



# Makine Öğrenmesi İle Ataletsel Navigasyon Sistemlerinde Doğruluğun İyileştirilmesi

## Improving Accuracy of Inertial Navigation Systems with Machine Learning

Fatih Şahin<sup>1</sup>, Faruk Ulaşım<sup>2</sup>

<sup>1</sup> Durali Alıç Mah. 925 Sok. 2/12 06480 Ankara, TÜRKİYE

<sup>2</sup> Sağlık Mahallesi Hacılar Kasabası Hacılar Hüseyin Aytemiz Meslek Yüksekokulu 71300 Kırıkkale, TÜRKİYE

Başyuru/Received: 10/06/2022

Kabul / Accepted: 31/01/2023

Çevrimiçi Basım / Published Online: 31/01/2023

Son Versiyon/Final Version: 31/01/2023

### Öz

Ataletsel navigasyon sistemleri, genellikle bünyesindeki Ataletsel Ölçüm Biriminden (AÖB) aldığı algılayıcı verilerini kullanarak hava, kara ve deniz araçlarının konumlarını bulabilmesine yardımcı olmaktadır. Son dönemlerde bu teknoloji ayağa veya vücudun çeşitleri yerlerine entegre edilerek giyilebilir hale getirilmektedir, fakat bu sistemlerin en büyük dezavantajı, kullanılan sensörler nedeniyle hataların zamanla artmasıdır. Bu hataları minimize etmek konum doğruluğu açısından büyük önem taşımaktadır. Ayağa takılı ataletsel ölçüm birimi ile yapılan ataletsel navigasyon sistemlerinde (ANS), sıfır hız algılama (SHA) işleminin doğru tespit edilmesi ölçüm hatalarını düşüren en önemli etkidir. Bu çalışmada, SHA'yı daha doğru bir şekilde yapabilmek için Tekrarlayan Sinir Ağı (TSA/RNN) yöntemi olan uzun kısa süreli bellek (UKSB/LSTM) kullanılmıştır. Bu yöntem sensör verilerini kullanarak sıfır hız algılama için ikili bir sınıflandırma yapmaktadır. Önerilen yöntemle yapılan ANS ölçümleri farklı ortamlar için uygulanmış ve standart ANS' den daha yüksek hassasiyette ölçümler yaptığı görülmüştür.

### Anahtar Kelimeler

“Ataletsel Navigasyon, Ataletsel Algılama, Ataletsel Ölçüm Birimi, Ölü Hesaplama, Sıfır Hız Algılama, Makine Öğrenmesi”

### Abstract

Inertial navigation systems help various air, land and sea vehicles to find their positions by using the sensor data received from an Inertial Measurement Unit (IMU). Recently, this technology has become wearable by integrating to the feet or various parts of the body, but the biggest disadvantage of these systems is that their errors grow with time due to the sensing quality of sensors used. Minimizing these errors is of great importance in terms of location accuracy. In inertial navigation systems (INS) made with an inertial measurement unit mounted on the foot, the correct determination of the zero velocity update (ZVA) process is the most important factor reducing the measurement errors. In this study, long short-term memory (LSTM), a Recurrent Neural Network (RNN) method, was used to detect zero velocity state more accurately. This method makes a binary classification for zero velocity detection using sensor data. INS measurements made with the proposed method have been applied for different environments and it has been observed that it provides measurements with higher precision than standard INS.

### Key Words

“Inertial Navigation, Inertial Sensing, Inertial Measurement Unit, Dead Reckoning, Zero Velocity Detection, Machine Learning”

## 1. Giriş

Günümüzde, herhangi bir cismin konumunu belirlemek için kullanılan en yaygın yöntem GNSS sistemlerinin kullanılmasıdır. Cep telefonlarından araç navigasyon sistemlerine kadar çok geniş bir alanda kullanılan bu sistemler, açık alanlarda yüksek hassasiyette çalışırken, özellikle kapalı alanlarda aynı performansı gösterememektedir. Çünkü kapalı ortamlarda duvar, eşya, insan, vb. çeşitli engeller elektromanyetik dalgaların yayılımını etkileyerek sönümlenmesine neden olmaktadır. Sönümlenen elektromanyetik dalgalar ve diğer telsiz cihazlardan kaynaklanabilecek girişim ya da gürültü konum belirlemeyi zorlaştırmaktadır. (Curran vd., 2009; Gu vd. 2009)

Kapalı ortamlarda konum belirlemek açık ortamlara göre daha zor bir problem olduğundan, işlem karmaşıklığı düşürmek için yeni yöntemlere ihtiyaç duyulmaktadır. (Curran vd., 2009; Gu vd. 2009) GNSS sinyallerinin kullanılmadığı kapalı alan konumlandırma için Radyo Frekansı Tanımlama (RFID), Kablosuz Yerel Alan Ağı (WLAN/WIFI) ve Ultra Geniş Bant (UWB) gibi yöntemler kullanılmaktadır.

RFID ile yapılan konum belirleme işlemlerinde, navigasyon sistemi içine gömülü mutlak konum bilgisi kullanılmaktadır. Bir nesnenin kimliğini (örn. seri numarası) ve diğer özelliklerini kablosuz olarak iletmek için radyo dalgalarını kullanan RFID (radyo frekansı tanımlama), nesnelere veya kişilerin hareketlilik takibine olanak tanıyan, gelişmekte olan bir konumlandırma teknolojisidir. Bir metreden daha az sınırlı bir tespit aralığı sunduğundan, RFID kapsamlı konumlandırma için değil, seçici bir nesne tanımlaması için uygundur. Bunun dışında uygun maliyetlidir, bakımı kolaydır ve hem tanımlama hem de konum sağlar. Bu, RFID aracılığıyla konumlandırmayı özellikle endüstriyel ortamlardaki (örneğin varlık yönetimi) izleme çözümleri için uygun hale getirir (Fu vd., 2009). WLAN sistemlerinde RSSI (Received Signal Strength Intensity) yöntemi ile konum bulma teknolojisi ise daha çok hastaneler, üniversiteler, vb. umuma açık olan yerlerde yaygın olarak konum belirlemede kullanılan bir yöntemdir. Kapalı mekânlardaki mevcut WLAN altyapısının kullanılarak konum belirlemenin yapılabilmesi maliyeti düşürmektedir. WLAN sinyal gücüne bağlı olan konum tahminlerinin doğruluğu kapalı ortamdaki engellerden olumsuz etkilenmektedir (Gu vd. 2009).

