



Makine Öğrenmesi Yöntemlerine Dayalı Veri Yönetim Sistemi

Ülgen AYDIN^{1*} , Gökay AKKAYA¹ 

¹Atatürk Üniversitesi, Endüstri Mühendisliği, Erzurum, Türkiye

Anahtar Kelimeler:

Eksik veri,
Makine Öğrenmesi,
Yapay Zekâ

Özet

Veri, bilgiyi edinebilmek için ihtiyaç duyduğumuz temel yapıdır. Geçmişten günümüze teknoloji ile gelişen veri tabanları eğitim ve iş dünyası başta olmak üzere her alanda önemini arttırmakta ve özellikle sensörlerin hayatımızın her adımında yer almaya başlamasıyla attığımız adımlardan yapmayı tercih ettiğimiz alışverişlere kadar hayatımızdaki her şey birer veriye dönüşmektedir. Veriyi anlamlı hale getirebilmek için ise veri ön işleme mekanizmaları devreye sokularak elimizdeki verilerin kullanabileceğimiz şekilde anlamlı olması sağlanmaktadır. Bir veri tabanını ön işleme tabi tuttuğumuzda karşılaştığımız en büyük sorunlardan biri eksik verilerin varlığıdır. Bu sorunun çözümü için kullanılan geleneksel istatistiksel yöntemler günümüz veri yığınlarıyla başa çıkamamakta, gelişen teknolojiyle yerini yapay zekaya bırakmaktadır. Bu makale, veri setlerindeki nümerik eksik verilerin etkili bir şekilde tahmin edilmesi amacıyla geliştirilmiş olan Python tabanlı bir masaüstü uygulamasını ele almaktadır. Uygulama, rastgele orman regresyonu algoritması ve yinelemeli tamamlayıcı modülünü birleştirerek, eksik veri tahmininde güçlü ve yenilikçi bir yaklaşım sunmaktadır. Uygulama dört farklı veri seti üzerinde test edilmiş ve %57 ile %79 arasında bir doğrulukla tahmin yapılmıştır. Bu önemli araç, veri madenciliği ve veri ön işleme konularında uzman olmayan kullanıcılar için dahi kullanımı kolay bir arayüz sunarak, eksik verilerin tahminini optimize etmeyi amaçlamaktadır.

*e-posta: gakkaya@atauni.edu.tr

Bu makaleye atıf yapmak için:

Ülgen AYDIN; Gökay AKKAYA, "Makine Öğrenmesi Yöntemlerine Dayalı Veri Yönetim Sistemi", Bayburt Üniversitesi Fen Bilimleri Dergisi, C. 7, s 1, ss. 20-26

How to cite this article:

Ülgen AYDIN; Gökay AKKAYA, "Data Management System Based on Machine Learning Methods", Bayburt University Journal of Science, vol. 7, no 1, pp. 20-26

Data Management System Based on Machine Learning Methods

Keywords:

Missing Data,
Machine Learning,
Artificial
Intelligence

Abstract

Data is the fundamental structure we rely on to acquire information. The evolution of technology has significantly increased the importance of databases in various sectors, especially in education and the business world. Particularly with sensors becoming integral to our daily lives, everything from the steps we take to our preferred shopping habits has transformed into data. To make data meaningful, preprocessing mechanisms come into play, ensuring that the available data is processed into a comprehensible format. One of the major challenges encountered when preprocessing a database is the existence of missing data. Traditional statistical methods used to address this issue struggle to cope with the voluminous datasets of the present day, making way for the integration of artificial intelligence. This article delves into a Python-based desktop application developed with the aim of effectively predicting numerical missing data within datasets. The application combines the random forest regressor algorithm and the iterative imputer module, presenting a robust and innovative approach to missing data prediction. The application has been tested on four different datasets, achieving prediction accuracies ranging from 57% to 79%. This significant tool endeavors to optimize the prediction of missing data by providing a user-friendly interface, making it accessible even to users not specialized in data mining and preprocessing. The application aims to address the effective prediction of numerical missing data in datasets by combining the random forest regressor algorithm and the iterative imputer module. Tested on four distinct datasets, the application demonstrates prediction accuracies ranging from 57% to 79%. This noteworthy tool not only provides a powerful and innovative approach to missing data prediction but also ensures accessibility for users lacking expertise in data mining and preprocessing.

