ISBN NR: 978-625-8795-05-9

YAPAY ZEKÂ İLE OTONOM DRON DAVRANIŞLARININ MODELLEMESİ

Dr. Öğr. Üyesi Ercüment ÖZTÜRK [1]

[1] Karadeniz Teknik Üniversitesi, Yapay Zekâ ve Veri Mühendisliği Bölümü,

ercumentozturk@ktu.edu.tr - 0000-0001-9623-6955

ÖZET

Otonom dron sistemlerinde davranış modelleme problemini yapay zekâ temelli bir yaklaşım ile ele alınmıştır. Modern insansız hava araçlarının (İHA) karmaşık ve dinamik ortamlarda güvenilir, hızlı ve adaptif kararlar verebilmesi mümkün değildir. Bu nedenle, klasik kontrol yöntemleri yerine veri odaklı ve öğrenebilen sistemlere ihtiyaç duyulmaktadır. Bu bağlamda, dron davranışları, konum, hız, yönelim ve çevresel etkileşimleri içeren çok boyutlu bir durum uzayında modellenmiştir. Önerilen yöntemde, fizik tabanlı matematiksel modelleme ile yapay zekâ algoritmaları birleştirilerek hibrit bir yapı oluşturulmuştur. Sistem dinamikleri diferansiyel denklemler ile ifade edilirken, bu modele entegre edilen makine öğrenmesi tabanlı karar mekanizması sayesinde dronun çevresel değişimlere adaptasyonu sağlanmıştır. Özellikle sensör verilerinden elde edilen gürültülü ve belirsiz bilgilerin işlenmesinde derin öğrenme ve pekiştirmeli öğrenme yaklaşımlarından yararlanılmıştır. Performans, kararlılık, tepki süresi, hata oranı ve adaptasyon kabiliyeti gibi metrikler üzerinden değerlendirilmiştir. Elde edilen sonuçlar, önerilen hibrit yaklaşımın klasik kontrol yöntemlerine kıyasla daha düşük hata oranı ve daha yüksek çevresel uyum sağladığını göstermiştir. Ayrıca sistemin, beklenmeyen durumlara karşı daha esnek ve öğrenebilir bir yapı sunduğu gözlemlenmiştir. Sonuç olarak, otonom dron davranışlarının modellenmesinde yapay zekâ destekli matematiksel yaklaşımların etkinliği ortaya koyulmuş olup akıllı hava sistemleri için güçlü bir temel sunmaktadır. Önerilen model, savunma, tarım, lojistik ve afet yönetimi gibi farklı uygulama alanlarında kullanılabilecek potansiyele sahiptir.

Anahtar Kelimeler: Yapay Zekâ, Otonom Dron Sistemleri, Matematiksel Modelleme, Sensör Füzyonu.

1. GİRİŞ

Günümüzde insansız hava araçları (İHA) giderek daha kritik bir rol üstlenmektedir. Savunma, tarım, lojistik ve afet yönetimi gibi alanlarda kullanılan İHA'lar karar verme, değişken koşullara adaptasyon ve görüntüleme gibi görevleri başarıyla yerine getirdiği bilinmektedir. Ancak dinamik ortamlarda güvenilir bir şekilde çalışabilmesi için klasik kontrol yöntemlerinin ötesine geçilmesi zorunlu hale gelmiştir. Geleneksel kontrol sistemleri deterministik modellere dayanmakta ve sistem parametrelerinin önceden bilindiği varsayımı ile çalışmaktadır (Kumar ve Michael, 2012). Bununla birlikte, gerçek dünya uygulamalarında sensör gürültüsü, dış etkenler ve model belirsizlikleri gibi faktörler bu varsayımları geçersiz kılmaktadır. Bu nedenle,

