

EJONS

International Journal on Mathematic, Engineering and Natural Sciences

(Uluslararası Fen, Mühendislik ve Doğa Bilimleri Dergisi)

<https://ejons.org/index.php/ejons>

e-ISSN: 2602 - 4136

Araştırma Makalesi

Doi: <https://doi.org/10.5281/zenodo.10814462>

Makine Öğrenmesi Yaklaşımları ile Uhf Rfid Konumlandırma: Rssi Verilerinden Uzaklık Tahmini

Ali MUSABEYOĞLU^{1,*}, Nedim TUĞ³, Ömer Can DURMUŞ³, Gazi AKGÜN⁴, Mustafa Caner AKÜNER⁵

¹ MNM Teknoloji, Ar-Ge Departmanı, 34726, İstanbul

² MNM Teknoloji, Ar-Ge Departmanı, 34726, İstanbul

³ Ahtapot Robotik Yazılım A.Ş., 34854, İstanbul

⁴ Marmara Üniversitesi, Teknoloji Fakültesi, Mekatronik Mühendisliği Bölümü, 34854, İstanbul

⁵ Marmara Üniversitesi, Teknoloji Fakültesi, Mekatronik Mühendisliği Bölümü, 34854, İstanbul

*Sorumlu Yazar e-mail: ali@mnmm.com.tr

Makale Tarihçesi

Geliş: 19.02.2024

Kabul: 15.03.2024

Anahtar Kelimeler

İç Mekan Konumlandırma,
Alınan Sinyal Gücü Göstergesi,
RFID,
Makine Öğrenmesi,

Öz: Nesnelerin interneti (IoT), sensör teknolojisi ve mobil internetin gelişmesiyle beraber iç mekân konumlandırması büyük önem kazanmıştır. İç mekân konumlandırma kapalı bir ortamdaki nesne veya kişilerin konumunun tespit edilmesi işlemidir. Dış mekân konumlandırmanın aksine GPS (Global Pozisyonlama sistemi) gibi teknolojiler iç mekânda etkili olarak kullanılamamaktadır. Bu durumun nedenleri arasında GPS sinyallerinin duvar, tavan vb. beton yapılar tarafından zayıflatılması ve iç mekânda çoklu sinyal yansıması nedeniyle hatalı konum hesaplamaları bulunmaktadır. İç mekân konumlandırma depo ve mağazalarda demirbaş takibi ve envanter konum kontrolü gibi ihtiyaçlara çözüm olmaktadır. Geçmiş yıllarda endüstri ve akademi bu alanda yapılan çalışmalarda kullanılan RFID (Radyo Frekans Tanımlama) teknolojisi, maliyet, düşük güç talebi, kolay uygulanabilirlik açısından öne çıkmaktadır. RFID teknolojisi ile tasarlanan iç mekân konum bulma sistemleri genellikle alınan sinyalin güç göstergesi (RSSI), sinyalin varış zamanı (ToA) ve sinyalin varış zamanı farkı (TDoA) gibi parametreleri kullanır. RSSI değerleri ile yapılan çalışmalar, alınan sinyal gücüne karşılık RFID etiketinin antene olan tahmini uzaklık değerini bulabilmektedir. Bu çalışmada kurulan deney ortamından pasif UHF (Ultra Yüksek Frekans) RFID etiketlerinin RSSI değerleri toplanmıştır. RSSI değerlerinden zaman ve frekans alanında öznelilikler hesaplanarak bu öznelilikler ile etiket uzaklık değerleri makine öğrenmesi modellerini eğitmek için kullanılmıştır. Makine öğrenme algoritmaları, test sonucu elde edilen ortalama mutlak hata (MAE) değerleri cinsinden karşılaştırmalı olarak tartışılmıştır.

Atıf Künyesi: Musabeyoğlu, A., Tuğ, N., Durmuş, Ö.C., Akgün, G., Aküner M.C. (2024). Makine Öğrenmesi Yaklaşımları ile Uhf Rfid Konumlandırma: Rssi Verilerinden Uzaklık Tahmini, EJONS International Journal on Mathematic, Engineering and Natural Sciences , 8(1): 166-173. **How To Cite:** Musabeyoğlu, A., Tuğ, N., Durmuş, Ö.C., Akgün, G., Aküner M.C. (2024). Uhf Rfid Localization with Machine Learning Approaches: Distance Estimation From Rssi Data, EJONS International Journal on Mathematic, Engineering and Natural Sciences, 8(1): 166-173.

