# DELTA KONUM TAHMİNİ TABANLI IMU ODOMETRY: MLP VE KOLMOGOROV–ARNOLD AĞLARININ KARŞILAŞTIRILMASI

***Osman TOKLUOĞLU[1], Emin KERESTECİ[2]***

*[1]Elektrik-Elektronik Mühendisliği Bölümü, Ankara Yıldırım Beyazıt Üniversitesi, Ankara / Türkiye*

*[2]Bilgisayar Mühendisliği Bölümü, TOBB Ekonomi ve Teknoloji Üniversitesi, Ankara / Türkiye*

**Öz:** Bu çalışmada, EuRoC MAV kıyaslama veri setinden elde edilen ham IMU ölçümleri kullanılarak öğrenme tabanlı atalet odometry problemi incelenmektedir. Mutlak konum regresyonu yerine—büyük sabit hatalara yol açan bir formülasyon—modeller, sabit 50 ms uzunluğundaki bir kayan pencere üzerinden artımlı yer değiştirmeyi (Δp) tahmin edecek şekilde eğitilmekte ve tam yörünge sayısal integrasyon yoluyla yeniden oluşturulmaktadır. Standart bir Çok Katmanlı Algılayıcı (MLP) ile öğrenilebilir B-eğrisi aktivasyonlarına sahip bir Kolmogorov–Arnold Ağı (KAN) karşılaştırılmaktadır. KAN, 6,9 kat daha az parametreye sahip olmasına karşın (8.444'e karşı 57.859), test yörüngesinde nihai kümülatif kayma açısından MLP'ye göre %44 daha düşük hata üretmektedir (9,61 m'ye karşı 17,23 m). Ayrıca KAN, daha düşük $P_{50}$ ve $P_{90}$ kümülatif kayma değerleriyle uzun süreli hata birikimi açısından daha kararlı bir davranış sergilemektedir. Bu bulgular, öğrenilebilir B-eğrisi tabanlı aktivasyonların atalet odometry probleminde hata birikimini azaltma potansiyeline sahip olduğunu göstermektedir.

***Anahtar Kelimeler:*** Atalet Odometry, Kolmogorov–Arnold Ağları, IMU, Yörünge Tahmini

## GİRİŞ

GPS'in kullanılamadığı kapalı ortamlarda otonom hava araçları için doğru ve güvenilir konum tahmini temel bir sorun olarak karşımıza çıkmaktadır. Atalet Ölçüm Birimleri (IMU'lar), açısal hız ve özgül kuvvet ölçümlerini yüksek frekansta sunarak birincil algılama yöntemi olarak cazip bir seçenek haline gelmektedir. Ancak IMU tabanlı ölü hesaplama, iyi bilinen hata birikmesinden muzdariptir: ham ölçümlerdeki küçük sapmalar ve gürültüler konuma ulaşmak için iki kez entegre edilmekte ve klasik mekanizasyon denklemleri altında zamanla ikinci dereceden büyüyen kaymaya yol açmaktadır (Woodman, 2007).

Klasik Atalet Seyrüsefer Sistemi (INS) yaklaşımları, bunu kameralar, LiDAR'lar veya barometre gibi tamamlayıcı sensörlerle sıkı eşleştirme ve Genişletilmiş Kalman Filtresi veya daha güncel faktör grafı optimizasyonu gibi model tabanlı filtreleme yoluyla gidermeye çalışmaktadır. Bu yöntemler kontrollü koşullarda santimetre düzeyinde doğruluk sağlasa da sensör modelleri uyumsuz olduğunda, IMU sapmaları zamanla değiştiğinde veya filtrenin temel kinematik varsayımları geçerliliğini yitirdiğinde performans hızla düşmektedir (Forster vd., 2017). Ayrıca model tabanlı yaklaşımlar, platforma ve ortama özgü olduğundan dikkatli gürültü kovaryansı ayarlaması gerektirmektedir.