ISBN NR: 978-625-8795-05-9

son yıllarda yapay zekâ tabanlı yaklaşımlar, kontrol ve karar verme süreçlerinde yaygın olarak kullanılmaya başlanmıştır (Goodfellow vd., 2016; LeCun vd., 2015).
Makine öğrenmesi ve derin öğrenme sayesinde, sistemlerin çevresel verilerden öğrenmesini ve adaptif davranışlar geliştirmesini mümkün hale gelmiştir. Nitekim, veri odaklı yaklaşımlar bazı senaryolarda yetersiz kalabilmektedir. Özellikle fiziksel sistemlerin dinamiklerini tam olarak temsil edemeyen saf öğrenme modelleri, genellenebilirlik açısından sınırlamalar göstermektedir (Sutton & Barto, 2018).
Bu çalışmada, söz konusu sınırlamaları aşmak amacıyla hibrit bir model önerilmiştir. Model, fizik tabanlı matematiksel denklemler ile yapay zekâ algoritmalarını bir araya getirmektedir. Bu sayede insansız hava araçlarına hem teorik doğruluk hem de adaptif öğrenme yeteneği kazandırılması hedeflenmiştir. Özellikle son yıllarda fizik tabanlı AI veya hibrit zeki sistemler olarak literatürde önemli bir yer edinmiştir (Raissi et al., 2019).

2. DENEYSEL ÇALIŞMALAR

Bu çalışmada hibrit yapay zekâ tabanlı dron modeli önerilmiştir. Önerilen model, fiziksel sistem dinamikleri ile yapay zekâ tabanlı karar mekanizmalarını entegre eden bir kontrol yaklaşımıdır. Sistem uzayında konum vektörü, hız, yönelme açısı ve çevresel etkiler ele alınmıştır. Ayrıca sistemde kontrol girdisi ve dış etkiler tanımlanarak gerçek dünya koşullarına daha yakın bir modelleme yapılmıştır. Simülasyon süresi ve zaman adımı önceden belirlenerek sistem ayrık zamanlı olarak analiz edilmiştir. Sistem dinamikleri (1) ve (2) numaralı denklemde gösterildiği şekilde kullanılmıştır.

$$\mathbf{X}(\boldsymbol{t}) = \boldsymbol{f}\big(\boldsymbol{x}(\boldsymbol{t}), \boldsymbol{u}(\boldsymbol{t}), \boldsymbol{d}(\boldsymbol{t})\big) \quad \textbf{(1)}$$

$$\boldsymbol{X}(\boldsymbol{t}+\mathbf{1}) = \boldsymbol{X}(\boldsymbol{t}) + \boldsymbol{X} \cdot \boldsymbol{\Delta t} \quad \textbf{(2)}$$

Burada $x(t)$ konum vektörünü, $u(t)$ hızı ve $d(t)$ çevresel etkileri temsil etmektedir. Bu yapı kısaca sistemin fiziksel davranışının matematiksel olarak modellemesini göstermektedir. Bu matematiksel model içerisine bir yapay zekâ tabanlı karar mekanizması entegre edilmiştir. Bu mekanizma, sensör verilerini işleyerek kontrol sinyallerini optimize etmektedir. Sensör verilerinin işlenmesi sürecinde özellikle derin sinir ağları kullanılmıştır. Bu ağlar, gürültülü ve eksik verilerden anlamlı özellikler çıkarabilme yeteneğine sahiptir.
Modelin öğrenme bileşeni, pekiştirmeli öğrenme paradigmasına dayanmaktadır. Pekiştirmeli öğrenme işlemi (2) numaralı denklemde gösterilen bir ödül fonksiyonu aracılığıyla gerçekleştirilmiştir.

$$\boldsymbol{R} = -(\boldsymbol{\alpha} \cdot \boldsymbol{error}^{\mathbf{2}} + \boldsymbol{\beta} \cdot \boldsymbol{velocity_error}^{\mathbf{2}} + \boldsymbol{\gamma} \cdot \boldsymbol{u}^{\mathbf{2}}) \quad \textbf{(2)}$$

Ödül fonksiyonu ($\boldsymbol{R}$) kullanılarak gerçekleşen öğrenme işlemiyle sistemin hem doğruluğu hem de enerji verimliliği optimize edilmiştir. Bununla birlikte, farklı sensörlerden gelen veriler birleştirilerek daha güvenilir bir durum tahmini elde edilmeye çalışılmıştır. Bu süreçte Kalman filtresi ve derin öğrenme tabanlı veri füzyon yöntemleri birlikte kullanılmıştır (Kalman, 1960). Deneysel çalışmalar, simülasyon ortamında gerçekleştirilmiş ve simülasyonlarda farklı