Uhf Rfid Localization with Machine Learning Approaches: Distance Estimation From Rssi Data

Article Info

Received: 19.02.2024

Accepted: 15.03.2024

Keywords

Indoor Localization,
Received Signal Strength Indicator,
RFID,
Machine Learning

Abstract: With the development of the Internet of Things (IoT), sensor technology and mobile internet, indoor localization has gained great importance. Indoor localization is the process of locating objects or people in an indoor environment. Unlike outdoor positioning, technologies such as GPS (Global Positioning System) cannot be used effectively indoors. The reasons for this include attenuation of GPS signals by concrete structures such as walls, ceilings, etc. and inaccurate position calculations due to multiple signal reflection indoors. Indoor positioning is a solution to needs such as fixture tracking and inventory location control in warehouses and stores. RFID (Radio Frequency Identification) technology, which has been used in industry and academia in the past years, stands out in terms of cost, low power demand and easy applicability.

Indoor location systems designed with RFID technology usually use parameters such as received signal strength indicator (RSSI), time of arrival (ToA) and time difference of arrival (TDoA). Studies with RSSI values can find the estimated distance of the RFID tag to the antenna in response to the received signal strength. In this study, RSSI values of passive UHF (Ultra High Frequency) RFID tags were collected from the experimental environment. Time and frequency domain features are calculated from the RSSI values and these features and tag distance values are used to train machine learning models. The machine learning algorithms are discussed comparatively in terms of mean absolute error (MAE) values obtained from the test results.

1. Giriş

İç mekan mobilite uygulamaları ile birlikte, nesnelerin interneti (IoT), sensör teknolojisi ve mobil internetin gelişmesiyle birlikte iç mekan konumlandırması büyük önem kazanmıştır. İç mekân konumlandırma kapalı bir ortamdaki nesne veya kişilerin konumunun tespit edilmesi işlemidir. Sağlık sektörü, endüstri, demirbaş takibi ve afet yönetimi gibi birçok alanda iç mekân konumlandırma uygulamaları gerçekleştirilmektedir (Zafarı vd., 2019). Doğru ve güvenilir konum bilgisinin elde etmek için geliştirilen iç mekân konumlandırma uygulamalarında, dış mekân konumlandırmada kullanılan "Küresel Konumlandırma Sistemi" (GPS) gibi yaygın kullanılan bir teknoloji bulunmamaktadır (Naser vd., 2023). Son yıllarda yapılan çalışmalara bakıldığında iç mekân konumlandırma da birden fazla metot önerilmiştir. Bununla birlikte, çoğu ortam koşullarına uyum sağlayabilen bir teknoloji henüz geliştirilmemiştir (Gomes vd., 2024).

Yapılan çalışmalarda iç mekân konumlandırma için WiFi, UWB, Radyo Frekanslı Tanımlama (RFID) ve benzeri teknolojiler kullanılmıştır (Xu vd., 2018). Kullanılan teknolojiler incelendiğinde RFID kullanım kolaylığı ve maliyeti ile dikkat çekmektedir. RFID, bir taşıyıcı üzerine yerleştirilen mikroişlemci ve anten sistemi olarak açıklanabilir (Baygin vd., 2022). Bir RFID sistemi basitçe RFID etiket, RFID okuyucu (alıcı - verici) ve RFID anteninden oluşmaktadır. Çalışma frekansları ve güç ihtiyaçları açısından birçok farklı RFID etiketi bulunmaktadır. Piyasa incelendiğinde en çok kullanılan etiket çeşidi pasif Ultra-Yüksek Frekans (UHF) RFID etiketleridir. UHF RFID etiketi 860 - 960 MHz okuma aralığına sahiptir (Abdulghafor vd., 2021). Pasif UHF RFID etiketleri dahili bir güç kaynağına sahip değildir ve etkinleşmek için RFID anteni tarafından iletilecek radyo dalgasına ihtiyaç duyar. RFID okuyucu tarafından RFID antenine iletilen radyo dalgaları, etiket anteni tarafından algılanarak gereken enerjiyi mikroişlemciye

