulaşımı ile ilgili tutumlarının anlaşılması.	Gözetimli Öğrenme	Destek vektör makineleri (Support Vector Machines)
Müşteri tarafından hangi hizmet bileşenlerinin değerlendirildiğinin anlaşılması.	Gözetimli Öğrenme	Destek vektör makineleri (Support Vector Machines)
Müşterilerin uçuş seçim sürecinde karar vermelerini etkileyen unsurların anlaşılması.	Gözetimli Öğrenme	"Multinomial Logit (MNL)"
Müşteri davranışları/Pazar Bölümleme (Satın alma aşamasında müşteri tercihleri ve satın alma kararının nasıl verildiğinin anlaşılması)	Gözetimli Öğrenme	Destek vektör makineleri (Support Vector Machines)
Müşteri davranışları/Pazar Bölümleme (Satın alma aşamasında müşteri tercihleri ve satın alma kararının nasıl verildiğinin anlaşılması)	Gözetimli Öğrenme	Destek vektör makineleri (Support Vector Machines)

Talebin çok değişken olduğu havayolu taşımacılığı sektöründe dinamik bir fiyatlandırma politikasını uygulayabilmek gelir yönetiminin başarısı için önemlidir. Bu nedenle, talep düzeyi ile eşleşen ve aynı zamanda

kapasitenin en yüksek gelir seviyesi ile kullanılmasını sağlayacak fiyatların belirlenmesi gerekmektedir (Burger ve Fuchs, 2005; Chen, vd., 2010) Bu bağlamda, incelenen çalışmaların doğru fiyatlandırmanın yapılması ve gelir yönetiminin etkinleştirilmesine yönelik olduğu görülmüştür. Diğer yandan, gelir yönetimi ve fiyatlandırma ile ilgili MÖ uygulamaları daha çok pekiştirmeli öğrenme algoritmaları ile yapılmıştır. Pekiştirmeli öğrenme kapsamında en çok Q-Öğrenme algoritmasından faydalanılmıştır.

**Tablo 8. Gelir Yönetimi İle İlgili Çalışmaların Kapsamı**

Konu	MÖ Tipi	MÖ Algoritması
Talebin belirsiz olduğu durumda gelir yönetiminin etkinleştirilmesi.	Pekiştirmeli Öğrenme	Thompson Örnekleme
Dinamik fiyatlandırma için çözüm üretimi.	Pekiştirmeli Öğrenme	SARSA, Q-learning, Monte Carlo Learning
Gelirleri maksimize edecek fiyatlandırma politikasının belirlenmesi.	Pekiştirmeli Öğrenme	Q-Öğrenme
Gelirleri maksimize edecek fiyatlandırma politikasının belirlenmesi.	Pekiştirmeli Öğrenme	Q-Öğrenme, P-Öğrenme
Kısıtlar gözönüne alarak en uygun fiyatların öngörülmesi, gelirlerin maksimize edilmesi.	Pekiştirmeli Öğrenme	Q-Öğrenme

Talebin ve fiyatın belirlenmesine dair çalışmaların yanı sıra incelenen çalışmalarda MÖ ile ekip, yakıt ve hava aracı verimliliğini artırmaya yönelik uygulamalar bulunmaktadır. Ayrıca, havacılık güvenliğini sağlamaya yönelik sabotaj potansiyeline sahip yolcuları tespit edecek algoritmalar üzerinde çalışılmıştır.

## SONUÇ

Günümüzde örgütler mal ve hizmet üretmenin yanı sıra çok miktarda veri üreten yapılar haline gelmişlerdir. Örgütler, çeşitli süreçlerine dair büyük miktarda veriler üretirken aynı zamanda stratejik karar verme aşamalarının birçoğunda veri ekosisteminin içerisinde faaliyetlerini sürdürmektedirler. Bu ekosistem müşterilerin ve rakiplerin davranışlarına, sektörel ve ekonomik göstergelere dair verilerden oluşmaktadır. Ayrıca, bu ekosistem anbean büyümektedir. Bu anlamda, bahsedilen miktarda veriyi sürekli olarak değerlendirerek, yorumlayabilecek araçları kullanabilmek önemli bir üstünlük olarak değerlendirilmektedir.

1950’li yıllardan itibaren üzerinde çalışılan, YZ’nin bir uygulaması olan MÖ’nün gelişimi 2000 yıllarda bilgisayarların performanslarındaki artış ile ivme kazanmıştır. Ayrıca bu ivmenin nedenlerinden birisi de Facebook, Google, Baidu ve Microsoft gibi teknoloji örgütlerinin bu alandaki artan ar-ge yatırımlarıdır (Boelaert & Ollion, 2018). Böylece, MÖ’den faydalanan yeni teknolojiler farklı sektörlerde kullanılmaya ve yaygınlaşmaya başlamıştır.