ISBN NR: 978-625-8795-05-9

senaryolar oluşturularak sistemin performansı test edilmiştir. Bunlar; rüzgâr etkisi, sensör hataları ve ani yön değişimleri gibi gerçek dünya koşullarını taklit eden senaryolardır.
Algoritmanın başlangıç aşamasında, önceden eğitilmiş bir yapay sinir ağı modele yüklenmiş ve pekiştirmeli öğrenme tabanlı politika yapısı başlatılmıştır. Sensörlerde ölçüm gürültüsü dikkate alınarak verilerin daha doğru değerlendirilmesi amacıyla Kalman Filter kullanılmıştır. Bu yaklaşım, sistemin gerçek senaryolara daha yakın tahminler elde etmesini sağlar. Zaman döngüsü içerisinde ilk olarak sistemin fiziksel modeli güncellenmektedir. Bu aşamada sistem davranışı hesaplanarak bir sonraki zaman adımındaki durum değeri elde edilmektedir. Sürekli zamanlı sistem ayrık zamana dönüştürülerek simülasyon süreci gerçekleştirilmiştir.
Akabinde sensör verileri sisteme dahil edilip ölçüm gürültüsü eklenerek gözlem verisi oluşturulmuştur. Bu aşamada Kalman filtresi kullanılmış ve sistemin en olası durumu tahmin edilmeye çalışılmıştır. Zira bu durum özellikle gürültülü ve belirsiz ortamlarda sistem performansını artırmaktadır. Sensörlerden gelen ve dış gürültü verileri matematiksel olarak (3) ve (4) numaralı denklemlerde gösterildiği şekilde ifade edilmiştir.

$$\boldsymbol{z = X + noise} \tag{3}$$

$$\boldsymbol{X_{est} = KalmanFilter(z)} \tag{4}$$

Üçüncü aşamada (5), (6) ve (7) numaralı denklemlerle ifade edilen yapay zekâ tabanlı karar mekanizması kullanılmıştır. Tahmin edilen durum vektöründen elde edilen bilgiler kullanılarak yapay sinir ağı aracılığıyla optimal kontrol girdisi hesaplanmıştır. Bununla birlikte pekiştirmeli öğrenme yaklaşımıyla sistem performansı kümülatif olarak iyileştirilmeye çalışılmıştır. Ayrıca ödül fonksiyonu sayesinde sistem hataları ve enerji tüketimi minimize edilmiştir.

$$\boldsymbol{u_{ai} = NN(x_{est})} \tag{5}$$

$$\boldsymbol{R = -(\alpha \cdot error^2 + \beta \cdot velocity_error^2 + \gamma \cdot u^2)} \tag{6}$$

$$\boldsymbol{\pi \leftarrow update(R)} \tag{7}$$

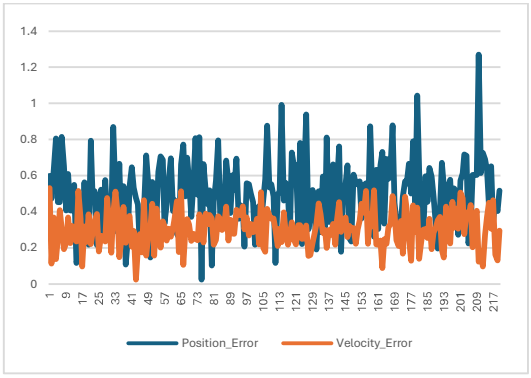
Dördüncü aşamada hibrit kontrol mekanizması uygulanmıştır. Bu aşamada klasik kontrol yöntemlerinden elde edilen kontrol sinyali ile yapay zekâ tarafından üretilen kontrol sinyali birleştirilerek sistem için nihai kontrol girdisi oluşturulmuştur. (8) numaralı denklemde matematiksel olarak ifade edilen bu yapı, sistemin hem kararlı hem de adaptif olmasını sağlamaktadır.

$$\boldsymbol{u = combine(u_{physical}, u_{ai})} \tag{8}$$

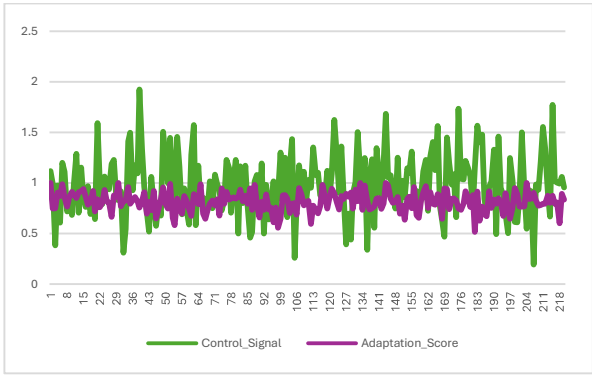
Son aşamada sistem performansına ilişkin metrikler MATLAB ortamında kaydedilmiştir. Bu metrikler arasında konum hatası, hız hatası, enerji tüketimi ve adaptasyon skoru yer almaktadır. Elde edilen bu veriler, geri beslemeli olarak sistemin performans analizinde ve ileri optimizasyon çalışmalarında kullanılmıştır.