iletir. Aktifleşen mikroişlemci bilgi sinyalini anteni yardımıyla, okuyucunun antenine iletir. RFID teknolojisi ile iç mekân konumlandırma uygulamaları bu sinyal kullanılarak gerçekleştirilir. Etiketten dönen sinyal ile etiketin yerini tespit etmek için varış zamanı (ToA), varış zamanı farkı (TDoA) ve alınan sinyal gücü göstergesi (RSSI) gibi farklı yöntemler kullanılmaktadır. Bu yöntemlerden RSSI, literatürde birçok farklı çözüme sahiptir (Hatem vd., 2020).


RSSI değerini kullanarak iç mekan konumlandırması yapan öncü çalışmalardan biri Landmarc'tır (NI vd., 2003). Bu çalışmada konumu bilinmeyen aktif RFID etiketleri ve konumları bilinen referans etiketleri kullanılır. Birden fazla RFID anteni ile etiketlerin RSSI değerleri ölçülür ve kaydedilir, daha sonrasında en yakın komşu (KNN) algoritması kullanılarak konumlandırma işlemi gerçekleştirilir. Landmarc'ta referans etiket sayısının fazla olması, aktif RFID ve çoklu anten kullanımı gibi nedenler bu çalışmanın kullanılabilirliğini olumsuz etkilemektedir.

Bu çalışmada, UHF RFID etiketlerinin RSSI değerlerinden okuyucu anten ile arasındaki uzaklığı tespit etmek amaçlanmıştır. Sabit bir anten ve okuyucu sistemi ile referans bir UHF RFID etiketinden alınan RSSI sinyallerinden faydalanarak makine öğrenmesi metotları ile RSSI değerlerinden etiket ve anten arası uzaklık değeri elde kestirilmiştir. 2 boyutlu uzayda bilinen anten konumu ve uzaklık değeri ile etiketin yaklaşık konumunu tespit etmek hedeflenmiştir. Bölüm 2' de deney düzeneđi anlatılmış, veri setinin toplanma yöntemleri ve kullanılan makine öğrenmesi algoritmaları verilmiştir. Bölüm 3'te makine öğrenmesi algoritmalarının sonuçları verilerle tartışılmıştır.