Bir diğer yöntem olan Ultra geniş band (UWB) sensör teknolojisi, kısa menzilli yüksek band genişliği iletişimde kullanılan bir radyo teknolojisidir. UWB, 500 MHz'den daha yüksek bant genişliğine sahiptir ve bu nedenle sinyaller genellikle birden fazla yolla alıcıya ulaşmaktadır. Bununla birlikte, yüksek bant genişliği farklı frekansların farklı zamanlarda kullanılmasına olanak tanımaktadır ve bu sayede çoklu yol problemlerine ve bozucu etkilere karşı bir çözüm olarak kullanılabilir. RFID, UWB ve WLAN gibi yöntemlerle yapılan konum belirleme işlemleri, kapalı alan içerisinde bir altyapı kurulumu gerektirmektedir (kapalı alanın olduğu yere kurulacak sensörler). Bundan dolayı alternatif bir yaklaşım ise, küçük, düşük güçlü, ucuz olma ve herhangi bir harici altyapıya veya işaret noktasına dayanmama avantajına sahip olan, genellikle bir AÖB olarak yapılandırılan ataletsel sensörleri kullanmak olabilir, fakat bu yöntemin de avantajları ve dezavantajları vardır.

Ataletsel navigasyon sistemleri, çeşitli sensörleri kullanarak, seyir halindeki uçak, kara araçları, füzeler, deniz araçları gibi çeşitli araçlar ile son yıllarda giyilebilir sensörler yardımıyla konumlarını bulmasına yardımcı olmaktadır. Ataletsel navigasyon sistemleri hâlâ başlangıç aşamasında olmasına rağmen, bu algoritmaların insan konumlandırma alanına aktarılması, acil durum ortamlarında personeli koordine etmek için hayati önem taşıyabilmektedir. Örneğin itfaiyeciler gibi ilk müdahale ekipleri için, ekip üyelerinin konumlarını gerçek zamanlı olarak takip etme yeteneği, daha etkili müdahale stratejilerini kolaylaştırabilmektedir ve beklenmedik olaylar veya yaralanmalar durumunda personelin çıkarılmasını hızlandırabilmektedir (Fischer vd., 2010). Ataletsel sensör tabanlı sistemler ortamdaki ve yüksek veri hızı ile sürekli navigasyon bilgisi sağlayabilmektedir. AÖB'leri tipik olarak sırasıyla açısal hız ve doğrusal ivmeyi ölçen birbirine dik yerleştirilmiş üç hız dönüölçer ve yine birbirine dik yerleştirilmiş üç ivmeölçer içermektedir. İvmeölçer, üç ekseninde üç ayrı analog sinyal üretmektedir. Bu nedenle jiroskoplar ve ivmeölçerler tek başına güvenilir ve kararlı veri sağlanamamaktadır ve tek başına kullanıldığında belirli bir süre sonra kaymaktadır. (Nilsson vd., 2012)

Mikroelektromekanik sistemler (MEMS) kullanan nispeten ucuz ataletsel sensörleriyle uygulanan yaklaşımlar yalnızca kısa süreler için doğrudur, çünkü işlenmemiş sensör tahminleri ve gürültüler hızla daha düşük kalitede tahminlere yol açmaktadır. ANS ile konum alınan sistemlerde, hataların zamana bağlı büyümesi nedeniyle büyük konum hatalarıyla karşılaşabilmektedir. Bu hatalar sensör kaynaklı veya uygulanan yöntem sebebiyle oluşan hatalardır. Sonuç olarak, düşük maliyetli AÖB hatasını düzeltmek için harici sensörlerden sık sık ölçüm güncellemeleri yapılmadıkça, konumlandırma uygulamaları için kullanımı nispeten sınırlı olmaktadır. Öte yandan, önemli sayıda kısıtlamaya sahip kapalı ortamlarda, ortamın haritası hakkında ön bilgi, hata büyümesini önemli ölçüde azaltmaya yardımcı olabilmektedir.

Navigasyon sistemlerinin güvenilirliğini artırmak için, sadece sensör derecesini yükseltmek yerine, bir navigasyon sisteminde başka sensörler veya ölçümler kullanmak daha verimli bir yol olmaktadır (Skog vd., 2010). Görüntü sensörleri (örneğin, kamera, hiper-spektral sensörler ve lazer mesafe bulucu gibi), haritalama ve ortam tespiti için yaygın olarak kullanılmaktadır. Bu yaklaşım, kameranın yönünün tahmini, aydınlatma koşulları ve çerçevelerdeki özelliklerin benzersizliği ile sınırlıdır. Son zamanlarda, ANS'yi ayakbağı'ya takma konsepti, yaya navigasyonu için düşük maliyetli ANS'yi mümkün hale getirmektedir. Bu, ayağın yerdeyken kısa bir süre sabit kalması gerektiği gibi önemli bir avantaj sağlamaktadır. Bir yaya ister yürüyor, koşuyor, ya da isterse merdiven çıkıyor olsun, atılan

her adımda, ayakkabıya takılan bir AÖB'nin hata düzeltilmesi için sıfır hız ölçümü sağlayabilen bir duruş aşaması vardır. Bu yaklaşıma SHA denir.

Literatürde yaygın olarak kullanılan SHA yöntemi, takip edilen kişinin yürürken ölçülen birikimli hatanın bastırılması amacıyla ayağın yere temas ettiği andaki duruş durumunu tespit etmektedir. Bu süre boyunca hız hataları Kalman filtresine gönderilir. Genel olarak tahmin teorisi ve özel olarak Kalman filtreleme, çeşitli sensörlerden gelen bilgileri birleştirmek için teorik bir çerçeve sağlamaktadır. Filtre, dahili navigasyon durum değişkenlerinin düzeltilmesi için ANS'ye geri beslenen "duruş" aşamasından faydalanarak hataları tahmin etmektedir. SHA işlemi yalnızca kullanıcının hızını düzeltmekle kalmaz, aynı zamanda konum ve yönelim hatalarını kısıtlamaya ve sensör hatalarını tahmin etmeye de yardımcı olur. Bu nedenle, ANS ölçümlerinde tekrarlanan bu düzeltmeler, hata büyümesini azaltabilir ve konum kaymasını en aza indirebilir. Sonuç olarak, her adımda duruş aşamasını doğru bir şekilde belirlemek ve ardından AÖB hata düzeltilmesi için SHA'yı uygulamak çok önemlidir. Doğru bir şekilde tanımlanırsa, sıfır hız güncellemeleri konumlandırma tahminlerini önemli ölçüde iyileştirebilmektedir. Bununla birlikte, yanlış pozitif algılamalar (sensörlerin olması gerekenden daha fazla değer algılamaları), kullanıcının yörüngesinin uzunluğunun daha az alınmasına neden olurken, yanlış negatif algılamalar (yani, örnekleme veya sensör kaynaklı olarak bazı ölçümlerin alınmaması) hızlı ve sınırsız hata büyümesine yol açmaktadır.

Doğru ve güvenilir sıfır hız tespiti, güncel bir araştırma problemidir. Yürüme, koşma ve merdiven çıkma periyotlarını içeren genel hareket sırasında mevcut sistemlerin yüksek doğrulukta konumlandırma yapabilmesi için önemli ilerlemeler kaydedilmesi gerekmektedir.

