

Federe Öğrenme ile Üroflowmetri Sınıflandırması ve Karar Destek Yaklaşımı

Dr. Ömer ALGORABİ




İKSAD
Publishing House

Federe Öğrenme ile Üroflovmetri Sınıflandırması ve Karar Destek Yaklaşımı

Dr. Ömer ALGORABİ

DOI: <https://dx.doi.org/10.5281/zenodo.17776518>



Copyright © 2025 by iksad publishing house
All rights reserved. No part of this publication may be reproduced, distributed
or transmitted in any form or by
any means, including photocopying, recording or other electronic or
mechanical methods, without the prior written permission of the publisher, except in
the case of

brief quotations embodied in critical reviews and certain other noncommercial
uses permitted by copyright law. Institution of Economic Development and Social

Researches Publications®

(The Licence Number of Publicator: 2014/31220)

TÜRKİYE TR: +90 342 606 06 75

USA: +1 631 685 0 853

E mail: iksadyayinevi@gmail.com

www.iksadyayinevi.com

It is responsibility of the author to abide by the publishing ethics rules.

Iksad Publications – 2025©

ISBN: 978-625-378-408-9

Cover Design: İbrahim KAYA

November / 2025

Ankara / Türkiye

Size: 16x24cm

ÖNSÖZ

Bu kitabın konusunu temsil eden araştırma, İstanbul Üniversitesi-Cerrahpaşa Mühendislik Fakültesi öğretim üyesi Prof. Dr. Yusuf Sait TÜRKAN danışmanlığında Endüstri Mühendisliği Anabilim dalında doktora tez çalışması olarak hazırlanmıştır.

Bu doktora tezi, çocuklarda üroflovetri paternlerinin yapay zekâ temelli yöntemlerle sınıflandırılmasını ve bu süreçte federe öğrenmenin uygulanabilirliğini araştırmak amacıyla hazırlanmıştır. Günümüzde sağlık verilerinin güvenli biçimde işlenmesi ve çok merkezli yapay zekâ modellerinin geliştirilmesi büyük önem taşımaktadır. Federe öğrenme, verilerin paylaşılardan ortak bir model oluşturulmasına imkân tanıyarak hem mahremiyeti korumakta hem de klinik karar destek sistemlerine yeni bir yaklaşım sunmaktadır.

Bu çalışma kapsamında çok merkezli veri yapısı kullanılmış, farklı kliniklerden elde edilen üroflovetri sinyalleri federatif mimari altında işlenerek çocuk ürolojisi alanında daha güvenilir ve genellenebilir patern sınıflandırma modelleri geliştirilmiştir. Elde edilen bulguların, klinik değerlendirme süreçlerine katkı sunacağı ve gelecekteki federatif sağlık uygulamalarına ışık tutacağı düşünülmektedir.

Bu sürece katkı veren danışmanlarıma, çalışma arkadaşlarıma ve veri sağlayan klinik merkezlere teşekkür ederim.

Dr. Ömer ALGORABİ
İstanbul, 2025

İÇİNDEKİLER

ÖNSÖZ.....	i
SİMGE VE KISALTMA LİSTESİ.....	vi
GİRİŞ.....	1
Çalışmanın Katkıları.....	2
Çalışmanın Kapsamı.....	3
1. KAVRAMSAL ÇERÇEVE	5
1.1. Sağlık Endüstrisi.....	5
1.1.1. Dünya’da Üroloji.....	6
1.1.2. Türkiye’de Üroloji.....	8
1.2. Federe Öğrenme	10
1.2.1. Veri Bölümlemesine Göre Federe Öğrenme Sınıflandırması	12
1.2.2. Gizlilik Mekanizmasına Göre Federe Öğrenme Sınıflandırması	15
1.2.3. Uygulanabilir Makine Öğrenimi Modeline Göre Federe Öğrenme Sınıflandırması	17
1.3. Sağlık Endüstrisinde Federe Öğrenme Uygulamalarının Analizi.....	19
1.3.1. Veri Kaynağı ve Yöntem	19
1.3.2. Bibliyometrik Analiz	20
1.4. Üroflovetri Testi	33
1.5. Literatür İnceleme	36
1.5.1. Sağlık Sektöründe Yapay Zekâ Uygulamaları Üzerine Kaynakça Taraması	36
1.5.2. Sağlık Sektöründe Optimizasyon Uygulamaları Üzerine Kaynakça Taraması	47
2. YÖNTEM	50
2.1. Federe Öğrenme Tabanlı Önerilen Karar Modeli	50
2.2. Veri Seti ve Veri Ön İşleme	51

2.2.1. Veri Temizleme.....	53
2.2.2. Veri Dönüştürme	55
2.3. Çok Katmanlı Algılayıcı.....	56
2.4. Hiperparametre Optimizasyonu.....	58
2.5. Federe Öğrenme Algoritmaları.....	60
2.5.1. FedAvg	60
2.5.2. FedProx	61
2.5.3. FedDyn	62
2.5.4. MOON.....	63
2.6. SHAP Analizi	64
2.7. Model Değerlendirme Ölçütleri	64
2.7.1. Sınıflandırma Modeli Performans Ölçütleri.....	64
2.7.2. Çizelgeleme Optimizasyonu Performans Ölçütü	67
2.8. İstatistiksel Anlamlılık ve Sağlamlık Testleri	67
2.8.1. K-Katlı Çapraz Doğrulama	67
2.8.2. Normallik Testi.....	68
2.8.3. Spearman Korelasyon Analizi	69
2.8.3. Kruskal Wallis Testi.....	70
2.9. İki Amaçlı Evde Sağlık Hizmeti Çizelgeleme Modeli	71
2.10. Karınca Kolonisi Optimizasyonu	73
2.11. Uygulama Platformu ve Yazılımlar	76
3. BULGULAR	77
3.1. Global Model.....	77
3.2. Merkezi Eğitim ve Federe Öğrenme	78
3.3. Deneyisel Ayarların Etkisi	85
3.3.1. İstemci Sayısının Etkisi.....	85
3.3.2. Federe Tur Sayısının Etkisi	86

3.3.3. Epoch Sayısının Etkisi	88
3.3.4. Hiperparametre Optimizasyon Etkisi	90
3.4. SHAP ve İstatistiksel Bulgular	91
3.5. Çizelgeleme Bulguları	93
4. TARTIŞMA	96
4.1. Araştırma Sonuçlarının Tartışılması	96
4.2. Araştırma Kısıtları ve Sınırlılıklarının Tartışılması	98
5. SONUÇ VE ÖNERİLER	100
KAYNAKLAR	100
EKLER	100

SİMGE VE KISALTMA LİSTESİ

Kısaltmalar	Açıklama
AEP	: Akış Eğrisi Paternleri
AI	: Artificial Intelligence
AOA	: Arşimet Optimizasyon Algoritması, Archimedes Optimization Algorithm
ASIR	: Yaşa Göre Standardize Edilmiş İnsidans Hızı (Age Standardized Incidence Rate)
AT	: Ağaç Tabanlı
CNN	: Evrişimsel Sinir Ağları (Convolutional Neural Networks)
DFÖ	: Dikey Federe Öğrenme
DNN	: Derin Sinir Ağları (Deep Neural Networks)
EAPC	: Tahmini Yıllık Yüzde Değişim (Estimated Annual Percentage Change)
ESH	: Evde Sağlık Hizmeti
FedAvg	: Federated Averaging
FedDyn	: Federated Dynamics
FedProx	: Federated Proximal
FÖ	: Federe Öğrenme
FL	: Federated Learning
FN	: Yanlış Negatif (False Negative)
FP	: Yanlış Pozitif (False Positive)
FTÖ	: Federe Transfer Öğrenme
GBDT	: Gradient-Boosting Karar Ağaçları (Gradient Boosting Decision Trees)
GDPR	: Genel Veri Koruma Yönetmeliği (General Data Protection Regulation)
GKFÖ	: Gizliliği Koruyan Federe Öğrenme
HHS	: Home Health Services
HŞ	: Homomorfik Şifreleme
KHŞ	: Kısmi Homomorfik Şifreleme
KKO	: Karınca Kolonileri Optimizasyonu
KNN	: K-En Yakın Komşu (K-Nearest Neighbor)

KVKK	: Kişisel Verilerin Korunması Kanunu
LR	: Lojistik Regresyon (Logistic Regression)
LSTM	: Uzun Kısa Vadeli Hafıza (Long Short-Term Memory)
ML	: Machine Learning
MLP	: Çok Katmanlı Algılayıcılar (Multi-Layer Perceptron)
MOON	: Model-Contrastive Federated Learning
MÖ	: Makine Öğrenme
RF	: Rastgele Orman (Random Forest)
SA	: Sinir Ağları
SGD	: Stokastik Gradyan İniş (Stochastic Gradient Descent)
SVM	: Destek Vektör Makineleri (Support Vector Machines)
TA	: Toplam Atıf
TY	: Toplam Yayın
THŞ	: Tam Homomorfik Şifreleme
TN	: Doğru Negatif (True Negative)
TP	: Doğru Pozitif (True Positive)
YFÖ	: Yatay Federe Öğrenme
YZ	: Yapay Zeka

GİRİŞ

Küresel sağlık sistemleri, nüfus artışı, kanser ve kronik hastalıkların artan yaygınlığı nedeniyle artan hasta sayısı, artan sağlık hizmetleri maliyetleri ve personel yetersizliği nedeniyle zorlanmaktadır (Roppelt ve diğ., 2024). Aynı zamanda Birleşmiş Milletler, küresel olarak toplumların sürdürülebilir kalkınmasını teşvik etmek için iyi sağlık ve refahın teşvik edilmesi ve eşitsizliklerin azaltılması çağrısında bulunmaktadır. Bu faktörler, hükümetler, klinik kurumlar ve şirketler de dahil olmak üzere sağlık sektöründeki kilit paydaşları mevcut uygulamaları yeniden düşünmeye ve inovasyonu artırmaya motive etmektedir.

Sağlık, günümüzde çoğu kişi için öncelikli bir konu değildir. Pek çok hasta maliyet ya da yoğunluk nedeniyle doktora gitmezken, tekrarlayan semptomların ihmal edilmesi ciddi sağlık sorunlarına yol açabilmektedir. (Badawy ve diğ., 2023). Bu noktada, yapay zekâ teknolojileri sağlık hizmetlerinde bir çözüm olarak ortaya çıkmıştır. YZ destekli uygulamalar, erken teşhis imkânı sunarak hastaların sağlık durumlarını evlerinden takip etmelerine olanak tanımakta, böylece hastaneye gitme ihtiyacını azaltmakta ve yoğun yaşam temposuna sahip bireyler için erişilebilir, zaman tasarrufu sağlayan alternatifler sunmaktadır.

Sağlık hizmetlerinde, yapay zeka telnolojilerinin ortaya çıkmasıyla önemli bir dönüşüm yaşanmaktadır (Rayhan ve diğ., 2023). Benzeri görülmemiş bir dijitalleşme çağına girerken, sağlık sektörü hasta bakımında devrim yaratmak ve genel refahı iyileştirmek için yapay zekanın tüm potansiyelinden yararlanmaya çalışmaktadır. Yapay zekanın sağlık hizmetlerine entegrasyonu, teşhis doğruluğunu artırma, tedavi yaklaşımlarını kişiselleştirme, sağlık hizmetleri süreçlerini optimize etme ve hastaları sağlıklarını yönetmede aktif bir rol üstlenmelerine olanak tanıma potansiyeli taşımaktadır.

Makine öğrenme, makinelerin açık bir programlama olmadan otomatik olarak öğrenmesini sağlayan bir mekanizmadır (An ve diğ., 2023). Makine öğreniminin ana alanı, verilere erişmek ve kural tabanlı bir sistem yerine doğruluğu tahmin etmek için gelişmiş algoritmalar ve istatistiksel teknikler kullanmaktır. Veri seti, makine öğrenimi doğruluk tahmininin birincil bileşenidir. Kaliteli ve amaca uygun veriler, tahmin modellerinin doğruluk oranlarını doğrudan etkilemektedir. Bu bağlamda, sağlık hizmetlerinde

uygulanan makine öğrenimi algoritmalarının başarısı büyük ölçüde kullanılan verinin niteliğine bağlıdır.

Sağlık hizmetleri sisteminin ve süreçlerinin karmaşık yapısı nedeniyle sağlık hizmetleri verileri tipik olarak parçalıdır (Xu ve diğ., 2021). Örneğin, farklı hastaneler yalnızca kendi hasta popülasyonlarının klinik kayıtlarına erişebilir. Bu kayıtlar, bireylerin korunan sağlık bilgileri açısından son derece hassastır. Kişisel Verilerin Korunması Kanunu (KVKK) gibi sıkı düzenlemeler, bu tür verilere erişim ve analiz sürecini düzenlemek için geliştirilmiştir. Bu durum, tipik olarak büyük miktarda eğitim verisi gerektiren derin öğrenme gibi modern veri madenciliği ve makine öğrenimi teknolojileri için büyük bir zorluk yaratmaktadır. Bu bağlamda, federe öğrenme, gelişmiş gizlilik koruması ile uygun maliyetli akıllı sağlık uygulamalarının gerçekleştirilmesi için umut verici bir çözüm olarak ortaya çıkmıştır. Kavramsal olarak FÖ, yerel verilere doğrudan erişime ihtiyaç duymadan birden fazla sağlık verisi istemcisinden toplanan yerel güncellemelerin ortalamasını alarak yüksek kaliteli MÖ modellerinin eğitilmesini sağlayan dağıtılmış bir YZ yaklaşımıdır (Nguyen ve diğ., 2022). Bu, hassas kullanıcı bilgilerinin ve kullanıcı tercihlerinin ifşa edilmesini potansiyel olarak önler ve böylece gizlilik sızıntısı risklerini azaltır. Ayrıca federe öğrenme, YZ modellerini eğitmek için bir dizi sağlık verisi istemcisinden büyük hesaplama ve veri kümesi kaynaklarını çektiğinden, sağlık verisi eğitim kalitesi, örneğin doğruluk, daha az veri ve sınırlı hesaplama yeteneklerine sahip merkezi YZ yaklaşımları kullanılarak elde edilemeyecek şekilde önemli ölçüde iyileştirilecektir.

Modern üroloji alanında yapay zeka teknolojisinin kullanımına ilişkin çalışmalar nispeten az olsa da, özellikle bilgisayar destekli görüntüleme, cerrahi eğitim, ürokinamik ve ileri stratejilerde potansiyel kullanım alanları çoktur (Barua ve diğ., 2023). Bu çalışmada bir hastanenin üroloji polikliğinden alınan üroflovetri testi raporları ile işeme paterni sınıflandırma problemi ele alınmıştır. Sınıflandırma modelinde merkezi, yerel istemci ve federe öğrenme çerçeveleri karşılaştırılmıştır. Elde edilen bulgular, evde sağlık hizmeti kapsamında bir çizelgeleme optimizasyonu probleminde kullanılmıştır.

Çalışmanın Katkıları

Son yıllarda sağlık alanında veri gizliliği, güvenliği ve veri minimizasyonu gibi etik ilkelere duyarlılık giderek artmış ve bu ilkeleri temel

alan yapay zekâ yaklaşımlarına olan ilgi büyük ölçüde artmıştır. Özellikle merkezi olmayan veri işleme yeteneğine sahip federe öğrenme yöntemleri, hasta mahremiyetini ihlal etmeden etkili tahmin sistemleri geliştirilmesine olanak tanımaktadır. Üroloji alanında da bu etik kaygılar son derece önemli olmakla birlikte, mevcut literatür incelendiğinde, özellikle üroflovetri paternlerinin tespitine yönelik federe öğrenme tabanlı bir uygulamaya yer verilmediği belirlenmiştir.

Bununla birlikte, evde sağlık hizmetlerinde hasta ihtiyaçlarına özel hizmet planlaması yapılabilmesi için doğru tahmin modellerinin operasyonel sistemlerle entegre edilmesi gerekmektedir. Ancak mevcut literatürde, makine öğrenmesi ile elde edilen tahminlerin evde sağlık hizmetlerinin çizelgelenmesi gibi optimizasyon problemlerine doğrudan entegre edildiği uçtan uca karar destek sistemlerine rastlanmamaktadır.

Bu çalışmanın katkıları şu şekilde özetlenebilir: (1) Sağlık sektöründeki federe öğrenme uygulamalarının kapsamlı bir bibliyometrik analizini yaparak mevcut literatüre katkıda bulunmaktadır. (2) Üroflovetri patern eğrilerinin sınıflandırılmasına yönelik literatürde yer almayan yeni öznitelikler tanımlanarak yenilikçi bir katkı sağlanmıştır. (3) Üroflovetri patern eğrilerinin sınıflandırılmasında federe öğrenme yöntemi kullanılarak veri güvenliği, mahremiyet ve veri minimizasyonu ilkeleri korunmuş; merkezi olmayan bir yapay zekâ mimarisi ile özgün bir çözüm geliştirilmiştir. (4) Federe öğrenme yoluyla elde edilen sınıflandırma sonuçlarının evde sağlık hizmeti kapsamında bir optimizasyon modeline girdi olarak entegre edilmesiyle, makine öğrenmesi ile üretilen tahminlerin operasyonel karar destek sistemlerinde etkin biçimde kullanılabileceği gösterilmiştir. (5) Veri gizliliğini temel alan, yüksek doğrulukta tahminler üretebilen ve bu tahminleri evde sağlık hizmetlerinin çizelgelenmesinde kullanan uçtan uca entegre bir akıllı karar destek sistemi önerilerek, hem yapay zekâ hem de sağlık hizmeti planlama alanında yenilikçi bir yaklaşım sunulmuştur.