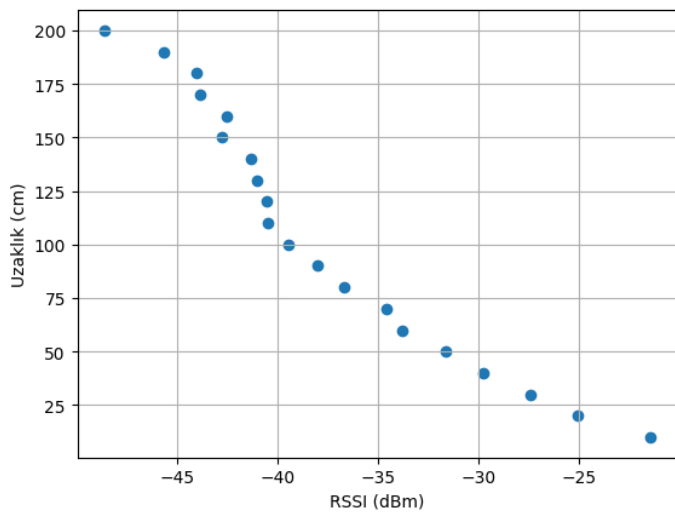
2. Materyal ve Yöntem

2.1 Veri Setinin Oluşturulması

Bu çalışmada kullanılacak veriler Impinj R700 UHF RFID Okuyucu, ALIEN Anten ve ALIEN UHF RFID etiketi ile oluşturulan bir deney setinden elde edilmiştir. Deney setinin kurulacağı ortam elektromanyetik dalgaların kırılım, kırınım ve yansıma durumları göz önünde bulundurularak metal ve diğer yansıtıcı cisimlerden arındırılmıştır. RFID etiketinden alınan sinyallerin RSSI değerleri Impinj ItemTest yazılımı ile toplanmıştır. Etiket ve anten yüksekliğinin sabit tutulması için etiket, bir kutu üzerine yerleştirilmiştir. Anteni sabitlemek için de 3 boyutlu yazıcıdan uygun yükseklikte parça imal edilmiştir. Veri setini oluşturmak için etiket antenden tek ekseninde (diğer eksen sabit bırakılmıştır) 10 cm uzaklaştırılmış ve her adımda yapılan 100 okuma sonucunda elde edilen RSSI verilerinin ortalaması kaydedilmiştir. Oluşturulan veri setinde bir etiketin 10 cm adımlarla maksimum 200 cm uzaklıktaki RSSI değerlerinin bulunduğu 20 adet değer bulunmaktadır. RSSI verilerini toplamak için kullanılan deney düzeneđi Şekil 1a' da ve elde edilen veriler Şekil 1b'de görülmektedir.



a.



b.

Şekil 1: Veri toplama düzeneği ve örnek verileri gösteren resimler (a: Verilerin toplandığı RFID etiketi ve RFID anten sistemi, b: Uzaklığa göre RSSI değerlerinin grafiği).

2.2 Model Eğitimi

Bağımsız değişkenden faydalanarak bağımlı değişken tahmin edilmeye çalışıldığı bu çalışmada regresyon modelleri kullanılmıştır. Bu çalışmada doğrusal olmayan durumlarda başarılı sonuçlar üreten polinomal regresyon, destek vektör regresyonu, elastic net regresyon, karar ağaçları regresyon ve yapay sinir ağları kullanarak makine öğrenimi modelleri eğitilmiştir. Model eğitimi için Python yazılım dili ve numpy, sklearn vb. makine öğrenmesi kütüphaneleri kullanılmıştır.

Elde edilen RSSI verileri incelendiğinde RSSI ve uzaklık verileri arasında doğrusal olmayan bir ilişkinin olduğu gözlemlenmiştir. Burada uzaklık bağımlı değişken ve RSSI değeri bağımsız değişken olarak ele alınacaktır. Sinyal karakteristiği denklem 1'deki gibi yazılır ise;

$$y = \beta_0 + \beta_1 x + \beta_2 x^2 + \dots + \beta_N x^N + b, \quad y = \sum_{n=0}^N \beta_n x^n + b \quad (1)$$

Burada y uzaklık değeri x , RSSI değerleri ve β_n katsayılar ve b artık hatadır. Bu lineer olmayan modelin optimum ve en iyi çözümü denklem 2'deki gibi en küçük kareler metodu ile bulunabilir. Bu polinomal regresyon metodu ile sistem modeli çıkarılabilecektir (Yao ve Ma, 2023).

$$\hat{\beta} = (X^T X)^{-1} X^T y, \quad X = \begin{bmatrix} 1 & x_1 & x_1^2 & \dots & x_1^m \\ 1 & x_2 & x_2^2 & \dots & x_2^m \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & x_n & x_n^2 & \dots & x_n^m \end{bmatrix} \quad (2)$$

Lineer olmayan model için parametrik olmayan bir yaklaşım olan destek vektör regresyonu kullanılır ise yine denklem 1 de verilmiş olan model için denklem 3'teki gibi ikinci dereceden bir maliyet fonksiyonu yazılabilir.

$$J(\beta) = \frac{1}{2} \beta' \beta + C \sum_{n=1}^N (\xi_n + \xi_n^*) \quad (3)$$

Burada β aranan katsayılardan oluşan bir matristir. C aşırı öğrenmeyi önleyen pozitif bir ceza katsayısı, ξ_n ve ξ_n^* ise her noktadaki yapay değişkendir. Bu maliyet fonksiyonunu $\forall n: |y_n - (x_n' \beta + b)| \leq \varepsilon$ olacak şekilde $\forall n: y_n - (x_n' \beta + b) \leq \varepsilon + \xi_n$ ve $\forall n: (x_n' \beta + b) - y_n \leq \varepsilon + \xi_n^*$ $\forall n: \xi_n \geq 0$ $\forall n: \xi_n^* \geq 0$ kısıtları ile optimize edilir ise en iyi çözüm bulunur. Bunun için denklem 3' te verilmiş olan model Lagrange çifti formülasyonu denklem 4'teki gibi yazılabilir. Burada α_n, α_n^* çiftleri hesaplanarak en iyi çözüme ulaşılır (Tondji vd., 2024).