Bu çalışmada sıfır hız durumlarını doğrudan sınıflandırmak için bir RNN türü olan uzun kısa süreli bellek (LSTM) sinir ağı eğitilmiş ve eşik ayarlama ihtiyacı ortadan kaldırılmıştır. Bununla birlikte ham veriler kullanılarak elde edilen sıfır hız destekli ANS çözümüyle karşılaştırılarak doğrulukları kıyaslanmıştır. Farklı rotalarda elde edilen konum verileri ve sıfır hız destekli bir ANS'nin hareket tahminlerini önemli ölçüde iyileştirdiği nicel verilerle gösterilmiştir.

## 2. Materyal ve Yöntem

Standart bir ANS'de, AÖB lineer ivmeleri ve açısız hızları ölçer, bunlar daha sonra navigasyon çerçevesine döndürülür ve zamanın bir fonksiyonu olarak durum güncellemeleri sağlamak için integral alınmaktadır. MEMS tabanlı nispeten ucuz ataletsel sensörler ile bu yaklaşım, sensör hataları ve gürültü hızla giderek daha düşük kalite tahminlerine yol açtığından, yalnızca kısa süreler için doğrudur.

Ataletsel sensör kaymasıyla başa çıkmak için kullanılan tekniklerden birisi (harici yardım veya mevcut haritalar gerektirmeyen), AÖB'yi bir insanın ayağına monte etmek ve sıfır hız güncelleme amacıyla kullanmaktır. Bu güncellemeler insanın ayağının yerde düz olduğu ve navigasyon eksen takımına göre sabit olduğu hareket kısmı sırasında meydana gelen hız durum değişkeninin sahte ölçümleridir. Genişletilmiş Kalman filtresi (EKF) gibi bir Bayes filtresi aracılığıyla ANS'ye bu tür sahte ölçümleri dahil ederek, konum bulma, ayak hareketleri arasındaki aralıklarla sınırlandırılır (Foxlin vd., 2005).

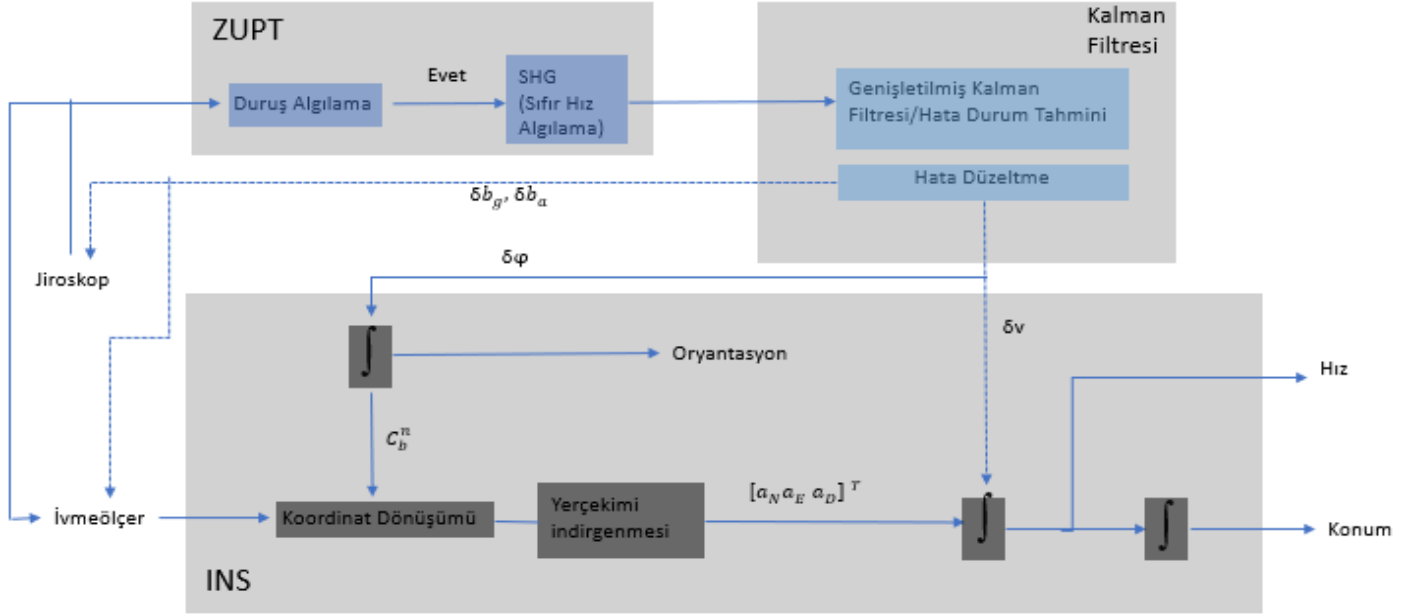
Sıfır hız algılamanın tipik yöntemi, ayağın sabit olduğu zamandaki noktayı/noktaları tahmin etmek için AÖB okumalarını kullanan bir olabilirlik oranı testidir (LRT). LRT tipik olarak iki koşulun buluşsal bir göstergesidir: (1) Ölçülen AÖB doğrusal ivmesinin büyüklük olarak eşit ve yerel yerçekimi vektörüne zıt yönde olması ve (2) ölçülen açısız hız normunun sıfır olması. Uygulamada, bu koşullar hiçbir zaman tam olarak yerine getirilmeyecektir; daha ziyade, bu deneysel yöntemler, bir eşikleme prosedürünün uygulanabileceği ölçülebilir bir ölçü içinde kodlanmaktadır.

Eşik parametresi, tipik olarak, minimum konum hatasına (Skog vd., 2010) yol açan değer seçilerek belirli bir veri kümesi için ayarlanır ve ardından gelecekteki deneyler sırasında sabitlenmektedir. Bununla birlikte, sabit bir eşik yalnızca tek tip hareketler için uygundur ve bu, doğası gereği "dinamik" olan hareketler sırasında dedektörün etkinliğini sınırlamaktadır. Dinamik hareketler, ayak zeminle temas ettiğinde çeşitli hızlanma ve açısız hız profilleri ile sonuçlanmaktadır. Sıfır hız algılama deneysel yöntemleri bu miktarlara bağlı olduğundan, dinamik hareketler boyunca güvenilir bir şekilde çalışması için tek bir sabit eşik dedektörünü ayarlamak zorlaşmaktadır. Çok düşük bir eşik, ayak altında sabitken tespitlerin rapor edilememesine yol açarken, çok yüksek bir eşik, ayak hareket ederken yanlış sıfır hız olaylarına yol açmaktadır. Her iki durum da telafi edilemeyen hata birikimine neden olmaktadır (Nilsson vd., 2012).

Sabit eşikli sıfır hız dedektörlerini geliştirmek için literatürdeki çeşitli yöntemler, kullanıcının hareketine uyum sağlayan değişken bir eşik belirlemeye çalışmaktadır. Örneğin, bir Bayes algılama modeli varsayılarak, eşik sıfır hız hipotezinden önce zamana göre değişen bir faktöre ve kaçırılan algılamalar için zamanla değişen bir kayıp olarak hesaba katılabilir (Wahlström vd., 2019). Alternatif olarak, eşik yürüyüş frekansının (Tian vd., 2016), tahmini lineer hızın (Walder vd., 2010; Ren vd., 2016) veya tahmini açısız hızın (Ma vd., 2017) bir fonksiyonu olarak açıkça modellenilebilir. Bununla birlikte, her tür hareket için uygun bir eşik uygulayan bir model geliştirmek zor olmaya devam etmektedir.