Çalışmanın Kapsamı

Bu çalışmada, Marmara Üniversitesi Üroloji Birimi'nden elde edilen, 0–18 yaş aralığındaki 599 çocuk hastaya ait üroflovetri test verileri kullanılarak işleme paterninin belirlenmesine yönelik akıllı bir karar destek modeli önerilmiştir. Geliştirilen model, federe öğrenme yaklaşımı çerçevesinde

Arşimet Optimizasyon Algoritması ile optimize edilmiş bir yapay sinir ağı mimarisine dayanmaktadır. İşeme paterni normal dışı olarak tahmin edilen bazı hastalar için ikinci testlerin evde sağlık hizmetleri kapsamında planlanabilmesi amacıyla bir çizelgeleme modeli ortaya konmuştur.

Bu çalışma şu şekilde yapılandırılmıştır: Giriş bölümünden sonra, Bölüm 1 (Kavramsal Çerçeve) üroloji alanını tanıtmakta, sağlıkla ilgili çalışmalar bağlamında federe öğrenmenin bibliyometrik bir analizini sunmakta ve yapay zekanın sağlık endüstrisindeki uygulamaları ile ilgili literatürü gözden geçirmektedir. Bölüm 2'de (Yöntem) kullanılan veri kümesi özetlenmekte ve araştırma problemini ele almak için kullanılan hesaplama yöntemleri detaylandırılmaktadır. Bölüm 3'te (Bulgular), elde edilen sonuçlar tablolar ve görselleştirmeler aracılığıyla sunulmakta ve yorumlanmaktadır. Bölüm 4 (Tartışma) sonuçları değerlendirmekte, çıkarımlarını detaylandırmakta ve çalışmanın sınırlamalarını ve kısıtlamalarını ele almaktadır. Son olarak, Bölüm 5 (Sonuç ve Öneriler) temel bulguları özetlemekte, federe öğrenme yaklaşımının önemini vurgulamakta ve gelecekteki araştırmalar için öneriler sunmaktadır.

1. KAVRAMSAL ÇERÇEVE

1.1. Sağlık Endüstrisi

Sağlık sektörü, bireylerin yaşam kalitesini artırmak ve hastalıkların önlenmesini sağlamak amacıyla sağlık hizmetlerinin sunulmasını kapsayan kritik bir alandır. Bu sektör; hastaneler, sağlık çalışanları, ilaç firmaları, tıbbi cihaz üreticileri ve kamu sağlığı kurumları gibi çok sayıda aktörü içinde barındırır. Dünya genelindeki sağlık sistemleri, sağlık hizmetlerinde “dörtlü hedefe” ulaşma konusunda ciddi zorluklarla karşı karşıyadır. Bu hedefler; toplum sağlığını iyileştirmek, hasta bakım deneyimini geliştirmek, sağlık çalışanlarının memnuniyetini artırmak ve artan sağlık hizmeti maliyetlerini azaltmaktır. (Bajwa ve diğ., 2021).

Dünya Sağlık Örgütüne göre; sağlık endüstrisi, üretkenliği ve dayanıklılığı artırmak için yenilikçi stratejiler gerektiren işgücü eksiklikleriyle karşı karşıyadır. Bu zorlukların üstesinden gelmek için sağlığın sosyal belirleyicilerinin, teknolojik gelişmelerin ve sağlıkta eşitlik taahhüdünün entegre edilmesine vurgu yapılmaktadır. Küresel olarak, bulaşıcı olmayan hastalıklardan kaynaklanan ölümlerin tüm ölümler içindeki payı 2019 yılına kadar istikrarlı bir şekilde %73,9'a yükselirken, bulaşıcı hastalıkların payı %18,2'ye düşmüştür. COVID-19'un ortaya çıkmasıyla birlikte bulaşıcı hastalıklar 2020'de tüm ölümlerin %23,0'üne, 2021'de ise %28,1'ine yükselerek 2005 seviyelerine geri dönmüştür. Sonuç olarak, bulaşıcı olmayan hastalıklardan ölümlerinin payı 2020'de %70'e ve 2021'de %65,3'e gerilemiştir (World Health Organization, 2024).

Covid-19 salgını, dünya çapında birçok sektörde derin dönüşümler yaratmıştır. İnsani ve sosyal açıdan değişiklikler dramatik olmakla birlikte, iş dünyasında ve eğitimde birçok yeni fırsat ortaya çıkmıştır (Basile ve diğ., 2023). Pandeminin neden olduğu sosyal mesafeyi koruma ve aynı zamanda çalışmaya devam etme ihtiyacı, şirketleri, çalışanları, öğrencileri ve farklı profesyonelleri dijital dönüşümü hızlandırmaya zorladı. McKinsey uzmanları, Covid-19 nedeniyle Avrupa'da dijital teknolojilerin benimsenme oranının %81'den %95'e çıktığını ve pandemi öncesi büyüme oranlarında bu değişimin ancak 2-3 yılda sağlanabileceğini tahmin etmektedir (Fernandez ve diğ., 2020). Dijitalleşmeden en çok etkilenen sektörlerden biri de sağlık sektörüdür. Son zamanlarda sağlık sektöründe dijitalleşme, kırılabilirlik karşıtı stratejilerin, yani

sağlık sektörünün Covid-19 salgını gibi bir kriz sırasında ve sonrasında daha güçlü hale gelmesini sağlayan stratejilerin benimsenmesini sağlamıştır.

Büyük veriyi analiz etmek için yapay zekanın gücünden yararlanmak, geleneksel sağlık hizmetlerinin sınırlarını aşma potansiyeline sahiptir (Panahi, 2025). Tahmine dayalı analitik sayesinde, reaktif hastalık yönetiminden proaktif sağlık stratejilerine geçebilir ve hastalıkların ortaya çıkmadan önce öngörülmesi sağlanabilmektedir. Bu yaklaşım zamanında müdahalelere, sağlığın daha etkili bir şekilde geliştirilmesine ve verimli kaynak tahsisine olanak tanır. Ayrıca, bireyin genetik profiline ve yaşam tarzı faktörlerine göre uyarlanmış kişiselleştirilmiş tıp, tedavi sonuçlarını optimize edebilir ve yan etkileri en aza indirebilir.


1.1.1. Dünya’da Üroloji

Üroloji, idrar yolları ve üreme sistemi ile ilgili rahatsızlıkların teşhis ve tedavisine odaklanan bir tıp uzmanlığıdır. Son zamanlarda yapılan çalışmalar, ürolojik hastalıkların küresel yükü ve bunların yönetimindeki ilerlemeler hakkında bilgi sağlamıştır.

Ürolojik rahatsızlıklar dünya çapında önemli bir hastalık yükü oluşturmaktadır ve gelişmekte olan ile gelişmiş ülkelerde ürologlara duyulan ihtiyaç giderek artmaktadır. Yüksek gelirli ülkeler ile düşük ve orta gelirli ülkeler arasında yeterli cerrahi bakıma erişimdeki belirgin eşitsizlikler yaygın olarak kabul edilmektedir (Bağcı ve diğ., 2024). Düşük ve orta gelirli ülkelerde ürolojik bakıma erişimi iyileştirme çabaları devam etmektedir. Kuruluşlar, ürolojik sağlık alanındaki eşitsizlikleri gidermek için cerrahi bakım sunumu, eğitim, araştırma ve savunuculuk konularına odaklanmaktadır (Sun ve Rapp, 2023).


Küresel Hastalık Yüğü 2021 verilerini analiz eden 2024 tarihli bir çalışmada, 2021 yılında ürolojik rahatsızlıklar arasında yaşa göre standartlaştırılmış en yüksek görülme oranlarının 100.000 kişide sırasıyla 5531,88 ve 2782,59 oranlarıyla İyi Huylu Prostat Büyümesi ve İdrar Yolu Enfeksiyonlarına ait olduğu bildirilmiştir (Zi ve diğ., 2024). Ürolojik enfeksiyonlar, özellikle de kateterle ilişkili idrar yolu enfeksiyonları, yılda 150 milyondan fazla insanı etkilemekte ve dünya genelinde sağlık sistemleri üzerinde önemli bir yük oluşturmaktadır (Öztürk ve Murt, 2020).

Zi ve arkadaşları 2021 ürolojik hatalıklar ilgili çalışmalarına göre Küresel ve 21 bölgede 6 ürolojik hastalık için yaşa göre standardize edilmiş insidans hızının (ASIR) tahmini yıllık yüzde değişimi (EAPC) Şekil 1'deki gibidir. 1990'dan 2021'e kadar, özellikle Orta Avrupa'da belirgin olmak üzere, çoğu bölgede mesane kanseri için ASIR'da kayda değer bir artış olmuştur. Buna karşılık, Prostat kanseri örüntüleri mesane kanseri örüntülerine çok benzemektedir; ASIR'daki en hızlı artışlar Doğu Avrupa, Kuzey Afrika ve Orta Doğu'da gözlenmiştir. Buna karşılık, yaşa göre standardize edilmiş ölüm oranında en önemli düşüşler Avustralya'da görülmüştür.



Şekil 1: Bölgelerdeki ürolojik hastalıkların yaşa göre standardize edilmiş insidans hızının tahmini yıllık yüzde değişimi

Aynı çalışmadaki 2021 yılı için 6 ürolojik hastalığın yaşa ve cinsiyete göre küresel insidansı Şekil 2'deki gibidir. Rapora göre; mesane, böbrek ve prostat kanseri insidansı ve prevalansı ağırlıklı olarak 70-74, 65-69 ve 70-74 yaş gruplarında yoğunlaşmıştır. Buna karşılık, ölümler en sık 80-84, 70-74 ve 80-84 yaş gruplarında meydana gelmiştir.



Şekil 2: 2021'de 6 ürolojik hastalığın yaşa ve cinsiyete göre küresel insidansı.


1.1.2. Türkiye'de Üroloji

Türkiye'de ürolojinin kuruluşu Osmanlı Üroloji Cemiyeti'nin kurulmasıyla 1908 yılına kadar uzanmaktadır (Verit ve diğ., 2018). İlk üroloji kliniği İstanbul'da Haydarpasa Askeri Hastanesi'nde kurulmuştur. Türkiye Cumhuriyeti'nin kuruluşundan bu yana üroloji popülerlik ve organizasyon kazanmıştır. Bugün ülke genelinde 3.500'den fazla ürolog ve eğitim ve

araştırma hastaneleri de dahil olmak üzere 100'den fazla üniversite kliniği bulunmaktadır (Republic of Türkiye, 2024).

Türk ürologlar küresel ürolojik araştırmalara önemli katkılarda bulunmuştur. Türkiye'den en çok atıf alan makaleler incelendiğinde, en sık ele alınan konuların böbrek taşı (%23,5), kısırlık (%15,6), iyi huylu prostat büyümesi (%11,7), cinsel işlev bozukluğu (%11,7) ve mesane kanseri (%9,8) olduğu görülmektedir. Bu çalışmaların %68,6'sı Ankara, İstanbul ve İzmir'de, %72,5'i ise üniversite hastanelerinde gerçekleştirilmiştir (İpekçi ve diğ., 2017).

Dünya Sağlık Örgütü'ne göre, prostat kanseri Türkiye'de yeni teşhis edilen kanser vakalarının yaklaşık %13'ünü oluşturmaktadır (Karagüz ve diğ., 2024). Ulusal bağlamda, iyi huylu ve kötü huylu tümörler birlikte, tüm ölümlerin %15,2'sini oluşturarak ikinci önde gelen ölüm nedenini temsil etmektedir. Kırk yaşın altındaki erkeklerde prostat kanseri gelişme olasılığı 10.000'de 1 gibi düşük bir oranda iken, bu risk yaşla birlikte önemli ölçüde artmakta ve yaşlı erkek popülasyonunda 8'de 1'e kadar yükselmektedir. 2015'teki bir çalışmaya göre Türkiye'de her altı kişiden birinde kronik böbrek hastalığı olduğu belirtilmiştir (Topbaş, 2015). Bir çalışmada, sağlık kuruluna başvuran hastaların %11,9'unda nöro-ürolojik hastalıklar tespit edilmiştir. Bu çalışmada nöro-ürolojik hastalıklar kadınlarda daha sık görüldüğü tespit edilmiştir (Yavuzsan ve diğ., 2022).




Şekil 3: Erkeklerde en sık görülen 10 kanser türünün toplam kanser içindeki dağılımı (T.C. Sağlık Bakanlığı, 2023).

Sağlık Bakanlığı'nın 2023 Sağlık İstatistikleri Yıllığı raporuna göre, Türkiye'de kanser türlerinin cinsiyete göre insidans değerleri (100.000 kişi başına, Dünya Standart Nüfusu baz alınarak) incelendiğinde, erkeklerde mesane kanseri insidansı 22,6 iken, kadınlarda bu oran 3,1 olarak kaydedilmiştir. Erkeklerde en sık görülen 10 kanser türünün toplam kanser içindeki dağılımı Şekil 3'teki gibidir.

1.2. Federe Öğrenme

Klasik merkezi öğrenme yaklaşımında, model eğitiminin gerçekleştirilebilmesi için verilerin tek bir merkezde toplanması gerekmektedir. Bu yaklaşım, yüksek işlem gücü ve geniş depolama kapasitesi gereksinimlerinin yanı sıra, ciddi veri gizliliği ihlali risklerini de beraberinde getirmektedir. Bu sorunlara çözüm üretmek amacıyla dağıtık öğrenme gibi alternatif teknolojiler geliştirilmiş olsa da, veri güvenliğinin tam olarak sağlanması ve mahremiyetin korunması açısından bu yaklaşımlar da yeterli düzeyde çözüm sunamamıştır (Nergiz, 2023).

Federe öğrenme, makine öğrenimi alanının artan veri gizliliği endişeleri ve dağıtılmış olarak sahip olunan veri silolarının yeni normaline uyum sağlamasına ve gelişmesine yardımcı olmayı amaçlayan bir makine öğrenimi paradigmasıdır (Yang ve diğ., 2020). Özel verileri ifşa etmeden model bilgilerini değiş tokuş ederek birden fazla katılımcının küresel olarak paylaşılan bir modeli eğitmesini sağlamak için umut verici bir alternatif sunar. Geleneksel merkezi makine öğrenimi, sınırlı iletişim bant genişliği, aralıklı ağ bağlantısı ve katı gecikme kısıtlamaları gibi altyapı eksiklikleri nedeniyle her yerde bulunan dağıtımları ve uygulamaları destekleyememektedir. Bu senaryoda, model eğitimini verilerin kaynaklandığı cihazlara iten FÖ, çok sayıda katılımcının kendi özel eğitim verilerini ifşa etmeden ortak bir makine öğrenimi modeli oluşturmasını sağlar.



Şekil 4: Makine öğrenme yaklaşımları (Nergiz, 2023).

Merkezi, Dağıtık ve FÖ yaklaşımlarını temsil eden modeller Şekil 4’teki gibidir. Şekilde üç farklı öğrenme yaklaşımı görselleştirilmiştir: Merkezi öğrenme, dağıtık öğrenme ve federe öğrenme. Merkezi öğrenmede tüm veriler tek bir merkezde toplanır ve model eğitimi burada gerçekleştirilir. Bu yöntem yüksek doğruluk sağlayabilir ancak veri gizliliği açısından risklidir. Dağıtık öğrenmede ise veriler farklı düğümlerde yer alır; model eğitimi farklı makinelerde gerçekleşir fakat genellikle veriler arasında paylaşım vardır. Federe öğrenme ise verilerin yerel cihazlarda kaldığı, sadece model güncellemelerinin merkezi sunucuya gönderildiği bir yöntemdir.

Federe öğrenme ilk olarak 2016 yılında Google tarafından on binlerce Android cihazda kullanıcının metin girişini tahmin etmek ve cihazdaki verileri tutmak için tanıtılmıştır (Li ve diğ., 2020). Genel Veri Koruma Yönetmeliği (GDPR) göz önüne alındığında, federe öğrenme çerçevesi son yıllarda hızla gelişmiştir. Günümüzde yapay zekâ kullanımının hızla artmasıyla birlikte federe öğrenme yaklaşımı akıllı telefonlar (Ek ve diğ., 2022), IoT (Savazzi ve diğ., 2020), sağlık hizmetleri (Guo ve diğ., 2022), reklamcılık (Bian ve diğ., 2023), otonom araçlar (Zeng ve diğ., 2022), enerji tahmini (Zhang ve diğ., 2022), dolandırıcılık tespiti (Abdul Salam ve diğ., 2024) ve sigortacılık (Gupta ve diğ., 2022) gibi birçok uygulamada kullanılmaktadır.

Genel bir federe öğrenme süreci aşağıdaki adımlardan oluşur (Kairouz ve diğ., 2021):

1. İstemci seçimi: Sunucu, uygunluk gereksinimlerini karşılayan bir dizi istemciden örnekleme yapar.

2. Yayın: Seçilen istemciler sunucudan mevcut model ağırlıklarını ve bir eğitim programını indirir.
3. İstemci hesaplaması: Seçilen her cihaz, örneğin yerel verilerle eğitim programını yürüterek model güncellemelerini yerel olarak gerçekleştirir.
4. Model birleştirme: Sunucu, cihaz güncellemelerinin bir toplamını bir araya getirir.
5. Model güncellemesi: Sunucu, mevcut tura katılan istemcilerden hesaplanan toplu güncellemeye dayalı olarak paylaşılan modeli yerel olarak günceller.