$$L(\alpha) = \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) x_i' x_j + \varepsilon \sum_{i=1}^N (\alpha_i - \alpha_i^*) + \sum_{i=1}^N y_i (\alpha_i - \alpha_i^*) \quad (4)$$

Yine denklem 1 de verilmiş olan lineer olmayan modelde denklem 5'te verilmiş olan amaç fonksiyonu minimize edilerek çözüm Elastik net regresyon yöntemi ile çözülebilir. Elastik net metodu ikinci dereceden ceza bileşenleri içerdiği için doğal olarak aşırı öğrenmeye karşı dirençlidir (Friedman vd., 2023).

$$\hat{\beta} = \operatorname{argmin} (||y - X\beta||^2 + \lambda_2 ||\beta||^2 + \lambda_1 ||\beta||_1) \quad (5)$$

Sistem modeli için lineer olmayan bir aktivasyon fonksiyonu ile güncellenir ise denklem 6'daki gibi yeniden tanımlanabilir.

$$z = \sum_{n=0}^N w_n x + b, \quad y = \frac{e^z - e^{-z}}{e^z + e^{-z}} \quad (6)$$


Denklem 6 da verilmiş olan yapay sinir ađları modelinin çözümlü eğimli iniş metodu ile bulunabilir. Denklem 7'de verilmiş olan maliyet fonksiyonunun minimum noktasına ilerleyen ađlırlıkları hesaplamak için denklem 8 deki öğrenme kuralı kullanılabilir (Ulkir ve Akgun, 2023).

$$J = (d - z)^2 / 2 \quad (7)$$

$$w_{ij} = w_{ij_{old}} + \eta \frac{\partial J}{\partial w_{ij}} + \alpha w_{ij_{old}} \quad (8)$$

Burada w_{ij} i. katman ve j. parametre için ađırlık, η öğrenme oranı, α yerel minimumlardan kaçınmak için momentum sabiti ve J amaç fonksiyonudur.

En doğru sonucu üretmesi için modellerin hiper parametreleri Grid arama metodu kullanarak optimize edilmiştir. Bu yöntem, eğitim algoritmasının hiper parametre uzayının belirli bir alt kümesi üzerinde tam bir arama yapar. Makine öğrenmesi algoritmasının parametre uzayı bazı parametreler için gerçel veya sınırsız deđerler içerebileceğinden, bir grid araması uygulamak için bir sınır belirtmemiz gerekir. Grid arama, yüksek boyutlu uzaylar için hantal bir algoritma olabilir ancak genellikle hiper parametre deđerleri birbirinden bağımsız olduğundan kolayca paralelleştirilebilir (Liashchynskiy ve Liashchynskiy, 2019).




Şekil 2: Grid arama algoritması.

Bunun sonucunda Destek Vektör Regresyon için en iyi hiper parametreler: 'C': 0.1, 'degree': 4, 'epsilon': 0.5, 'kernel': 'poly', Elastic Net Regresyon için en iyi hiper parametreler 'alpha': 10, 'l1_ratio': 0.5, 'max_iter': 1000 elde edilmiştir. Yapay Sinir Ađı mimarisinde 2 katmanlı bir mimari oluşturulmuştur. Yapay Sinir ađı mimarisinde ilk katmanda aktivasyon fonksiyonu olarak hiperbolik tanjant (tanh) ikinci katmanda ise aktivasyon fonksiyonu lineer seçilmiştir. Ađ 15000 iterasyon boyunca eğitilmiştir.

3. Bulgular ve Tartışma

Eđitilen modeller hakkında fikir sahibi olmak için Resim 3 modellerin veriler üzerinde dağılımını göstermektedir.