Bu çalışmada, SHA işlemi, sınıflandırma tabanlı bir makine öğrenmesi yöntemi olan RNN tabanlı LSTM ile yapılmıştır. Çalışmadaki yaklaşıma uygun olarak, sıfır hız eşiklerini uyarlamalı olarak güncellemek için veriye dayalı hareket sınıflandırması kullanılmıştır. AÖB

durağan olduğunda doğrudan sınıflandırmak için tekrarlayan bir sinir ağını eğiterek tamamen öğrenmeye dayalı bir strateji benimsenmiştir. SHA yönteminin kullanıldığı ANS ile SHA kullanılan fakat eğitilmemiş ANS' ler çeşitli deneysel ortamlarda kıyaslanmış ve SHA yönteminin kullanıldığı ANS lerin daha iyi sonuç verdiği gözlemlenmiştir.



Şekil 1. SHG ve Kalman Filtresi kullanılarak hata üretiminin azaltılmaya çalışıldığı standart bir ANS çözüm şeması

## 2.1. Sıfır Hız Güncellemeli Ataletsel Navigasyon Sistemi

Sistem, kullanıcının hareketini atalet verilerinden tahmin etmek için bir hata durumlu genişletilmiş Kalman filtresi (EKF) kullanır.  $k$  adımındaki filtre durumu için, AÖB'nin konumu ( $p_k$ ), hız ( $v_k$ ) ve oryantasyonun ( $q_k$ )dan oluşur, tümü sabit bir yerel navigasyon çerçevesine göre ifade edilir,

$$x_k = [p_k^T \ v_k^T \ q_k^T]^T \quad (I)$$

Nominal durum, ayrık zamanlı doğrusal olmayan bir hareket modeli (Nilsson vd., 2014) kullanılarak ileriye doğru yayılır,

$$x_k = [p_k \ v_k \ q_k] = \left[ p_{k-1} + p_{k-1} + v_{k-1} \Delta t \ v_{k-1} + (R(q_{k-1})a_k + g) \Delta t \ \Omega(w_k \Delta t) q_{k-1} \right] \quad (II)$$

burada  $q_{k-1}$ ,  $\Delta t$  aralığı boyunca artan AÖB dönüşü ile  $w_k$  açışal hızının entegre edilmesiyle güncellenir. Hız ( $v_{k-1}$ ), navigasyon çerçevesinde ivme vektörünü ifade ettikten ve yerçekiminden kaynaklanan katkıyı kaldırdıktan sonra,  $a_k$  ile güncellenir. Son olarak,  $p_{k-1}$  konumu, integral alınmış hız terimi ile güncellenir. Birinci dereceden Euler entegrasyon yöntemini uygulandığını, ancak diğer yüksek dereceli entegrasyon şemalarının da kullanılabileceğini unutmamak gerekmektedir.

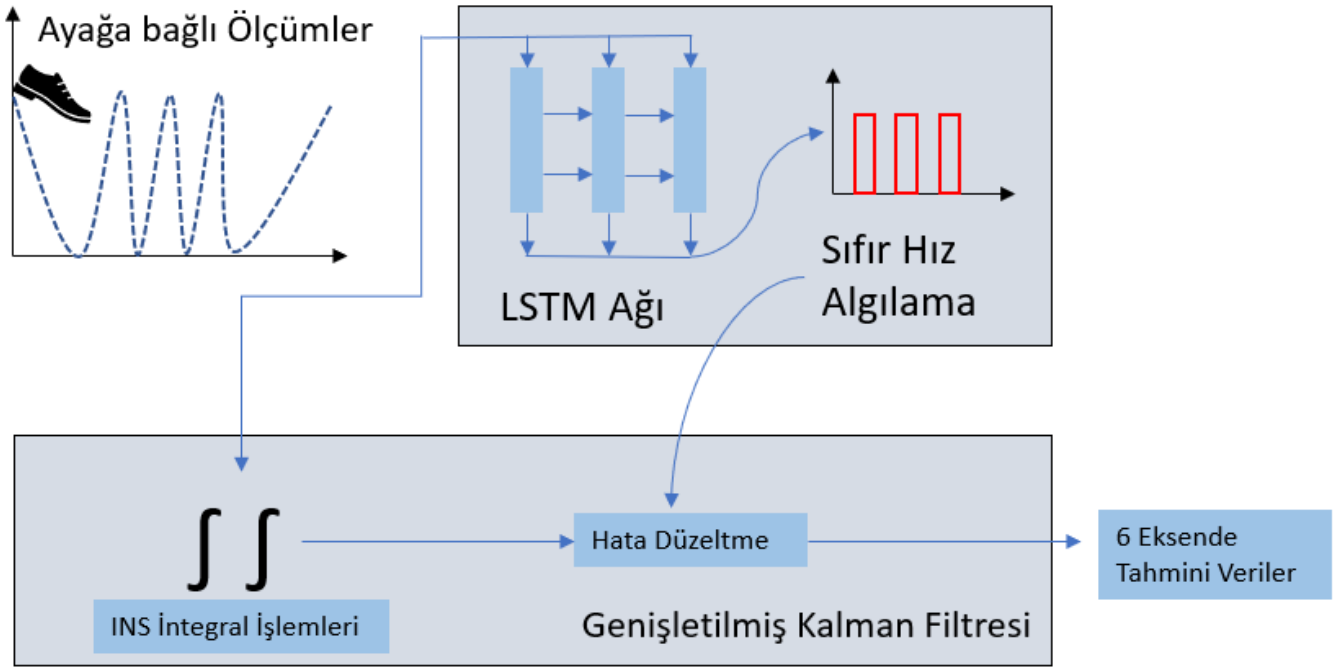
Bu model ivmeölçer veya jiroskop hatalarını içermez (sıfır hız tespiti yoluyla gözlemlenebilseler de), çünkü Nilsson (2012)'de bahsedildiği gibi, sıfır hız varsayımından kaynaklanan yanlışlıklar baskın hata kaynağıdır. Nominal duruma paralel olarak, sistemdeki gürültü ve bozulmaları izlemek için hata durumu zaman içinde ileriye doğru yayılır. Sıfır hız durumu tespit edildiğinde, hız hatasının bir tahminini üretmek için mevcut hız durumu sıfır ile karşılaştırılır. Sıfır hızlı sözde ölçümün ek Gauss gürültüsü tarafından bozulduğu olağan varsayımını yapılır ve standart EKF düzeltme adımı uygulanır.