Bu döngü belirlenen tur sayısı kadar tekrar eder.


Federe öğrenme, ham verileri yerel cihazlarda tutarken merkezi olmayan model eğitime olanak tanıyarak veri gizliliği, güvenliği ve veri minimizasyonu ilkeleriyle uyumlu çeşitli avantajlar sunar (Jatain ve diğ., 2022). Merkezi veri toplamadan kaçınarak iletişim ve depolama ek yükünü azaltır ve sağlık ve finans gibi hassas alanlarda mevzuata uygunluğu destekler. Birleştirilmiş öğrenme, çeşitli ve dağıtılmış veri kümelerinden yararlanarak, özellikle heterojen ortamlarda model doğruluğunu ve genelleştirmeyi artırabilir. Ayrıca, istemciler arasında paralel yerel eğitim, genel eğitim süresini azaltabilir ve modelleri yerel olarak uyarlama yeteneği, ölçeklenebilirlikten ödün vermeden kişiselleştirilmiş öğrenmeye olanak tanır.

1.2.1. Veri Bölümlemesine Göre Federe Öğrenme Sınıflandırması

1.2.1.1. Yatay Federe Öğrenme

Yatay Federe Öğrenme (YFÖ) katılımcıların örtüşen veri özelliklerini paylaştığı, yani veri özelliklerinin katılımcılar arasında uyumlu olduğu, ancak veri örneklerinde farklılık gösterdikleri durumu ifade eder (Yang ve diğ., 2022). Verilerin bir tablo görünümü içinde yatay olarak bölümlendirildiği duruma benzer. Bu nedenle, YFÖ, örnek bölümlemeli olarak da adlandırılır. Şekil 5, üç istemcili senaryoda yatay federe öğrenme çerçevesini göstermektedir.


Örneğin, birkaç hastane aynı değişkenlere (örn. yaş, kan basıncı) sahip ancak farklı hastalara ait hasta kayıtlarını kullanarak ortak bir tanı modeli geliştirmek istemektedir. YFÖ, verileri yerel tutarak ve yalnızca model parametrelerini paylaşarak veri gizliliğini sağlar.



Şekil 5: Yatay Federe Öğrenme Gösterimi (Nergiz, 2022).

1.2.1.2. Dikey Federe Öğrenme

Dikey federe öğrenme (DFÖ), iki veri kümesinin kullanıcı özelliklerinin çok az örtüştüğü ancak kullanıcıların çok fazla örtüştüğü durumlarda kullanılabilir (Zhang ve diğ., 2021). DFÖ, veri kümelerini dikey olarak böler (kullanıcı özelliği boyutuna göre), ardından kullanıcıların aynı olduğu ancak kullanıcı özelliklerinin eğitim için tam olarak aynı olmadığı veri bölümünü çıkarır. Başka bir deyişle, farklı sütunlardaki veriler aynı kullanıcıya sahiptir (kullanıcıya göre hizalanmış). Bu nedenle, dikey federe öğrenme eğitim verilerinin özellik boyutunu artırabilir. Dikey federe öğrenme şeması Şekil 6'daki gibidir.




Şekil 6: Dikey federe öğrenme gösterimi (Nergiz, 2022).

Örneğin, bir hastane ve bir mobil sağlık uygulaması aynı müşterilere hizmet verebilir ancak farklı veri türlerini (finansal ve satın alma davranışı) depolayabilir. DFÖ, bu tarafların ham verileri ifşa etmeden özelliklerini birleştirerek daha kapsamlı ve doğru modeller oluşturmalarını sağlar.

1.2.1.2. Federe Transfer Öğrenme

Federe transfer öğrenme (FTÖ), ne veri örneklerinde ne de özelliklerde örtüşme olmadığı durumlar için geçerlidir (Yang ve diğ., 2022). Transfer öğrenme, alanlar arası bilgi transferi için çözümler sunan bir öğrenme tekniğidir. Birçok uygulamada, MÖ modellerinin güvenilir bir şekilde oluşturulamayacağı şekilde yalnızca az miktarda etiketli veriye veya zayıf denetime sahibiz. Bu gibi durumlarda, benzer görevler veya alanlardaki modellerden yararlanarak ve bunları uyarlayarak yine de yüksek performanslı makine öğrenimi modelleri oluşturulabilir. Şekil 7, iki istemcili senaryoda federe transfer öğrenme çerçevesini göstermektedir.

Örneğin, bir hastane ve bir ilaç şirketi, FTÖ aracılığıyla birleştirildiğinde ilaç yanıtı tahmini gibi sonuçları iyileştiren farklı ancak ilgili verilere sahip olabilir. FTÖ, tüm ham verileri yerel tutarak ve yalnızca ara temsilleri veya model güncellemelerini aktararak veri gizliliğini korur.



Şekil 7: Federe transfer öğrenme gösterimi (Nergiz, 2022).

1.2.2. Gizlilik Mekanizmasına Göre Federe Öğrenme Sınıflandırması

1.2.2.1. Model Birleştirme

Global modeli eğitmek için, temel olarak tüm taraflardan gelen model parametrelerini özetleyerek çalışan model birleştirme yöntemi kullanılır (Jatani ve diğ., 2022). Optimum sonuçlar elde etmek için, gerçek zamanlı olarak parametre değişimi ile verimli sonuçlar elde eden bir mekanizma kullanılabilir.

Model füzyonu olarak da bilinen model birleştirme, FÖ'de hayati bir rol oynar. Kullanıcı verilerinin gizliliğini korurken istemci cihazlardan yerel olarak oluşturulan modellerin tek bir global modelde birleştirilmesini içerir (Qi ve diğ., 2024). Bununla birlikte, ortaya çıkan global modelin doğruluğu ve güvenilirliği seçilen birleştirme yöntemine bağlıdır ve bu da uygun bir yöntemin seçilmesini çok önemli hale getirir.

Federated Averaging (FedAvg) algoritması FÖ'de kullanılan en yaygın model birleştirme tekniğidir ve stokastik gradyan iniş (SGD) optimizasyonuna dayanır (Heiyanthuduwage ve diğ., 2024). FedAvg esas olarak yatay veri bölümlenmesine sahip bir istemci-sunucu mimarisi için uygundur. FedAvg, merkezi bir sunucu ile birden fazla uç cihazın model güncellemelerini paylaşarak ortak bir model eğitmesini sağlar. Bu yöntemde, her uç cihaz, yerel eğitimi tamamladıktan sonra yalnızca model ağırlıklarını veya gradyanlarını sunucuya gönderir ve gelen model ağırlıklarını ortalayarak yeni bir global model oluşturulur (McMahan ve diğ., 2017). FedMA algoritması daha incelikli bir model birleştirme işlemi gerçekleştiren bir algoritmadır (Sannara ve diğ., 2021). Özellikle FedMa, benzer nöronların birleştirilebildiği ve yenilerinin eklenebildiği katman bazlı bir birleştirme süreci dahil ederek sinir modeli mimarisini değiştirir. Bu yaklaşım, bir katmandaki düğüm sayısını, konvolüsyonel sinir ağları ve tekrarlayan sinir ağlarına bir uzantısı olarak ayarlanacak bir hiper parametre yerine çözülmesi gereken bir alt problem olarak ele alır. FedMa, daha akıllı bir toplama işlemi gerçekleştirmek için bir sinir ağı katmanındaki nöronların permütasyon değişmez olduğunu göz önünde bulundurur. FedBoost ise, topluluk yöntemlerinden yararlanarak federe öğrenmeyi geliştirmek için tasarlanmış, iletişim açısından verimli bir algoritmadır (Hamer ve diğ., 2020).

1.2.2.2. Homomorfik Şifreleme

Kriptografi başlangıçta, bir tarafın bir mesajı şifrelediği ve daha sonra şifresini çözen başka bir tarafa gönderdiği, birden fazla taraf arasında güvenli iletişim için bir teknik olarak geliştirilmiştir (Wood ve diğ., 2020). Şifrelenmiş veriler üzerinden hesaplama kavramı ilk olarak 1978 yılında Rivest, Adleman ve Dertouzos tarafından bir “gizlilik dönüşümü” olarak tanıtılmış ve günümüzde homomorfik şifreleme çalışmasına dönüşmüştür. Genel olarak, homomorfik şifreleme şifrelenmiş veriler üzerinde hesaplama yapılmasını sağlar.

Homomorfik şifreleme (HŞ), şifre çözme olmadan şifre metinleri üzerinde aritmetik işlemler yapılmasını sağlayan bir teknolojidir (Park ve Lim, 2022). HŞ şeması, veri gizliliğinin önemli olduğu alanlarda gizliliği koruyan federe öğrenme (GKFÖ) geliştirmek için kullanılabilir. İlk olarak, sadece toplama veya çarpma yapabilen kısmi homomorfik şifreleme (KHŞ) geliştirilmiştir. Örneğin, sadece toplama işlemi gerçekleştirebilen eklemeli homomorfik şifreleme (EHŞ) şemasının özelliği Denklem 1’deki gibi gösterilir:

$$D_{sk_i} \left(E_{pk_i}(m_1) \cdot E_{pk_i}(m_2) \right) = m_1 + m_2, \quad (1)$$

Burada $D_{sk_i}(-)$ özel anahtar ski kullanan bir şifre çözme fonksiyonu, $E_{pk_i}(-)$ açık anahtar pki kullanan bir şifreleme fonksiyonu ve m_i bir düz metindir. Bulut sunucusu Denklem 1’i kullanarak şifre çözme olmadan homomorfik toplama işlemlerini gerçekleştirebilir. Daha sonra, Gentry (2009) çalışmasında çeşitli homomorfik işlemleri uygulamakta zorlanan KHŞ'nin kısıtlamalarının üstesinden gelmek için hem toplama hem de çarpma işlemlerini yapabilen tam homomorfik şifreleme (THŞ) oluşturmuştur. THŞ, toplama ve çarpma işlemleri kullanılarak çeşitli işlemlerin gerçekleştirilmesini sağlar. Bu HŞ teknolojileri, bulut ve makine öğrenimi alanlarında GKFÖ algoritmalarının geliştirilmesine yol açmıştır.

1.2.2.2. Diferansiyel Gizlilik

Diferansiyel Gizlilik (DG), veri analizinde gizliliği sağlamak için yaygın olarak benimsenen bir standarttır (Aziz ve diğ., 2023). DG'nin temel ilkesi, iki komşu veri kümesine uygulandığında bir algoritmanın davranışını değerlendiren bir düşünce deneyini içerir. DG iki tür olarak sınıflandırılır: saf ve yaklaşık (Ahmadzai ve Nguyen, 2023). Saf diferansiyel gizlilik hiçbir bireyin verisinin açığa çıkmayacağını garanti etse de pratikte bunu başarmak

zor olabilir. Bu garanti, gerçek dünya uygulamaları için genellikle daha pratik olduğu düşünülen yaklaşık DG tarafından biraz gevşetilir. DG'ye ulaşmak için en yaygın yöntem, verileri yayınlamadan önce rastgele gürültü kullanmaktır. Eklenen gürültü miktarı, veriden faydalı bilgilerin çıkarılmasına izin verirken bireysel gizliliği korumak için dikkatlice kalibre edilir ve matematiksel olarak Denklem 2'deki gibi tanımlanır:

$$Pr [A(D_1 \in S)] \leq e^\epsilon * Pr [A(D_2 \in S)] \quad (2)$$

A , veri analizi algoritmasının çıktısının, D_1 ve D_2 komşu veri setlerinde yalnızca bir veri noktası ile farklılık gösterme olasılığının benzer olmasını ve benzerlik derecesinin negatif olmayan gizlilik parametresi ϵ tarafından belirlenmesini sağlar. Bu, D veri setindeki bireysel verilerin varlığının veya yokluğunun A 'nın çıktısı üzerinde önemli bir etkisi olmadığı ve veri setindeki bireylerin gizliliğini koruduğu anlamına gelir.

1.2.3. Uygulanabilir Makine Öğrenimi Modeline Göre Federe Öğrenme Sınıflandırması

1.2.3.1. İstatistiksel modeller

Federe öğrenme sistemlerinde istatistiksel modeller çok sık başvurulan yöntemler arasındadır. Diğer modellerle karşılaştırıldığında istatistiksel model basit ve uygulanması kolaydır ve federe öğrenmeyi uygulamak için etkili bir modeldir. İstatistiksel yöntemler temel olarak doğrusal ve lojistik regresyonu içerir, her ikisi de yaygın olarak kullanılır (Jatain ve diğ., 2022).

He ve diğ. (2021) çalışmalarında, MNIST veri setini kullanarak dikey federe öğrenme sisteminde homomorfik şifrelemeye dayalı lojistik regresyon modeli geliştirmişlerdir. Nikolaenko ve diğ. (2013), homomorfik şifrelemeli bir ridge regresyon sistemi tasarlamışlardır. Bir başka çalışmada ise global modelin parametrelerini güncellemek ve istemcilerden sunucuya yükleme maliyetlerini azaltmak için lineer regresyon modeli kullanılmıştır (Kashima ve diğ., 2024).

1.2.3.2. Karar ağacı tabanlı modeller

Ağaç tabanlı modeller gibi geleneksel makine öğrenimi modelleri birçok uygulayıcı arasında popülerlik kazanmıştır. Ağaç tabanlı (AT) modeller, beyaz kutu modelleri olup diğer modellere göre birçok avantaja sahiptir. AT modellerinin yorumlanması ve modelin nasıl oluşturulduğunun anlaşılması kolaydır, her daldaki kullanıcıların özelliklerini açıklar ve özellikle

kullanıcıların özelliklerinin gizliliğini ve güvenliğini sağlamada şeffaflığı korur (Heiyanthuduwege ve diğ., 2024).

Federe öğrenme, gradyan artırımı karar ağaçları ve rastgele ormanlar gibi tekli veya çoklu karar ağaçlarını eğitmek için kullanılabilir (Zhang ve diğ., 2021). Gradient Boosting Karar Ağaçları (GBDT) algoritması, birçok sınıflandırma ve regresyon görevindeki iyi performansı nedeniyle son yıllarda yaygın olarak bahsedilen bir algoritmadır. Zhao ve diğ. (2018), GBDT gizlilik koruma sistemini ilk kez regresyon ve ikili sınıflandırma görevlerinde uygulamıştır. AdaBoost algoritması, gradyan iniş tabanlı yöntemlere bağlı kalmadan güçlü federe modeller oluşturmak için dağıtık ortamlarda kullanılmıştır (Polato ve diğ., 2022). Blok zinciri aracılığıyla paylaşılan karar ağaçları ile oluşturulan yerel rastgele orman algoritmalarından yararlanan bir FÖ sistemi geliştirilmiştir (de Souza ve diğ., 2020). XGBoost, gradyan artırma çerçevesinin verimli ve ölçeklenebilir bir versiyonudur. Cheng ve arkadaşları (2021) çalışmalarında, bir FÖ kurulumunda XGBoost kullanarak bir karar ağacı oluştururken bölme işlevini hesaplamak için homomorfik şifreleme kullanmışlardır.

1.2.3.2. Sinir ağı tabanlı modeller


Sinir ağları (SA'lar), verilerden karmaşık desenleri öğrenme yeteneğine sahip güçlü modellerdir. FÖ'de, uygulamaya bağlı olarak çeşitli sinir ağı türleri kullanılabilir. Sinir ağları ile Federe Öğrenme, veri gizliliğini korurken güçlü dağıtılmış yapay zeka uygulamaları sağlar. Model toplama, kişiselleştirme ve gizliliği koruma tekniklerindeki gelişmeler FÖ'yi gerçek dünya uygulamaları için pratik bir çözüm haline getirmektedir.

Tam Bağlı Sinir Ağları yapılandırılmış veri sınıflandırması ve regresyon için kullanılır (Zhang ve diğ., 2023). Evrimsel Sinir Ağları (CNN'ler), FÖ'de görüntü ve video işleme için yaygın olarak kullanılır (Li ve diğ., 2022; Divya Anand ve Sharma, 2024; Simić ve diğ., 2024) . Tekrarlayan Sinir Ağları (RNN'ler) ve uzun kısa vadeli hafıza (LSTM'), FÖ'de konuşma ve zaman serisi tahmini gibi sıralı veriler için uygulanır (Da Costa ve diğ., 2023; Kaur ve diğ., 2024) . Dönüştürücüler & BERT Modelleri, birleştirilmiş doğal dil işleme için kullanılır (Peng ve diğ., 2024). Otomatik Kodlayıcılar ve Üretken Çekişmeli Ağ'lar, FÖ'de anomali tespiti ve veri sentezi için kullanılır (Shrestha ve diğ., 2024).