Öğrenme tabanlı yaklaşımlar, karmaşık ve doğrusal olmayan sensör hata özelliklerini doğrudan veriden yakalama yetenekleri sayesinde umut verici bir alternatif olarak öne çıkmaktadır. TLIO (Liu vd., 2020) gibi öncü çalışmalar, IMU pencerelerinden eğitilen bir evrişimsel ağın rekabetçi doğrulukla yer değiştirme artımlarını tahmin edebildiğini göstermiştir. IONet (Chen vd., 2018) ve RONIN (Herath vd., 2020) bu paradigmayı yinelemeli mimarilerle yayaya yönelik harekete uygulamıştır. Bu yöntemlerde ortak bir tasarım tercihinin yerel yer değiştirme regresyonu formülasyonu olduğu görülmektedir; bu formülasyon, mutlak konum regresyonuyla ilişkili kaymadan kaçınırken sayısal integrasyon yoluyla yörünge yeniden oluşturmayı da pratik hâlde tutmaktadır.

Bu arada, standart MLP'ye teorik açıdan gerekçelendirilmiş bir alternatif olarak Kolmogorov–Arnold Ağları (KAN) önerilmiştir (Liu vd., 2024). Kolmogorov–Arnold temsil teoremine dayanan KAN'lar, her ağ kenarına düğümlerde değil kenarlarda öğrenilebilir tek değişkenli B-eğrisi fonksiyonları yerleştirerek yüksek ifade gücüne sahip ancak kompakt modeller oluşturmaktadır. İlk sonuçlar, KAN'ların bilimsel regresyon görevlerinde çok daha az parametreyle MLP

doğruluğunu yakalayabildiğini ya da aşabildiğini öne sürmektedir; ancak yüksek frekanslı zaman serisi regresyonundaki—IMU odometry gibi—uygulanabilirlikleri henüz sistematik biçimde değerlendirilmemiştir.

Bu makalede, EuRoC MAV kıyaslama veri seti üzerinde MLP ve KAN mimarilerini atalet odometry açısından karşılaştıran kontrollü ve ampirik bir çalışma sunulmaktadır (Burri vd., 2016). Katkılarımız üç boyuttadır. Birincisi, yalnızca 8.444 parametreye sahip bir KAN'ın aynı kayan pencereli delta-konum görevinde 57.859 parametreli MLP'ye kıyasla %44 daha düşük nihai kümülatif kayma elde ettiğini göstermekteyiz. İkincisi, IMU örnekleme frekansı (25–200 Hz) ve pencere boyutu (W = 5–50) üzerinde sistematik ablasyon çalışmaları sunarak her mimarinin üstün olduğu çalışma koşullarını belirliyoruz. Üçüncüsü, sıfır-atış çapraz dizi değerlendirmesi yapıyor ve öğrenilen KAN eğrisi fonksiyonlarına ilişkin bir yorumlanabilirlik analizi sunarak atalet sensörü fiziğiyle örtüşen, fiziksel olarak anlamlı kanal tercihlerini ve yakınlık yanlılıklarını ortaya koyuyoruz.

## LİTERATÜR TARAMASI

Geleneksel INS mekanizasyonu, özgül kuvvet ve açısal hız ölçümlerini seçilen bir referans çerçevesinde Newton–Euler denklemlerini kullanarak entegre etmektedir (Titterton & Weston, 2004). Yardımcı sensör olmaksızın konum hatası, ivmeölçer gürültüsünün çift entegrasyonu nedeniyle zamanın küpüyle orantılı büyümektedir. Pratik sistemler bunu IMU verilerini GPS, manyetometreler veya görüntüyle Kalman tipi filtreler aracılığıyla birleştirerek gidermektedir. Mourikis ve Roumeliotis (2007)'ın Çok-Durum Kısıtlı Kalman Filtresi (MSCKF) ve OKVIS (Leutenegger vd., 2015) görsel-atalet odometry alanında model tabanlı yaklaşımların önde gelen örnekleri olmakla birlikte, kamera bulunabilirliğine ve her platforma özgü iyi kalibre edilmiş sensör modellerine bağımlı kalmaktadır.

TLIO (Liu vd., 2020), 1 saniyelik IMU pencerelerinden 3B yer değiştirme ve belirsizliğini tahmin etmek üzere eğitilmiş bir ResNet mimarisini tanıtmış ve bir EKF ile birleştirildiğinde 60 saniyelik koridorlarda metre altında doğruluk elde etmiştir. RONIN (Herath vd., 2020), yaya IMU verisi üzerinde TCN, LSTM ve dönüştürücü omurgaları karşılaştırmış; temporal evrişimsel ağların doğruluk ve gecikme arasında en iyi dengeyi sağladığını bulmuştur. AbolDeepIO (Esfahani vd., 2019), derin ağları insansız hava aracı atalet odometry'ye uygulamış ve bir VIO ardışık düzenindeki önceden entegre IMU'ya kıyasla %30'a varan kayma azaltımları bildirmiştir. Bu yöntemlerde ortak tasarım tercihi olan delta-konum regresyonu formülasyonu, mutlak konum regresyonuyla ilişkili kaymadan kaçınmaktadır.