1 GİRİŞ

Teknolojik gelişmelerin hızla yaşandığı günümüz dünyasında, araştırmacıların ilgilendiği konuların başında veri gelmektedir. Veri bir araştırmada sonuca ulaşabilmemiz için gereken ilk bilgidir. Doğruluk ve güvenilirlik ise veriyi anlamlı kılar. Kaliteli veri elde etmek için ise veri analiz sürecinin optimum tutulması şarttır. Zayıf bir veri, kuruluşları birçok yönden etkiler. Operasyonel düzeyde, zayıf verinin müşteri memnuniyeti üzerinde etkisi vardır, operasyonel girdileri artırır ve çalışan iş memnuniyetinin düşmesine neden olabilir. Benzer şekilde stratejik düzeyde, zayıf veri, karar verme sürecinin kalitesini etkiler. Bir işletme çeşitli veri sorunları yaşayabilir. Ancak sorunları bilmeden ve ölçmeden hiçbir iyileştirme yapılamaz [1]. Bu süreçteki zorlukların en büyüğü eksik ya da hatalı verilerin düzeltilmesidir. İstatistiksel bir analiz tipik olarak önemli ve temsili bir veri seti gerektirir ve bu duruma yaklaşım, tutarsızlıklar tolere ederken veya bu tutarsızlıkları ele almak için teknikleri benimserken eksiksizliği tercih edecektir [1, 2]. 2000’li yılların başlarından bugüne geldiğimizde karşımıza çıkan gerçek, son 20 yılda insanoğlunun ürettiği veri, tarih boyunca üretilen veriden çok daha fazladır. Bu süre zarfında sadece verilerin boyutu artmamış aynı zamanda gelişen teknoloji ile veri türleri ve onları değerlendirme şeklimiz de değişmiştir. Verinin bilgiye dönüşme aşamasında kazanılan ve kaybedilen zaman karar verme sürecinde şirketler, veri bilimciler ve araştırmacılar için hayati öneme dönüşmüştür. Bugünün dünyasında oluşan veri yığınlarının anlamlandırılabilmesi için istatistiksel yöntemler artık yeteri kadar fayda sağlamamaktadır. Veriyi anlamlandırmada ve yorumlamada gerekli olan doğruluk ve zaman kazanımı ihtiyacı istatistik yöntemlerini aşmış bulunmaktadır. Geleneksel istatistik yöntemlerine baktığımızda en çok kullanılan yöntemlerin satır bazında silme, ortalama alma veya manuel olarak doldurma gibi işlemler olduğunu görürüz [3]. Bu yöntemler arasında en çok kullanılan satır bazlı silme işlemi ele alırsak verinin özelliğine, verilerin birbirleri ile olan ilişkisine ve veri setindeki eksik verilerin toplam veri sayısına oranına bakarak silme işlemi yapıldığında varyans artar ve rassal olarak hatalı veya yanlış sonuçlar üretir [4]. Elde edilen bu yanlış sonuçlar ise araştırmacılar ve şirketler için zaman ve mali kayıplara yol açar.

2. Dünya savaşı sonrası ortaya çıkan yapay zekâ kavramı insanlık tarihini adım adım değiştirmeye başladığından beri hayatımızdaki birçok problemin başlıca çözüm mekanizması haline gelmeye başlamıştır. Yapay zekânın alt dallarını temsil eden makine öğrenmesi ve derin öğrenme yöntemleri ile mühendislik problemlerinin çözümünde araştırmacılara günümüz şartlarında en iyi çözümü vermektedir. Özellikle veri setlerinin yorumlanmasında en

önemli yapıya sahip makine öğrenmesi yöntemleri günümüzde veri analizi ve tahmin problemlerinin çözümünde önemli bir role sahiptir. Veri setlerindeki eksik veya kayıp verilerin üstesinden gelebilmek için makine öğrenmesi yöntemleri kullanılabilir [5]. Veri setlerindeki eksik değerleri tahmin etmek ve tamamlamak için makine öğrenmesi algoritmalarını kullanan Python tabanlı bir eksik veri tamamlama sistemi, bu çalışma kapsamında geliştirilmiştir. Bu sistem eksik verileri tamamlamak için model öğrenimi ve tahmine dayalı yöntemler kullanır.

Bu sistemlerin kullanıldığı birçok alan vardır: sağlık sektöründe hastaların tıbbi verilerinden eksik bilgilerin tamamlanması, mühendislik projelerinde eksik sensör verilerinin tahmini gibi pek çok alanda kullanılmaktadır. Sonuç olarak, makine öğrenmesi teknikleriyle eksik veri tamamlama sistemi, veri analizi ve tahmin problemlerinde karşılaşılan eksik verilerin tamamlanması konusunda etkili bir yaklaşımdır.