## 2.2. RNN Tabanlı Sıfır Hız Sınıflandırması

Uzun Kısa Süreli Bellek ağları – genellikle “LSTM” olarak adlandırılır – uzun süreli bağımlılıkları öğrenebilen özel bir RNN türüdür. İlk defa Hochreiter & Schmidhuber (1997) tarafından kullanılmış ve sonraki çalışmalarda birçok kişi tarafından geliştirilip, popüler hale getirilmiştir. Çok çeşitli problemler üzerinde çok iyi çalışmalar ve günümüzde yaygın olarak kullanılmaktadırlar.

RNN'ler, uzun vadeli bağımlılık sorununu önlemek için tasarlanmıştır. Bilgileri uzun süre hatırlamak, pratik olarak onların varsayılan davranışdır, öğrenmekte zorlandıkları bir şey değildir. Sıfır hız algılamaya yönelik öğrenmeye dayalı yaklaşım, sıfır hız detektörünü tamamen tekrarlayan bir sinir ağı (RNN) ile değiştirerek çoğu modelleme varsayımını (örneğin, farklı hareket sınıflarının varsayımı)

ortadan kaldırır. Sıfır hız etiketleriyle atalet ölçümleri içeren bir veri kümesinden sıfır hız tespitinde ikili bir sınıflandırıcıyı eğitmek için denetimli bir öğrenme yaklaşımı kullanılmaktadır.



Şekil 2. RNN eklenerek SHG yapılan geliştirilmiş ANS çözümü

Atalet ölçümleri sıralı ve düşük boyutludur (zaman adımı başına altı değer), bu da onları dizi öğrenimi için çok uygun hale getirir. Kısa bir veri dizisini kullanan klasik sıfır hız algılama yöntemlerinin aksine, bir RNN, bellek durumunu uzun giriş dizileri arasında yayabilir. Bu nedenle ağ, sınıflandırma sırasında zamansal bağlamdan faydalanabilir ve insan yürüyüşünün periyodik doğasından yararlanabilir. Uygulanan yaklaşım, sıralı veri işleme için popüler bir seçim olan uzun kısa süreli bellek (LSTM) ağı adı verilen bir tür RNN kullanır; bir RNN ağı, kaybolan gradyanlara (birçok RNN modelinde bilinen bir sorun) karşı dirençliyen gradyan bilgisini verimli bir şekilde geri yayabilir.

Her eylemsiz veri kümesi için ikili sıfır hız sınıflandırmaları (hareket edene karşı durağan) oluşturulmaktadır ve sınıfları sıfır hız sınıflandırıcının denetimli eğitimi için kullanılmaktadır. Mevcut çalışma, basınç algılama (Olivares vd., 2012) veya manuel anlatma yoluyla veri kümesi sınıflandırması gerçekleştirirken, bir hareket tipinin kısa bir hareket dizisinde konum hatasını en aza indirmek için optimize edilmiş mevcut klasik dedektörlerin çıktısından yararlanılmaktadır. Bu sıfır hız sınıflandırma tekniği, iki koşulun karşılanması durumunda sıfır hız detektörlerinin optimal çıktılar üretebileceği varsayımına dayanmaktadır: kullanıcının hareketi sabit bir tip ve yoğunluktadır, ve sıfır hız eşiği mevcut hareket için optimize edilmiştir.

### 2.3. Deney

RNN için kullanılan eğitim verileri bir AÖB tarafından toplanmıştır ve önerilen yöntemler iki veri seti kullanılarak değerlendirilmiştir. Bu veri setleri; yürüme hareketlerinden oluşan bir veri seti ve bir merdiven çıkma veri setinden oluşmuştur.

#### 2.3.1. Veri kümesi toplama

Veri seti 50 hareket denemesinden oluşmaktadır. Tüm denemeler, sağ ayaklarının üstüne ayakkabı bağcıkları ile sabitlenmiş bir AÖB takılmış tek bir kişi tarafından yapılmıştır. İlk veri toplama için 200 Hz'de çalışan bir MTI-30-2A8G4-DK AÖB kullanılmıştır. Hareket denemeleri temel olarak çeşitli yürüme rotalarından oluşmuştur, ancak aynı zamanda birkaç farklı merdiven çıkma içermektedir. RNN

sıfır hız sınıflandırıcısını eğitmek için Bölüm 2.2.'de açıklanan prosedürü kullanarak üretilen ikili sıfır hız sınıflandırmaları gereklidir. Özetle, yere göre konum hatasını en aza indirerek en iyi performans gösteren veri grubundan sıfır hız çıktısı seçilmiştir.

#### 2.3.2. RNN eğitimi

Bir RNN hücresi, mevcut  $x^{(t)}$  girdisini ağın gizli durumu  $h^{(t-1)}$  ile birleştiren temel tekrarlayan hücre üzerine kurulur:

$$h^{(t)} = \phi(W^{hx}x^{(t)} + W^{hh}h^{(t-1)})$$

(III)

$h^{(t)}$  çıkışı, önceki durum ile  $\tanh(\cdot)$  gibi bir aktivasyon fonksiyonundan,  $\varphi(\cdot)$  geçen mevcut girdinin doğrusal bir birleşimidir.  $W^{hx}$  ve  $W^{hh}$  matrisleri, eğitim sırasında güncellenen ağırlıkları içerir. Bu duruma ( $h^{(t)}$ ) ek olarak, RNN'ler bir dahili durum ( $s^{(t)}$ ) yayar. Her zaman adımında,  $s^{(t)}$  güncellemeleri iki kapı yapısı tarafından yönetilir: giriş kapısı  $i^{(t)}$  ve unutmaya kapısı  $f^{(t)}$  'dır. Giriş kapısı,  $g^{(t)}$  giriş düğümünün hangi elemanlarının duruma ekleneceğini kontrol ederken, unutmaya kapısı artık ihtiyaç duyulmayan durum elemanlarını kaldırır.  $h^{(t)}$ 'ye geçirilecek  $s^{(t)}$  elemanlarını seçmek için üçüncü bir  $o^{(t)}$  kapısı kullanılır,

$$g^{(t)} = \phi(W^{gx}x^{(t)} + W^{gh}h^{(t-1)} + b_g), \quad (IV)$$

$$i^{(t)} = \sigma(W^{ix}x^{(t)} + W^{ih}h^{(t-1)} + b_i), \quad (V)$$

$$f^{(t)} = \sigma(W^{fx}x^{(t)} + W^{fh}h^{(t-1)} + b_f), \quad (VI)$$

$$o^{(t)} = \sigma(W^{ox}x^{(t)} + W^{oh}h^{(t-1)} + b_o), \quad (VII)$$

$$s^{(t)} = g^{(t)} \odot i^{(t)} + s^{(t-1)} \odot f^{(t)}, \quad (VIII)$$

$$h^{(t)} = \phi(s^{(t)}) \odot o^{(t)}, \quad (IX)$$

$\sigma(\cdot)$  sigmoid fonksiyondur ve eleman bazında çarpmayı temsil eder. Sekiz adet ağırlık parametresi ( $W_{jk}$ ) vardır, burada  $j \in \{g, i, f, o\}$  ve  $k \in \{x, h\}$ ,  $b_g, b_i, b_f, b_o$  eğitilebilir ağ parametreleridir. RNN'ler, kaybolan gradyan sorununa karşı dayanıklılıklarından dolayı popüler bir seçim haline gelmiştir, çünkü  $s^{(t)}$ , zamansal olarak birbirinden uzak olan zaman adımları arasında doğrudan bir bağlantı sağlar. Böylece, gradyanlar uzun diziler boyunca zaman içinde geri yayılabilir ve ağırlık uzun menzilli bağımlılıkları öğrenmesini sağlar. Belirlenen sıfır hız detektörü, katman başına 80 birim içeren 6 katmanlı bir RNN'den oluşmaktadır. RNN'den sonra ağırlık çıkışı 2D'ye indirilen tek bir tam bağlı katman eklenir.