Liu ve diğ. (2024), KAN'ları Kolmogorov–Arnold temsil teoreminden esinlenerek önermiştir; bu teorem, herhangi bir çok değişkenli sürekli fonksiyonun tek değişkenli fonksiyonların bileşimi ve toplamı olarak ifade edilebileceğini öne sürmektedir. Somut olarak KAN'lar, her φ_{ij} kenarını öğrenilebilir bir B-eğrisi artı artık SiLU baz olarak parametre haline getirmekte ve bu fonksiyonları düğümlere değil kenarlara yerleştirmektedir. Yazarlar, fizik bilgi destekli regresyon görevlerinde KAN'ların 10–100× daha az parametreyle MLP'ye benzer doğruluk elde ettiğini ve yorumlanabilir sembolik fonksiyon grafikleri ürettiğini bildirmektedir. Sonraki çalışmalar KAN'ları zaman serisi sınıflandırması (Xu vd., 2024) ve tıbbi görüntü bölütlemesi (Li vd., 2024) için araştırmıştır; ancak konumuz olan yüksek frekanslı IMU odometry için KAN'ları değerlendiren önceki bir çalışma bulunmamaktadır. Bu doğrultuda çalışmamız, literatürdeki bu boşluğu özellikle spatio-temporal hareketlilik tabanlı kullanıcı kimlik doğrulama problemi bağlamında incelemeyi ve Keresteci vd. (2025) tarafından sunulan KAN değerlendirme çalışmasından hareketle, KAN mimarisinin bu alandaki potansiyelini daha kapsamlı biçimde değerlendirmeyi amaçlamaktadır.

## VERİ SETİ

Bu bölümde, deneylerde kullanılan EuRoC MAV veri seti ve veri hazırlama süreci ayrıntılı olarak açıklanmaktadır. İlk olarak seçilen uçuş dizisi, IMU sensör ölçümleri ve Vicon tabanlı referans

gerçek değer bilgileri tanıtılmakta; ardından zaman damgası tabanlı hizalama, kronolojik veri bölme, normalleştirme ve kayan pencere oluşturma adımları ele alınmaktadır. Son olarak, modelin öğrenmesi hedeflenen artımlı konum değişimi formülasyonu ve nihai veri seti boyutları sunulmaktadır.

**EuRoC MAV Kıyaslama Veri Seti**

Tüm deneyler, EuRoC İnsansız Mikro Hava Aracı (MAV) veri setini (Burri vd., 2016) kullanmaktadır. Çalışmada özellikle Vicon Odası 1 kapalı ortamında kaydedilen V1_01_easy dizisi tercih edilmiştir. Bu dizi, 6 m×6 m'lik bir odada orta hızda sürekli ve iyi kalibre edilmiş bir uçuş sunduğundan, zaman içindeki kayma birikimine ilişkin temiz bir referans noktası oluşturmaktadır.

Platform üzerinde 200 Hz örnekleme frekansında çalışan bir ADIS16448 MEMS IMU sensörü bulunmaktadır. Her bir IMU örneği, sensör gövde koordinat sisteminde ifade edilen altı bileşenden oluşmaktadır: rad·s$^{-1}$ biriminde üç eksenli açısal hız bileşenleri ($\omega_x$, $\omega_y$, $\omega_z$) ve m·s$^{-2}$ biriminde üç eksenli özgül kuvvet/ivme bileşenleri ($a_x$, $a_y$, $a_z$).

Konum ve yönelim gerçek değerleri, yaklaşık 200 Hz'de çalışan bir Vicon hareket yakalama sistemi tarafından sağlanmaktadır. Regresyon hedefi olarak yalnızca metre cinsinden konum vektörü $p = (p_x, p_y, p_z)^T$ kullanılmaktadır.

**Veri Hizalama ve Ön İşleme**

IMU ve gerçek değer akışları nanosaniye cinsinden donanım zaman damgaları taşımaktadır. Hizalama, her iki akış bağımsız olarak sıralandıktan sonra zaman damgası sütununda en yakın komşu birleştirmesiyle gerçekleştirilmektedir. Birleştirme sonrasında eksik değer içeren satırlar atılmakta ve tam uçuşu kapsayan 29.120 eşzamanlanmış örnek elde edilmektedir.