Bu makale kapsamında daha önce yapılan çalışmalar baz alınarak makine öğrenmesi metotları bütünleşmiş bir şekilde kullanıldı ve güçlü bir algoritma oluşturularak eksik veri tahmini yazılımı geliştirilerek bu yazılım masaüstü uygulaması haline dönüştürüldü ve araştırmacılar için zaman ve maliyet tasarrufu sağlama amacına yönelik literatüre katkı sağlandı.

2 MATERYAL VE METOT

Eksik verilerle başa çıkma, veri setlerini doğru bir şekilde analiz etme ve modelleme süreçlerinde kritik bir rol oynamaktadır [6]. Bu makale kapsamında, özel olarak tasarlanmış bir Python tabanlı uygulama geliştirilmiştir. Uygulama, veri seti seçimi, eksik veri raporu oluşturma ve görselleştirme, eksik verileri doldurma işlemleri ve elde edilen sonuçları kaydetme gibi 4 temel adımdan oluşmaktadır. Bu adımlar, grafiksel bir kullanıcı arayüzü aracılığıyla gerçekleştirilmektedir. Son olarak, makale eksik veri doldurma işlemlerinin sonuçlarını ve çıktıları değerlendirmek için bir bölüm içermektedir.



Şekil 1. Sistemin işleyişi

2.1 Veri seti seçimi

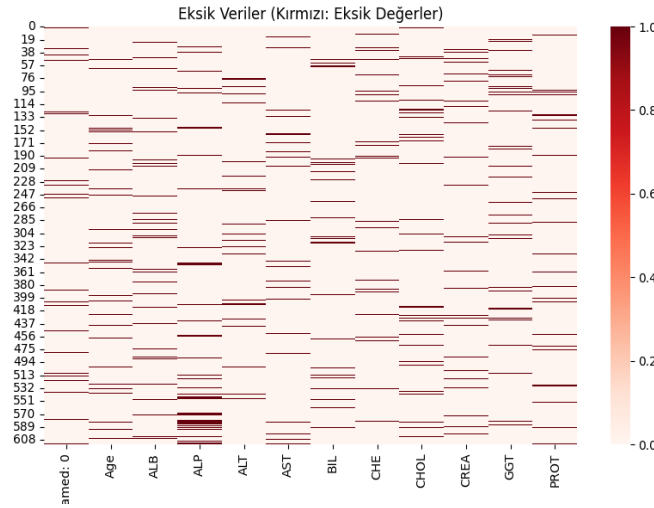
İlk adım olarak araştırmacıların konusunda uzman olmasa bile rahatlıkla kullanabileceği bir arayüz ile veri setini seçebileceği kullanıcı dostu bir arayüz geliştirildi. Uygulamayı başlatan kullanıcı, ilk adım olarak bir dosya iletişim kutusu aracılığıyla eksik veri içeren bir CSV dosyası seçer. Kullanıcının seçtiği veri seti okunur, sayısal ve kategorik sütunlara ayrılır. Eğer seçilen veri setinde eksik veri yoksa kullanıcıya hata mesajı olarak gösterilir.

2.2 Eksik veri raporu ve görselleştirme

Araştırmacı veri setini seçtiğinde, veri setindeki eksik verilerin sayısı ve türleri, bir rapor aracılığı ile kullanıcıya sunulur. Kullanıcıya daha etkili analiz yapma imkânı sunmak için eksik olan sayısal değerlerin ısı haritası gösterilir.

Eksik Veri Raporu		
	Eksik Veri Sayısı	Veri Türleri
Unnamed: 0	31	float64
Age	35	float64
ALB	40	float64
ALP	56	float64
ALT	32	float64
AST	24	float64
BIL	36	float64
CHE	29	float64
CHOL	43	float64
CREA	37	float64
GGT	36	float64
PROT	30	float64

Şekil 2. Eksik veri raporu



Şekil 3. Eksik verilere ait ısı haritası

2.3 Eksik verileri doldurma ve sonuçları kaydetme

Kod parçasında, eksik verileri doldurmak için `IterativeImputer` sınıfı kullanılmıştır. Bu sınıf, eksik verileri, eksik olmayan verileri kullanarak bir döngü içinde tahmin eden bir yöntemdir. Tahmin etmek için, `RandomForestRegressor` sınıfı kullanılmıştır. Bu sınıf, birden çok karar ağacı kullanarak bir regresyon modeli oluşturan bir makine öğrenmesi algoritmasıdır. Kod parçasında, eksik verileri doldurmak için en iyi iterasyon sayısını bulmak için bir fonksiyon tanımlanmıştır. Ayrıca, eksik veri raporunu ve imputasyon sonuçlarını göstermek için birkaç fonksiyon daha tanımlanmıştır.