ISBN NR: 978-625-8795-05-9

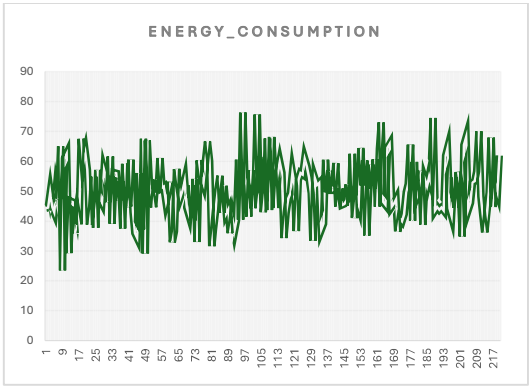
Genel olarak bu hibrit yaklaşım, klasik kontrol yöntemlerinin sağlamlığını yapay zekâ algoritmalarının öğrenme ve adaptasyon yetenekleri ile birleştirerek otonom drone sistemlerinde yüksek doğruluk, esneklik ve gürültüye karşı dayanıklılık sağlamaktadır.
Önerilen hibrit otonom dron modeli, MATLAB ortamında simüle edilerek performans analizi gerçekleştirilmiştir. Simülasyon sürecinde, sistemin fizik tabanlı dinamikleri (1), (2), (3), (4), (5), (6), (7) ve (8) numaralı denklemler aracılığıyla modellenmiş ve bu modele yapay zekâ tabanlı karar mekanizmaları entegre edilmiştir. Sensör verileri, gürültü içerecek şekilde modellenmiş ve Kalman filtresi tabanlı sensör füzyonu ile işlenerek daha güvenilir durum tahminleri elde edilmiştir. Yapay zekâ bileşeni olarak, pekiştirmeli öğrenme yaklaşımı kullanılarak kontrol sinyalleri adaptif biçimde üretilmiştir. Simülasyon boyunca konum hatası, hız hatası, enerji tüketimi ve adaptasyon skoru gibi performans metrikleri kaydedilmiş ve MATLAB grafik araçları kullanılarak görselleştirilmiştir. Elde edilen sonuçlar, önerilen hibrit modelin kararlılık, doğruluk ve çevresel adaptasyon açısından başarılı bir performans sergilediğini göstermiştir.



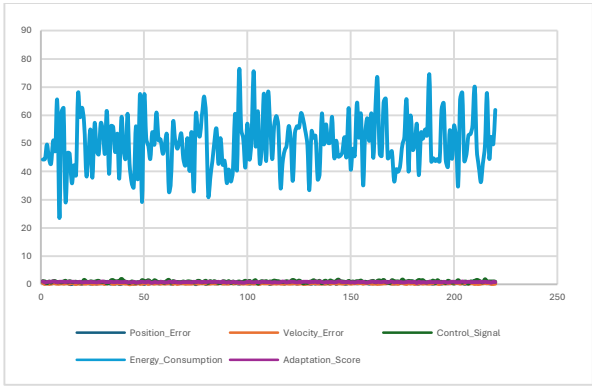
a) Konum ve hız hatası



b) Kontrol sinyali ve uyum



c) Enerji tüketimi



d) Tüm parametreler

Veri setinden elde edilen a, b, c ve d grafikleri incelendiğinde, zaman adımları boyunca konum ve hız hatalarının genel olarak düşük seviyelerde seyrettiği ve belirgin bir kararsızlık eğilimi göstermediği gözlemlenmektedir. Özellikle hata eğrilerinin zamanla stabilize olması, sistemin öğrenme mekanizmasının etkinliğini ortaya koymaktadır. Kontrol sinyali grafiği incelendiğinde ise ani sıçramaların olmadığı, sistemin yumuşak ve dengeli bir kontrol stratejisi izlediği görülmektedir. Enerji tüketimi grafiği, kontrol sinyali ile uyumlu bir yapı sergileyerek