1.3. Sağlık Endüstrisinde Federe Öğrenme Uygulamalarının Analizi

1.3.1. Veri Kaynağı ve Yöntem

Sağlık endüstrisinde federe öğrenme çalışmalarının incelenmesi için bibliyometrik analiz gerçekleştirilmiştir. Yapılan araştırmanın tasarımı Şekil 8’de verilmiştir. Veri toplama aşamasında arama konusu “Federated learning” olarak belirlenmiş olup bu konuya ek olarak “health” veya “healthcare” veya “medicine” veya “medical” veya “clinical” veya “patient care” veya “diagnosis” veya “drug” veya “covid” veya “cancer” veya “hospital” konuları araştırılmıştır. Analiz ilk yayından 2024 yılı sonuna kadar olan çalışmaları kapsamaktadır. WoS havuzunda 2161 yayın taranmıştır. Yayınların belge tiplerine göre sınıflandırması Şekil 9’daki gibidir. Bu alanda yapılan yayınların 1336’sı makale ve 605’i bildiri olduğu tespit edilmiştir. Bu alandaki en eski çalışma 2018 yılında yayınlanmıştır. Bibliyometrik analizde, belge türü yalnızca makale olarak filtrelendi ve taranan 1336 yayın dikkate alınmıştır.



Şekil 8: Araştırma tasarımı



Şekil 9: Yayınların belge türleri

1.3.2. Bibliyometrik Analiz


1.3.2.1. Yayınlar ve atıflar: yapı analizi

Makale çalışmalarının WoS'a göre kategorizasyonu Şekil 10'da gösterilmiştir. Makale yayınlarının en çok bilgisayar bilimleri bilgi sistemleri (computer science and information systems) ve elektrik elektronik mühendisliği (engineering electrical electronic), ve çalışma kategorilerinde yer aldığı görülmüştür. Bu kategorilerdeki sağlık alanında federe öğrenme yayınlarının sayısı 400'den fazladır. Bu kategorilerden sonra en fazla makalenin yer aldığı alanlar telekomünikasyon (telecommunications), Bilgisayar bilimi çok disiplinli uygulamalar (Computer Science Interdisciplinary Applications) ve Bilgisayar Bilimleri Yapay Zeka (Computer Science artificial intelligence) kategorileridir. Tıbbi bilişim (Medical Informatics) Biyomedikal mühendisliği (Engineering Biomedical) kategorilerinde sırasıyla 142 ve 91 çalışma vardır.

WoS veri tabanından elde edilen verilere göre, yıllık sağlık endüstrisinde federe öğrenme çalışmalarının sayısı Şekil 11'de gösterilmiştir. Grafiğe göre ilk yayın 2018 yılına aittir. 2019 yılında bu alandaki çalışmalar 2 makale ile sınırlı kalmıştır. 2021 ve sonrasında ise federe öğrenme çalışmaları ivme kazanmış ve yayın sayısı giderek artmıştır. 2021 yılında makale sayısı ilk kez 100'ü aşmış, 2022 yılında ise 235 makale yayımlanmıştır. 2024 yılındaki yayın sayısı ise 2022 yılına göre 2,3 kat daha fazladır.




Şekil 10: Yayınların ilk 10 WoS kategorisi



Şekil 11: Yıllık yayın sayıları

Şekil 12'de yıllık toplam atıf (TA) ve yayın başına düşen yıllık atıf sayısı gösterilmektedir. 2018-2024 yılları arasında yapılan makale çalışmalarına göre yayın başına ortalama 16,85 atıf düştüğü belirlenmiştir. 2018 yılındaki Brismi ve diğ. çalışmaları, 487 atıf almıştır. 2020, 2022 ve 2023 yılları çalışmaları ise 5000'in üzerinde atıf almıştır. Güncel çalışmaların da önemli sayıda atıf aldığı belirlenmiştir.

En yüksek atıf sayısına göre en etkili ilk 10 yayın Tablo 1'de verilmiştir. Lim ve diğ. (2020) 1272 atıf ile en etkili makaledir. İlk 10 makalenin tamamına 300'den fazla atıf yapılırken, ilk 4 makaleye 500'den fazla atıf yapılmıştır. Ortalama olarak, ilk 10'da yer alan sekiz makaleye yılda 100 veya daha fazla atıf yapılmaktadır.



Şekil 12: Atıf trendi analizi

Tablo 1: En etkili makaleler

Sıra	Yazar	Yıl	Başlık	Dergi	TA	TA/Yıl
1	Lim ve diğ.	2020	Federated Learning in Mobile Edge Networks: A Comprehensive Survey	IEEE Communications Surveys and Tutorials	1272	254,4
2	Rieke ve diğ.	2020	The Future of Digital Health with Federated Learning	NPJ Digital Medicine	996	234,35
3	Sheller ve diğ.	2020	Federated Learning in Medicine: Facilitating Multi-institutional Collaborations Without Sharing Patient Data	Scientific Reports	547	121,55
4	Nguyen ve diğ.	2021	Federated Learning for Internet of Things: A Comprehensive Survey	IEEE Communications Surveys and Tutorials	516	129
5	Brisimi ve diğ.	2018	Federated learning of predictive models from federated Electronic Health Records	International Journal of Medical Informatics	487	73,12
6	Xu ve diğ.	2021	Federated Learning for Healthcare Informatics	Journal of Healthcare Informatics Research	466	124,26
7	Chen ve diğ.	2020	FedHealth: A Federated Transfer Learning Framework for Wearable Healthcare	IEEE Intelligent Systems	471	110,82

8	Warnat-Herresthal ve diğ.	2021	Swarm Learning for Decentralized and Confidential Clinical Machine Learning	Nature	419	119,71
9	Schwendicke ve diğ.	2020	Artificial Intelligence in Dentistry: Chances and Challenges	Journal of Dental Research	372	82,66
10	Hao ve diğ.	2020	Efficient and Privacy-Enhanced Federated Learning for Industrial Artificial Intelligence	IEEE Transactions on Industrial Informatics	365	85,88

1.3.2.2. Yazar ve kurum analizi


2018 yılından bu yana yazarlar, sağlık alanında federe öğrenme ile birçok çalışma gerçekleştirmiştir. Bu alanda en üretken yazarlar Tablo 2'de verilmiştir. Sekiz yazar 8'den fazla makale yayınlamıştır. Toplam yayın sayısına göre Guizani (16 yayın), Gadekallu (12 yayın) ve Lakhan (12 yayın) en çok katkı sağlayan yazarlardır. Guizani ve Gadekallu atıf sayısında da öne çıkmaktadırlar. Bu iki yazar 500'den fazla atıf almış olup, TA/TY oranları sırasıyla 210,74 ve 191,88'dir. Bir diğer önemli performans ölçütü de h indeksidir. Guizani, Gadekallu ve Lakhan bu alandaki çalışmalar bazında en yüksek h endekse sahip yazarlardır.

Tablo 2: En üretken yazarlar

Sıra	Yazar	TY	TA	TA/TY	h_index
1	Guizani, Mohsen	16	571	35,68	13
2	Gadekallu, Thippa Reddy	12	527	43,91	10
3	Lakhan, Abdullah	12	237	19,75	10
4	Mohammed, Mazin Abed	9	181	20,11	8
5	Srivastava, Gautam	8	240	30	6
6	Tanwar, Sudeep	8	166	20,75	6
7	Abdulkareem, Karrar Hameed	8	107	13,37	7
8	Hu, Xiong	8	53	6,62	4

Kurumların sağlık endüstrisinde federe öğrenme yayınlarına katkıları Şekil 13'te verilmiştir. Özellikle Çin'deki üniversitelerin FÖ alanına önemli

katkıları olmuştur. “Chinese Academy of Sciences”, 43 yayınlı bu alanda ilk sırada yer almaktadır. Çin’den sonra en üretken kuruluşların ABD, Hindistan ve Suudi Arabistan’dan olduğu tespit edilmiştir. Harvard University, Vellore Institute of Technology ve King Saud University kurumlarının sırasıyla, 37, 36, 33 makale çalışmasında katkıları olmuştur. İlk 16’da yer alan kurumların makale sayısının ise 20’in üzerinde olduğu belirlenmiştir.




Şekil 13: En üretken kurumlar

1.3.2.3. Ülke / bölge analizi

Bibliyometrik analiz çerçevesinde en üretken 10 ülke analiz edilmiş ve yıllara göre toplam yayın sayıları Şekil 14’te gösterilmiştir. Toplam makale açısından Çin (556 yayın) ve Amerika Birleşik Devletleri’nin (ABD’nin) (248 yayın) sağlık endüstrisinde federe öğrenme çalışmalarına en önemli katkı sağlayan ülkeler olduğu, bunları Hindistan (190 yayın), İngiltere (120 yayın) ve Suudi Arabistan’ın (115 yayın) izlediği belirlenmiştir. Kanada (91 yayın), Avusturalya (90 yayın), Güney Kore (86 yayın), Almanya (79 yayın) ve Pakistan (60 yayın) ülkelerinin daha az etkin olduğu görülmüştür. Çin’de yıllar içinde yayın sayısında hızlı bir artış olmuştur. 2024 yılında 233 yayın çalışmasında bulundular. Çin makalelerin %42’sine katkıda bulunmuştur. ABD, 2024’te 85 yayınlı sağlıkta federe öğrenmeye önemli ölçüde katkıda bulunmuştur. ABD’de toplam yayınların %18,5’inde yer almıştır.

ABD, sağlıkta federe öğrenme üzerine ilk makalesini 2018 yılında gerçekleştirmiştir. Bu yıl bu alanda yapılan tek çalışmadır. İlk 10’da yer alan


ülkelerin çoğunun 2020 yılında sağlık alanında federe öğrenme üzerine makaleler üzerinde çalışmaya başladığı görülmüştür. En üretken ilk 10 ülke arasında yer alan Pakistan'ın çalışmalara 2022 yılında başladığı tespit edilmiştir.



Şekil 14: En üretken ülkeler

1.3.2.4. Yayın kaynakları analizi

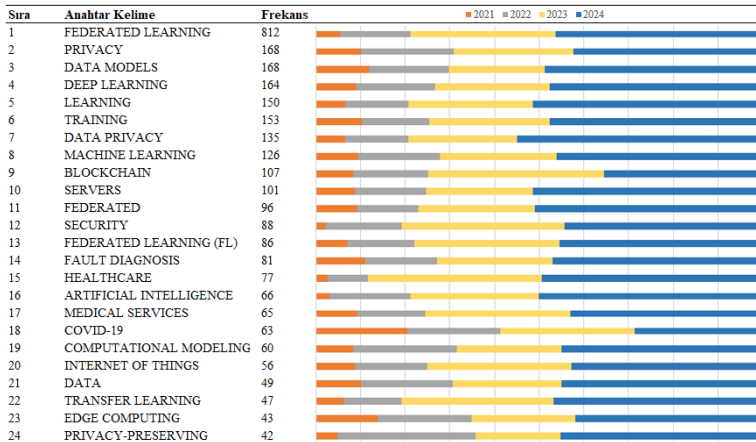
Sağlık endüstrisinde federe öğrenme çalışmalarını yayımlayan ilk 10 dergi başlığının listesi Şekil 15'te gösterilmektedir. Bu alandaki çalışmalarının en çok yayımlandığı derginin 78 makale ile IEEE Access olduğu tespit edilmiştir. Bu dergiyi 57 makale ile IEEE Internet of Things Journal ve 47 makale ile IEEE Journal of Biomedical and Health Informatics takip etmektedir. İlk 10'da yer alan diğer yedi dergideki yayın sayısı ise 30'un altındadır. Sağlık alanında federe öğrenme çalışmalarına en çok katkı sağlayan bu 10 dergi toplam makalelerin %27'sini kapsamaktadır.




Şekil 15: Katkıda bulunan ilk 10 derginin listesi

1.3.2.5. Zaman çizelgesi analizi

Bibliyometrik analizde, sağlık endüstrisinde federe öğrenme araştırma içeriğinin zaman içindeki gelişimi araştırılmış ve zaman çizelgeleri oluşturulmuştur. 2021-2024 yılları arasında makalelerde en sık kullanılan anahtar kelimelerin zaman çizelgesi Şekil 16'da gösterilmektedir. Yayınlarında en sık kullanılan anahtar kelimelerin “Federated Learning”, “Privacy”, “Data Models” ve “Deep Learning” olduğu tespit edilmiştir. Listede yer alan 24 terimin tamamının 40'tan fazla makalede anahtar kelime olarak kullanıldığı görülmektedir. 2024 yılı yayınlarında “Federated Learning”, “Privacy” ve “Data Models” anahtar kelimelerinin kullanım oranları sırasıyla %69, %13 ve %15'tir. Sağlık ile ilgili terimler arasında “Healthcare”, “Medical Services” ve “Covid-19” anahtar kelimelerin ön plana çıktığı tespit edilmiştir.



Şekil 16: Makalelerde en sık kullanılan anahtar kelimeler




Şekil 17: Makale başlıklarındaki en yaygın bigramlar

Federe öğrenme ile ilgili makale başlıklarında en sık kullanılan terimleri gösteren zaman çizelgesi Şekil 2.17'de sunulmuştur. 2022-2024 yıllarında makale başlıklarında, “Federated Learning” dışında en çok kullanılan bigram’ların “Fault Diagnosis”, “Deep Learning”, “Learning Framework”, “Learning Approach”, “Machine Learning” ve “Medical Image” olduğu tespit edilmiştir. 2024 yılında bu terimlerin başlıklarda kullanım sıklığı sırasıyla 44, 21, 28, 13, 12 ve 21 olmuştur. 2023 yılına kıyasla 2024 yılında, “Fault Diagnosis”, “Learning Framework” ve “Medical Image” bigramların kullanımında sırasıyla %100, %100, %75 artış olduğu belirlenmiştir.


1.3.2.6. Sosyal ağ analizi

Sağlık alanında federe öğrenme makale çalışmalarında kuruluşların ve ülkelerin işbirliği ilişkileri Şekil 18 ve 19'da verilmiştir. Şekiller, R programlama dilinin bibliyometrik kütüphanesi ve Shiny paket çerçevesi kullanılarak oluşturulmuştur. İki düğüm arasındaki bir bağlantı, ülkeler veya kuruluşlar arasındaki bir bağlantıyı ifade eder ve bağlantının genişliği işbirliği sıklığını temsil eder. Düğümün boyutu toplam bağlantı gücünü gösterir. Kurumlar renkle ayırt edilen dört kümeye ayrılırken, ülkeler iki kümeye ayrılmıştır. Etiket boyutu ne kadar büyük ve çizgi ne kadar kalın olursa, iki yazar veya iki çalışma arasındaki bibliyometrik ilişki o kadar güçlü ve yoğun olur.

Şekil 18'e göre en çok etkileşim içinde olan kurumların King Saud University, Technical University of Munich, Shanghai Jiao Tong University ve Harvard University Medical Affiliates olduğu tespit edilmiştir. En yoğun ilişkinin ise Imperial College London ve Technical University of Munich kurumları arasında olduğu belirlenmiştir.



Şekil 18: Kurumların işbirliği ağı




Şekil 19: Ülkelerin işbirliği ağı

Şekil 19'da ülkeler arasındaki işbirlikler sunulmuştur. Çin en çok işbirlikçi çalışma (481 bağlantı) gerçekleştiren ülke olduğu belirlenmiştir. Çin'in, ABD, Birleşik Krallık, Hindistan, Kanada ve Avusturalya ile gerçekleştirdiği çalışma sayıları sırasıyla, 73, 52, 33, 31, ve 30 olduğu tespit


yoğunluk-yüksek merkezilik: temel temalar; (3) düşük yoğunluk-düşük merkezilik: ortaya çıkan veya kaybolan temalar; (4) yüksek yoğunluk-düşük merkezilik: çok özel/niş temalar.

Şekil 22, federe öğrenme makalelerindeki anahtar kelimeler kullanılarak elde edilen tematik haritayı göstermektedir. Tematik haritanın temel temaları arasında “data models”, “privacy”, “ai”, “segmentation”, “fault diagnosis”, “cnn”, “classification” gibi konular yer almaktadır. Temel temalar kapsamlı araştırmalardan geçmiştir ve gelecekteki yönlerini tahmin etmek zordur. İleri düzey konuları temsil eden motor temalar arasında “cloud”, “disease prediction”, “medical data”, “health care”, “optimization”, “attention” gibi alanlar yer almaktadır. “lstm”, “covid 19 detection”, “wearable sensors”, “diabetic retinopathy”, “electrocardiography”, “smart city”, “5g” gibi konular kapsamlı bir şekilde araştırılmış ancak bağlantısız alanlara işaret eden özel/niche temalar olarak kabul edilmiştir. “ensemble learning”, “contrastive learning”, “vertical federated learning” gibi konular düşük yoğunluklu ve merkeziyetçi konulardır. Bu temalar yeni ortaya çıkan konuları temsil etmektedir veya çalışma alanından kaybolacaktır. “federated learning” teması hem temel hem de motor bir temadır.




Şekil 22: Anahtar kelimeler tematik haritası

Makale başlıklarındaki bigram analizine dayanan tematik harita Şekil 23'te gösterilmektedir. Temel temalar, “deep learning”, “faul diagnosis”, “disease diagnosis”, “machine learning”, “cancer classification”, “federated semi-supervised” ve diğer konulardır.. Aynı zamanda, “lung cancer” ve “cancer diagnosis” motor temalardır. “blockchain technology” ve “health data” gelişime açık niş temalar arasında yer alırken, “reinforcement learning” ve “scalable federated” gelişebilecek ya da yok olabilecek konular olarak haritada tanımlanmıştır.



Şekil 23: Makale başlığı bigramları tematik haritası

Verilerin boyutluluğunu azaltmak ve düşük boyutlu bir uzayda temsil etmek için faktör analizi yapılmıştır. Çoklu uyum analizi (MCA), çeşitli kategorik bağımlı değişkenlerin ilişki örüntüsünü analiz etmek için boyutları azaltmaya yönelik popüler bir yaklaşımdır. MCA yöntemi uygulanarak oluşturulan kavramsal yapı haritası Şekil 24'te gösterilmektedir. Küme sayısı beş olarak belirlenerek konular kümelenmiştir.