Birçok farklı sektör gibi ulaştırma sektöründe de verimlilik oldukça ön plandadır. Verimliliğin sağlanabilmesi çoğu zamanda operasyonel etkinliklerin sağlanmasına bağlıdır. Ayrıca, rekabetin yoğun olması havayolu işletmelerinin bütün süreçlerinin verimliliğini oldukça kritik bir noktaya çekmektedir. Nitekim, Uluslararası Hava Ulaştırma Birliği (International Air Transportation Association-IATA) havayolu taşımacılığı sektöründe MÖ’nün öncelikli uygulama alanlarını “müşteri ile ilgili süreçler”, “operasyonel yetenekler”, “destek ve yönetsel yetenekler” olarak tanımlamaktadır (IATA, 2018: 13). Bahsedilen alanlarda çözüm üretmek üzere yöneylem araştırması kapsamında bir çok çalışma yapılmıştır. Diğer yandan, bu araştırma kapsamında MÖ ile ilgili çalışmalar incelendiğinde bahsedilen alanlarda operasyonel yetenekler üzerinde oldukça fazla durulduğu görülmüştür. MÖ’nün gözetimli algoritmalarından faydalanarak havayolu işletmelerinin gecikmelerinin yapısını incelemek, öngörmek ve nedenlerini sınıflandırmak için kullanılabilmesi anlaşılmaktadır. Gecikmelerin incelenmesinin yanı sıra bir diğer kritik operasyonel nitelik olan uçuş emniyeti alanında da MÖ’den faydalanabileceği incelenen çalışmalardan anlaşılmaktadır. Elde edilen sonuçlar; uçuş planlandırmanın emniyet odaklı tasarlanması, olağandışı durumlara verilecek ekip tepkilerinin öngörülmesi ve kaza-kırımların nedenlerinin incelenmesi gibi geniş bir kapsamda MÖ’nün kullanılabilirliğini ortaya koymuştur.

IATA tarafından da belirtildiği gibi MÖ’nün havayolu taşımacılığı sektöründe kullanılabilmesi bir diğer alan olan müşteri ile ilgili süreçlerde de akademik ilginin mevcut olduğu görülmektedir. Nitekim; satın alma, hizmet kalitesini değerlendirme, müşteri profili belirleme gibi alanlarda MÖ’nün uygulanabileceği görülmüştür. Buna ilave olarak, fiyatlandırma ve gelir yönetimi alanında özellikle pekiştirmeli öğrenme algoritmalarının tercih edilerek MÖ’nün uygulanabileceğini göstermiştir. Bu alanda, özellikle Destek Vektör Makineleri Algoritması’nın geniş bir uygulama alanı bulduğu görülmektedir.

Araştırma kapsamında incelenen otuz dört çalışmadan sadece biri (Kocak & Polat, 2016) Türkiye’deki alanyazına aittir. Bu durum, önemli bir uygulama alanına sahip olan MÖ’nün ülkemizde havayolu işletmeleri ile ilgili çalışmalarda yeterli ilgiyi görmediğini de ortaya koymaktadır. Elde edilecek veri setleri ile uçuş emniyet, gelir yönetimi, gecikme ve müşteri davranışı ile ilgili konularda özgün çalışmalar yapılarak hem yerli alanyazına hem de havayolu sektörüne katkı sağlanacağı tahmin edilmektedir. Ayrıca, ülkemizde 2003 yılından itibaren tüm ulaştırma sektörlerinin yeniden yapılandırılması ile ilgili devlet politikalarının uygulandığı görülmektedir. MÖ ile yapılacak çalışmalar ile pazar büyüklüklerinin, ulaştırma düğümlerinin, filo büyüklüklerinin, liman ve havalimanları konum ve büyüklüklerinin belirlenmesinde fayda elde edilebileceği düşünülmektedir.