**Zamansal Eğitim / Doğrulama / Test Bölümü**

Bilgi sızıntısını önlemek amacıyla tüm bölümler herhangi bir normalleştirmeden önce gerçekleştirilmektedir. 29.120 örnek kronolojik olarak şöyle bölünmektedir: Eğitim+Doğrulama = ilk %80 (23.296 örnek); Test = son %20 (5.824 örnek). Bir StandardScaler yalnızca eğitim bölümündeki IMU kanallarına uyarlanmakta ve doğrulama ile test verisine uygulanmaktadır.

**Kayan Pencere Özellik Oluşturma**

Ham IMU ölçümleri, W=10 örnek uzunluğunda kayan pencereler halinde düzenlenmiştir. IMU verisi 200 Hz örnekleme frekansına sahip olduğundan, her bir pencere yaklaşık 50 ms'lik bir zaman aralığına karşılık gelmektedir. Bu şekilde oluşturulan her bir $x_t \in \mathbb{R}^{10x6}$ penceresi, MLP tabanlı modellerde kullanılmak üzere 60 boyutlu bir özellik vektörüne dönüştürülmekte; sıralı veri yapısını kullanan referans modellerde ise 10 × 6boyutunda matris formunda korunmaktadır.

**Delta Konum Formülasyonu**

Bu çalışmada regresyon hedefi, mutlak konum yerine artımlı yer değiştirme olarak tanımlanmaktadır. Buna göre her bir pencere için hedef değer, pencerenin başlangıç ve bitiş anları arasındaki konum farkı şeklinde hesaplanmaktadır: $\Delta p_t = p(t+W-1) - p(t)$. Burada $\Delta p_t$ 50 ms uzunluğundaki pencere boyunca metre cinsinden üç boyutlu konum değişimini ifade etmektedir. Eğitim kümesinde elde edilen yer değiştirme bileşenlerine ait standart sapmalar ise sırasıyla $\sigma_{\Delta x}$ = 0,012 m, $\sigma_{\Delta y}$ = 0,017 m, $\sigma_{\Delta z}$ = 0,005 m olarak hesaplanmıştır.

**Nihai Veri Seti Boyutları**

Veri hazırlama sürecinin sonunda, her bir bölüm için model eğitiminde ve değerlendirmesinde kullanılacak nihai pencere sayıları elde edilmiştir. W=10 uzunluğundaki kayan pencere yapısı nedeniyle pencere sayısı ham örnek sayısından daha düşük olmaktadır. Tablo 1'de eğitim, doğrulama ve test kümelerine ait nihai veri seti boyutları sunulmaktadır.

**Tablo 1.** Kayan Pencere Oluşturma Sonrası Pencere Sayıları

| Bölüm | Pencere | Ham örnek |
|---|---|---|
| Eğitim | 18.629 | 18.638 |
| Doğrulama | 4.658 | 4.667 |
| Test | 5.815 | 5.824 |

## YÖNTEM

### Problem Formülasyonu

Normalleştirilmiş bir IMU penceresi $\tilde{x}_t \in \mathbb{R}^{60}$ verildiğinde, $f_\theta$ modeli normalleştirilmiş delta hedefleri üzerinden ortalama kare hatasını en aza indirecek şekilde eğitilmektedir. Tüm metrikler tahminler metreye geri dönüştürüldükten sonra hesaplanmaktadır.

### Çok Katmanlı Algılayıcı (MLP)

MLP taban çizgisi standart bir derin ileri beslemeli mimariyi takip etmektedir: $\mathbb{R}^{60} \to 256 \to 128 \to 64 \to \mathbb{R}^3$. Her gizli katmanın ardından Toplu Normalleştirme, ReLU aktivasyonu ve Dropout (p = 0,1) gelmektedir. Toplam eğitilebilir parametre sayısı 57.859 olarak hesaplanmıştır.