Şekil 24: Anahtar kelimeler kavramsal yapı haritası

1.4. Üroflovetri Testi

Ürodinamik testler üreter, idrar yolu, mesane ve büzgecin idrarı depolama ve bırakma yeteneğini değerlendirmek için kullanılır. Bu testler, işeme sürecinin basit bir şekilde gözlemlenmesinden üreter içi basıncı ölçmek için basınç sensörlü kateterlerin yerleştirilmesine kadar uzanır (Alothmany ve diğ., 2018).

Üroflovetri üroloji pratiğinde yaygın olarak kullanılan tanısal bir testtir. Bu test, işeme semptomlarının anlaşılmasına yardımcı olan objektif ve kantitatif bilgiler verir (Sorel ve diğ., 2017). Ayrıca, invaziv olmayan ve nispeten ucuz olması nedeniyle, alt üriner sistem disfonksiyonu şüphesi olan hastalar için zorunlu bir tarama testidir. Bununla birlikte, anormalliğin güvenilir bir şekilde ölçülebilmesi için sağlıklı kişilerde üroflovetri parametrelerinin sonuç aralığının belirlenmesi gerekmektedir.

Çeşitli kortikal, spinal, pelvik ve idrar yolu girdileri mesaneyi, dışarı akışı veya her ikisini birden etkileyerek üroakışın kesin özelliklerini değiştirebilir (Sinha, 2024). Bu nedenlerle, üroflovetri kayıtları bir bireyde önemli ölçüde farklılık gösterebilir ve belirli bir raporun hastayı temsil ettiği varsayılmaz. Bu sınırlamalara rağmen, basitliği, yaygın kullanılabilirliği ve hasta tarafından kabul edilebilirliği nedeniyle üroflovetri yaygın olarak önerilmekte ve tanıya ulaşmada yardımcı olabilmektedir. Mevcut klinik kullanım çoğunlukla bir sağlık kuruluşunda geleneksel bir akış ölçer tarafından kaydedilen maksimum akış hızı ve üroakış modelinin incelenmesiyle sınırlıdır. Bu testler, hastanın idrarını toplayan ve gerekli parametreleri hesaplamak için


bir ölçüm sistemine yönlendiren bir huniye özel olarak idrar yapmasını içerir (Alothmany ve diğ.,2018).

Avrupa Üroloji Birliği kılavuzları, güvenli sonuçlar elde etmek için optimum koşullar altında iki veya daha fazla tekrarlanan test önermektedir (Sekerci ve diğ., 2023). Üroflovetride en önemli parametreler akış eğrisi paternleri (AEP), işenen hacim, akış hızı ve detrüör sfinkter dissinerjisidir.

AEP, işeme sırasında idrar akış hızının zamana göre değişimini grafiksel olarak gösterir ve obstrüktif ya da nörojenik mesane bozukluklarının ayırt edilmesinde önemli rol oynar (Clothier ve Wright, 2018). İşenen hacim, mesanenin ne kadar idrar tuttuğunu ve hastanın yeterli işeme yaptığına dair bilgi verir. Akış hızı ise üroflovetride mesaneden dışarı atılan idrarın birim zamandaki miktarını ifade eder ve genellikle mililitre/saniye (mL/sn) cinsinden ölçülür (Abrams ve diğ., 2003). En sık kullanılan iki ölçüt, maksimum akış hızı (Qmax) ve ortalama akış hızı (Qave)'dir. Qmax, işeme sürecindeki en yüksek idrar akış hızını gösterir ve mesane çıkımında tıkanıklık olup olmadığını değerlendirmede önemli bir göstergedir. Ortalama akış hızı ise tüm işeme süresince ortalama idrar çıkış hızını verir. Detrüör-Sfinkter Dissinerjisi, işeme sırasında mesane kası olan detrüör kasının istemli olarak kasıldığı sırada, normalde gevşemesi gereken dış üretral sfinkterin istemsiz şekilde kasılı kalması durumudur (Panicker ve diğ., 2015). Normal bir üroflovetri eğrisinden elde edilen parametreler Şekil 25'teki gibidir.

İşenen hacim, ideal olarak 150 mL ve üstü olması beklenmektedir. Erkeklerde Qmax >15 mL/s normal kabul edilirken, <10 mL/s değerler patolojiye işaret eder. Kadınlarda, daha kısa üretra ve prostatik direncin olmaması gibi anatomik farklılıklar nedeniyle yorumlama daha karmaşıktır. Normal kadın Qmax değerleri tipik olarak 20 ila 36 mL/s arasında değişir (Pessoa ve Kim, 2018). Sağlıklı çocuklar üzerine yapılan bir araştırmada uroflowvetri değerleri aşağıdaki gibidir (Gupta ve diğ., 2013):


- Erkek (Yaş 5-10): Qmax = 15.26 ± 4.54 mL/s; Qavg = 7.68 ± 3.26 mL/s
- Kız (Yaş 5-10): Qmax = 17.98 ± 6.06 mL/s; Qavg = 9.19 ± 4.23 mL/s
- Erkek (Yaş 11-15): Qmax = 22.50 ± 7.24 mL/s; Qavg = 10.78 ± 4.03 mL/s
- Kız (Yaş 11-15): Qmax = 27.16 ± 9.37 mL/s; Qavg = 13.48 ± 5.21 mL/s



Şekil 25: Üroflovetri eğrisinden elde edilen parametreler (Yağmur, 2016)

Uluslararası Çocuk Kontinans Derneği üroflovetrinin standart terminolojisini, çan, kule, kesik kesik, aralıklı ve plato akış paternleri olarak spesifik AEP'yi tanımlamıştır. Ancak, alt idrar yolu disfonksiyonlarının tanısı için geliştirilen bu AEP'nin tanımları net değildir. Klinik uygulamada üroflovetrik parametrelerin yorumlanmasında farklılıklar olduğu da bilinmektedir. Yetişkinler ve çocuklarla yapılan çeşitli çalışmalarda, aynı akım paterninin yorumlanmasında gözlemci içi ve gözlemciler arası farklılıklar bildirilmiştir. Bu farklılıklar özellikle üroflovetride anormal bulgularla ilişkilendirilmiştir.

Şekil 26'da yer alan üroflovetri eğrileri farklı işeme paternlerini yansıtmaktadır. (a) ile gösterilen çan paterni, normal işeme fonksiyonunu temsil eder. (b) kule paterni, genellikle aşırı aktif mesane bulgusudur. (c) kesik kesik paterni, disfonksiyonel işemeyi düşündürürken; (d) aralıklı patern, abdominal ıkınmayla birlikte görülen düşük aktif detrusor fonksiyonuna işaret eder. Son olarak, (e) plato paterni, anatomik ya da fonksiyonel mesane çıkış obstrüksiyonunu düşündürmektedir (Clothier ve Wright, 2018).



Şekil 26: Üroflovetri eğrisi paternleri.

1.5. Literatür İnceleme

Çalışmada ele alınacak problem ana hatlarıyla belirlendikten sonra, ilgili alanlarda kapsamlı bir literatür taraması gerçekleştirilmiştir. 2013 yılı ve sonrasına ait literatür incelenerek, çalışma alanıyla ilgili literatürdeki trendler ve boşluklar belirlenmiştir.

1.5.1. Sağlık Sektöründe Yapay Zekâ Uygulamaları Üzerine Kaynakça Taraması

Son zamanlarda, bakım hizmeti kalitesini ve tıbbi kaynakların verimliliğini artırmak için sağlık kurumlarında YZ destekli teknolojilerin yaygın uygulamaları bulunmaktadır (Lee ve Yoon, 2021). YZ, MÖ, doğal dil işleme ve akıllı robotları kapsadığından, YZ tabanlı teknolojiler bilgi yoğun sağlık sektöründe inovasyon için çok sayıda fırsat sunmaktadır. Sağlık sektörüyle ilgili olarak, YZ, gelişmekte olan ve gelişmiş ülkelerdeki personel eksikliğinin üstesinden gelme, kurumsal verimliliği artırma ve insan temelli değerlendirmelere kıyasla kalite açısından en azından karşılaştırılabilir

sonuçlar sağlayarak teşhis doğruluğunu ve hasta sonuçlarını en üst düzeye çıkarma potansiyeline sahiptir (Roppelt ve diğ., 2024). Sağlık hizmetlerinde MÖ ve DÖ, önleyici tıp, görüntü tanıma teşhisi, kişiselleştirilmiş tıp ve klinik karar verme süreçlerine giderek daha fazla ve başarılı bir şekilde uygulanmaktadır (Suarez-Ibarrola ve diğ., 2020).

Bu çalışmada, sağlık endüstrisindeki yapay zeka uygulamaları ile ilgili kaynakça taraması aşağıdaki alt başlıklarda özetlenmiştir.

1.5.1.1. Sağlık Sektöründe Federe Öğrenme Uygulamaları Üzerine Kaynakça Taraması

Dijital dönüşüm, sağlık hizmetlerinin verimliliğini, kalitesini ve maliyet etkinliğini artırmak için dijital araçların ve sistemlerin kullanılmasını içerir. FÖ, sağlık kuruluşlarının işbirliği yapmasını ve modelleri eğitmesini sağlarken hasta verilerinin gizliliğini sağlayan benzersiz bir makine öğrenimi yaklaşımıdır. FÖ, gizlilik düzenleyicileri de dahil olmak üzere gizlilik ve güvenliğin çok önemli olduğu sağlık hizmetleri için özellikle uygundur.

FÖ çalışmaları, verilerin bölümlere ayrılma şekline göre farklılık gösterir. Bazı çalışmalar, verilerin benzer özellik uzaylarına ancak farklı örneklerle sahip istemciler arasında dağıtıldığı YFÖ ilkelerine uyarken, diğerleri aynı kullanıcı kümesi için farklı özellik kümelerine sahip istemcileri içeren DFÖ kategorisine girer. Son beş yılı kapsayan bir kaynakça taraması yapılmış ve seçilen YFÖ ve DFÖ uygulamalarına ilişkin özet bilgiler sırasıyla Tablo 3 ve Tablo 4'te sunulmuştur.

Tablo 3: Sağlık endüstrisinde YFÖ uygulamaları

Referans	Ele Alınan Problem	Yöntem	Temel Bulgular
Lo ve diğ. (2021)	Retinal mikrovaskülatür segmentasyonu ve sevk edilebilir diyabetik retinopati (RDR) sınıflandırması (	VGG19, ImageNet ve FedAVG	Mikrovaskülatür segmentasyonu için, federe öğrenme modeli, tamamen merkezileştirilmiş bir veri kümesi üzerinde eğitilen modellerle benzer performans elde etmiştir. Sınıflandırma için, federe öğrenme ortalama 0,954 ve 0,960 AUROC elde ederken; merkezi modeller ortalama 0,956 ve 0,973 AUROC elde etmiştir.
Jalal ve diğ. (2022)	Kalp ve damar hastalığı sınıflandırması	Hiperparametre ayarlı Federe Rastgele Orman	İstemci 1'de %2 ve istemci 2'de %6'lık bir doğruluk artışı ile istemci 1'de %2,2 ve istemci 2'de %2,9'luk bir f1-skor iyileştirmesi elde edilmiştir.
Ahmed ve diğ. (2022)	Ruh sağlığı belirti tespiti	Hiper-Grafik Dikkat Tabanlı FedAvg ve BiLSTM	Geliştirilen model ile 0,86'lık F-değeri elde edilmiştir.
Pati ve diğ. (2022)	Nadir görülen glioblastoma hastalığı için tümör sınırı tespiti	3DResUNet ve FedAvg	Halka açık olarak eğitilmiş bir modele kıyasla, cerrahi olarak hedeflenebilir tümör için %33 ve tüm tümör kapsamı için %23'lük bir tanımlama iyileştirmesi elde edilmiştir.
Hossen ve diğ. (2022)	Deri hastalığı sınıflandırması	VGG16, AlexNet, FedAVG ve FedML	Önerilen model akne, egzama ve sedef hastalığı için %86, %43 ve %60 kesinlik ve %67, %60 ve %60 anma, elde etmiştir. Federe öğrenme yaklaşımında, veri kümesi 1000, 1500, 2000 ve 2500 istemci arasında dağıtıldıktan sonra, model ortalama %81,21, %86,57, %91,15 ve %94,15 doğruluk göstermiştir.

Cao ve diğ. (2023)	Akciğer Görüntü Sınıflandırması	HŞ, FÖ sistemi ve ResNet50	Önerilen yöntemle elde edilen modelin doğruluğu, her bir sağlık kurumundaki bireysel eğitimden %3 - %8 daha yüksek, merkezi eğitimden %1-%2 daha düşüktür.
Kujur ve diğ. (2023)	COVID vakalarının tahmin edilmesi ve sınırlı kaynakların kullanımının optimize edilmesi	Yatay federe öğrenme	Kriz sırasında kritik kaynakların kullanımını optimize edecek bir işbirlikçi sistem geliştirmiştir.
Jiménez-Sánchez ve diğ. (2023)	Meme kanseri sınıflandırması	Hafızaya duyarlı müfredat federe öğrenme (Memory-aware curriculum federated learning), ResNet-22	Önerile yöntem, farklı tedarikçilerden alınan üç klinik veri kümesi ile değerlendirilmiş olup, AUC ve PR-AUC ölçütlerinin geleneksel FÖ düzenine kıyasla sırasıyla ortalama %5 ve %6 oranında iyileştirildiği belirtilmiştir.
Sun ve diğ. (2023)	Fizyolojik sinyal sınıflandırması	Meta sürekli öğrenme, CNN, FedAVG ve blokzincir	Meta sürekli öğrenmenin iyileştirme sınıflandırma performansının %98,35 olduğu ve karşılaştırılan son teknoloji ürünü çalışmalardan daha iyi performans gösterdiği ortaya konmuştur.
Mehta ve diğ. (2023)	Gelişmiş mango yaprak hastalığı tespiti	CNN ve FedAVG	Modelin çeşitli veri dağılımlarına sahip istemciler arasındaki verimliliği araştırılmış ve en düşük doğruluk oranına sahip istemcinin, makro ortalama (93,92), ağırlıklı ortalama (93,96) ve mikro ortalama (93,96)

			değerlerine sahip olduğu bulunmuştur.
Lakhan ve diğ. (2023)	Alzheimer hastalığı tespiti	Federe öğrenme etkin evrimsel derin evrişimsel sinir ağı şeması	Önerilen yöntemin bazı çalışmaların modellerine kıyasla güvenliği %38 oranında optimize ettiğini, son tarih başarısızlık oranını %29 oranında azalttığını ve farklı Alzheimer sınıfları arasında seçim doğruluğunu %50 oranında artırdığı tespit edilmiştir.
Zhang C. ve diğ. (2023)	Beyin hastalığı teşhisi	FedBrain	Otizm Beyin Görüntüleme Veri Değişimi veri seti üzerindeki deneysel sonuçlar, FedBrain'in FÖ'nin iletişim yükünü azaltabildiği ve %79'luk en yüksek ortalama doğruluğa ulaşabildiği tespit edilmiştir.
Bebortta ve diğ. (2023)	IoT tabanlı elektronik sağlık kayıtlarında kalp hastalıklarının tahmini	Destek Vektör Makinesi (SVM) ve Küme Primal Dual Bölme Yöntemi	Önerilen yöntem, Genetik Algoritma(GA)-SVM, SVM, ve Fed-SVM modellerine göre daha üstün bulunmuştur.
Rahman ve diğ. (2023)	Hastane hastalarının yatış süresi tahmini	Lineer regresyon, Lineer Lasso regresyon, Lineer Ridge regresyon ve FedAVG	Yerel eğitim performansının veri boyutuna bağlı olarak değiştiğini belirtilmiştir. FÖ teknolojisini kullanan birleşik modelin, FÖ sürecini tamamladıktan sonra bireysel istemcilerin yerel tahmin performanslarını aştığı gözlemlenmiştir.
Noman ve diğ. (2023)	Çok sınıflı solunum hastalığı sınıflandırması	Derin sinir ağları (DNN), değiştirilmiş FedAVG ve blokzincir teknolojisi	Elde edilen metrik puanlardan, çeşitli ve heterojen verilerden öğrenen önerilen fÖ modelin performansının tek kaynaklı modele benzer olduğu gösterilmiştir. Önerilen birleştirme tekniği kullanılarak, %88,60 test

			doğruluğu elde edilirken, tek kaynaklı modelde %88,10'luk en yüksek test doğruluğu elde edilmiştir
--	--	--	--