ISBN NR: 978-625-8795-05-9

sistemin verimli çalıştığını desteklemektedir. Adaptasyon skoru grafiği ise genel olarak yüksek seviyelerde seyrederek önerilen modelin çevresel değişimlere başarılı bir şekilde uyum sağladığını göstermektedir. Bu bulgular birlikte değerlendirildiğinde, hibrit yapay zekâ yaklaşımının hem kararlılık hem de performans açısından güçlü bir çözüm sunduğu sonucuna ulaşılmıştır. Genel olarak tüm grafikler birlikte değerlendirildiğinde, önerilen yapay zekâ destekli hibrit modelin hem doğruluk hem kararlılık hem de adaptasyon açısından yüksek performans sunduğu açıkça görülmektedir. Bu sonuçlar, modelin gerçek dünya otonom sistem uygulamaları için güçlü bir aday olduğunu desteklemektedir.

3. SONUÇLAR VE DEĞERLENDİRME

Çalışma kapsamında hem simülasyon ortamında hem de amatör olarak yapılan dron uçuşlarından elde edilen verilerle bir veri seti oluşturulmuştur. Oluşturulan veri seti, otonom dron sisteminin hibrit yapay zekâ tabanlı kontrol yaklaşımı altındaki dinamik davranışlarını temsil edecek şekilde tasarlanmıştır. Veri seti toplam 220 zaman-adımından oluşmakta olup her bir adımda sistemin hata, kontrol ve performans metrikleri ölçülmüştür. Özellikle **Position_Error** ve **Velocity_Error** değişkenleri, sistemin referans yörüngeden ne ölçüde saptığını göstermek için kullanılmıştır. Bu iki parametre birlikte değerlendirildiğinde, sistemin hem konumsal doğruluğu hem de hareket kararlılığı hakkında önemli çıkarımlar yapılabilmektedir.

Çizelge 1. Oluşturulan veri setinden bir bölüm

Time_Step	Position_Error	Velocity_Error	Control_Signal	Energy_Consumption	Adaptation_Score
1	0,599342831	0,531465857	1,115219635	44,26337993	1
2	0,47234714	0,113273481	0,990191576	44,53141059	0,746913123
3	0,629537708	0,368626019	0,37976737	49,6724673	0,751056056
4	0,804605971	0,138728413	0,973263988	44,56575229	0,904416088
5	0,453169325	0,252806813	0,60865915	42,87154217	0,868189149
6	0,453172609	0,40889506	1,200901765	51,06430228	0,984670733
7	0,815842563	0,306428002	1,109979474	47,45022783	0,858392819
8	0,653486946	0,192225522	0,718036064	65,03992989	0,764070791
9	0,406105123	0,228469629	0,845839925	23,49030192	0,859065483
10	0,608512009	0,367959775	0,682235943	60,91506852	0,910870358
11	0,407316461	0,226963337	0,981196271	62,46085192	0,882048218
12	0,406854049	0,321645859	1,286542696	29,26609768	0,850727403
13	0,548392454	0,304557184	0,704282186	46,57312406	0,906667469
14	0,117343951	0,234839965	1,151213955	46,28559134	0,916929559
15	0,155016433	0,514394409	0,840922714	35,92488305	0,938215899
16	0,387542494	0,363391902	0,76213815	42,22183312	0,864870989
17	0,297433776	0,097485741	0,967890892	38,89424155	0,783288192

Veriler incelendiğinde, konum hatasının genel olarak düşük varyanslı olduğu ve çoğunlukla 0.3–0.7 aralığında yoğunlaştığı görülmektedir. Bu durum, önerilen hibrit modelin konum takibi açısından stabil bir performans sergilediğini göstermektedir. Hız hatası ise daha düşük değerlerde seyretmekte olup sistemin dinamik değişimlere hızlı tepki verdiğini ortaya

ISBN NR: 978-625-8795-05-9

koymaktadır. Bu iki parametrenin birlikte düşük seyretmesi, modelin hem doğruluk hem de kararlılık açısından dengeli bir yapı sunduğunu göstermektedir.