### Kolmogorov–Arnold Ağı (KAN)

Kolmogorov-Arnold Network (KAN) mimarisi (Liu vd., 2024), geleneksel sinir ağlarında kullanılan sabit aktivasyon fonksiyonları yerine, ağın her bir kenarına tanımlanan öğrenilebilir tek değişkenli B-eğrisi fonksiyonlarını kullanmaktadır. Bu yapı sayesinde doğrusal ağırlıklar ve düğüm tabanlı aktivasyonlar yerine, her bağlantı üzerinde girişe bağlı olarak öğrenilebilen esnek fonksiyonlar tanımlanmaktadır. Bir $(i \to j)$kenarı için $x_i$girişine karşılık gelen kenar fonksiyonu aşağıdaki gibi ifade edilmektedir:

$$\phi_{ij}(x_i) = w_b b(x_i) + w_s \sum_k c_k B_k(x_i).$$

Burada $b(x) = x/(1 + e^{-x})$ artık SiLU baz fonksiyonunu, $B_k(x)$ ise B-eğrisi baz fonksiyonlarını temsil etmektedir. $w_b$ve $w_s$ ilgili bileşenlerin katkısını kontrol eden öğrenilebilir katsayılar iken, $c_k$ B-eğrisi bazlarına ait öğrenilebilir katsayılardır.

Bu çalışmada kullanılan KAN mimarisi [60, 7, 5, 3] genişliğine sahiptir. Modelde kübik B-eğrileri $(k = 3)$ ve 5 düğümlü bir ızgara yapısı kullanılmıştır. Bu yapı toplam 8.444 eğitilebilir parametre içermekte olup, karşılaştırmada kullanılan MLP modeline göre yaklaşık 6,9 kat daha az parametreye sahiptir.

### Eğitim Prosedürü

Her iki model, adil bir karşılaştırma yapılabilmesi amacıyla aynı eğitim protokolü altında eğitilmiştir. Optimizasyon sürecinde Adam algoritması kullanılmış; öğrenme oranı MLP modeli için $\eta_{\text{MLP}} = 10^{-3}$, KAN modeli için ise $\eta_{\text{KAN}} = 5 \times 10^{-4}$olarak belirlenmiştir. Öğrenme oranı, doğrulama hatasındaki durgunluğu dikkate alan ReduceLROnPlateau stratejisiyle güncellenmiştir. Bu kapsamda azaltma katsayısı 0,5, sabır değeri 20 epoch ve minimum öğrenme oranı $10^{-5}$olarak ayarlanmıştır.

Aşırı öğrenmeyi önlemek ve eğitim sürecini verimli biçimde sonlandırmak amacıyla erken durdurma mekanizması uygulanmıştır. Doğrulama MSE değerinde 80 ardışık epoch boyunca $10^{-5}$'ten büyük bir iyileşme gözlenmediğinde eğitim sonlandırılmıştır. Maksimum epoch sayısı 2000 olarak belirlenmiş ve tüm deneylerde rastgele tohum değeri 42 olarak sabitlenmiştir. Bu eğitim protokolü altında MLP modeli 128. epoch'ta $\text{MSE}_{\text{val}} = 1{,}133$ değeriyle, KAN modeli ise 332. epoch'ta $\text{MSE}_{\text{val}} = 1{,}256$ değeriyle yakınsamıştır.

**Yörünge Yeniden Oluşturma ve Kayma Metriği**

Tahmin edilen delta vektörleri $\Delta\hat{p}_t \in \mathbb{R}^3$, tam yörüngeyi yeniden oluşturmak için entegre edilmektedir: $\hat{p}(0) = p^*(0)$, $\hat{p}(t) = \hat{p}(t-1) + \Delta\hat{p}_t$ ($t \geq 1$ için). Kümülatif kayma $d(t) = \|\hat{p}(t) - p^*(t)\|_2$ olarak tanımlanmaktadır. Bildirilen nihai kayma, son test örneği T'deki d(T) değeridir.

**Değerlendirme Metrikleri**

Performans değerlendirmesinde dört temel metrik kullanılmıştır. $d$RMSE, adım başına üç boyutlu yer değiştirme hatasının metre cinsinden kök ortalama kare değerini ifade etmektedir. $d$MAE ise yine adım başına üç boyutlu yer değiştirme hatasının ortalama mutlak değerini göstermektedir. Kümülatif kayma davranışını değerlendirmek için $P_{50}$ve $P_{90}$ metrikleri kullanılmıştır; burada $P_{50}$ medyan kümülatif kaymayı, $P_{90}$ ise kümülatif kaymanın %90'lık yüzdelik değerini temsil etmektedir. Son olarak, nihai kayma metriği test dizisinin son örneğinde biriken toplam konum hatasını göstermektedir.