Tablo 4: Sağlık endüstrisinde DFÖ uygulamaları

Referans	Ele Alınan Problem	Yöntem	Temel Bulgular
Sun ve diğ. (2021)	Ameliyat sırası komplikasyonlar prognostik tahmin	FedIO	FedIO, doğruluk açısından her bir istemciden %4,49 oranında daha iyi performans göstermiştir; bu da hastane içi ve dışı bilgilerin eşzamanlı olarak kullanılmasının ameliyat sonrası komplikasyonların tahmin modelinin doğruluğunu artıracakı belirtilmiştir.
Cha ve diğ. (2021)	Beyin tümörleri sınıflandırma Hasta ölüm oranı tahmini	Otokodlayıcı tabanlı sinir ağı	Kullanılan veri setlerinde sırasıyla %1,2, %8,89 ve %1,23 doğruluk kaybı ve %1,1, %0 ve %1,12 AUROC kaybı olmuştur.
Zhang R. ve diğ. (2022)	Fetal sağlık sınıflandırma	Sınıflandırma ve regresyon ağacı algoritması, doğrusal HŞ, π_{SS-FS} Gizli Paylaşım ve π_{H-FS} Hibrit Protokolü	Önerilen yaklaşımın %27'ye varan doğruluk kazanımları sağladığı belirtilmiştir.
Tang ve diğ. (2023)	Meme kanseri sınıflandırma	Özel Küme Keşimi protokolü ve Lojistik Regresyon (LR)	Önerilen model, amaç gizleme hedefini korurken Meme Kanseri tıbbi veri kümesi üzerinde daha iyi verimlilik (5 dakikadan az) ve doğruluk (%97) sağlayabildiği belirtilmiştir.
Wang ve diğ. (2023)	Farklı kurumlardan toplanan çoklu	Derin yaşam ağı, Köprü Metni	Şifrelenmiş çoklu omiks verilerini kullanarak tek omiks verilerini kullanmaktan daha yüksek tahmin

	omik veriler ile kanser prognoz tahmini	Aktarım Protokolü ve DFÖ	doğruluğu (ortalama %6,5) elde edildiği belirtilmiştir.
Shajimon ve diğ. (2023)	Kardiyovasküler hastalık risk tahmini	DNN ve DFÖ gizlilik mekanizması	İki istemcili önerilen yöntem ile %88,53 doğruluk oranı elde edilirken, geleneksel DNN tabanlı yöntemle %85,25 doğruluk oranı elde edilmiştir. Önerilen yöntemin, gizlilik, özellik ayrımı ve istemcilerin eğitim etiketlerinden bağımsız olması gibi avantajlar sağladığı belirtilmiştir.
Chen ve diğ. (2023)	Deri hastalığı sınıflandırma	Meta veri ve görüntü özelliklerinin eş farkındalıklı yarı denetimli dikey federe öğrenme	Geliştirilen model, FedMC, FedCVT ve Vanilla DFÖ'den daha üstün bulunmuştur.
Yang ve diğ. (2024)	Çok aşamalı hastalıkların teşhisi	Paillier Şifreleme ve Dikey Derin Sinir Ağı	Önerilen yöntem, Fate Derin Sinir Ağına göre daha iyi sınıflandırma performansı, daha hızlı çalışma süresi ve daha yüksek iletişim verimliliği elde etmiştir.
Sakib ve Das (2024)	Diyabet hastalığı sınıflandırma	Açıklanabilirlik-Gizlilik Ödünleşimi ve SHAP analizi	Orijinal veri seti ile %74,28 doğruluk oranına ulaşılırken, dikey federe öğrenme ile bu oran %72,11 olarak elde edilmiştir.
Shi ve diğ. (2025)	Meme kanseri sınıflandırma	FedRL	FedRL, diğer çalışmalardaki SplitVFL, FedHSSL ve VFedTrans yöntemlerine kıyasla doğruluk, AUC ve F1-skorunda sırasıyla %4,7, %5,6 ve %4,8'lik ortalama iyileştirmeler elde ettiği belirtilmiştir.

1.5.1.2. Ürolojide yapay zeka uygulamaları üzerine kaynakça taraması

YZ'nın ürolojide kullanımı son birkaç yılda artmıştır ve bu süre zarfında hasta iş akışının optimizasyonunu, teşhis doğruluğunun artmasını ve radyolojik ve patolojik görüntülerin bilgisayar analizinin geliştirilmesini sağlamıştır (Cacciamani ve diğ., 2024). Literatür incelendiğinde, üroloji alanındaki sorunları ele almak için çeşitli makine öğrenimi yaklaşımlarının uygulandığı görülmektedir. Bu yaklaşımlar arasında regresyon tabanlı modeller, ağaç tabanlı algoritmalar ve sinir ağı mimarileri yer almaktadır. Son on yılda ürolojik araştırmalarda bu yöntemleri kullanan seçilmiş çalışmaların bir özeti Tablo 5'te sunulmuştur.

Tablo 5: Ürolojide MÖ uygulamaları

Referans	Çalışmanın Amacı	Yöntem
Garapati ve diğ. (2017)	Bilgisayarlı tomografi ürografiye mesane kanseri evresini değerlendirmek için objektif bir bilgisayar destekli sistem kullanmanın fizibilitesi değerlendirilmiştir.	Doğrusal diskriminant analizi, sinir ağı (SA), RF, SVM
Choo ve diğ. (2018)	Çalışmada, üreter taşı vakalarında tek seans şok dalga litotripsi sonrası tedavi başarısını tahmin etmek için bir makine öğrenmesi algoritması kullanılarak bir karar destek modeli geliştirilmiştir.	Karar Ağacı
Leyh-Bannurah ve diğ. (2018)	Çalışmada, doğal dil işlemeye uygulanan derin sinir ağlarına dayalı anlatı şeklinde yazılmış ürolojik elektronik sağlık kayıtlarından ayrıntılı bilgilerin çıkarılması gerçekleştirilmiştir.	DNN
Auffenberg ve diğ. (2019)	Çalışmada, prostat kanseri kayıtlarını kullanan web tabanlı bir sistem geliştirilerek yeni tanı konmuş erkeklere benzer özelliklere sahip hastalara dayalı olarak öngörülen tedavi kararlarını görüntüleyebilecekleri bir platform sağlanması amaçlanmıştır.	CNN
Tan ve diğ. (2021)	Çalışmada, radikal prostatektomi sonrası biyokimyasal rekürrensi tahmin etmek için	Naïve Bayes (NB), RF ve SVM

	makine öğrenmesi algoritmaları kullanılmış ve geleneksel regresyon modelleri ve nomogramlarla karşılaştırılmıştır.	
Hobbs ve diğ. (2022)	Çalışmada, spina bifida popülasyonunda ürokinamik çalışmalarda detrusor aşırı aktivitesini tanımlayan bir makine öğrenme algoritması geliştirilmiştir.	k- en yakın komşu (KNN) ve SVM ile doğrusal, polinom ve radyal temel fonksiyon çekirdekleri
Iwamura ve diğ. (2022)	Çalışmada, Ig N-glikan imzaları kullanılarak makine öğrenimi yaklaşımı ile oluşturulan ürolojik hastalığa özgü bir skorlama sistemi değerlendirilmiştir.	TensorFlow Derin Öğrenme Sınıflandırıcısı
Kim ve diğ. (2022)	Çalışmada, üretra darlığı olan ve olmayanlar arasındaki retrograd ürotoqram görüntülerini karakterize etmek için derin öğrenme tabanlı bir model geliştirilmiştir.	CNN
Kavoussi ve diğ. (2022)	Çalışmada, böbrek taşı hastalığına yönelik ampirik tedaviyi yönlendirmeye yardımcı olmak için, makine öğrenimi yöntemlerini kullanarak 24 saatlik idrar anormalliklerini tahmin etmenin fizibilitesi ortaya konmuştur.	XGBoost ve LR
Bang ve diğ. (2022)	Çalışmada, alt idrar yolu semptomlarını noninvasiv bir şekilde teşhis etmek için, basit üroflovetri kullanarak mesane çıkış obstrüksiyonu ve detrusor underaktivitesi tahmin modeli oluşturulmuştur	CNN
Welvaars ve diğ. (2023)	Çalışmada, üroloji bölümünden taburcu olduktan sonraki 30 gün içinde planlanmamış tekrar başvuruları tahmin etmek için makine öğrenme tabanlı olasılık hesaplayıcısı geliştirilmiştir.	Lojistik regresyon, LASSO regresyon, RIDGE regresyon, karar ağacı, bagged trees, boosted trees, XGBoost, RF
Altıntaş ve diğ. (2024)	Çalışmada, ameliyat öncesi kan parametrelerinden elde edilen veriler kullanılarak makine öğrenme tabanlı algoritmalar ile transüretal prostat	Karar ağacı, LR, KNN, SVM ve NB

	rezeksiyonu sonrası üretral darlık olasılığını tahmin edilmiştir.	
Liu ve diğ. (2024)	Çalışmada, yorumlanabilir bir makine öğrenimi yöntemi kullanılarak Caprini ölçeğine dayalı olarak ürolojik yatan hastalarda venöz tromboembolizm için temel risk faktörlerini belirlenmiştir.	Geri yayımlı yapay sinir ağı , RF ve SVM
Koh ve diğ. (2024)	Çalışmada, ürolojide kalite göstergeleri çıktıların risk ayarlaması için makine öğrenme tabanlı bir model geliştirilmiştir.	Varyasyonel Bayes
Geraghty ve diğ. (2024)	Çalışmada, perkütan nefrolitotomi sonuçlarını tahmin etmek için zamansal olarak doğrulanmış makine öğrenimi modelleri kullanılmıştır.	XGBoost, LR, DNN

Hasta mahremiyeti ve veri güvenliğinin kritik önem taşıdığı üroloji alanında FÖ, sağlam tahmin modelleri geliştirmek için çeşitli ve dağıtılmış klinik verilerden yararlanmaya yönelik umut verici bir çözüm sunuyor. FÖ, kurumların görüntüleme, teşhis ve tedavi kayıtları gibi ürolojik verileri işbirliği içinde analiz etmesini sağlayarak, veri gizliliğini korurken kişiselleştirilmiş tıp alanındaki gelişmeleri destekliyor. Kaynakça tarandığında bu alanda kısıtlı sayıda çalışmanın olduğu görülmektedir. Bu alanda gerçekleştirilen çalışmaların bir özeti Tablo 6'da sunulmuştur.

Tablo 6: Ürolojide FÖ uygulamaları

Referans	Çalışmanın İçeriği	Yerel Öğrenme Metodu	Gizlilik Mekanizması/Federe Öğrenme Algoritması
Rajagopal ve diğ. (2023)	Çalışmada, prostat kanserinin çok merkezli MRI tabanlı tespiti ele alınmıştır.	UCNet derin öğrenme modeli	Model Birleştirme FedSGD algoritması

Huang ve diğ. (2023)	Çalışmada, Tayvan'daki kritik hastalarda akut böbrek hasarı (AKI) tahmini için model birleştirme üzere federe öğrenme algoritması kullanılmıştır.	XGBoost, sinir ağıları, rastgele orman ve lojistik regresyon	Model Birleştirme FedAVG algoritması
Ahmed ve diğ. (2023)	Çalışmada, idrar yolu enfeksiyonlarının gerçek tespiti için federe öğrenme ve pekiştirmeli öğrenme stratejisi tarafından etkinleştirilen bir çerçeve sunulmuştur.	Derin-Q-Öğrenme	Model Birleştirme Federe Düğüm Birleştirme
Kong ve diğ. (2024)	Çalışmada, geliştirdikleri federe öğrenme algoritmasını, prostat kanseri teşhisi ve Gleason derecelendirmesi görevlerindeki etkinliği uygulamaları üzerinde değerlendirmişlerdir	Sinir ağı modeli	Diferansiyel Gizlilik Federe dikkat tutarlı öğrenme
Mohammed ve diğ. (2024)	Çalışmada, Nesnelerin İnterneti (IoT) böbrek hastalığı görüntü işleme için Uyarlanabilir Federe Pekiştirmeli Öğrenme Sistemi sunulmuştur.	CNN ResNET Q-öğrenmeye dayalı karar ağacı şeması	Model Birleştirme Federe pekiştirmeli öğrenme
Reyes-Amezcuca ve diğ. (2024)	Çalışmada, böbrek taşı türü sınıflandırma problemi ele alınmıştır.	ResNet18 ve ImageNet	Model Birleştirme FedAVG algoritması
Cao ve diğ. (2024)	Çalışmada, kas-invaziv mesane kanseri teşhisi ve otomatik mesane tümörü lezyon segmentasyonu için federe öğrenme teknolojilerinden yararlanılmıştır.	ResNet-50	Model Birleştirme FedAvg, FedProx, FedBN, SiloBN algoritmaları

1.5.2. Sağlık Sektöründe Optimizasyon Uygulamaları Üzerine Kaynakça Taraması

1.5.2.1. Sağlık sektöründe çizelgeleme problemleri üzerine kaynakça taraması

Optimizasyon, karar verme, kaynak tahsisi ve operasyonel verimliliği geliştirerek sağlık sektöründe çok önemli bir rol oynamaktadır. Ameliyatların planlanması (Banditori ve diğ., 2023) ve hastane yataklarının yönetilmesinden tedavi planlarının ve tedarik zincirlerinin optimize (Umoren ve diğ., 2021) edilmesine kadar gelişmiş optimizasyon teknikleri, sağlık hizmeti sağlayıcılarının sınırlı kaynaklarla (Eriskin ve diğ., 2024) daha iyi sonuçlar elde etmesine yardımcı olur. Bu yöntemler, hasta bakımını geliştiren, maliyetleri azaltan ve sağlık hizmetlerini kolaylaştıran veri odaklı stratejileri destekler.

Optimizasyon çalışmalarında, çözüm yönteminin seçimi genellikle problemin boyutuna ve karmaşıklığına bağlıdır. Bazı çalışmalar ticari çözümler kullanarak optimum çözümleri başarıyla elde ederken, diğerleri daha büyük veya hesaplama açısından daha yoğun problemleri ele almak için sezgisel veya metasezgisel yaklaşımlar kullanmıştır.

Çizelgeleme problemleri, sağlık sektöründeki en yaygın ve kritik zorluklardan birini temsil etmektedir. Bazı çalışmalar, toplam seyahat süresini veya maliyeti en aza indirmek gibi tek amaçlı formülasyonlara odaklanırken, diğerleri kaynak kullanımı, hasta memnuniyeti ve hizmet eşitliği gibi birden fazla kriteri aynı anda ele alan çok amaçlı bir yaklaşım benimsemektedir. Sağlık sektöründe çizelgeleme optimizasyonu alanında gerçekleştirilen uygulamaların bir özeti Tablo 7'deki gibidir.

Tablo 7: Sağlık endüstrisinde çizelgeleme çalışmaları

Yazar	Yıl	Ele Alınan Problem	Yöntem
Topaloglu ve Ozkarahan	2011	Asistanların nöbet saatlerini çizelgelemek için gece nöbetçi, izin günü, dinlenme süresi ve toplam çalışma saati Akreditasyon Konseyi Lisansüstü Tıp Eğitimi (ACGME) düzenlemelerinin yanı sıra asistanlık programının talep karşılama	Ticari çözücü


		gerekliliklerini de dikkate alan bir karma tamsayı programlama modeli geliştirilmiştir.	
Hiermann ve diğ.	2015	Çoklu model evde sağlık hizmeti çizelgelemesi problemi ele alınmıştır. Problem, hemşirelerin hasta taleplerine atanmasını ve yan kısıtlamalar ile toplam seyahat süresi ihlallerinin minimize edilmesini içeren tur planlamasıdır.	Memetik algoritma, dağınık arama ve benzetilmiş tavlama
Huang ve diğ.	2018	Stokastik tıbbi kaynaklar için dinamik yapılandırma çizelgeleme problemi ele alınmıştır. Çalışmada, cerrahi ameliyathane kısıtlıdır ve gelen çağrılar (yani hasta sayısı) dinamiktir. Bir hasta geldiğinde, hemşire anestezi ve anestezi uzmanı kısıtlıdır, ancak hasta başına tıbbi hizmet süresi rastgeledir.	Tambur tampon halatı çizelgeleme yaklaşımı ve Monte Carlo simülasyonu
Khan ve diğ.	2021	Gerçek zamanlı sağlık hizmetlerinde tıbbi veri işleme ve hizmet kayıtlarının optimizasyonu problemi ele alınmıştır. Ortamla ilgili zorluklar, programlayıcı optimizasyonu (hizmet oranı) sorunları ve hizmet sunum yaşam döngüsü dikkate alınmıştır.	Genetik algoritma
Ghelichi ve diğ.	2021	tıbbi malzemelerin ulaşılması zor yerlere) zamanında teslimi için bir dron filosunun lojistiği optimize edilmiştir.	Önişleme prosedürü ve ticari çözücü

Vali ve diğ.	2022	Hasta akışını optimize etmek ve toplam karbon ayak izini en aza indirmek için esnek bir iş atölyesi çizelgeleme problemi ele alınmıştır.	Karşıtlık Tabanlı Öğrenme ve Sinüs Kosinüs ile Geliştirilmiş Kaotik Salp Sürü Algoritması
Vahedi-Nouri ve diğ.	2022	Yeniden Yapılandırılabilir Üretim Sisteminin uyarlanabilirliği ve esnekliği ile COVID-19 salgını sırasında işgücü planlaması ve üretim çizelgeleme sorunu ele alınmıştır.	Ticari çözücü
Ala ve diğ.	2022	Hasta randevu çizelgelemesi problemi ele alınmıştır. Problem, hasta bekleme süresinin minimize edilmesini ve hastaların memnuniyetinin maksimize edilmesini içerir.	Bulanık karınca aslanı optimizasyonu ve NSGA-II
Bargetto ve diğ.	2023	Ameliyathane planlama ve çizelgeleme problemi ele alınmıştır. Çalışmada, farklı enfeksiyon seviyelerine sahip ameliyathane nedeniyle ortaya çıkan sıraya bağlı ameliyathane temizlik sürelerinin bir modeli ele alınmıştır.	Problemin zamana endeksli formülasyonuna dayalı dal-fiyat-ve-kes algoritması
Durak ve Mutlu	2024	Fiziksel, zihinsel ve çevresel ergonomik riskleri de gözönünde bulunduran evde sağlık hizmeti hemşire rotalama ve çizelgeleme problemi ele alınmıştır.	Bulanık çıkarım sistemi ve ticari çözücü

2. YÖNTEM

2.1. Federe Öğrenme Tabanlı Önerilen Karar Modeli

Bu çalışmada üroloji alanında bir akıllı karar modeli geliştirilmiştir. Üroloji kliniği için geliştirilen bu akıllı karar modelinin mimarisi Şekil 27’de verilmiştir.