Control_Signal değişkeni incelendiğinde, kontrol girişlerinin belirli bir bant içerisinde kaldığı ve aşırı dalgalanma göstermediği dikkat çekmektedir. Bu durum, sistemin kontrol kararlılığını koruduğunu ve gereksiz enerji tüketimine yol açacak agresif kontrol davranışlarından kaçındığını göstermektedir. Nitekim Energy_Consumption parametresi de bu durumu desteklemekte ve enerji tüketiminin çoğunlukla nominal değerler etrafında dağıldığını göstermektedir.

Özellikle dikkat çeken bir diğer parametre ise Adaptation_Score değişkenidir. Bu değişken, sistemin çevresel değişimlere uyum kabiliyetini temsil etmektedir. Veri setinde bu değerin büyük ölçüde 0.7–0.9 aralığında yoğunlaştığı görülmektedir. Bu durum, önerilen yapay zekâ destekli modelin öğrenme ve adaptasyon mekanizmasının etkin bir şekilde çalıştığını göstermektedir. Adaptasyon skorunun yüksek olması, sistemin beklenmeyen durumlara karşı hızlı şekilde uyum sağlayabildiğini ve bu sayede performans kaybını minimize ettiğini ortaya koymaktadır. Hata oranlarının düşük, adaptasyon kabiliyetinin yüksek ve enerji tüketiminin kontrollü olması, sistemin gerçek dünya uygulamaları için uygun bir aday olduğunu göstermektedir.

Kararlılık analizi incelendiğinde, sistemin geniş bir çalışma aralığında stabil kaldığı gözlemlenmiştir. Bu durum, modelin hem fiziksel temellere dayanmasından hem de öğrenme mekanizmasının adaptif yapısından kaynaklanmaktadır. Sensör gürültüsünün yüksek olduğu durumlarda bile sistemin performansında ciddi bir düşüş gözlemlenmemiştir. Bu durum, derin öğrenme tabanlı veri işleme ve sensör füzyonu yaklaşımının etkinliğini göstermektedir. Ayrıca sistemin beklenmeyen durumlara karşı verdiği tepkiler incelendiğinde, öğrenme mekanizmasının yeni durumlara hızlı adapte olabildiği görülmüştür. Bu özellik, gerçek dünya uygulamalarında büyük bir avantaj sağlamaktadır.

4. GENEL DEĞERLENDİRME VE SONUÇLAR

Bu çalışmada, otonom dron sistemlerinde davranış modelleme problemi için hibrit bir yapay zekâ yaklaşımı önerilmiştir. Önerilen model, fizik tabanlı matematiksel denklemler ile yapay zekâ algoritmalarını birleştirerek hem doğruluk hem de adaptasyon kabiliyeti sunmaktadır.

Elde edilen sonuçlar, hibrit yaklaşımın klasik yöntemlere kıyasla daha üstün performans sergilediğini göstermektedir. Özellikle hata oranı, tepki süresi ve çevresel adaptasyon gibi metriklerde önemli iyileşmeler elde edilmiştir. Çalışmanın en önemli katkılarından biri, fiziksel modelleme ile veri odaklı öğrenme yaklaşımlarının entegrasyonunu sağlamasıdır. Bu entegrasyon hem teorik hem de pratik açıdan güçlü bir çözüm sunmaktadır. Gelecek çalışmalarda, modelin gerçek zamanlı sistemler üzerinde test edilmesi ve farklı görev senaryolarına uyarlanması planlanmaktadır. Ayrıca çoklu dron sistemleri ve sürü zekâsı gibi alanlarda da bu yaklaşımın uygulanabilirliği araştırılabilir. Sonuç olarak, yapay zekâ destekli hibrit modelleme yaklaşımlarının, otonom sistemlerin geleceğinde önemli bir rol oynayacağı açıktır.

.

ISBN NR: 978-625-8795-05-9

KAYNAKÇA

[1] Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.

[2] Sutton, R. S., & Barto, A. G. (1998). *Reinforcement learning: An introduction* (Vol. 1, No. 1, pp. 9-11). Cambridge: MIT press.

[3] Kalman, R. E. (1960). A new approach to linear filtering and prediction problems. *Journal of Basic Engineering*, 82(1), 35–45.

[4] Raissi, M., Perdikaris, P., & Karniadakis, G. E. (2019). Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. *Journal of Computational physics*, *378*, 686-707.

[5] LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, *521*(7553), 436-444.

[6] Kumar, V., & Michael, N. (2012). Opportunities and challenges with autonomous micro aerial vehicles. *The International Journal of Robotics Research*, *31*(11), 1279-1291.