## KAYNAKÇA

- Abhijit, G. (2004). A Reinforcement Learning Algorithm Based on Policy Iteration for Average Reward: Empirical Results with Yield Management and Convergence Analysis. *Machine Learning*, 55(1), 5-29.
- Achenbach, A., & Spinler, S. (2018). Prescriptive Analytics in Airline Operations: Arrival time prediction and cost index optimization for short-haul flights. *Operations Research Perspectives*, 5, 265-279.
- Al-Tabbakh, S. M., Mohamed, H. M., & El-Zahed, H. (2018). Machine Learning Techniques For Analysis Of Egyptian Flight Delay. *International Journal of Data Mining & Knowledge Management Process (IJDKP)*, 8(3), 1-14.
- Amnur, H. (2017). Customer Relationship Management and Machine Learning. *International Journal of Informatics Visualization*, 1(1), 12-15.
- Andronie, M. (2015). Airline Applications of Business Intelligence Systems. *INCAS*, 7(3), 153-160.
- Aoun, O., Sarhani, M., & El Afia, A. (2016). Investigation of hidden markov model for the tuning of metaheuristics in airline scheduling problems. *IFAC PapersOnLine.*, 49, 347-352.
- Atalay, M., & Çelik, E. (2017). Büyük Veri Analizinde Yapay Zekâ ve Makine Öğrenmesi Uygulamaları. *Mehmet Akif Ersoy Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 9(22), 155-172.
- AU Department of Transport. (1998). *Advanced Technology Aircraft Safety Survey Report*. Canberra: Secretary of the Department of Transport and Regional Development .
- Aytug, H., Bhattacharyya, S., Koehler, G., & Snowdon, J. (1994). A review of machine learning in scheduling. *IEEE Transactions on Engineering Management*, 41(2), 165-171.
- Azoff, M. (2015). *Machine Learning in Business Use Cases: Artificial intelligence solutions that can be applied today*. London: OVUM.
- Badea, L. M. (2014). Predicting Consumer Behavior with Artificial Neural Networks. *Procedia Economics and Finance*, 15, 238-246.
- Bai, Y., Sun, Z., Deng, J., Li, L., Long, J., & Li, C. (2018). Manufacturing Quality Prediction Using Intelligent Learning Approaches: A Comparative Study. *Sustainability*, 10(1), 1-15.
- Balakrishna, P., Ganesan, R., & Sherry, L. A. (2010). Accuracy of reinforcement learning algorithms for predicting aircraft taxi-out times: A case-study of Tampa Bay departures. *Transportation Research: Part C.*, 18(6), Balakrishna P, Ganesan R, Sherry L. Accuracy of reinforcement learning algorithms for predicting aircraft taxi-out times: A case-s950-962.
- Barnhart, C., & Cohn., A. (2004). Airline Schedule Planning: Accomplishments and Opportunities. *Manufacturing and Service Operations Management*, 6(1), 3-22.
- Barnhart, C., Farahat, A., & Lohatepanont, M. (2009). Airline Fleet Assignment with Enhanced Revenue Modeling. *Barnhart, C., Farahat, A., & Lohatepanont, M. (2009). AiOperations Research*, 57(1), 231–244.
- Bartosz, B., Dariusz, M., & Krzysztof, A. C. (2018). A Machine Learning Approach to the Detection of Pilot's Reaction to Unexpected Events Based on EEG Signals. *Computational Intelligence and Neuroscience*, 2, 1-9.
- Bayoumi, A. E.-M., Saleh, M., Atiya, A., & Aziz, H. A. (2013). Dynamic Pricing for Hotel Revenue Management Using Price Multipliers. *Journal of Revenue and Pricing Management*, 12(3), 271-285.
- Belkin, V. A. (2017). On the Issue of Aircraft Maintenance Process Optimization on the Criterion of Minimum Fuel Consumption. *Naučnyj Vestnik MGTU GA*, 20(1), 61-68.
- Belobaba, P. (2016). Airline Operating Costs and Measures of Productivity. P. Belobaba, A. Odoni, & C. Barnhart içinde, *The Global Airline Industry* (s. 146-158). Noida, India: John Wiley & Sons.
- Belobaba, P. P. (1987). Airline Yield Management. An Overview of Seat Inventory Control. *Transportation Science*, 21(2), 63-73.
- Belobaba, P. P., & Farkas, A. (1999). Yield management impacts on airline spill estimation. *Transportation Science*, 33(2), 217–232.
- Belobaba, P., Odoni, A., & Barnhart, C. (2009). *The Global Airline Industry*. Wiltshire: John Wiley & Sons.
- Bhatnagar, R. (2018). Machine Learning and Big Data Processing: A Technological Perspective and Review. M. F. Aboul Ella Hassanien içinde, *The International Conference on Advanced Machine Learning Technologies and Applications (AMLTA2018)* (s. 468–478). Cham: Springer.
- Boelaert, J., & Ollion, É. (2018). The Great Regression. *Revue française de sociologie*, 3(59), 216-246.
- Bramer, L. M., Chatterjee, S., Holmes, A. E., Robinson, S. M., Bradley, S. F., & Webb-Robertson, B.-J. M. (2015). A Machine Learning Approach for Business Intelligence Analysis using Commercial Shipping Transaction Data. *The 11th International Conference on Data Mining (DMIN 2015)* (s. 162-167). Las Vegas, Nevada: Pacific Northwest National Lab. .
- Buchanan, B. (2005). A (very) Brief History of Artificial Intelligence. *AI Magazine*, Winter, 53-60.
- Bude, G., Hoogenboom, L., Kastrop, W., Reniers, N., & Frasinca, F. (2018). Predicting User Flight Preferences in an Airline E-Shop. *Web Engineering*, 2018, 245-260.
- Burger, B., & Fuchs, M. (2005). Dynamic pricing-A future airline. *Journal of Revenue & Pricing Management*, 4(1), 39-53.
- Caetano, D. J., Dionisio, N., & Gualda, F. (2017). Daniel Jorge An exact model for airline flight network optimization based on transport momentum and aircraft load factor. Daniel Jorge Caetano, Nicolau Dionisio Fares Gualda. An exact model for airline flight network optimizatioTransportes, 25(4), 14-26.