Bir softmax fonksiyonu, ayrı çıkışların dedektörünün AÖB'nin hareket halinde veya sabit olduğuna ilişkin karşılık gelen çıkışların toplamını 1'e sınırlamak için kullanılır. Çıktı, yalnızca kararlılık 0,85'in üzerinde olduğunda AÖB'nin durağan olduğunu varsayacak şekilde filtrelenmektedir. (yanlış pozitif algılamaların neden olduğu hatayı en aza indirmek için deneysel olarak belirlenir).

Bölüm 2.2.'de açıklanan veri seti, sırasıyla 41 ve 9 hareket denemesinden oluşan bir eğitim seti ve bir test seti olarak ayrılmıştır. RNN giriş dizileri, ham, altı kanallı atalet verilerinden oluşmuştur. Her hareket denemesinden, her biri ardışık 100 AÖB zaman adımından (veya 200 Hz'de 0,5 saniyelik atalet verisinden) oluşan 7.000 küme çıkarıldı ve bu, toplamda  $N = 420.000$  ayrı numunelik bir veri kümesi boyutuyla sonuçlandırılmıştır.

Her eğitim örneği  $x_i \in \mathbb{R}^{100 \times 6}$  son zaman adımında orta durum etiketine karşılık gelen tek bir  $y_i \in \{0,1\}$  etiketine sahiptir. Her eğitim örneği için, daha hızlı veya daha yavaş hareketi simüle etmek için rastgele bir döndürme (R) (örnekteki tüm veri noktaları için a ve  $\omega$ 'ye uygulanır), rastgele bir ölçeklendirme faktörü,  $s \in [0.90, 1.10]$  uygulandı, ve her kanala sıfır ortalamalı Gauss gürültüsü ( $\sigma = 0.075$ ) eklendi. Standart bir çarpaz entropi kayıp fonksiyonu ile Adam optimizasyonu kullanılarak model 300 aralık için eğitildi.

$$\zeta = -\frac{1}{N} \sum_i^N y_i \log(p_i) + (1 - y_i) \log(1 - p_i) \quad (X)$$

Model PyTorch üzerinde uygulandı. Eğitim ve test setlerinde sırasıyla %95-90.0 sınıflandırma doğruluğu elde edildi.

### 2.3.3. Yürüyüş deneyleri

Kırıkkale Üniversitesi Hacılar Hüseyin Aytemiz Meslek Yüksekokulu spor sahasında bir dizi hareket denemesi yaparak, önerilen algoritma farklı rotalar üzerinde değerlendirildi. Bu deneyler için 200 Hz'de çalışan bir MTI-30-2A8G4-DK AÖB kullanıldı. Her yürüyüş denemesi için ARMSE (Konum hatası sonuçları) rapor edildi. Deneme yürüyüşleri, başlangıç noktasından aynı konuma tekrar dönecek şekilde karesel bir rota ve dairesel rota olacak şekilde, farklı zaman dilimlerinde iki farklı şekilde gerçekleştirilmiştir.

10m x 10m boyutlarındaki karesel alanlarda farklı zamanlarda üçer tur atılarak yapılan testler sonucunda elde edilen grafikler şekil 3,4,5'da gösterilmektedir. Yer konumunu doğrulamak için Google Earth üzerinde rotalar çizilerek şekil 6'de gösterilmiştir. Buna göre şekil 3,4,5'da görüldüğü üzere RNN kullanılarak geliştirilen çözümün ZUPT kullanan standart ANS çözümünden daha doğru bir şekilde konum doğruluğu gözlenmektedir.

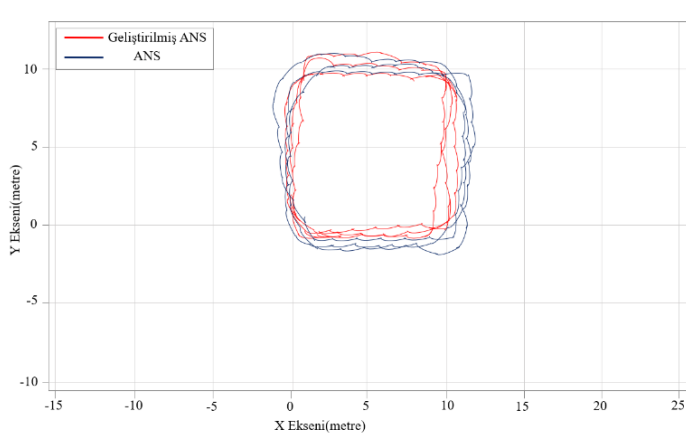
5 metre yarıçaplı dairesel alanlarda farklı zamanlarda üçer tur atılarak yapılan testler sonucunda elde edilen grafikler şekil 7, 8, 10'da gösterilmektedir. Yer konumunu doğrulamak için Google Earth üzerinde rotalar çizilerek şekil 9'de gösterilmiştir. Şekil 7, 8, 10'da

görüldüğü gibi RNN kullanılarak geliştirilen çözüm, dairesel bir rota üzerinde standart ANS çözümünden daha az hata üreterek konum doğruluğu sağlandığı gözlenmektedir.


Her deneme için standart ataletsel navigasyon sistemi ve RNN tabanlı sıfır hız sınıflandırıcı kullanan sistem üzerinde test edilmiştir. Tablo 1, denemeler için bu sistemlerin performansını göstermektedir. Ortalama olarak, RNN tabanlı sistem ile standart ANS'den %42.8 daha düşük ARMSE(Average Root Mean Square Error) elde edilmiştir. ANS olarak XSENS firmasına ait MTI-30-2A8G4-DK kullanılmıştır.