Şekil 27: Akıllı karar modeli


Bu çalışmada önerilen akıllı karar modeli kapsamında, ilk olarak Marmara Üniversitesi Üroloji Birimi'nden çocuk hastalara ait üroflowmetri test raporları toplanmıştır. Toplanan veriler, sınıflandırma modeline uygun hâle getirilmek üzere çeşitli veri önileme adımlarına tabi tutulmuştur.

Sınıflandırma sürecinde çok katmanlı algılayıcı mimarisi kullanılmış ve bu yapının hiperparametreleri olan nöron sayısı ile öğrenme oranı, arşimet optimizasyon algoritması ile optimize edilmiştir. Elde edilen veri seti, iki istemciye rastgele dağıtılarak federe öğrenme sistemine uygun hâle getirilmiş ve optimize edilmiş model, her bir istemcide yerel olarak eğitilmiştir. Yerel eğitimler sonucunda elde edilen model ağırlıkları, merkezi sunucuda federe öğrenme teknikleriyle birleştirilmiş ve böylece global model oluşturulmuştur. Model eğitimi, belirlenen federe tur sayısı kadar sürdürülmüş ve elde edilen modellerin performansları test verileri üzerinden değerlendirilmiştir.

En iyi sınıflandırma başarımı gösteren modeli kullanarak işeme paterni normal olmayan bireyler tespit edilmiş ve bu hastalar için ikinci testlerin planlaması yapılmıştır. Bu planlama, evde sağlık hizmeti kapsamında gerçekleştirilmiş olup, iki amaçlı bir çizelgeleme matematiksel modeli geliştirilmiştir. Geliştirilen bu çizelgeleme problemi, ticari çözücü ve karınca kolonisi optimizasyonu algoritması ile çözülerek optimal çizelgeler elde edilmiştir.

2.2. Veri Seti ve Veri Ön İşleme

Bu çalışmada klinikten alınan 599 hastaya ait üroflovetri test raporları kullanılarak, 0-18 yaş kız ve erkek çocukların işeme paternleri tahmin edilmiştir. İşeme paternleri, Uluslararası Çocuk Kontinans Derneği tarafından önerilen Çan (Bell), Kule (Tower), Kesik Kesik (Staccato), Aralıklı (Interrupted) ve Plato (Plateau) olarak sınıflandırıldı. Üroflovetri testi raporuna ait bir örnek Şekil 28’de verilmiştir.



Şekil 28: Üroflovetri testi rapor örneği


Üroflovetri paterni sınıflandırma için kullanılan veriler Tablo 8’de verilmiştir. Dikkate alınan özellikler arasında, hastaların genel demografik bilgileri olarak cinsiyet ve test sırasındaki yaş yer almıştır. Üroflovetri test raporlarından şu parametreler çıkarılmıştır: işeme süresi, toplam işenen hacim, azami akış hızı ve ortalama akış hızı. Ek olarak, üroflovetri akış ve hacim grafiklerinden üretilen değerler şunları içermektedir: akış çıkış sayısı, global ve lokal maksimum akış arasındaki fark, global akışa çıkarken saniyelik akış değişimi, global akıştan inerken saniyelik akış değişim, yerel maksimum akışa çıkarken akış değişim, iki yerel maksimum akış arasındaki maksimum süre ve test sırasında akışın sıfıra düşüp düşmediğini temsil eden bir gösterge değişkeni.

Tablo 8: Veri seti bilgileri

Girdiler	Çıktı
Hasta Bilgileri Cinsiyet(C): Kategorik Test tarihindeki yaşı (TTY): Nümerik	
Üroflovetri Testi Raporunun Verdiği Değerler İşeme Süresi (İS): Nümerik Azami Akış (AA): Nümerik Toplam işeme hacmi (TİH): Nümerik Ortalama akış hızı (OAH): Nümerik	İşeme tipi (Kategorik) 0: Çan 1: Kule 2: Kesik Kesik 3: Aralıklı 4: Plato
Üroflovetri Testi Raporunun Akış ve Hacim Grafiklerinden Elde Edilen Paternler Akış sıfıra düştü mü? (ASD): Kategorik Akış çıkış sayısı (AÇS): Nümerik Global maksimum akış ile yerel maksimum akış arasındaki fark (GMAİYMAAF): Nümerik Global akışa çıkarken saniyelik akış değişimi (GAÇSAD): Nümerik Global akıştan inerken saniyelik akış değişimi (GAİSAD): Nümerik Yerel maksimum akışa çıkarken akış değişimi (YMAÇAD): Nümerik İki yerel maksimum akış arasındaki maksimum süre (İYMAAMS): Nümerik	

Evde sağlık hizmeti çizelgeleme problemi için hastaların ev adresleri bilgisi Kişisel Verilerin Korunması Kanunu (KVKK) nedeniyle gizli tutulması gerektiğinden, hasta lokasyonları üroloji kliniğine yakınlık ağırlığına göre rastgele üretilmiştir.

Bir veri madenciliği yönteminin uygulanmasından önce kullanılan teknikler kümesi, veri madenciliği için veri ön işleme olarak adlandırılır (García ve diğ., 2016). Veriler muhtemelen kusurlu olacağından, tutarsızlıkları ve fazlalıkları içermek bir veri madenciliği sürecini başlatmak için doğrudan uygulanabilir değildir. İş, sanayi, akademik ve bilim uygulamalarında veri üretim oranları ve boyutları hızla artmaktadır. Toplanan daha büyük miktardaki veriler, bunları analiz etmek için daha sofistike mekanizmalar gerektirmektedir. Veri ön işleme, verileri her bir veri madenciliği algoritması tarafından ortaya konan gereksinimlere uyarlayabilir ve uygun olmayan verilerin işlenmesini sağlar. Veri ön işleme adımları Şekil 29'daki gibidir.



Şekil 29: Veri ön işleme adımları

2.2.1. Veri Temizleme

Veri Temizleme, bir veri kümesinden yanlış, eksik, tutarsız veya ilgisiz veri kayıtlarını tespit etme, düzeltme veya kaldırma işlemidir. Amaç, veri kalitesini artırmak ve doğru, güvenilir analiz sağlamaktır.

2.2.1.1. Kayıp Veri Analizi

Kayıp veri analizi, bir veri setindeki veri eksikliğini tanımlama, anlama ve ele alma sürecidir. Eksik veriler, uygun şekilde ele alınmadığı takdirde yanlış tahminlere, istatistiksel gücün azalmasına ve yanıltıcı sonuçlara yol açabilir. Kayıp veri problemini ele almak için farklı yöntemler izlenebilir.

Silme yöntemi: Eksik veri içeren tüm satırlar silinerek sadece tam veri içeren durumlar kullanılır.

Yaklaşık değer atama yöntemi: Veri tipine göre sütunun ortalaması, medyanı veya modu alınarak kayıp veri yerine atama yapılır.

K-en yakın komşu atama yöntemi: Benzer veri noktalarını kullanarak eksik değerleri doldurur.

Model tabanlı atama yöntemi: Kayıp değerleri tahmin etmek için eğitilmiş Regresyon, Rastgele Ormanlar vb. kullanılır.

Bu çalışmada, veri setinde önemsiz düzeyde eksik veri bulunmuş olup, bu eksiklikler yaklaşık değer atama yöntemiyle giderilmiştir.

2.2.1.2. Aykırı Değer Analizi

Aykırı değer tespiti, verilerin çoğunluğundan önemli ölçüde sapan gözlemleri veya veri noktalarını belirleme sürecidir. Aykırı değer analizi için birçok yöntem geliştirilmiştir.

Kutu Grafiği Yöntemi: Verilerin dağılımının grafiksel bir gösterimidir (Walfish, 2006). Grafik, medyan ile birlikte alt çeyrek dilimi (Q1) ve üst çeyrek dilimi (Q3) temsil eder. Medyan, verilerin 50. yüzdelik dilimidir. Alt çeyreklik 25. yüzdelik dilim, üst çeyreklik ise 75. yüzdelik dilimdir. Üst ve alt limitler genellikle çeyrekler arası aralıktan ($Q3 - Q1$) sabit bir mesafe olarak belirlenir. Bu limitlerin dışındaki herhangi bir gözlem potansiyel bir aykırı değer olarak kabul edilir. Veriler normal dağılmadığında bile kutu grafiği kullanılabilir çünkü verilerin ortalamasına değil medyanına bağlıdır.

Z Skor Yöntemi: Anormal davranış öğelerini, bir argüman koleksiyonunun standart sapması ve ortalaması ile ilişkisi açısından temsil eden bir yöntemdir (Anusha ve diğ., 2019). Z-skorumu tahmin etmek için standart sapma ve ortalama 0 ve 1 olarak gösterilerek bir serpilme diyagramı çizilir. Z-skorumları tahmin etmenin amacı, veri noktalarının konum ve ölçek özelliklerini ortadan kaldırmak ve benzer olmayan veri kümelerinin tam olarak ilişkilendirilmesine izin vermektir. Aykırı değer tanıma için Z-skor tekniği tarafından kullanılan prensip, veri öğelerini serpilme diyagramında çizdikten sonra, sıfır değerinden uzak olan öğelerin aykırı değer olarak kabul edilmesidir.

Bu çalışmada, aykırı değer analizi kutu grafiği yöntemiyle gerçekleştirilmiş ve analiz sonucunda veri setinde bir aykırı değere rastlanmamıştır.

2.2.2. Veri Dönüştürme

Veri Dönüşümü, verileri orijinal formatından veya yapısından analiz, modelleme veya görselleştirme için daha uygun bir formata dönüştürme işlemidir. Makine öğrenimi algoritmaları ve istatistiksel modeller için veri uyumluluğunu, tutarlılığını ve kalitesini artırır.

2.2.2.1. Normalizasyon

Veri normalizasyonu, verilerin her bir özelliğın eşit katkısını sağlayacak şekilde ölçeklendirildiğı veya dönüştürüldüğü ön işleme yaklaşımlarından biridir (Singh ve Singh, 2020). Bu önemlidir çünkü birçok makine öğrenimi algoritması girdi özelliklerinin ölçeğine duyarlıdır ve veriler normalleştirildiğinde daha iyi sonuçlar üretebilir. Genellikle sınıflandırma algoritmaları için kullanışlıdır.

Min-Maks Normalizasyonu: Yöntem, normalleştirilmemiş verileri önceden tanımlanmış bir alt ve üst sınıra doğrusal olarak ölçeklendirir. Veriler genellikle 0 ila 1 veya -1 ila 1 aralığında yeniden ölçeklendirilir. Verilerin her bir örneğı, $x_{i,n}$, Eşitlik 3'deki gibi $x'_{i,n}$ 'ye dönüştürölür:

$$x'_{i,n} = \frac{x_{i,n} - \min(x_i)}{\max(x_i) - \min(x_i)} (nMaks) - (nMin) + nMin \quad (3)$$

Burada min ve max sırasıyla i . özelliğın minimum ve maksimum değerini gösterir. Verileri yeniden ölçeklendirmek için alt ve üst sınırlar sırasıyla $nMin$ ve $nMax$ ile gösterilir.

Z Skor Normalizasyonu: Ortalama ve standart sapma ölçöleri, elde edilen özellikler sıfır ortalamaya ve birim varyansa sahip olacak şekilde verileri yeniden ölçeklendirmek için kullanılır. Eşitlik 4'teki gibi hesaplanır:

$$x'_{i,n} = \frac{x_{i,n} - \mu_i}{\sigma_i} \quad (4)$$

Burada μ ve σ sırasıyla i . özelliğın ortalamasını ve standart sapmasını gösterir.

Bu çalışmada, sinir ağlarına dayalı öğrenme süreçlerinde daha hızlı ve kararlı sonuçlar elde edebilmek amacıyla Z-skor normalizasyonu yöntemi uygulanmıştır.

2.2.2.2. Kategorik değişkenlerin kodlanması

Kategorik veriler, özellikle sağlık, finans ve sosyal bilimler gibi alanlarda birçok veri kümesinde yaygın olarak görülür. Sayısal verilerin aksine kategorik

veriler cinsiyet, ülke veya ürün türü gibi ayrı değerleri veya kategorileri temsil eder. Ancak makine öğrenimi algoritmaları sayısal girdi gerektirdiğinden kategorik verilerin sayısal bir formata dönüştürülmesi gereklidir. Bu işlem kodlama olarak bilinir.

Etiket Kodlama: Her kategoriye benzersiz bir tamsayı atayan basit ve anlaşılır bir yöntemdir. Bu yöntem, kategorilerin sırasının anlamlı olduğu sıralı veriler için uygundur.

One-Hot Kodlama: Kategorik verileri, her kategorinin ikili bir vektörle temsil edildiği ikili bir matrise dönüştürür. Bu yöntem nominal veriler için uygundur.

Bu çalışmada “Cinsiyet” özniteliği için etiket kodlama gerçekleştirilmiştir.

2.2.2.3. Grafik verilerini dışarı aktarma

Makine öğrenimi modelleri (özellikle doğrusal regresyon, karar ağaçları vb. gibi klasik modeller) ham görüntüleri doğrudan işleyemez; genellikle özellik vektörleri, piksel dizileri veya koordinatlar şeklinde yapılandırılmış sayısal girdiye ihtiyaç duyarlar. Dolayısıyla, bir çizgi grafiğini (veya herhangi bir görüntüyü) bir modelde kullanmak istiyorsak, önce ondan sayısal verileri çıkarmamız gerekir. Bu dönüşüm, modellerin örüntüleri, eğilimleri veya anormallikleri tanımasını sağlar.

Bu çalışmada üroflovetri test raporlarındaki akış ve hacim grafikleri sayısal verilere dönüştürölüp, FÖ çalışmasında kullanmak için paternler elde edilmiştir.

2.3. Çok Katmanlı Algılayıcı

Çok Katmanlı Algılayıcı Sinir Ağı, ileri beslemeli tipte bir Sinir Ağıdır (Desai ve Shah, 2021). 1958 yılında Frank Rosenblatt, bir girdi katmanı, öğrenmeyen rastgele ağırlıklara sahip bir gizli katman ve öğrenilebilir bağlantılara sahip bir çıktı katmanından oluşan bir algılayıcı (perceptron) modeli önermiştir. Bununla birlikte, MLP'leri gerçekten güçlü kılan çok katmanlı ağ kavramı ve eğitim için geriye yayılım kullanımı daha sonra, özellikle Rumelhart ve arkadaşları tarafından 1986 tarihli makalelerinde popüler hale getirildi.

Bir MLP mimarisi örneği Şekil 30'da verilmiştir (Altay ve Varol Altay, 2023). Gizli nöronların ve girdilerin sayısına göre değişen düğümler, toplama ve aktivasyon olmak üzere iki fonksiyonu yerine getirmektedir. Girdilerin ağırlıklı toplamaları Denklem 5 kullanılarak hesaplanmıştır.


$$Top_j = \sum_{i=1}^n w_{i,j} I_i + \beta_j \quad (5)$$

Burada n , giriş düğümlerinin sayısı, w_{ij} , giriş katmanındaki i 'inci düğümün ve gizli katmandaki j 'inci düğümün bağlantı ağırlığı, β_j , j 'inci gizli düğümdeki önyargı değeri ve I_i , i 'inci giriş düğümüdür. Denklemden elde edilen değerler kullanılarak aktivasyon işlemi gerçekleştirilir. MLP'de Sigmoid, Tanh, ReLU, GELU vb. çok farklı aktivasyon fonksiyonlarından yararlanılabilmektedir. Sigmoid fonksiyonuna ait hesaplama Denklem 6'da verilmiştir.

$$f_j(x) = \frac{1}{1+e^{-Top_j}} \quad (6)$$

Gizli katmandaki her bir nöronun çıktısı hesaplandıktan sonra, ağırlık nihai çıktısı Denklem 7'deki gibi hesaplanır.

$$y_i = f_j(\sum_{i=1}^n w_{i,j} I_i + \beta_j) \quad (7)$$



Şekil 30: n girdili, h nörondan oluşan bir gizli katmanlı ve k çıktılı bir MLP topolojik yapısı

Denklemlerde gösterildiği gibi, ağırlık ve önyargı parametreleri MLP davranışını ve performansını şekillendirmede kritik bir rol oynar. Girdi ve çıktı katmanları arasında en etkili temsili elde etmek için bu parametreler optimize

edilmelidir. MLP modelinin tahmin performansını en üst düzeye çıkarmak için optimum ağırlık ve önyargı kümesini belirlemek gerekmektedir.