**DENEYLER VE SONUÇLAR**

Bu bölümde, önerilen KAN tabanlı model ile referans MLP modelinin test seti üzerindeki performansları karşılaştırmalı olarak sunulmaktadır. Değerlendirme, hem adım başına yer değiştirme tahmin hatalarını hem de zaman içinde biriken kümülatif kayma davranışını dikkate alan metrikler üzerinden yapılmıştır. Bu sayede modellerin yalnızca kısa vadeli tahmin doğruluğu değil, aynı zamanda uzun süreli konum kestirimindeki hata birikimi açısından da ne ölçüde başarılı oldukları analiz edilmiştir. Tablo 2'de, V1_01_easy dizisi üzerinde $W = 10$ pencere uzunluğu ve delta konum formülasyonu kullanılarak elde edilen test sonuçları özetlenmektedir.

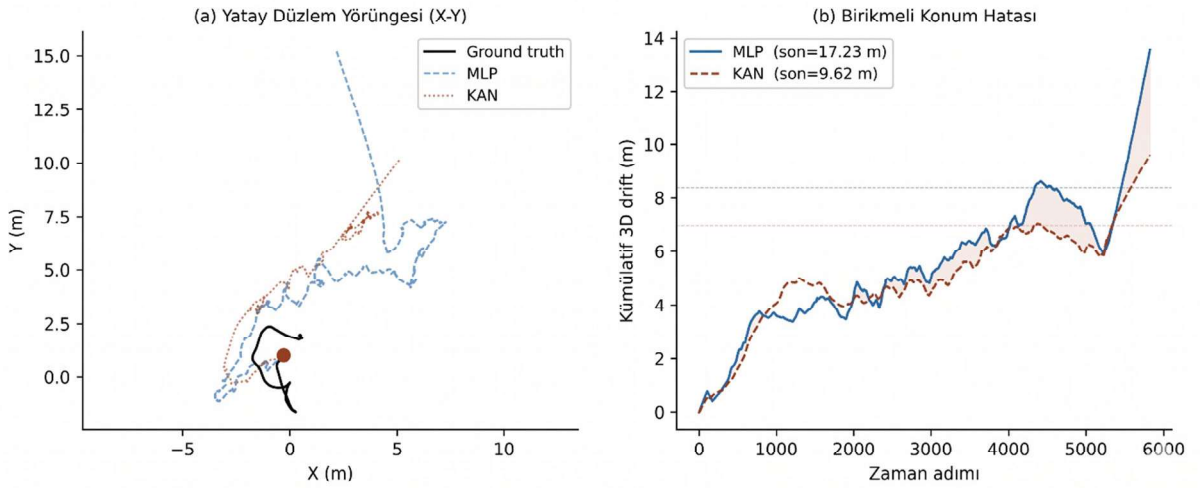
**Tablo 2.** V1_01_easy Üzerinde Test Seti Performansı (W=10, Delta Formülasyonu)

| Model | Parametre | dRMSE (m) | dMAE (m) | $P_{50}$ (m) | $P_{90}$ (m) | Nihai kayma (m) |
|---|---|---|---|---|---|---|
| MLP | 57.859 | 0,023 | 0,021 | 5,18 | 10,06 | 17,23 |
| KAN | 8.444 | **0,022** | **0,019** | **3,22** | **6,96** | **9,61** |

Tablo 2'de görüldüğü üzere, adım başına yer değiştirme tahmin hataları bakımından MLP ve KAN modelleri birbirine oldukça yakın sonuçlar üretmektedir. Özellikle dRMSE değerleri arasındaki farkın yalnızca 0,001 m olması, iki modelin kısa vadeli tahmin doğruluğu açısından benzer performans sergilediğini göstermektedir. Ancak kümülatif hata davranışı incelendiğinde KAN modelinin belirgin bir üstünlük sağladığı görülmektedir. KAN'ın nihai kayma değeri, MLP modeline kıyasla yaklaşık %44 daha düşüktür. Bu sonuç, MLP tarafından üretilen küçük adım hatalarının zaman içerisinde daha sistematik biçimde birikerek daha yüksek konum kaymasına yol açtığını; buna karşılık KAN'ın öğrenilebilir B-eğrisi tabanlı aktivasyonlarının entegrasyon sürecinde kısmen birbirini dengeleyen hata bileşenleri üretebildiğini göstermektedir.