- Chen, S., Gallego, G., Z.F.Li, M., & Lin, B. (2010). Optimal seat allocation for two-flight problems with a flexible demand segment. *European Journal of Operational Research*, 201(3), 897-908.
- Chiu, C., Chiu, N. H., & Hsu, C. I. (2004). Intelligent aircraft maintenance support system using genetic algorithms and case-based reasoning. *International Journal of Advanced Manufacturing Technology*, 24(5), Chiu, C & Chiu, N.-H & Hsu, C.-I. (2004). Intelligent aircraft maintenance support system using genetic algorithms and case-ba440-446.
- Cioca, M., Ghete, A. I., Cioca, L.-I., & Gîfu, D. (2013). Machine Learning and Creative Methods Used to Classify Customers in a CRM Systems. *Applied Mechanics and Materials*, 317, 769-773.
- Collins, A., & Thomas, L. (2012). Comparing reinforcement learning approaches for solving game theoretic models: a dynamic airline pricing game example. A Collins, L Thomas. Comparing reinforcement learning approaches for solving game theoretic models: aThe Journal of the Operational Research Society, 63(8), 1165-1173.
- Collins, A., & Thomas, L. (2013). Learning competitive dynamic airline pricing under different customer models. *Journal of Revenue & Pricing Management*, 12(5), 416-430.
- Coughlan, J. (1999). Airline overbooking in the multi-class case. *Journal of the Operational Research Society*, 50(11), 1098-1103.
- Dasgupta, A., & Nath, A. (2016). Classification of Machine Learning Algorithms. *International Journal of Innovative Research in Advanced Engineering (IJIRAE)*, 3(3), 6-11.
- Dattaram, B. A., & Madhusudanan, N. (2016). Delay Prediction of Aircrafts Based on Health Monitoring Data. *International Journal of Business Analytics & Intelligence*, 4(1), Dattaram BA, Madhusudanan N. Delay Prediction of Aircrafts Based on Health Monito29-37.
- Delahaye, T., Acuna-Agost, R., Bondoux, N., Nguyen, A., & Boudia, M. (2017). Data-driven models for itinerary preferences of air travelers and application for dynamic pricing optimization. *Journal of Revenue and Pricing Management*, 16(6), 621-639.
- Deloitte. (2017). Business impacts of machine learning. Sydney: Deloitte.
- Doganis, R. (2006). *The airline business*. London: Routledge.
- Dullaghan, C., & Rozaki, E. (2017). Integration of Machine Learning Techniques to Evaluate Dynamic Customer Segmentation Analysis for Mobile Customers. *International Journal of Data Mining & Knowledge Management Process*, 7(1), 13-24.
- Elliott, K. M., & Roach, D. W. (1993). Service Quality in the Airline Industry: Are Carriers Getting an Unbiased Evaluation from Consumers? *Journal of Professional Services Marketing*, 9(2), 71-82.
- Emtiya, S., & Keyvanpour, M. R. (2011). Customers Behavior Modeling by Semi-Supervised Learning in Customer Relationship Management. *Advances in Information Sciences and Service Sciences*, 3(9), 229-236.
- Escoba, C. A., & Morales-Menendez, R. (2018). Machine learning techniques for quality control in high conformance manufacturing environment. *Advances in Mechanical Engineering*, 10(2), 1-16.
- Fan, J., Jiao, J., & Zhao, T. (2014). Dispatch Reliability of Civil Aviation Simulation Based on Generalized Stochastic Petri Nets (GSPN). 10th International Conference on Reliability, Maintainability and Safety (s. 1033-1038). Guangzhou: IEEE.
- Ferreira, K. J., Simchi-Levi, D., & Wang, H. (2018.). Online Network Revenue Management Using Thompson Sampling. Ferreira, Kris Johnson, David Simchi-Levi, and He Wang. 2018. "Online NetOperations Research, 50(6), 1586-1602.
- Financial Stability Board. (2017). Artificial intelligence and machine learning in financial services: Market developments and financial stability implications. Basel: Financial Stability Board.
- Finlay, S. (2017). *Artificial Intelligence and Machine Learning for Business: A No-Nonsense Guide to Data Driven Technologies*. Lancashire: Relativistic Books.
- Florez-Lopez, R., & Ramon-Jeronimo, J. M. (2009). Marketing Segmentation Through Machine Learning Models: An Approach Based on Customer Relationship Management and Customer Profitability Accounting. *Social Science Computer Review*, 27(1), 96-117.
- Gan, X.-S., Yang, C., & Duanmu, J.-S. (2014). Information-Applied Technology in Neural Network Prediction Model of Aviation Unsafe Event Based on PSO Algorithm with Gradient Acceleration. *Advanced Materials Research*, 952, 303-306.
- Géron, A. (2017). *Hands-On Machine Learning with Scikit-Learn: Concepts, Tools, and Techniques to Build Intelligent Systems*. Sebastopol, CA: O'Reilly Media.
- Gittinger, J. M., Suknot, A. N., Jimenez, E. S., Spaulding, T. W., & Wenrich, S. A. (2018). Passenger baggage object database. *AIP Conference Proceedings*, 1949, 1-6.
- Gosavi, A. (2004). A Reinforcement Learning Algorithm Based on Policy Iteration for Average Reward: Empirical Results with Yield Management and Convergence Analysis. *Machine Learning*, 55(1), 5-29.
- Gosavi, A., Bandla, N., & Das, T. K. (2002). A reinforcement learning approach to a single leg airline revenue management problem with multiple fare classes and overbooking. *IIE Transactions*, 34(9), 729-742.
- Grau, M. M., Tajtakova, M., Tajtakova, M., & D.Arias-Aranda. (2009). Machine learning methods for the market segmentation of the performing arts audiences. *International Journal of Business Environment*, 2(3), 356 - 375.
- Gyulai, D., Kádár, B., & Monostori, L. (2014). Capacity Planning and Resource Allocation in Assembly Systems Consisting of Dedicated and Reconfigurable Lines. *Procedia CIRP*, 25, 185-191.