Eksik verileri doldurma işlemi şu şekilde gerçekleştirilir:

Öncelikle, veri seti eğitim ve test olarak ikiye ayrılır. Eğitim verisi, eksik verileri doldurmak için kullanılır. Test verisi, eksik verileri doldurmanın performansını ölçmek için kullanılır. Veri setini bölmek için, `train_test_split` fonksiyonu kullanılır. Bu fonksiyon, veri setini belirli bir oranda rastgele karıştırarak iki alt kümeğe ayırır. Sonra, en iyi iterasyon sayısını bulmak için, `self.find_best_iteration` fonksiyonu çağırılır. Bu fonksiyon, çapraz doğrulama yöntemini kullanır. Çapraz doğrulama, veri setini belirli sayıda parçaya bölerek, her parçayı sırayla test verisi olarak kullanır. Diğer parçalar ise eğitim verisi olarak kullanılır. Böylece, her parça için bir hata ölçüsü elde edilir. Bu hata ölçüleri, ortalama alınarak, modelin genel performansını verir. Bu fonksiyonda, çapraz doğrulama için `cross_val_score` fonksiyonu kullanılır. Bu fonksiyon, verilen bir modeli, verilen bir veri seti üzerinde belirli sayıda çapraz doğrulama yaparak, hata ölçülerini döndürür. Örneğin, `cv=5` parametresi, veri setinin 5 parçaya bölünmesini sağlar. Bu fonksiyonda, `IterativeImputer` sınıfının `max_iter` parametresi, farklı değerler alarak, en iyi iterasyon sayısını bulunmaya çalışılır. `max_iter` parametresi, eksik verileri tahmin etmek için tekrarlanan işlemin sayısını belirler. Bu fonksiyonda, `max_iter` parametresi, 1'den 10'a kadar değiştirilerek, her bir değer için çapraz

doğrulama sonucu elde edilir. Çapraz doğrulama sonuçları, bir liste halinde tutulur. Son olarak, bu liste içindeki en küçük hata ölçüsüne karşılık gelen `max_iter` değeri, en iyi iterasyon sayısı olarak döndürülür.

Sonra, en iyi iterasyon sayısı ile eksik verileri doldurmak için, `IterativeImputer` sınıfı kullanılır. Bu sınıf, eksik verileri, eksik olmayan verileri kullanarak bir döngü içinde tahmin eden bir yöntemdir. Tahmin etmek için, `RandomForestRegressor` sınıfı kullanılır. Bu sınıfların nesnelere, `imputer` ve `estimator` olarak adlandırılır. `Imputer` nesnesi, `estimator` nesnesini parametre olarak alır. `Imputer` nesnesi, `fit_transform` fonksiyonu ile eğitim verisi üzerinde eksik verileri doldurur. Bu fonksiyon, hem modeli eğitir, hem de veri setini dönüştürür. Dönüştürülen veri seti, eksik verilerin yerine tahmin edilen değerleri içerir. Bu veri seti, `filled_data` olarak adlandırılır. `filled_data`, bir numpy dizisidir. Bu diziyi, bir pandas veri çerçevesine dönüştürmek için, `pd.DataFrame` fonksiyonu kullanılır. Bu fonksiyon, bir diziyi, sütun isimleri verilerek, bir veri çerçevesine çevirir. Bu veri çerçevesi, `filled_data_df` olarak adlandırılır. Bu veri çerçevesi, sadece sayısal verileri içerir.

Sonra, doldurulmuş veri setini kaydetmek için, kullanıcıdan bir dosya yolu seçmesi istenir. Bu işlem için, `QFileDialog` sınıfı kullanılır. Bu sınıf, grafik arayüzde dosya seçim penceresi açmaya yarar. Bu sınıfın `getSaveFileName` fonksiyonu, kullanıcıya kaydedilecek dosyanın yolunu ve adını belirlemesini sağlar. Kullanıcı bir dosya yolu seçerse, bu dosya yolu, `output_file_path` olarak adlandırılır. Sonra, doldurulmuş veri seti, `to_csv` fonksiyonu ile seçilen dosyaya kaydedilir. Bu fonksiyon, bir veri çerçevesini, belirli bir araç ile CSV formatında bir dosyaya yazar. Bu şekilde kullanıcı doldurulmuş verileriyle birlikte oluşturulan veri setini istediği şekilde kaydedebilir.

