

YAPAY ZEKA İLE SİVİL HAVACILIKTA UÇUŞ EMNİYETİ VE RİSK TAHMİNİ

Göksu Anıl KIZILDOĞAN¹

¹ANALYTHINX Atatürk Mh. Metropol İstanbul Sitesi C1 Blok Kat:23 Ataşehir İstanbul TÜRKİYE
Tel: +90 212 288 47 30, E-Posta goksu.kizildogan@analythinx.com

Özet- Bu açıklamalar kamera hazır şekliyle tablolar ve grafiklerle birlikte bildiri kitapçığı için gereken formatta hazırlanmıştır. Yayıncı bildiride değişiklik yapamaz ve verilen formattan uzak olan makaleleri basmayı reddedebilir. (Yanlış marginler, yazı ve resimlerin okunamayışı, SI birimlerinin kullanılmaması) Lütfen akıcı objektif bir Türkçe'yle üçüncü kişilere hitaben kişiselleştirilmeden, sadece SI birimleri ve yaygın terimleri kullanarak yazınız.

Anahtar Sözcükler: Makine öğrenmesi, uçuş emniyeti, sivil havacılık, derin öğrenme

1. Giriş

Sivil havacılıkta uçuş emniyeti, havayolu endüstrisinin en önemli önceliklerinden biridir. Uçuş emniyeti, her seferinde yolcuların ve mürettebatın emniyetini ve güvenliğini sağlamak için çeşitli önlemlerin alındığı bir sistemdir. Bu önlemler, havayollarının faaliyetlerini düzenlemek, uçaklarının bakımını yapmak, pilotlarının eğitimini sağlamak ve uçuş operasyonlarını denetlemek gibi çeşitli alanlarda uygulanır.

Uçuşu tehlikeye atabilecek, uçuşu emniyetsiz hale sokabilecek durumlara ise risk faktörü denmektedir. Başlıca uçuş emniyeti risk faktörlerinden birkaçı ise, türbülans, arazi engeline doğru kontrollü uçuş (CFIT) [1], uçuşta kontrol kaybı (LOCI) [2], rüzgar yön ve süratinin ani olarak büyük oranda değişmesi (WSHR) [3] vb. olarak sıralanabilir.

Emniyet yönetim sistemleri (SMS) [4] yukarıdaki risk faktörlerini gözlemek, kaydetmek, yorumlamak ve aksiyon almak için kurulmuş sistemlerdir. Bu sistemler uçuş öncesinde, uçuş sırasında ve uçuş sonrasında, proaktif veya reaktif olarak çalışabilirler. Havayollarında yer alan uçuş emniyet ekipleri, kokpit ekibi, uçuş mühendisi vb. emniyet açısından kritik öneme sahip kişiler bu sistemler aracılığıyla emniyeti sağlamaktadır.

Bu çalışmada bir emniyet yönetim sistemine entegre olabilecek şekilde tasarlanmış, kritik uçuş emniyeti risk faktörlerinden üçünü inceleyen bir açıklanabilir

yapay zeka (XAI) tasarımı anlatılmaktadır. Çalışmanın amacı farklı öznelikler yardımı ile üç risk faktörünü tahmin edecek modeli eğitmek ve gelecekteki uçuşlar için bu model yardımı ile tahminler gerçekleştirilmektedir. Pegasus Hava Yolları'nın gerçekleştirmiş olduğu uçuşlardaki farklı veri kaynaklarından toplanan veriler bir araya getirildikten sonra öznelik mühendisliği uygulanarak modellenmeye hazırlanmıştır. Modele hazır veriler farklı algoritmalar ile değerlendirilerek yeni verileri tahmin etmeye hazır, uçtan uca bir yapay zeka veri hattı kurulmuştur. Veri kaynakları, genel yaklaşım, kullanılan algoritmalar vb. tüm içerikler açıkça paylaşılsa da bilgi güvenliği kapsamında seçilmiş üç risk faktörü Risk 1, Risk 2 ve Risk 3, öznelikler ise alfabetik sıraya göre dizilip en baştaki 1 olacak şekilde Öznelik 1, Öznelik 2 ... Öznelik N olarak kodlanmıştır. Özneliklerin sahip olduğu sayısal değişkenler ise normalizasyona sokularak boyutsuzlaştırılmıştır.