- Hansman, R. (2005). The Impact of Information Technologies on Air Transportation. 43rd AIAA Aerospace Sciences Meeting and Exhibit (s. 1-12). Nevada: AIAA.
- Homaie-Shandizi, A.-H., Nia, V. P., Gamache, M., & Agard, B. (2016). Flight deck crew reserve: From data to forecasting. *Engineering Applications of Artificial Intelligence*, 50, 106-114.
- Hurwitz, J., & Kirsch, D. (2018). *Machine Learning*. Hoboken, N: John Wiley & Sons.
- IATA. (2018). *AI in Aviation*. Montreal : IATA.
- Kamthania, D., Pahwa, A., & Madhavan, S. S. (2018). Market Segmentation Analysis and Visualization Using K-Mode Clustering Algorithm for E-Commerce Business. *Journal of Computing and Information Technology*, 26(1), 57-68.
- Khoo, H. L., & Teoh, L. E. (2014). An optimal aircraft fleet management decision model under uncertainty. *Khoo, H. L., & Teoh, L. E. (2014). An optimal aircraft fle**Journal of Advanced Transportation*, 48(7), 798–820.
- Kocak, B. B., & Polat, I. K. (2016). Twitter Kullanıcılarının Havayolu Pazarına Yönelik Duygu Kutuplarının Belirlenmesi: Bir Fikir Madenciliği Örneği. *PressAcademia*, 2(1), 684-691.
- Lambert, A., & Luiz, J. (2011). Passenger service quality expectations as perceived by long haul airline managers in South Africa. *African journal of business management*, 529(29), 11662-11675.
- Lautenbacher, C. J., & Stidham, S. (1999). Underlying Markov decision process in the single-leg airline yield-management problem. *Transportation Science*, 33(2), 136–146.
- Lee, J., & Mo, J. (2011). Analysis of Technological Innovation and Environmental Performance Improvement in Aviation Sector. *International Journal of Environmental Research and Public Health*, 8, 3777-3795.
- Legrand, K., Puechmorel, S., & Daniel Delahaye, Y. Z. (2018). Robust Aircraft Optimal Trajectory in the Presence of Wind. *IEEE Aerospace and Electronic Systems Magazine, Aerospace and Electronic Systems Magazine, IEEE, IEEE Aerosp. Electron. Syst. Mag*, 11, 30-39.
- Lheritier, A., Bocamazo, M., Delahaye, T., & Acuna-Agost, R. (2018). Airline itinerary choice modeling using machine learning. *Journal of Choice Modelling*, DOI: 10.1016/j.jocm.2018.02.002. '.
- Lohatepanont, M., & Barnhart, C. (2004). Airline schedule planning: integrated models and algorithms for schedule design and fleet assignment. *Transportation Science*, 38(1), Lohatepanont M, Barnhart C (2004) Airline schedule planning: integrated19–32.
- Lu, Z., Liang, X. Z., & Zhou, J. (2017). Markov process based time limited dispatch analysis with constraints of both dispatch reliability and average safety levels. *Reliability Engineering & System Safety*, 167, 84-94.
- M., S., Deokar A., V., & Janze, C. (2018). Disentangling consumer recommendations: Explaining and predicting airline recommendations based on online reviews. *Decision Support Systems*, 107, 52-63.
- Mei, A. v., & Doomernik, J.-P. (2017). Artificial intelligence potential in power distribution system planning. *CIREC - Open Access Proceedings Journal*, 2017, 2115-2117.
- Min, H. (2010). Artificial intelligence in supply chain management: Theory and applications. *International Journal of Logistics*, 13(1), 13-39.
- Ming, W., Bao, Y., Hu, Z., & Xiong, T. (2014). Multistep-Ahead Air Passengers Traffic Prediction with Hybrid ARIMA-SVMs Models. *The Scientific World Journal*, 2014, 1-14.
- Müller, H., Bosse, S., & Turowski, K. (2018). Capacity Management as a Service for Enterprise Standard Software. *Complex Systems Informatics and Modeling Quarterly*, 74(13), 1–21.
- Narahari, Y., Raju, C., Ravikumar, K., & Shah, S. (2005). Dynamic pricing models for electronic business. *Sadhana*, 30(2), 231-256.
- Nash, B. (1981). A Simplified Alternative to Current Airline Fuel Allocation Models. *Interfaces*, 11(1), 1-9.
- Naumann, M., & Suhl, L. (2013). How does fuel price uncertainty affect strategic airline planning? *Operational Research*, 13(3), 343–362.
- Odoni, A. (2009). The International Institutional and Regulatory Environment. P. Belobaba, A. Odoni, & C. Barnhart içinde, *The Global Airline Industry* (s. Odoni, A. (2009). The International Institutional and Regulatory Environment. In *The Global Airline Industry* (eds P. Belobaba, A. Odoni and C. Barnhart)). 19-46: John Wiley & Sons.
- Oza, N., & Castle, J. S. (2009). Classification of Aeronautics System Health and Safety Documents. *Classification of Aeronautics System Health and Safety Documents*, 39(6), 670-680.
- Prabakaran, N., & Kannadasan, R. (2018). Airline Delay Predictions using Supervised Machine Learning. *Prabakaran. N; Rajendran International Journal of Pure and Applied Mathematics*, 119(7), 329-337.
- Punnoose, R., & Ajit, P. (2016). Prediction of Employee Turnover in Organizations using Machine Learning Algorithms. *International Journal of Advanced Resea*, 5(9), 22-26.
- Rana, R., & Oliveira F., S. (2014). Real-time dynamic pricing in a non-stationary environment using model-free reinforcement learning. *Omega*, 47, 116-126.
- Raschka, S., & Mirjalili, V. (2017). *Python Machine Learning: Machine Learning and Deep Learning*. Birmingham: Packt Publishing.
- Rauf, K., Nyor, N., Kanu, R. U., & Omolehin, J. O. (2016). An Airline Crew Scheduling for Optimality. *International Journal of Mathematics & Computer Science*, 11(2), 187-198.
- Ravnik, R., Solina, F., & Zabkar, e. (2014). Modelling In-Store Consumer Behaviour Using Machine Learning and Digital Signage Audience Measurement Data. *VAAM(8811)*, 123-133.