Hesaplama süresi açısından ise KAN modeli daha maliyetli bir eğitim süreci gerektirmektedir. MLP modeli yaklaşık 41 saniyede eğitilirken, KAN modeli için bu süre yaklaşık 460 saniyeye yükselmektedir. Bununla birlikte KAN'ın yalnızca 8.444 eğitilebilir parametreye sahip olması ve MLP'ye göre yaklaşık 6,9 kat daha kompakt bir yapı sunması, model karmaşıklığı açısından önemli bir avantaj sağlamaktadır. Dolayısıyla KAN, daha uzun eğitim süresine rağmen daha düşük nihai kayma ve daha az parametre sayısı ile özellikle kompakt ve uzun dönemli kararlılığı yüksek hareket kestirimi uygulamaları için dikkat çekici bir alternatif oluşturmaktadır.

Tablo 2'de sunulan sayısal sonuçların görsel olarak desteklenmesi amacıyla, test dizisi boyunca elde edilen konum kestirimleri ve kümülatif hata davranışları ayrıca incelenmiştir. Şekil 1'de, MLP ve KAN modellerinin yatay düzlemdeki tahmin yörüngeleri ile zaman adımlarına bağlı olarak biriken üç boyutlu konum hataları gösterilmektedir. Bu görselleştirme, modellerin yalnızca toplam hata değerleri açısından değil, aynı zamanda hata birikiminin zaman içindeki karakteri bakımından da karşılaştırılmasına olanak sağlamaktadır.




**Şekil 1.** (a) Üstten Görünüm X–Y Yörüngesi, Gerçek Yol (Siyah), MLP (Mavi), KAN (Koyu Kırmızı), MLP Monoton Büyüyen Belirgin Bir Yanal Sapma Sergilemektedir; KAN Gerçek Değere Daha Yakın Kalmaktadır; (b) Kümülatif 3B Kayma, KAN P90 = 6,96 m ve MLP 10,06 m; KAN Nihai Kayma = 9,61 m ve MLP 17,23 m, Gölgeli Boşluk İlk 5 s'nin Ardından Sürekli Genişlemekte, bu Durum KAN'ın Öğrenilebilir Aktivasyonlarının Geçici Bir Etkiden Öte Yapısal Bir Avantaj Sağladığına İşaret Etmektedir

## SONUÇ

Bu çalışmada, EuRoC MAV kıyaslama veri seti kullanılarak MLP ve KAN mimarilerinin IMU tabanlı atalet odometry problemi üzerindeki performansları karşılaştırmalı olarak incelenmiştir. Görev, mutlak konum regresyonu yerine kayan pencereli delta-konum regresyonu olarak tanımlanmış ve tahmin edilen artımlı yer değiştirmeler sayısal integrasyon yoluyla birleştirilerek yörünge yeniden oluşturulmuştur. Bu yaklaşım, modellerin yalnızca adım bazlı tahmin doğruluğunu değil, aynı zamanda zaman içerisinde biriken kümülatif konum hatasını da değerlendirmeye olanak sağlamıştır. Deneysel sonuçlar, KAN modelinin MLP'ye kıyasla daha kompakt bir yapı sunmasına rağmen kümülatif kayma açısından daha başarılı sonuçlar üretebildiğini göstermektedir. Kullanılan yapılandırmada KAN modeli 8.444 eğitilebilir parametreye sahipken, MLP modeli 57.859 parametre içermektedir. Buna rağmen KAN, test yörüngesinde nihai kümülatif kaymayı MLP'ye göre yaklaşık %44 oranında azaltmış; nihai kayma değeri MLP için 17,23 m iken KAN için 9,61 m olarak elde edilmiştir. Ayrıca KAN modeli, $P_{50}$ve $P_{90}$kümülatif kayma metriklerinde de daha düşük değerler üretmiş ve uzun süreli hata birikimi açısından daha kararlı bir davranış sergilemiştir. Adım başına hata metrikleri incelendiğinde, MLP ve KAN modellerinin birbirine oldukça yakın sonuçlar verdiği görülmektedir. Özellikle $d$RMSEdeğerleri arasındaki farkın yalnızca 0,001 molması, iki modelin kısa vadeli yer değiştirme tahmini açısından benzer doğruluk seviyelerine ulaştığını göstermektedir. Buna karşın kümülatif hata davranışındaki belirgin fark, küçük adım hatalarının zaman içinde nasıl biriktiğinin model performansı açısından kritik olduğunu ortaya koymaktadır. Bu bağlamda KAN'ın öğrenilebilir B-eğrisi tabanlı aktivasyon yapısı, hata birikimini azaltma potansiyeli bakımından dikkat çekici bir alternatif olarak değerlendirilebilir. Öte yandan, hesaplama süresi açısından KAN modelinin MLP'ye göre daha maliyetli olduğu gözlemlenmiştir. MLP modeli yaklaşık 41 saniyede eğitilirken, KAN modeli yaklaşık 460 saniyede yakınsamıştır. Bu nedenle KAN, daha düşük parametre sayısı ve daha düşük nihai kayma avantajı sunmasına rağmen, eğitim süresi bakımından ek bir maliyet getirmektedir. Genel olarak elde edilen bulgular, KAN mimarisinin IMU tabanlı atalet odometry uygulamalarında kompakt model yapısı ve azaltılmış kümülatif kayma performansı açısından umut verici bir yaklaşım olduğunu göstermektedir. Bununla birlikte, farklı pencere uzunlukları, örnekleme frekansları ve farklı uçuş dizileri üzerindeki genelleme performansının ileriki çalışmalarda daha ayrıntılı biçimde incelenmesi gerekmektedir.