2. VERİ

İnsan hayatının önemli olduğu diğer sektörler gibi havacılık sektöründe de veri büyük bir öneme sahiptir. Emniyetli bir sistemi modellemek için öncelikle sistemin verilerini anlamak gerekmektedir. Meteorolojik veriler, telemetri sistemleri, kokpit ekibi bilgileri, havayolu firmasının sahip olduğu diğer veriler bir sistemi oluşturan verilerin büyük çoğunluğudur.

2.1 Veri Kaynakları

Meteorolojik veriler: Kabin ekibi güncel meteorolojik verileri uçuş sırasında edinerek gerekli aksiyonu alabilseler de güncel teknoloji sayesinde detaylı hava durumu tahmini METAR, TAF vb. formatlarda geçmişe ve geleceğe yönelik toplanabilmektedir [5].

Havayolu verileri: Uçağın AirFASE sisteminden toplanılan veriler, uçuş tarife verileri ve kabin ekibinin verilerinden oluşan verilerdir. Uçuş veri gözlemlemesi enstrümanları, uçuşun kalkış ve iniş havalimanları gibi bilgilerden harmanlanmaktadır.

2.2 Veri Birleştirme

Farklı kaynaklardan gelen verilerin birleştirilmesinde birtakım problemler olabilir. Bu problemler aynı zamanda gerçekleşmiş iki olayın farklı zamanda kaydının tutulması, yerel/global zaman dilimleri veya aynı ölçüm için kullanılan metriklerin farklı kaynaklarda farklı olması gibi sıralanabilir.

Bu çalışma kapsamında ise uçuşun gerçekleşmiş olduğu iniş, kalkış ve seyir saatleri baz alınmıştır. Baz alınan saatlerin Eşgüdümlü Evrensel Zaman (UTC) +0'daki değeri hesaplanmış, tüm veri birleştirilmeleri bu değer etrafında yapılmıştır.

3. ÖZNİTELİK MÜHENDİSLİĞİ

Ham veriler, her ne kadar farklı kaynaklardan alındıkları için belirli seviyede açıklayıcılığa sahip olsalar da her zaman tek başlarına veya oldukları halleriyle modellemeye uygun olmayabilirler. Verileri modellemeye uygun hale getirmek için yapılan geleneksel dönüşümlere ek olarak bu çalışmada uçuşlara ait örüntüleri yakalayıp bir hafıza oluşturmaya çalışılmıştır.

3.1 Örüntü ve Hafıza

Yapay zeka modellerinin öğrenim kalitesi, üzerinde eğitildiği verinin kalitesi ile orantılıdır [6]. Bu sebeple uçuşlardaki risk faktörleriyle ilintili örüntüleri yakalamak suretiyle modele uçuş hafızası kazandırılması amaçlanmıştır. Uçuşlara dair gündüz veya gece uçuşu olması, kışın veya yazın olması, uçuşun haftanın hangi gününde gerçekleştiği vb. kümeleme yaklaşımlarıyla yeni öznitelikler türetilmiştir.

3.2 İstatistiksel Öznitelikler

Hem bu çalışma kapsamında hem de uçuş emniyeti ekiplerine görüş sağlaması amacıyla ham verilerden istatistiksel öznitelikler türetilmiştir. Bu öznitelikler bir havaalanına yapılan aylık ortalama uçuş sayısı gibi tekdüze değerlerden bir havaalanından diğer havaalanına kışın yapılan uçuşlardaki bir risk faktörünün diğer risk faktörü ile oranı gibi çok boyutlu hesaplamaları da içermektedir.

Bunlara ek olarak sayısal değerlerin birbirlerine oranı, periyodik gruplamalar ile türetilmiş ortalama, minimum, maksimum gibi değerlerden de yararlanılmıştır.