- Rosenberg, N., Thompson, A., & Belsley, S. E. (1978). *Technological Change and Productivity Growth in the Air Transport Industry*. Springfield: NASA.
- Rubin, J. A. (1973). Technique for the Solution of Massive Set Covering Problems, with Application to Airline Crew Scheduling. *Transportation Science*, 7(1), 34-48.
- Sabbeh, S. F. (2018). Machine-Learning Techniques for Customer Retention: A Comparative Study. *International Journal of Advanced Computer Science and Applications*, 9(2), 273-281.
- Schultz, M., & Reitmann, S. (2018). Consideration of Passenger Interactions for the Prediction of Aircraft Boarding Time. *Aerospace (Basel)*, 5(4), 1-14.
- Serengil, S. I., & Ozpinar, A. (2017). Workforce Optimization for Bank Operation Centers: A Machine Learning Approach. *International Journal of Interactive Multimedia and Artificial Intelligence*, 4(6), 81-87.
- Shaw, S. (2007). *Airline marketing and management*. Burlington: Ashgate Publishing Company.
- Sherali, H., & Zhu, X. (2008). Two-stage fleet assignment model considering stochastic demands. *Operation Research*, 56(2), 383-399.
- Shin, C. K., & Park, S. C. (2000). A machine learning approach to yield management in semiconductor manufacturing. *International Journal of Production Research*, 38(17), 4261-4271.
- Smart, E., Brown, D., & Denman, J. (2012). A two-phase method of detecting abnormalities in aircraft flight data and ranking their impact on individual flights. *IEEE Transactions on Intelligent Transportation Systems*, 13(3), 1253-1265.
- Song, C., Guan, X., Zhao, Q., & Ho, Y.-C. (2005). Machine Learning Approach for Determining Feasible Plans of a Remanufacturing System. *IEEE Transactions on Automation Science and Engineering*, 2(3), 262-275.
- Spedicat, G. A., Dutang, C., & Petrini, L. (2018). Machine Learning Methods to Perform Pricing Optimization. A Comparison with Standard GLMs. *Variance Advancing the Science Risk*, 12(1), 69-89.
- Srisaeng, P., Baxter, G. S., & Wild, G. (2015). An adaptive neuro-fuzzy inference system for forecasting Australia's domestic low cost carrier passenger demand. *Aviation*, 19(3), 150-163.
- Subramanian, J., Stidham, S., & Lautenbacher, C. J. (1999). Airline Yield Management with Overbooking, Cancellations, and No-Shows. *Transportation Science*, 33(2), 147-168.
- Thiagarajan, B., Srinivasan, L., Sharma, A. V., Sreekanth, D., & Vijayaraghavan, V. (2017). A machine learning approach for prediction of on-time performance of flights. 2017 IEEE/AIAA 36th Digital Avionics Systems Conference (s. 1-6). St. Petersburg: IEEE.
- Thomas, L., Gast, C., Grube, R., & Craig, K. (2015). Fatigue Detection in Commercial Flight Operations: Results Using Physiological Measures. *Procedia Manufacturing*, 3, 2357-2364.
- Tulabandhula, T., & Rudin, C. (2013). Machine Learning with Operational Costs. *Journal of Machine Learning Research*, 14, 1989-2028.
- Vance, P. H., Barnhart, C., Johnson, E. L., & Nemhauser, G. L. (1997). *Airline Crew Scheduling: A New Formulation and Decomposition Algorithm*. Pamela H. Vance, Cynthia Barnhart, Ellis L. Johnson, & George L. Nemhauser. (1Operations Research, 45(2), 188-200.
- Wei, K., & Vikrant, V. (2018). Modeling Crew Itineraries and Delays in the National Air Transportation System. *Transportation Science*, 52(5), 1276-1296.
- Williams, J. K. (2014). Using random forests to diagnose aviation turbulence. *Machine Learning*, 95(1), 51-70.
- Yan, S., & Wang, C.-R. (2010). The planning of aircraft routes and flight frequencies in an airline network operations. *Journal of Advanced Transportation*, 35(1), 33-46.
- Yan, S., Tang, C.-H., & Fu, T.-C. (2008). An airline scheduling model and solution algorithms under stochastic demands. *European Journal of Operational Research*, 190(1), 22-29.
- Yang, H., Lu, W. F., & Lin, A. C. (1992). Intelligent Process Planning Using a Machine Learning Approach. *IFAC Proceedings Volumes*, 25(28), 147-151.
- Yanto, J., & Liem, R. P. (2018). Aircraft fuel burn performance study: A data-enhanced modeling approach. *Transportation Research Part D Transport and Environment*, 65, 574-595.
- Yen, J. W., & Birge, J. R. (2006). A Stochastic Programming Approach to the Airline Crew Scheduling Problem. *Transportation Science*, 40(1), 3-14.
- Yu, G., & Yang, J. (1998). Optimization Applications in the Airline Industry. P. Pardalos içinde, *Handbook of Combinatorial Optimization* (s. 1381-1472). Boston: Springer.
- Zheng, Y., Sheng, W., Sun, X., & Chen, S. (2017). Airline Passenger Profiling Based on Fuzzy Deep Machine Learning. *IEEE Transactions on Neural Networks and Learning Systems*, 28(12), "Airline Passenger Profiling Based on Fuzzy Deep Machine Learning," in IEEE Tra2911-2923.
- Zouein, P. P., Abillama, W. R., & Tohme, E. (2002). A Multiple Period Capacitated Inventory Model for Airline Fuel Management: A Case Study. *The Journal of the Operational Research Society*, 53(4), 379-386.