**Tablo 1.** Yürüyüş deneyleri

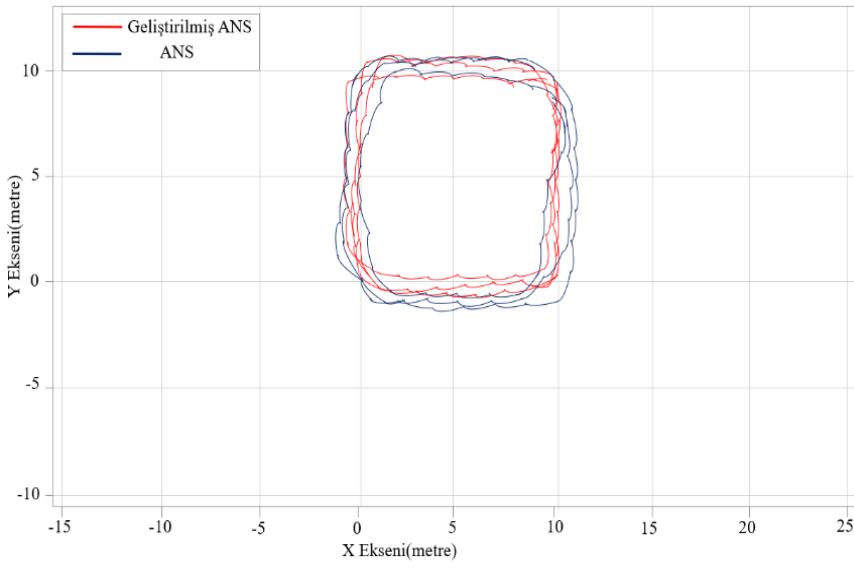
Hareket Tip	Set	ARMSE(metre)	
		ANS	RNN(LSTM)
Yürüyüş	0	1.78	0.45
	1	1.89	0.7
	2	2.52	1.56
	3	3.45	1.39
	4	2.1	0.88
	5	1.65	0.76
<b>Ortalama</b>		2.23	0.956




**Şekil 3.** Karesel olarak belirlenen rota üzerinde yapılan 1. deney




**Şekil 4.** Karesel olarak belirlenen rota üzerinde yapılan 2. deney




Şekil 5. Karesel olarak belirlenen rota üzerinde yapılan 3. deney



Şekil 6. Karesel rota için doğrulama rotası



Şekil 7. Dairesel olarak belirlenen rota üzerinde yapılan 1. deney




Şekil 8. Dairesel olarak belirlenen rota üzerinde yapılan 2. deney





Şekil 9. Dairesel rota için doğrulama rotası



Şekil 10. Dairesel olarak belirlenen rota üzerinde yapılan 3. deney

#### 2.3.4. Merdiven çıkma deneyleri

Çalışmada iki ve dört kat merdiven çıkılan bir veri seti de eklenmiştir. Deney sırasında her kat arasında kısa bir yatay yürüyüş yolu da mevcuttur. En yüksek kat zemin kattan yaklaşık 8.3 m yüksekliktedir. Deneyde toplam dört defa merdiven çıkma denemesi gerçekleştirilmiştir.

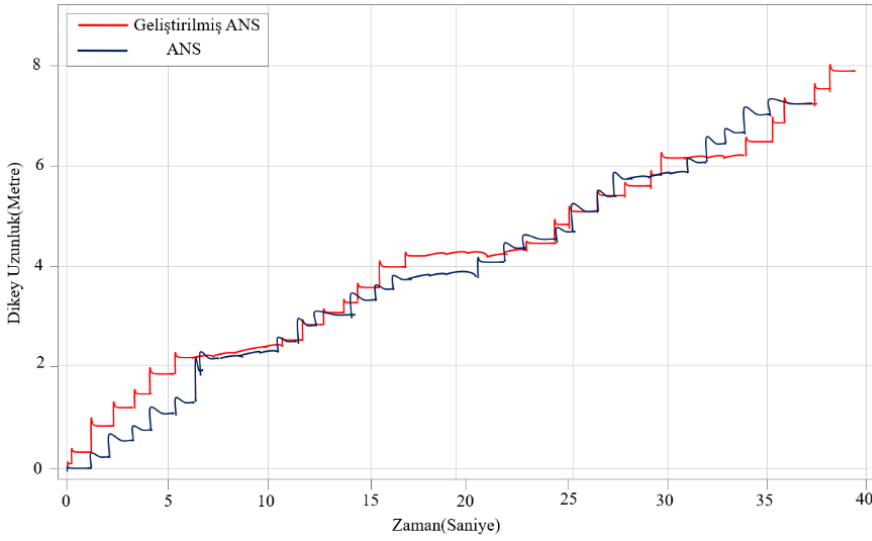
İlk dört deneme, sırasıyla zemin kattan 1. ve 2. katlara çıkmaktan oluşmaktadır. Diğer denemede zemin kattan 1., 2., 3., ve 4. kat'a çıkılmıştır. Yine, harekete uyarlamalı dedektörün ve RNN tabanlı sıfır hız sınıflandırıcının performansı standart ANS ile karşılaştırılmıştır. Buradaki grafiklere bakılacak olursa yine geliştirilmiş ANS çözümünün, standart ANS çözümünden daha yüksek bir doğruluk sağladığı gözlemlenmiştir.

Tablo 2, AÖB'nin tahmini yüksekliği ile yörünge'nin en uzak noktasındaki bilinen yüksekliği arasındaki fark olarak tanımlanan dikey en uzak nokta hatası için sonuçları göstermektedir. Her durumda, veriye dayalı dedektör standart bir ANS yönteminden büyük bir farkla daha iyi performans göstermiştir. Şekil 11, 12 merdiven çıkma deneylerinin sonuçlarını göstermektedir.

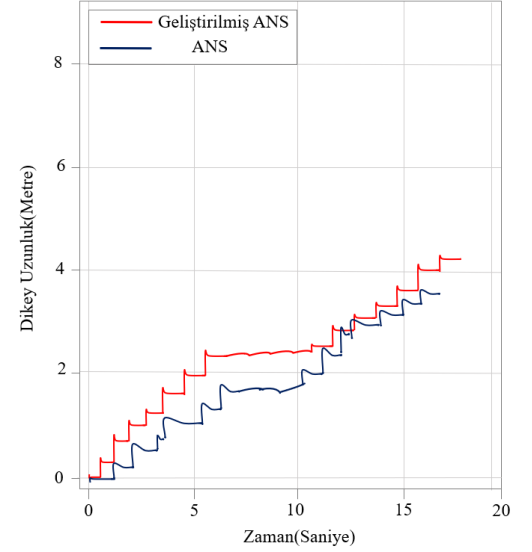
Şekil 11 ve 12'de, standart bir ANS çözümünün hem fazla tahmin edilen hem de eksik tahmin edilen dikey yer değiştirmeyi göstermektedir. Buna karşılık, önerilen veriye dayalı çözüm, ortalama olarak zemin seviyesi tahmini için gereken doğruluğu aşan bir dikey tahmin üretmiştir. Önerilen RNN çözümü, 100 adımda dikey ekseninde 1 metreden daha iyi bir doğruluğu korurken, standart ANS çözümü, 25 adımda bu hata sınırını aşmıştır.