3.3 Veri Normalizasyonu

Hem bilgi güvenliği kapsamında öznitelikleri şifrelemek hem de ağaç bazlı olmayan algoritmalarda da avantaj sağlaması sebebiyle

veriler normalize edilmiştir. Normalizasyon yöntemi olarak standardizasyon seçilmiştir ve tüm sayısal veriler her bir öznitelikteki değer "x" olacak şekilde aşağıdaki formüle göre işlenmiştir:

$$x' = \frac{(x - \bar{x})}{\sigma} \quad (1)$$

x': Normalize değer ; $\bar{x}$: Ortalama x; σ : Standart sapma

4. MAKİNE ÖĞRENMESİ ALGORİTMALARI

Çalışma kapsamında riskleri tahmin etmek amacıyla, gözetimli öğrenim altındaki farklı sınıflandırma algoritmaları kullanılmıştır. Algoritma sayısının çokluğu sebebiyle algoritmalar ağaç tabanlılar ve diğerleri olarak ayrılmıştır.

Algoritmaların eğitimi için her bir algoritma özelinde hiperparametre uzayları oluşturulmuş ve eğitimler bu uzay içerisinde hedef metrik için en iyi sonuca ulaşacak şekilde yapılmıştır.

4.1 Ağaç Bazlılar

Yüksek açıklanabilirliği yüksek doğrulukla sağlayabilmesi sebebiyle ağaç bazlı algoritmalarından XGBoost (XGB) [7] ve LGBM (LGB) [8] seçilmiştir. Rassal orman algoritması da performans anlamında değerlendirilse de eğitim süresinin uzunluğu sebebiyle elenmiştir.

4.2 Diğerleri

Doğruluktan feragat ederek hızlı sonuç vermesi veya özniteliklerin arasındaki ilişkiyi lineer bir şekilde açıkça paylaşması sebebiyle ağaç bazlı olmayan algoritmalar da denenmiştir. Bu algoritmalar arasında lojistik regresyon analizi (LR) ve k En yakın Komşu (KNN) algoritmaları seçilmiştir.

Her ne kadar doğrulukları ve potansiyelleri yüksek olsa da açıklanabilirlik bakımından yeterince şeffaf olmamaları bakımından yapay sinir ağları bu çalışmada değerlendirilmemiştir.

5. METRİKLER

Risk faktörlerinin gerçekleşme oranı doğaları gereği gerçekleşmeme oranından daha düşüktür. Bundan dolayı klasik metrikler, örneğin doğruluk, model performansını tek başına tam olarak ifade etmemektedir. Bu sebeple de dengesiz veri setleri için farklı metrikler kullanılmaktadır. Bu çalışmada doğruluk, duyarlılık, kesinlik, logaritmik kayıp (log-loss) gibi metrikler sadece gözlem için kaydedilmiştir. Model hiperparametreleri eğrinin altında kalan alan (AUC) metriğine göre eğitilmiş, tahmin eşiği ise F1-skora göre belirlenmiştir [9][10].

6. EĞİTİM-DOĞRULAMA

Modellerin aşırı öğrenme problemini engellemek için kullanılan veri seti ve algoritmalarındaki ilgili kısımlar ayarlanmıştır. Veriler, tüm risk faktörleri için %80'i eğitim, %20'si ise test olacak şekilde iki gruba ayrılarak model eğitimi yapılmaktadır. Eğitim-test ayrımı ve çapraz-doğrulama adımlarında hedef değişkenin katmanlaştırılmasına dikkat edilmiştir.

Yukarıda bahsedilen ayarlara ek olarak model eğitimi adımına gelmeden önce işlenmiş verinin yaklaşık olarak son bir ayı doğrulama seti olarak ayrılmıştır. Veri hattı, eğitim ve test verileri üzerinde eğitim ve puanlama yaparken eğitimi tamamlanmış modellerin doğrulama seti üzerindeki puanlamasını da yapmaktadır.

Metrikler kısmında da bahsedilen veri dengesizliğinin model eğitimi sırasında örneklem sayısı düşük olan sınıfa handicap yaratmaması için sınıf ağırlıkları aşağıdaki denkleme göre belirlenmiştir.

$$w_i = \frac{N_{toplaml}}{N_i} \quad (2)$$

w_i : Sınıf ağırlığı; N_i : Sınıf örneklem sayısı; $N_{toplaml}$: örneklemelerin toplam sayısı

Burada amaç her sınıfın ağırlığının örneklem sayısı ile ters orantılı olmasını sağlayarak modelin tüm sınıfları eşit derecede önemsemesini sağlamaktır.