Şekil 3: Eğitim verileri üzerinde model performansları.

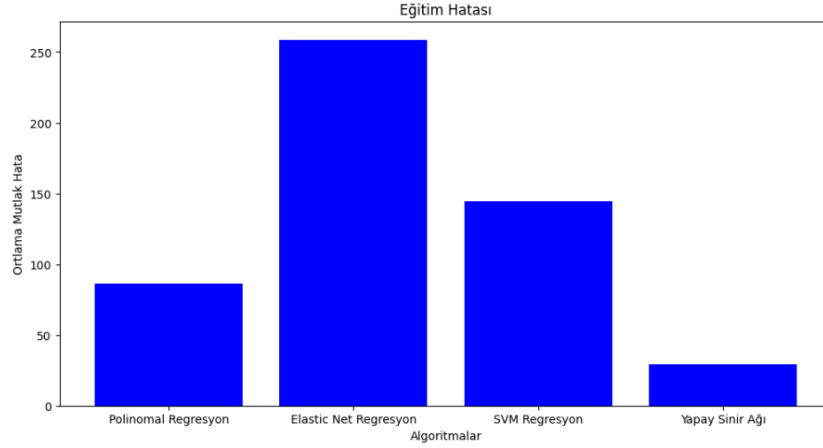
Modelleri test etmek için antenden 7 farklı kademe uzaklıktaki konumlarda bulunan etiketlerin RSSI değerleri kaydedilmiştir. Modellerin bu sinyal değerlerine karşılık kestirdikleri uzaklık çıktıları Tablo 1’de gösterilmektedir.

Tablo 1: Modellerin uzaklık tahminleri.

Test Etiketlerinin Uzaklıkları	Polinomal Regresyon Tahmini	Elastic Net Regresyon Tahmini	Destek Vektör Regresyon Tahmini	Yapay Sinir Ađı Tahmini
25 cm	25.82 cm	30.71 cm	27.26 cm	28.29 cm
37 cm	36.79 cm	47.55 cm	36.45 cm	38.63 cm
53 cm	54.75 cm	69.32 cm	52.08 cm	53.45 cm
71 cm	76.95 cm	91.09 cm	72.75 cm	70.60 cm
106 cm	117.43 cm	123.19 cm	114.55 cm	117.67 cm
134 cm	140.36 cm	138.73 cm	140.55 cm	145.61 cm
169 cm	165.03 cm	154.02 cm	170.35 cm	166.02 cm


Sonuçlar incelendiğinde genel olarak etiket ile anten arasındaki mesafe arttıkça tahmin doğruluğunun azaldığı görülmüştür. Elastic Net yönteminin tahmin yeteneđi diđer yöntemlere göre daha düşük görülmektedir. Bunun nedeninin Elastic Net mimarisinde bulunan ceza katsayıları olabileceđi tahmin edilmektedir. Model verilen aralık içinde bir aşırı öğrenmeye neden olmamakla birlikte daha fazla hata yapmıştır.

Eđitilen modeller gerçek deđer ve hesaplanan deđer arasındaki ortalama kare hatası ile karşılaştırılmıştır. Şekil 4 ve Şekil 5’te eğitim ve test verileri için modellerin ortalama kare hatası deđerleri görülmektedir.



Őekil 4: Eđitim iin modellerin ortalama kare hataları.

Eđitim ve test verileri incelendiđinde tm modeller iin test bařarılarının eđitim bařarılarından yksek olduđu grlmektedir. Bu da modellerin herhangi bir ařırı đrenme belirtisi gstermediđini iřaret etmektedir.



Őekil 5: Test iin modellerin ortalama kare hataları.

4.Sonuç

Bu alıřmada UHF RFID etiketlerinin gnderdiđi sinyallerin RSSI deđerleri, anten ve etiket arasındaki uzaklıđın tahmini iin toplanmıřtır. Etiket ve anten arasındaki uzaklık deđeri makine đrenme yntemleri ile tahmin edilmeye alıřılmıřtır. Tahmin iřleminin dođruluđunu arttırmak ve makine đrenme metodunun uygunluđunu grmek iin birden fazla regresyon yntemi ile eđitim yapılmıřtır. Bu modeller arasında yer alan yntemler Polinomal Regresyon, Destek Vektr Regresyon ve Yapay Sinir Ađı'dır. Model eđitimi sırasında hiper parametre seiminin model dođruluđuna dođrudan etki etmesi nedeni ile hiper parametreler Grid Arama yntemi ile belirlenmiřtir. Yapılan karřılařtırma sonucu modeller arasındaki en dřk ortalama karesel hata deđerine sahip model Destek Vektr Regresyon olmuřtur.