## Ek: Havayolu Sektöründe Araştırma Sorularını Makine Öğrenmesi İle İnceleyen Çalışmalar

Yayın bilgileri	Kullanılan Yöntem	Kullanım Amacı	Yayın bilgileri
(Lu, Liang, & Zhou, 2017)	"Pekiştirmeli Öğrenme"	"Monte Carlo Learning"	Dispeç Güvenilirliği (Dispeç güvenilirlik düzeyinin analizinin yapılması)
(Achenbach & Spinler, 2018).	"Gözetimli Öğrenme"	"Rasgele Orman" (random forest)	Dispeç güvenilirliği (Havaaraçlarının varış zamanlarının ön görülmesi)
(Balakrishna, Ganesan, & Sherry, 2010)	"Pekiştirmeli Öğrenme"	"Eşzamanlı Pertürbasyon Stokastik Yaklaşım (SPSA)"	Dispeç Güvenilirliği (Taksi Sürelerinin kısaltılması )
(Thiagarajan, Srinivasan, Sharma, Sreekanthan, & Vijayaraghavan, 2017)	"Gözetimli Öğrenme"	"Rasgele Orman" (random forest), "Ekstra-Ağaç Regresyonu", Gradyen Güçlendirme, Çok Katmanlı Algılayıcı (Multilayer Perceptron-MLP)	Dispeç Güvenilirliği (Zamanında kalkış ve varış performansının tahmin edilmesi)
(Prabakaran & Kannadasan, 2018)	"Gözetimli Öğrenme"	"Gradyen Güçlendirme", "Ekstra-Ağaç Regresyonu"	Dispeç Güvenilirliği, Gecikme (Gecikmelerin tahmin edilmesi)
(Gosavi, Bandla, & Das, 2002)	"Pekiştirmeli Öğrenme"	"Q-Öğrenme"	Havayolu fiyatlama/ Gelir yönetimi (Kısıtlar gözönüne alarak en uygun fiyatların öngörülmesi, gelirlerin maksimize edilmesi)
(Dattaram & Madhusudanan, 2016)	"Gözetimli Öğrenme"	"Regresyon Ağacı Modellemesi"	Dispeç Güvenilirliği, Gecikme (Havaaracıdan kaynaklanan gecikmelerin öngörülmesi, havaaracı bileşenlerine dair bakım incelemelerini temel alan gecikme analizi)
(Wei & Vikrant, 2018)	"Gözetimli Öğrenme"	"Destek vektör makineleri" (Support Vector Machines)", "Yapay sinir ağları"	Ekip Planlama (Ekip planlamanın optimizasyonunun sağlanması)
(Aoun, Sarhani, & El Afia, 2016)	"Gözetimsiz Öğrenme"	"Arı Kolonisi Algoritması"	Ekip Planlama (Ekip planlamanın optimizasyonunun sağlanması)
(Zheng, Sheng, Sun, & Chen, 2017)	"Gözetimli Öğrenme"	"Pisagor Temelli Bulanık Mantık Derin Boltzmann Makinesi (PFDBM)"	Güvenlik (Havalimanına girişte potansiyel sabotaj profil olan yolcuların normal yolculardan ayrılması)
(Gittinger, Suknot, Jimenez, Spaulding, & Wenrich, 2018)	"Pekiştirmeli Öğrenme"	"Otomatik nesne tespit algoritmaları"	Güvenlik (Yolcu bagaj görüntülemelerindeki sıradışlıkların tespit edilmesi)
(Al-Tabbakh, Mohamed, & El-Zahed, 2018)	"Gözetimsiz Öğrenme"	"Apriori algoritması"	Dispeç Güvenilirliği (gecikme tiplerinin sınıflandırılması)
(Chiu, Chiu, & Hsu, 2004)	"Gözetimsiz Öğrenme"	"Genetik Algoritma"	Havaaracı Verimliliği (Yolcular ve ekip için en uygun ışıklandırma düzeyinin sağlanması)
(Ferreira, Simchi-Levi, & Wang, 2018.)	"Pekiştirmeli Öğrenme"	"Thompson Örnekleme"	Havayolu fiyatlama/ Gelir yönetimi (Talebin belirsiz olduğu durumda gelir yönetiminin etkinleştirilmesi)
(Collins & Thomas, Comparing reinforcement learning approaches for solving game theoretic models: a dynamic airline pricing game example, 2012)	"Pekiştirmeli Öğrenme"	"SARSA", "Q-learning", "Monte Carlo Learning"	Havayolu fiyatlama/ Gelir yönetimi (Dinamik fiyatlama için çözüm üretimi)
(Rana & Oliveira F., 2014)	"Pekiştirmeli Öğrenme"	"Q-Öğrenme"	Havayolu fiyatlama/ Gelir yönetimi (Gelirleri maksimize edecek fiyatlama politikasının belirlenmesi)
(Abhijit, 2004).	"Pekiştirmeli Öğrenme"	"Q-Öğrenme", "P-Öğrenme"	Havayolu fiyatlama/ Gelir yönetimi (Gelirleri maksimize edecek fiyatlama politikasının belirlenmesi)
(Kocak & Polat, 2016)	"Gözetimli Öğrenme"	"Destek vektör makineleri" (Support Vector Machines)"	Müşteri Davranışlar (Duygu analizi ile müşterilerin havayolu ulaşımı ile ilgili tutumlarının anlaşılması)
(M., Deokar A., & Janze, 2018)	"Gözetimli Öğrenme"	"Destek vektör makineleri" (Support Vector Machines)"	Müşteri Davranışları (Müşteri tarafından hangi hizmet bileşenlerinin değerlendirildiğinin anlaşılması)