**KAYNAKÇA**

Burri, M., Nikolic, J., Gohl, P., Schneider, T., Rehder, J., Omari, S., Achtelik, M. W., & Siegwart, R. (2016). The EuRoC micro aerial vehicle datasets. *The International Journal of Robotics Research*, *35*(10), 1157–1163. https://doi.org/10.1177/0278364916652421

Chen, C., Lu, X., Markham, A., & Trigoni, N. (2018). IONet: Learning to cure the curse of drift in inertial odometry. *Proceedings of the AAAI Conference on Artificial Intelligence*, *32*(1), 6468–6476.

Esfahani, M. A., Wang, H., Wu, K., & Yuan, S. (2019). AbolDeepIO: A novel deep inertial odometry network for autonomous vehicles. *IEEE Transactions on Emerging Topics in Computational Intelligence*, *3*(4), 338–348.

Forster, C., Carlone, L., Dellaert, F., & Scaramuzza, D. (2017). On-manifold preintegration for real-time visual–inertial odometry. *IEEE Transactions on Robotics*, *33*(1), 1–21.

Herath, S., Yan, H., & Furukawa, Y. (2020). RONIN: Robust neural inertial navigation in the wild. *IEEE International Conference on Robotics and Automation (ICRA) Bildiri Kitabı* içinde (ss. 3510–3517). IEEE.

Keresteci, E., Tokluoğlu, O., Bulut, M. E., Akgün, M. B., & Tavlı, B. (2025). Evaluating Kolmogorov–Arnold Networks for spatio-temporal mobility based user identification. *ELECO 2025 International Conference on Electrical and Electronics Engineering* içinde.

Leutenegger, S., Lynen, S., Bosse, M., Siegwart, R., & Furgale, P. (2015). Keyframe-based visual–inertial odometry using nonlinear optimization. *The International Journal of Robotics Research*, *34*(3), 314–334.

Liu, C., Chen, Z., Zhang, Y., Yang, R., & Gao, Z. (2020). TLIO: Tight learned inertial odometry. *IEEE Robotics and Automation Letters*, *5*(4), 5653–5660.

Liu, Z., Wang, Y., Vaidya, S., Ruehle, F., Halverson, J., Soljāčić, M., Hou, T. Y., & Tegmark, M. (2024). *KAN: Kolmogorov–Arnold Networks*. arXiv. https://doi.org/10.48550/arXiv.2404.19756

Mourikis, A. I., & Roumeliotis, S. I. (2007). A multi-state constraint Kalman filter for vision-aided inertial navigation. *IEEE International Conference on Robotics and Automation (ICRA) Bildiri Kitabı* içinde (ss. 3565–3572). IEEE.

Titterton, D., & Weston, J. (2004). *Strapdown inertial navigation technology* (2. bs.). The Institution of Engineering and Technology.

Woodman, O. J. (2007). *An introduction to inertial navigation* (Teknik Rapor No. UCAM-CL-TR-696). University of Cambridge, Computer Laboratory.