Model eğitimi sırasında gerçekleşen hiperparametre doğrulaması ise 5 adımlı çapraz-katmanlı-doğrulama ile gerçekleştirilmiştir.

7. ÇIKTILAR VE DEĞERLENDİRME

Tüm modeller Python dili ve ilgili model kütüphaneleri kullanılarak aynı platformda koşulmuştur. Platform Ryzen 9 5900X (12C-24T) işlemci, 64 GB 3200MHz Ram donanımlarına sahiptir. Veri setinin özelliği ve algoritmaların kıyasını yapabilmek sebebiyle GPU ile paralelizasyon desteği kapalı tutulmuştur.

Öğrenim ve test setleri üzerindeki model eğitimleri ve değerlendirmeleri bu kısımda paylaşılmaktadır. Veri setindeki tüm değerler ve tahmin edilen hedef risk faktörleri kodlansa da bu kısımdaki tüm sayısal değerler açık bir şekilde paylaşılmaktadır.

7.1 Öğrenim-Test Seti Metrikleri

Veri setinin dengesiz olmasını göz önünde bulundurarak sonuçlar incelendiğinde üç risk faktörü için de ortak nokta ağaç bazlı algoritmaların daha iyi sonuç vermesidir.

TABLO 1. Risk 1 Metrikleri

RİSK 1	LR	KNN	LGB	XGB
Eğitim Süresi (dakika)	9.42	241	5.89	49.77
Doğruluk	0.78	0.8	0.83	0.83
Kesinlik	0.22	0.22	0.32	0.33
Duyarlılık	0.46	0.4	0.69	0.69
F1 Skoru	0.3	0.29	0.44	0.45
Log Loss	0.61	1.2	0.44	0.43
AUC	0.73	0.69	0.87	0.87

TABLO 2. Risk 2 Metrikleri

RİSK 2	LR	KNN	LGB	XGB
Eğitim Süresi (dakika)	20.47	252	6.01	35.45
Doğruluk	0.74	0.77	0.8	0.8
Kesinlik	0.49	0.5	0.58	0.58
Duyarlılık	0.78	0.78	0.8	0.79
F1 Skoru	0.6	0.63	0.67	0.67
Log Loss	0.53	0.51	0.47	0.47
AUC	0.82	0.84	0.86	0.86

TABLO 3. Risk 3 Metrikleri

RİSK 3	LR	KNN	LGB	XGB
Eğitim Süresi (dakika)	5.59	213	4.26	22.13
Doğruluk	0.56	0.64	0.69	0.7
Kesinlik	0.36	0.37	0.47	0.48
Duyarlılık	0.76	0.76	0.74	0.74
F1 Skoru	0.49	0.52	0.58	0.58
Log Loss	0.64	0.61	0.56	0.56
AUC	0.68	0.73	0.78	0.78

Diğer modeller parametrik algoritmaları kullanırken KNN parametrik olmayan bir model olması ve veri setini bir bütün olarak kullanması sebebiyle beklenildiği üzere açık farkla en yavaş algoritma olmuştur. Benzer yöntemle çalışsalar da sahip oldukları temel birkaç farktan ve implementasyondan dolayı LGB tüm risk tahminlerinde XGB'den daha hızlı eğitilmiştir [11].

Modeller tahmin gücü açısından incelendiğinde ağaç bazlı modellerin önde olduğu görülmektedir. LR ve KNN bazı metriklerde LGB ve XGB algoritmalarına yaklaşılsalar da özellikle hiperparametre ayarı ve tahmin eşliğinde kullanılan metriklerde geride kalmaktadırlar. Gradyan artırma yöntemini kullanan LGB ve XGB ise geniş hiperparametre uzayı sayesinde yakın sonuçlar vermektedir.

7.2 Öznitelik Önemleri

Öğrenim metrikleri kıyaslandıktan sonra tüm riskler için en detaylı çalışma LGB ile devam ettirilmiştir. Risklerin tahmininde kullanılan en önemli 5 öz niteliğin azalan sırada önemleri aşağıdaki tablolarda paylaşılmıştır.