(Lheritier, Bocamazo, Delahaye, & Acuna-Agost, 2018)	"Gözetimli öğrenme"	"Multinomial Logit (MNL)"	Müşteri davranışları (Müşterilerin uçuş seçim sürecinde karar vermelerini etkileyen unsurların anlaşılması)
(Bude, Hoogenboom, Kastrop, Reniers, & Frasinca, 2018)	"Gözetimli öğrenme"	"Destek vektör makineleri" (Support Vector Machines)"	Müşteri davranışları/Pazar Bölümleme (Satın alma aşamasında müşteri tercihleri ve satın alma kararının nasıl verildiğinin anlaşılması)
(Delahaye, Acuna-Agost, Bondoux, Nguyen, & Boudia, 2017)	"Gözetimli Öğrenme"	"Destek vektör makineleri" (Support Vector Machines)"	Müşteri davranışları/Pazar Bölümleme (Satın alma aşamasında müşteri tercihleri ve satın alma kararının nasıl verildiğinin anlaşılması)
(Homaie-Shandizi, Nia, Gamache, & Agard, 2016)	"Gözetimli Öğrenme"	"Karar ağaçları"	Pilot Kaynağının Planlanması (Pilot kaynağının sürekliliğinin sağlanmasına yönelik modelleme)
(Schultz & Reitmann, 2018)	"Gözetimli Öğrenme"	"Yapay sinir ağları"	Süreç Planlama (En uygun uçağa kabul zamanının belirlenmesi.)
(Srisaeng, Baxter, & Wild, 2015)	"Gözetimli Öğrenme"	"Yapay sinir ağları", "Bulanık mantık", "Bulanık-sinir ağı modelleme")	Talep tahmini (Düşük maliyetli havayolu talebinin ön görülmesi)
(Ming, Bao, Hu, & Xiong, 2014)	"Gözetimli Öğrenme"	"Destek vektör makineleri" (Support Vector Machines)"	Talep tahmini (Havayolu yolcu talebinin belirlenmesi)
(Collins & Thomas, Learning competitive dynamic airline pricing under different customer models, 2013)	"Pekiştirmeli Öğrenme"	"SARSA"	Talep tahmini, (Müşteri tercihlerinin belirlenmesi)
(Oza & Castle, 2009)	"Gözetimli Öğrenme"	"Destek vektör makineleri" (Support Vector Machines)"	Uçuş Emniyeti (ASRS ve ASAP veri tabanlarının incelenerek kaza/kırım nedenlerinin sınıflandırılması)
(Thomas, Gast, Grube, & Craig, 2015)	"Gözetimsiz Öğrenme"	"Kümeleme"	Uçuş Emniyeti (Değişik seviyelerdeki yorgunluğun ve iş yükünün pilotun performans ve psikolojik tepkileri üzerindeki etkilerinin eş zamanlı olarak tespiti)
(Gan, Yang, & Duanmu, 2014)	"Gözetimsiz Öğrenme"	"Parçacık Sürüşü Optimizasyon Algoritması"	Uçuş emniyeti (Olağandışı durumların yönetilmesi ve karar vermenin etkinleştirilmesi)
(Bartosz, Dariusz, & Krzysztof, 2018)	"Gözetimli Öğrenme"	"K-en yakın komşu algoritması", Destek Vektör Makineleri (Support Vector Machines), Rastgele Karar Ağaçları, Yapay Sinir Ağları, Doğrusal ve Radyal Temelli Kernel Fonksiyonları	Uçuş emniyeti (Pilotların beklenmedik olaylara tepkileri, electroensefalografik sinyallerin pilotların performansını geliştirmek için kullanılması)
(Smart, Brown, & Denman, 2012)	"Gözetimli Öğrenme"	"Destek vektör makineleri" (Support Vector Machines)"	Uçuş Emniyeti (Uçuşun iniş aşamasında oluşan sıradışı durumların incelenmesi.)
(Williams, 2014)	"Gözetimli Öğrenme"	"Rasgele Orman" (random forest)	Uçuş emniyeti, uçuş planlama (Türbilanslı sahaların öngörülmesi)
(Yanto & Liem, 2018)	"Gözetimsiz Öğrenme"	"K-Ortalama Kümeleme"	Havaaracı Verimliliği (Uçuş aşamalarına göre havaaracı yakıt sarfiyat etkinliğinin modellenmesi)