**Tablo 2.** Merdiven çıkma deneyleri

Hareket Tip	Set	Yatay Hata	
		ANS	RNN(LSTM)
Merdiven Çıkma	0	1.5	0.77
	1	2.85	1.11
	2	1.99	0.66
	3	2.74	1.39
<b>Ortalama</b>		2.27	0.9825



Şekil 11. Merdiven çıkma deneyleri 1.deney



Şekil 12. Merdiven çıkma deneyleri 2.deney

### 3.Sonuç

RNN tabanlı LSTM sıfır hız sınıflandırıcısının farklı AÖB yerleşimleri, kullanıcıları ve değişen hareket türleri için aynı performansı gösterebileceği gösterilmiş olsa da, farklı donanım özelliklerine sahip bir AÖB ile düzgün çalışması beklenmemektedir. Bunu geliştirmek için, eğitim veri kümesi içindeki verileri farklı bir AÖB'nin çıktılarını temsil edecek şekilde dönüştüren bir veri işleme tekniği kullanılması gerekmektedir. Dönüştürülen verilerle sıfır hız sınıflandırıcısını yeniden eğiterek, RNN ağı farklı, daha düşük kaliteli bir sensörden gelen atalet verilerine daha iyi genelleme yapılabilir.

Tasarlanan yöntem büyük ölçüde ayak üzerindeki AÖB'nin oryantasyonundan bağımsız olarak çalıştırılmıştır ve ayrıca AÖB'nin ayakkabı üzerindeki konumuna ve genel olarak ayakkabı tipine göre değişmeyecek şekilde konumlandırılmıştır. Önerilen dönüştürme tekniği, her AÖB kanalına sıfır ortalamalı Gauss gürültüsü ekler ve ardından orijinal verileri daha düşük bir frekansa indirger. Bu adımlar, değişen AÖB örnek hızlarını ve değişen ölçüm kalitesini hesaba katmak içindir. Yeni dönüştürülen veriler daha sonra RNN ağını alternatif bir AÖB ile uyumlu olacak şekilde yeniden eğitmek için kullanılmaktadır.

Öğrenmeye dayalı çözümün sağladığı doğruluk artışına rağmen, daha fazla iyileştirmenin yapılabileceği alanlar vardır. RNN tabanlı sıfır hız sınıflandırıcı, test alanı dışındaki farklı alanlarda ve daha yüksek hızlarda toplanan eğitim verilerini kullanabilmektedir. Öğrenme tabanlı dedektörlerin kullanımından elde edilen konumlandırma doğruluğundaki artışın, öncelikle gelişmiş bir hız tahmininin bir sonucu olduğu belirtilmelidir. Sıfır hız güncellemeleri AÖB yuvarlanma ve eğim tahminlerini etkilese de, sapma (yön) gözlemlenemez halde kalır. Öğrenmeye dayalı dedektörlerin kullanımının, tutum tahmininin doğruluğunu büyük ölçüde değiştirmediği söylenebilir.

Doğru SHA'nın sağlanması, ayağa monte edilen ataletsel verilerden doğru iç mekan konumlandırmasını elde etmeye yönelik çok önemli bir adımdır. RNN tabanlı sıfır hız sınıflandırıcısı, harekete özgü herhangi bir parametre ayarı gerektirmeden sıfır hızlı ölçümleri doğrudan verir. Önerilen teknik için hareket görevleri gerçekleştiren farklı kişilerden gelen birkaç büyük veri setinde mevcut eşik tabanlı dedektörlerden daha iyi performans gösterdiğini ve RNN tabanlı sıfır hız sınıflandırıcısının, merdiven çıkma hareketlerini içeren veri setlerinde en düşük ortalama hatayı ürettiği gösterilmiştir. Ayrıca, RNN tabanlı sınıflandırıcısının ek eğitim verileri toplamaya gerek kalmadan daha düşük maliyetli AÖB'lerle kullanımına izin veren bir genelleme yöntemi de sunulmaktadır.

### 4.Referanslar

Curran, K., & Norrby, S. (2009). RFID-enabled location determination within indoor environments. *International Journal of Ambient Computing and Intelligence (IJACI)*, 1(4), 63-86.

Fischer, C., & Gellersen, H. (2010). Location and navigation support for emergency responders: A survey. *IEEE Pervasive Computing*, 9(01), 38-47.

Foxlin, E. (2005). Pedestrian tracking with shoe-mounted inertial sensors. *IEEE Computer graphics and applications*, 25(6), 38-46.

- Fu, Q., & Retscher, G. (2009). Another look indoors GPS+ RFID. *GPS World*, 20(3).
- Gu, Y., Lo, A., & Niemegeers, I. (2009). A survey of indoor positioning systems for wireless personal networks. *IEEE Communications surveys & tutorials*, 11(1), 13-32.
- Ma, M., Song, Q., Li, Y., & Zhou, Z. (2017, December). A zero velocity intervals detection algorithm based on sensor fusion for indoor pedestrian navigation. In *2017 IEEE 2nd Information Technology, Networking, Electronic and Automation Control Conference (ITNEC)* (pp. 418-423). IEEE.
- Nilsson, J. O., Gupta, A. K., & Händel, P. (2014, October). Foot-mounted inertial navigation made easy. In *2014 International Conference on Indoor Positioning and Indoor Navigation (IPIN)* (pp. 24-29). IEEE.
- Nilsson, J. O., Skog, I., & Händel, P. (2012). A note on the limitations of ZUPTs and the implications on sensor error modeling. In *2012 International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, 13-15th November 2012.
- Olivares, A., Ramírez, J., Górriz, J. M., Olivares, G., & Damas, M. (2012). Detection of (in) activity periods in human body motion using inertial sensors: a comparative study. *Sensors*, 12(5), 5791-5814.
- Ren, M., Pan, K., Liu, Y., Guo, H., Zhang, X., & Wang, P. (2016). A novel pedestrian navigation algorithm for a foot-mounted inertial-sensor-based system. *Sensors*, 16(1), 139.
- Skog, I., Handel, P., Nilsson, J. O., & Rantakokko, J. (2010). Zero-velocity detection—An algorithm evaluation. *IEEE transactions on biomedical engineering*, 57(11), 2657-2666.
- Skog, I., Nilsson, J. O., & Händel, P. (2010, September). Evaluation of zero-velocity detectors for foot-mounted inertial navigation systems. In *2010 International Conference on indoor positioning and indoor navigation* (pp. 1-6). IEEE.
- Tian, X., Chen, J., Han, Y., Shang, J., & Li, N. (2016). A novel zero velocity interval detection algorithm for self-contained pedestrian navigation system with inertial sensors. *Sensors*, 16(10), 1578.
- Wahlström, J., Skog, I., Gustafsson, F., Markham, A., & Trigoni, N. (2019). Zero-velocity detection—A Bayesian approach to adaptive thresholding. *IEEE Sensors Letters*, 3(6), 1-4.
- Walder, U., & Bernoulli, T. (2010, September). Context-adaptive algorithms to improve indoor positioning with inertial sensors. In *2010 International Conference on Indoor Positioning and Indoor Navigation* (pp. 1-6). IEEE.