TABLO 4. Risk 1 Öznitelik Önemleri

Öznitelik	% Önem
ÖZNİTELİK 26	18
ÖZNİTELİK 91	15
ÖZNİTELİK 29	15
ÖZNİTELİK 27	11
ÖZNİTELİK 30	10

TABLO 5. Risk 2 Öznitelik Önemleri

Öznitelik	% Önem
ÖZNİTELİK 76	49
ÖZNİTELİK 66	14
ÖZNİTELİK 26	8
ÖZNİTELİK 27	7
ÖZNİTELİK 106	4

TABLO 6. Risk 3 Öznitelik Önemleri

Öznitelik	% Önem
ÖZNİTELİK 26	18
ÖZNİTELİK 68	13
ÖZNİTELİK 27	13
ÖZNİTELİK 78	9
ÖZNİTELİK 29	9

Önem tablolarının model açısından önemi hedef değişken olan risk faktörlerinin açıklanmasındaki kuvvetleridir. Açıklayıcılık kuvveti aynı zamanda emniyet ekiplerine de faktörler özelinde üzerinde durulması gereken parametreleri anlattığı için iş ekibi bakış açısına da sağlam bir görüş sunmaktadır.

7.3 Doğrulama Seti Metrikleri

Öznitelik önem analizinin ardından LGB ile yapılan çalışmalar doğrulama seti tahmini yapılması şeklinde devam ettirilmiştir. Güncel veriye sahip olan doğrulama seti üzerindeki tahminler modellerin öğrenim kuvvetini, aşırı veya az öğrenme durumlarını, tekrardan eğitim ihtiyacı gibi model açısından kritik pek çok bilgiyi açığa çıkartmaktadır.

Aşağıdaki tablolarda her üç risk için de öğrenim ve doğrulama seti metrikleri karşılaştırılmıştır.

TABLO 7. Risk 1 Doğrulama Seti Metrikleri

Metrik	Eğitim	Doğrulama	% Değişim
Doğruluk	0.83	0.91	10.00
Kesinlik	0.32	0.30	-5.01
Duyarlılık	0.69	0.60	-13.30
F1 Skoru	0.44	0.40	-8.38
Log Loss	0.44	0.29	-33.29
AUC	0.87	0.89	2.65

TABLO 8. Risk 2 Doğrulama Seti Metrikleri

Metrik	Eğitim	Doğrulama	% Değişim
Doğruluk	0.8	0.68	-15.13
Kesinlik	0.58	0.44	-23.34
Duyarlılık	0.8	0.75	-6.20
F1 Skoru	0.67	0.56	-16.66
Log Loss	0.47	0.69	47.29
AUC	0.86	0.76	-11.93

TABLO 9. Risk 3 Doğrulama Seti Metrikleri

Metrik	Eğitim	Doğrulama	% Değişim
Doğruluk	0.69	0.85	23.19
Kesinlik	0.47	0.52	9.61
Duyarlılık	0.74	0.59	-20.48
F1 Skoru	0.58	0.55	-5.28
Log Loss	0.56	0.41	-26.41
AUC	0.78	0.80	2.62

Genel anlamda doğrulama seti metriklerinde “kabul edilebilir” oranda bir değişim olmuştur. Buradaki değişimin temel sebebi, bu veri setine klasik bir veri seti olarak değil zaman serisi seti olarak yaklaşmaktır. Zaman serisi seti yaklaşımında verinin hedef değişkenin dağılımından ziyade kronolojik sıradaki son kısmı alındığı için hedef değişken ve açıklayıcılığı yüksek öz niteliklerin dağılımları değişebilmektedir.

8. SONUÇ

Çalışma kapsamında ciddi öneme sahip 3 farklı emniyet risk faktörü, öz nitelik havuzu içerisinde seçilmiş öz nitelikler ve farklı algoritmalar ile değerlendirilmiştir. Değerlendirme sonunda gradyan artırma bazlı LightGBM algoritmasının benzer veri setleri için yüksek doğruluğu korurken hızlıca eğitilebildiği görülmüştür. Zaman serisi verisi yaklaşımıyla yapılan modellemelerin havacılıkta kullanılabileceği kanıtlanmıştır. Farklı öz niteliklerin birden fazla risk faktörünün açıklanmasında yüksek öneme sahip olması birtakım ortak öz niteliklerin

sistem bütünü yaklaşımda değerlendirilebileceğini ortaya koymaktadır.