2.4 Sonuç ve çıktı

İmputasyon sonuçları, eksik verileri doldurmadan önce ve sonra veri setinin istatistiksel özelliklerini karşılaştıran bir tablo olarak sunulmuştur. Bu tablo, `self.display_imputation_results` fonksiyonu ile oluşturulmuştur. Ayrıca durum raporu olarak kullanıcıya sonuç çıktısı sunulmaktadır.

3 BULGULAR

Yapılan çalışmanın doğruluğunu test etmek için 4 farklı veri seti seçilmiş ve bu veri setlerinin her biri rasgele olarak %5, %10 ve %15 tamamen rasgele eksik (Missing completely at random-MCAR)[7] bir şekilde azaltılıp R^2 (Coefficient of Determination Square- Belirlilik katsayısı) ve RMSE (Root Mean Square Error- Hata Karelerinin Kök Ortalaması) değerleri hesaplanmıştır. Hata ve doğruluk değerlerini hesaplamak için R^2 ve RMSE değerlerini hesabını yapan 3 katmanlı bir yapay sinir ağı geliştirilmiş ve orijinal veri seti ile doldurulmuş veri seti arasındaki R^2 ve RMSE değerleri geliştirilen yapay sinir ağı ile hesaplanmıştır.

3.1 Veri setleri

Çalışmada kullanılan veri setleri ile ilgili detaylı bilgi aşağıda verilmiştir:

3.2 Hepatit C veri seti

Hepatit veri seti, hepatit C hastalığının tahmin edilmesi için kullanılan bir veri setidir. Veri seti, 615 hastanın kan testi sonuçlarını ve hepatit C tanısı durumlarını içerir. 1 bağımlı değişken ve 12 bağımsız değişkenden oluşur [8].

3.3 Altın fiyatı tahmini veri seti

2011-2019 yılları arasında oluşturulan altın fiyatlarının yer aldığı 1718 satır ve 80 sütundan oluşan veri setidir [9].

3.4 Bükreş konut fiyatları veri seti

Bükreş kentinde 2019 yılın ait 6 bağımsız değişken ve 1 bağımlı değişkenden ve 3530 satır 7 sütundan oluşan veri setidir [10].

3.5 UV-visible spektrum datası

1202 satır ve 6 sütundan oluşan veri seti molekül yapısını gösterir. UV-visible datası, yapılan çalışmada, ele edilen nanoparçacığın optik özelliklerinin karakterize edilmesi amacıyla kullanılmıştır [11]. Yapılan çalışma da 4 farklı veri seti %5, %10 ve %15 oranında eksiltilmiş, orijinal veri seti ile doldurulmuş veri seti arasında arasındaki RMSE

oranını ve R^2 değerini hesaplayan bir yapay sinir ağı geliştirilmiştir. Elde edilen sonuçlar aşağıda tablo halinde verilmiştir:

Tablo 1. Hepatit veri tabanı test sonuçları

Eksiltme Oranı	RMSE Değeri	R^2 Değeri
%5	2,432197	0,76871
%10	2,897318	0,75332
%15	3,344554	0,72297

Tablo 2. Altın fiyatları veri set test sonuçları

Eksiltme Oranı	RMSE Değeri	R^2 Değeri
%5	4,476231	0,79414
%10	5,067433	0,77641
%15	5,949174	0,68134

Tablo 3. Bükreş konut fiyatı datası test sonuçları

Eksiltme Oranı	RMSE Değeri	R^2 Değeri
%5	8,441538	0,69147
%10	9,178293	0,68881
%15	9,817835	0,67101

Tablo 4. UV-visible spektrum datası test sonuçları

Eksiltme Oranı	RMSE Değeri	R^2 Değeri
%5	0,032126	0,60976
%10	0,041114	0,59855
%15	0,049852	0,57890