Bu alıřma UHF RFID etiketlerinin RSSI deđerlerinden faydalanarak etiket ve anten arasındaki uzaklık tahmininde regresyon algoritmalarının karřılařtırmasını ele almıřtır. Bu alıřmalar uzaklıđa etki eden bađımsız deđiřkenlerin sayısı arttırılarak farklı regresyon yntemleri zerinde ileri alıřmalar yapılması potansiyeline sahiptir. Bu alanda yapılacak ar-ge alıřmaları i mekn konumlandırma da teknolojik geliřmelerin nn aacaktır.

Kaynaklar

- Abdulghafor, R., Turaev, S., Almohamedh, H., Alabdan, R., Almutairi, B., Almutairi, A., and Almotairi, S. (2021). Recent advances in passive UHF-RFID tag antenna design for improved read range in product packaging applications: A comprehensive review. *IEEE* .
- Baygin, M., Yaman, O., Baygin, N., and Karakose, M. (2022). A blockchain-based approach to smart cargo transportation using UHF RFID. *Expert Systems with Applications*, 188, 116030.
- Friedman, J., Hastie, T., Tibshirani, R., Narasimhan, B., Tay, K., Simon, N., ... & Yang, J. (2023). glmnet: Lasso and elastic-net regularized generalized linear models. *Astrophysics Source Code Library*, ascl-2308.
- Gomes, E. L., Fonseca, M. S. P., Lazzaretti, A. E., Munaretto, A., & Guerber, C. R. (2024). Sliding Window, Hierarchical Classification, Regression, and Genetic Algorithm for RFID Indoor Positioning Systems. *Expert Systems with Applications*, 238, 122298.
- Hatem, E., Abou-Chakra, S., Colin, E., Laheurte, J. M., and El-Hassan, B. (2020). Performance, accuracy and generalization capability of RFID tags' constellation for indoor localization. *Sensors*, 20(15), 4100.
- Liashchynskiy, P., and Liashchynskiy, P. (2019). Grid search, random search, genetic algorithm: a big comparison for NAS. *arXiv preprint arXiv:1912.06059*.
- Naser, R. S., Lam, M. C., Qamar, F., and Zaidan, B. B. (2023). Smartphone-Based Indoor Localization Systems: A Systematic Literature Review. *Electronics*, 12(8), 1814.
- Ni, L. M., Liu, Y., Lau, Y. C., and Patil, A. P. (2003, March). LANDMARC: Indoor location sensing using active RFID. In *Proceedings of the First IEEE International Conference on Pervasive Computing and Communications, 2003.(PerCom 2003)*. (pp. 407-415). *IEEE*.
- Tondji, Y., Ghazi, G., and Mihaela Botez, R. (2024). Neural networks and support vector regression for the CRJ-700 longitudinal dynamics modeling. *Journal of Aerospace Information Systems*, 1-16.
- Ulkir, O., and Akgun, G. (2023). Predicting and optimising the surface roughness of additive manufactured parts using an artificial neural network model and genetic algorithm. *Science and Technology of Welding and Joining*, 1-10.
- Xu, H., Wu, M., Li, P., Zhu, F., and Wang, R. (2018). An RFID indoor positioning algorithm based on support vector regression. *Sensors*, 18(5), 1504.
- Yao, Y. A., and Ma, Z. (2023). Toward a holistic perspective of congruence research with the polynomial regression model. *Journal of Applied Psychology*, 108(3), 446.
- Zafari, F., Gkelias, A., and Leung, K. K. (2019). A survey of indoor localization systems and technologies. *IEEE Communications Surveys & Tutorials*, 21(3), 2568-2599.