Bu çalışmada gelecekteki çalışmalarda değerlendirilebilecek yapay sinir ağları gibi daha yüksek doğruluklu modellerin kullanımına da temel hazırlanmıştır. Hazırlanmış veri setleri makine öğrenmesi modellerine ek olarak statik ve dinamik diğer istatistiki analizlere de kaynak olacaktır.

9. TEŞEKKÜR

Verilerin sağlanması, emniyet bakış açısının pekiştirilmesi, öznetelik hazırlığı adımları vs. tüm süreçte uçtan uca tecrübe aktarımında bulunan tüm Pegasus Hava Yolları profesyonellerine teşekkürlerimi sunarım.

10. REFERANSLAR

- [1] D.Kelly, M.Efthymiou "An analysis of human factors in fifty controlled flight into terrain aviation accidents from 2007 to 2017." Journal of safety research cilt 69, Haz. 2019 s.155-165
- [2] E.Ancel A.Shih, "The analysis of the contribution of human factors to the in-flight loss of control accidents" 12. AIAA Aviation Technology, Integration and Operations Konferansı, Indianapolis, Eylül 2012, s.123
- [3] F.H.Proctor, D.A.Hinton, R.L.Bowles, "A windshear hazard index" Aviation, Range and Aerospace Meteorology, Orlando, Ocak 2000
- [4] L.Yuling, F.W.Guldenmund, "Safety management systems: A broad overview of the literature", Safety Science cilt 103, 2018, s.94-123
- [5] J.Novotny, K.Dejmal, V.Repal, M.Gera, D.Sladek "Assessment of TAF, METAR, and SPECI Reports Based on ICAO ANNEX 3 Regulation" Atmosphere cilt 12, 2021, s.138
- [6] V.N.Gudivada, A.Apon, J.Ding "Data Quality Considerations for Big Data and Machine Learning: Going Beyond Data Cleaning and Transformations" International Journal on Advances in Software cilt 10, 2017
- [7] T.Chen, C.Guestrin "XGBoost: A Scalable Tree Boosting System", International Conference on Knowledge Discovery and Data Mining, Ağu. 2016, s.785-794
- [8] G.Ke, Q.Meng, T.Finley, T.Wang, W.Chen, W.Ma, Q.Ye, T.Liu "LightGBM: A Highly Efficient Gradient Boosting Decision Tree" Advances in Neural Information Processing Systems 30, 2017, s.3149-3157
- [9] I.U.Hassan, R.H.Ali, Z.U.Abideen, T.A.Khan, R.Kouatly "Significance of Machine Learning for Detection of Malicious Websites on an Unbalanced Dataset", Digital, 2022 cilt 2, s.501-519
- [10] J.Pereira, F.Saraiva "A Comparative Analysis of Unbalanced Data Handling Techniques for Machine Learning Algorithms to Electricity Theft

Detection", 2020 IEEE Congress on Evolutionary Computation, 2020, s.1-8

[11]A.Omar, K.Belkhat "XGBoost and LGBM for Porto Seguro's Kaggle challenge: A comparison" Preprint Semester Project, Ocak 2018

11. ÖZGEÇMİŞ

Göksu Anıl KIZILDOĞAN

Lisans derecesini 2017'de Orta Doğu Teknik Üniversitesi Makina Mühendisliği bölümünde, yüksek lisans derecesini ise 2020'de Eskişehir Osmangazi Üniversitesi Makine Mühendisliği bölümünde tamamlamıştır. 2017-2021 yılları arasında Tusaş Motor Sanayi Pistonlu Motorlar Tasarım Müdürlüğü içerisinde Performans ve Kalibrasyon mühendisi olarak çalışmıştır. 2021'den itibaren Analythinx bünyesinde kıdemli veri bilimci ve IoT analitikleri pratik lideri olarak çalışmaktadır.