4 SONUÇLAR

Bu makale kapsamında eksik verilerin tahminini yapmak için Python tabanlı eksik veri yönetim sistemi geliştirilmiştir. Çalışmanın amacı doğrultusunda alanında uzman olmasa bile her bir kullanıcının veya araştırmacının rahatlıkla kullanabileceği bir arayüz oluşturularak veri setlerindeki eksik veriler doldurulmaya çalışılmıştır. Bu çalışma kapsamında sadece nümerik veriler üzerinde çalışılmıştır. Üzerine çalıştığımız 4 farklı veri setinin eksik verilerini %57 ile % 79 oranında doğruluk ile tahmin ettiğimizi sonuçlara bakarak görüyoruz. Elde edilen sonuçlar nümerik veriler için geçerlidir. Amaçladığımız gibi, eksik verileri silme veya klasik istatistik yöntemlerden uzaklaşarak yanlılığı azaltacak, daha doğru tahminler yapılmasını sağlayan bir eksik veri tamamlama sistemi geliştirerek literatüre katkı sağladık. Bu çalışmanın daha sonraki aşamalarında sözel veriler üzerinde de durulup hem eksik sözel verileri tek başına değerlendiren hem de her iki veri türündeki eksik verileri en doğru şekilde tahmin edebilen kompakt bir algoritma üzerine çalışılacaktır.

Teşekkür

Atatürk Üniversitesi Bilimsel Araştırma Projeleri (BAP) koordinasyon birimi tarafından desteklenen ve FYL-2023-11813 nolu proje kapsamında ihtiyaç duyulan bütçe tahsisini sağladıkları ve değerli katkılarından dolayı BAP koordinasyon birimine teşekkür ederim.

Yazar Katkıları

Ülgen AYDIN: Kavramlaştırma, Metodoloji, Yazılım, Doğrulama, Veri analizi, Araştırma, Materyaller / Kaynaklar, Veri İyileştirme, Yazım- Özgün Taslak, Yazım- Değerlendirme & Düzenleme, Görselleştirme, Süpervizyon, Proje yönetimi, Finansman temini

Gökay AKKAYA: Kavramlaştırma, Metodoloji, Araştırma, Yazım- Özgün Taslak, Yazım- Değerlendirme & Düzenleme, Görselleştirme, Süpervizyon, Proje yönetimi, Finansman temini

Yazarlar makalenin son halini okuyup onaylamışlardır.

Çıkar Çatışması Beyanı

Yazarlar herhangi bir çıkar çatışması olmadığını beyan eder.

Kaynakça

- [1] H. T. Moges, K. Dejaeger, W. Lemahieu, and B. Baesens, “A multidimensional analysis of data quality for credit risk management: New insights and challenges,” *Information and Management*, vol. 50, no. 1, pp. 43–58, 2013, doi: 10.1016/j.im.2012.10.001.
- [2] H.-T. Moges, K. Dejaeger, W. Lemahieu, and B. Baesens, “A multidimensional analysis of data quality for credit risk management: New insights and challenges,” *Information & Management*, vol. 50, no. 1, pp. 43–58, Jan. 2013, doi: 10.1016/j.im.2012.10.001.
- [3] K. Veriler *et al.*, “The Effects of Different Methods Used for Value Imputation Instead of Missing Values on Model Data Fit Statistics,” 2015.
- [4] Y. Celik, “Comparison of Data Used For Loss Of Data Mining Methods,” 2013. [Online]. Available: <https://www.researchgate.net/publication/348787393>
- [5] F. Arslan *et al.*, “Yapay Zekâ Tabanlı Büyük Veri Yönetim Aracı.”
- [6] M. Abdella and T. Marwala, “The Use Of Genetic Algorithms and Neural Networks to Approximate Missing Data in Database,” 2005.
- [7] D. R. RJA Little, *Statistical analysis with missing data*. 2019.
- [8] G. Hoffmann, A. Bietenbeck, R. Lichtenhagen, and F. Klawonn, “Using machine learning techniques to generate laboratory diagnostic pathways—a case study,” *J Lab Precis Med*, vol. 3, pp. 58–58, Jun. 2018, doi: 10.21037/jlpm.2018.06.01.
- [9] Kaggle, “Gold Price Prediction Dataset,” 2019. [Online]. Available: <https://www.kaggle.com/datasets/sid321axn/gold-price-prediction-dataset>. [Accessed: 10-Dec-2023]
- [10] Kaggle, “Bucharest House Price Dataset,” 2022. [Online]. Available: <https://www.kaggle.com/datasets/denisadutca/bucharest-house-price-dataset>. [Accessed: 20-Dec-2023]
- [11] S. Aydin, O. Ustun, A. Ghosigharehaghaji, T. Tavaci, A. Yilmaz, and M. Yilmaz, “Hydrothermal Synthesis of Nitrogen-Doped and Excitation-Dependent Carbon Quantum Dots for Selective Detection of Fe³⁺ in Blood Plasma,” *Coatings*, vol. 12, no. 9, Sep. 2022, doi: 10.3390/coatings12091311.