2.4. Hiperparametre Optimizasyonu

Sinir ağları, verilerden karmaşık doğrusal olmayan örüntüleri öğrenebilen son derece esnek modellerdir; ancak performansları büyük ölçüde öğrenme hızı, katman sayısı, nöron sayısı, aktivasyon fonksiyonları ve düzenleme terimleri gibi parametrelerin dikkatli bir şekilde ayarlanmasına bağlıdır. Uygun optimizasyon olmadan, ağlar yetersiz veya aşırı uyumdan etkilenebilir ve bu da görünmeyen veriler üzerinde zayıf genellemeye yol açabilir. Bu parametrelerin optimize edilmesi yakınsama hızını artırır, sınıflandırma veya regresyon doğruluğunu geliştirir ve hesaplama maliyetini azaltır. Ayrıca, makine öğrenimi uygulamalarında, hiperparametre optimizasyonu, özellikle büyük ölçekli veriler veya karmaşık sinir ağı mimarileri içeren görevlerde, eğitimin kararlılığını ve sağlamlığını önemli ölçüde etkileyebilir.

Izgara Arama (Grid Search), makine öğrenimi ve sinir ağlarında hiperparametre optimizasyonu için en yaygın kullanılan ve basit tekniklerden biridir (Belete ve Huchaiah, 2022). Hiperparametre uzayının manuel olarak belirlenmiş bir alt kümesinde sistematik olarak arama yapmayı içerir. Her bir parametre (örneğin öğrenme oranı, yığın boyutu, gizli katman sayısı) için ayrı değerler seçilerek bir ızgara oluşturulur ve model olası her kombinasyon için eğitilir ve değerlendirilir. Izgara Arama, ızgara içinde en iyi performans gösteren kombinasyonun bulunacağını garanti etse de, özellikle parametre sayısı ve bunların aday değerleri arttıkça hesaplama açısından pahalıdır.

Doğal olaylardan esinlenen metasezgisel algoritmalar, özellikle yüksek boyutlu veya karmaşık optimizasyon problemlerinde Izgara arama gibi kapsamlı arama yöntemlerine güçlü bir alternatif sunmaktadır (Nematzadeh ve diğ., 2022). Genetik Algoritmalar, Parçacık Sürüşü Optimizasyonu, Gri Kurt Optimizasyonu ve Arşimet Optimizasyon Algoritması gibi algoritmalar büyük ve doğrusal olmayan arama uzaylarını daha verimli bir şekilde keşfedebilmektedir. Bu yöntemler, önceki değerlendirmelerden elde edilen geri bildirimlere dayanarak aramayı umut verici bölgelere yönlendirmek için stokastik veya sezgisel kurallar kullanır. Hiperparametre ayarlamasında meta sezgisel yöntemler, daha az model değerlendirmesiyle optimuma yakın

çözümlerin belirlenmesine yardımcı olarak daha iyi ölçeklenebilirlik ve esneklik sunar. Izgara Arama'nın aksine, parametre uzayının kapsamlı bir şekilde numaralandırılmasını gerektirmezler ve optimizasyon işlemi sırasında dinamik olarak adapte olabilirler, bu da onları parametre etkileşimlerinin oldukça karmaşık olduğu derin öğrenme modellerini ayarlamak için uygun hale getirir.

Algoritma 1. AOA
Başla Girdi: -Popülasyon boyutu -Maksimum iterasyon -Sabitler -Değişkenler Başlangıç değerlerin rastgele seçimi (nesneler, hacim, yoğunluk, konum, uygunluk fonksiyonu) iterasyon=1 koşul doğru iken (iterasyon <= maksimum iterasyon) döngü her nesne için yap: güncelle (nesne_yoğunluk, nesne_hacim) hesapla (değişim_yüzdesi_faktörü) koşul (yüzde_faktörü<=0,5) normalizasyon (hız-ivme) güncelle (konum) değilse normalizasyon (hız-ivme) güncelle (hareket yönü) güncelle (konum) koşul sonu döngü sonu hesapla (en iyi uygunluk değeri) iterasyon=iterasyon+1 koşul doğru iken sonu Bitir

Arşimet Optimizasyon Algoritması, Arşimet'in kaldırma yasası, kaldırma kuvveti ve akışkanlar mekaniği ilkelerinden esinlenen metasezgisel bir optimizasyon algoritmasıdır (Hashim ve diğ., 2021). Algoritma, fiziksel yasaları taklit ederek ve bunların hesaplama stratejilerinden yararlanarak optimizasyon problemlerini çözmek için tasarlanmıştır. AOA popülasyon tabanlı bir algoritmadır. Popülasyon bireyleri daldırılmış nesnelerdir. Diğer popülasyon tabanlı metasezgisel algoritmalar gibi AOA da arama sürecine rastgele hacimlere, yoğunluklara ve ivmelere sahip başlangıç nesne

popülasyonu (aday çözümler) ile başlar. AOA algoritmasının sözde kodu Algoritma 1’de verilmiştir (Toğaçar, 2022).

2.5. Federe Öğrenme Algoritmaları

Federe öğrenme genel olarak, kümenin kendi yerel verilerini diğerlerine sızdırmadan tüm istemcilerin birleştirilmiş veri kümeleri üzerinde model eğitimi gerçekleştirmesine olanak tanıyan dağıtılmış bir çerçeveyi tanımlar (Zhou ve diğ., 2021). Bu, her katılımcı istemcinin merkezi sunucuya kendi yerel veri kümesi yerine yalnızca küresel modelin geliştirilmesine yardımcı olabilecek bilgileri göndermesine izin verilerek gerçekleştirilir.

Bu çalışmada, Federated Averaging (FedAvg), Federated Proximal (FedProx), Federated Dynamics (FedDyn) ve Model-Contrastive Federated Learning (MOON) algoritmaları kullanılmıştır. Yöntemler ile ilgili açıklamalar alt başlıklar olarak verilmiştir.

2.5.1. FedAvg

FedAvg algoritması, federe öğrenme kapsamında önerilen ilk model birleştirme yöntemi olarak McMahan ve diğ. (2017) tarafından literatüre kazandırılmıştır. FedAvg, eğitim sürecini paylaşılan global model w_t 'yi koruyan merkezi bir sunucu aracılığıyla koordine eder; burada t iletişim turunu ifade eder (Nilsson ve diğ., 2018). Ancak asıl optimizasyon, tipik olarak Stokastik Gradyan İnişi gibi yöntemler kullanılarak istemci cihazlarda yerel olarak gerçekleştirilir.

Algoritma 2. FedAvg

Başla

Girdi:

- K: istemci sayısı
- C: her turda hesaplama yapan istemcilerin oranı
- B: yerel mini parti boyutu
- E: yerel epoch sayısı
- η : öğrenme oranı
- w_0 : global başlangıç ağırlıkları
- P_k : k istemcisindeki veri noktalarının indekslerinin kümesi
- n_k : k istemcisinin örnek sayısı

Sunucu çalıştırılır:

w_0 başlat

döngü her tur $t=1,2,...$ için yap:

```

m ← maks(C·K, 1)
St ← m istemciden oluşan rastgele küme
döngü her istemci k ∈ St için paralel olarak yap
    wt+1k ← İstemciGüncelleme(k, wt)
wt+1 ←  $\sum_{k=1}^K \frac{n_k}{n} w_{t+1}^k$ 
İstemciGüncelle(k, w): // k istemcisi üzerinde çalıştır
    B ← (Pk'yı B büyüklüğünde gruplara böl)
    döngü 1'den E'ye kadar her yerel epoch i için yap
        döngü b ∈ B partisi için yap
            w ← w - η ∇ ℓ(w;b)
        w'yı sunucuya geri gönder
Bitir

```

FedAvg algoritması, her bir istemcide yerel olarak hesaplanan sinir ağı parametrelerinin (yerel ağırlıkların, yerel gradyanların) güncellemelerinin ağırlıklı ortalamasını alarak yeni bir global model oluşturur. FedAvg algoritmasının sözde kodu Algoritma 2'de verilmiştir (McMahan ve diğ., 2017).

2.5.2. FedProx

FedProx, cihazların farklı sistem yeteneklerine ve özdeş olmayan dağıtılmış verilere sahip olabileceği federe öğrenme ortamlarındaki heterojenliğin zorluklarını ele almak için tasarlanmış bir federe öğrenme algoritmasıdır (Li T ve diğ., 2020). FedAvg yöntemini, yakınsamayı stabilize etmeye yardımcı olan ve cihazların değişken miktarlarda yerel iş yapmasına izin veren yerel amaç fonksiyonlarına proksimal bir terim ekleyerek genişletir. Bu modifikasyon teorik yakınsama garantileri sağlar ve heterojen ortamlarda kararlılığı ve doğruluğu artırdığı tespit edilmiştir. FedProx algoritmasının sözde kodu Algoritma 3'te verilmiştir (Li T ve diğ., 2020).

Algoritma 3. FedProx

Başla

Girdi:

- K: istemci sayısı
- T: tur sayısı
- μ: proksimal terim
- γ: 0-1 aralığında parametre
- w₀: global başlangıç ağırlıkları
- n_k: k istemcisinin örnek sayısı
- döngü** her tur t=1,2,...T-1 için yap:

Sunucu rastgele K cihazdan oluşan bir S_t alt kümesi seçer (her k cihaz p_k olasılığı ile seçilir)
 Sunucu seçilen tüm cihazlara w^t ağırlıklarını gönderir
 Seçilen her $k \in S_t$ cihazı, γ_k^t -inexact minimizeri olan w_k^{t+1} 'yi bulur: $w_k^{t+1} \approx \arg \min_w h_k(w; w^t) = F_k(w) + \frac{\mu}{2} \|w - w^t\|^2$
 Her $k \in S_t$ cihazı w_k^{t+1} 'yi sunucuya geri gönderir
 Sunucu w 'leri w^{t+1} olarak birleştirir, $w^{t+1} = \frac{1}{K} \sum_{k \in S_t} w_k^{t+1}$

döngü sonu

Bitir

Özellikle FedProx, k cihazının yalnızca yerel amaç fonksiyonu $Fk(\cdot)$ 'yi değil, daha çok artırılmış bir amaç olan hk 'yi en aza indirmesini sağlayarak yerel optimizasyon sürecini değiştirir. Bu amaç proksimal bir terim içerir ve cihaz hk değerini yaklaşık olarak en aza indirmek için tercih ettiği yerel çözücüyu kullanır, böylece heterojen veri ortamlarında kararlılığı artırır.

2.5.3. FedDyn

FedDyn, istemciler arasında bağımsız ve özdeş dağılımlı (IID) olmayan veriler nedeniyle ortaya çıkan istemci kayması sorununu ele alan bir federe öğrenme algoritmasıdır (Acar ve diğ., 2021). FedAvg gibi basitçe model ağırlıklarının ortalamasını alan algoritmaların aksine FedDyn, yerel güncellemeleri global optimizasyon hedefiyle daha iyi uyumlu hale getirmek için dinamik bir düzenleme terimi sunar. FedDyn algoritmasının sözde kodu Algoritma 4'te verilmiştir.

Algoritma 4. FedDyn (Acar ve diğ., 2021)

Başla

Girdi:

- T : tur sayısı

- θ : sınır ağı modeli parametreleri

- α : FedDyn parametresi

- $L_k(\theta)$: k . cihazın ampirik kaybıdır

döngü her tur $t=1,2,\dots,T-1$ için yap:

$P_t \subseteq [m]$ cihazlarını örnekleyin ve seçilen her cihaza θ^{t-1} iletin.

döngü her $k \in P_t$ cihazı için ve paralel olarak şunları yap:

$$\theta_k^t = \argmin L_k(\theta) - \langle \nabla L_k(\theta_k^{t-1}), \theta \rangle + \frac{\alpha}{2} \|\theta - \theta^{t-1}\|^2,$$

$$\nabla L_k(\theta_k^t) = \nabla L_k(\theta_k^{t-1}) - \alpha(\theta_k^t - \theta^{t-1}),$$

Cihaz modelini θ_k^t sunucuya iletir

döngü sonu

döngü her $k \notin P_t$ cihazı ve paralel olarak şunları yap:

$$\theta_k^t = \theta_k^{t-1}, \nabla L_k(\theta_k^t) = \nabla L_k(\theta_k^{t-1}),$$

döngü sonu

$$h^t = h^{t-1} - \alpha \frac{1}{m} (\sum_{k \in P_t} \theta_k^t - \theta^{t-1}),$$

$$\theta_t = \left(\frac{1}{|P_t|} \sum_{k \in P_t} \theta_k^t \right) - \frac{1}{\alpha} h^t$$

döngü sonu

Bitir

Her turda, $t \in [T]$, $P_t \subset [m]$ cihazlarının bir alt kümesi aktiftir ve sunucu mevcut modelini, θ^{t-1} bu cihazlara iletir. Her bir aktif cihaz daha sonra kendi yerel ampirik kaybı ve cezalandırılmış risk fonksiyonunun toplamı olan yerel bir ampirik risk hedefini optimize eder. Dinamik olarak güncellenen cezalandırılmış risk, mevcut yerel cihaz modeline ve alınan sunucu moduna dayanır. Bu yaklaşımla önerilen risk hedefi, yerel kayıp fonksiyonlarını dinamik olarak değiştirir, böylece yerel modeller bir uzlaşmaya yakınsarsa, uzlaşma noktası küresel kaybın durağan noktasıyla tutarlı olacaktır.

2.5.4. MOON

MOON, farklı istemciler arasında IID olmayan verilerle ilgili zorlukları ele alarak federe öğrenmeyi geliştirmek için tasarlanmış bir çerçevedir (Li ve diğ., 2021). Geleneksel federe öğrenme yöntemleri genellikle veri heterojenliği ile mücadele eder ve bu da optimal olmayan model performansına yol açar. MOON, yerel istemci modelleri tarafından öğrenilen temsilleri global modelinkilerle hizalayan model düzeyinde bir zıt öğrenme yaklaşımı sunar. MOON, bu temsiller arasındaki uyumu en üst düzeye çıkararak, IID olmayan veri dağılımlarının neden olduğu sapmayı etkili bir şekilde azaltır. MOON algoritmasının sözde kodu Algoritma 5'te verilmiştir.

Algoritma 5. MOON (Li ve diğ., 2021)

Başla

Girdi:

- K: istemci sayısı
- T: tur sayısı
- μ : proksimal terim
- γ : 0-1 aralığında parametre
- w_0 : global başlangıç ağırlıkları
- n_k : k istemcisinin örnek sayısı

döngü her tur $t=1,2,\dots,T-1$ için yap:

Sunucu rastgele K cihazdan oluşan bir S_t alt kümesi seçer (her k cihaz p_k olasılığı ile seçilir)

Sunucu seçilen tüm cihazlara w^t ağırlıklarını gönderir

Seçilen her $k \in S_t$ cihazı, γ_k^t -inexact minimizeri olan w_k^{t+1} 'yi bulur: $w_k^{t+1} \approx$

$$\arg \min_w h_k(w; w^t) = F_k(w) + \frac{\mu}{2} \|w - w^t\|^2$$

Her $k \in S_t$ cihazı w_k^{t+1} 'yi sunucuya geri gönderir

$$\text{Sunucu } w^t\text{'leri } w^{t+1} \text{ olarak birleştirir, } w^{t+1} = \frac{1}{K} \sum_{k \in S_t} w_k^{t+1}$$

döngü sonu

Bitir

2.6. SHAP Analizi

SHapley Additive ExPlanations (SHAP), özellikle öznitelik önemi ve bireysel tahminler açısından makine öğrenimi modellerini açıklamak için kullanılan ve Lundberg ve Lee tarafından önerilen (Lundberg ve Lee, 2017) popüler bir yöntemdir. Bu isim, SHAP tarafından işbirlikçi oyun teorisinden (Štrumbelj ve Kononenko, 2014) esinlenerek oluşturulan ve tüm özelliklerin “katkıda bulunanlar” olarak ele alındığı bir eklemeli açıklama modeli olan SHapley Additive exPlanation'dan gelmektedir. Tahmin edilen her örnek için model tahmin edilen bir değer üretir ve SHAP değeri örnekteki her özelliğe atanan değerdir (Yang ve diğ., 2021).

N oyunculu ve v getiri fonksiyonlu (süper-katkılı olması gerekmez) bir oyundaki her bir i oyuncusu için Shapley değeri, $(\phi_i(v))$, Denklem 8'deki gibi hesaplanır (Pham ve Milazzo, 2025):

$$\phi_i = \sum_{S \subseteq N \setminus \{i\}} \frac{|S|!(|N|-|S|-1)!}{|N|!} [f(S \cup \{i\}) - f(S)] \quad (8)$$

Burada; ϕ_i i . özelliğin model tahminine olan katkısını; N , tüm özelliklerin kümesi; S , özelliklerin alt kümesi; $f(S)$, S kümesindeki özelliklerle eğitilmiş modelin tahmini; $f(S \cup \{i\})$, özellik i 'yi içeren modelin tahminini ifade eder. SHAP, her bir özelliğe belirli bir tahmine katkısına göre bir önem değeri atar. Katkı, tüm olası özellik kombinasyonları dikkate alınarak ve marjinal katkılarının ortalaması alınarak hesaplanır.

2.7. Model Değerlendirme Ölçütleri

2.7.1. Sınıflandırma Modeli Performans Ölçütleri

Sınıflandırma problemlerinde performans ölçümleri, bir modelin farklı sınıflar arasında ne kadar iyi ayırım yaptığını değerlendirmeye yardımcı olur. Karışıklık matrisi, tahmin edilen ve gerçek değerleri karşılaştırarak bir

sınıflandırma modelinin performansını özetleyen bir tablodur. İki sınıftan oluşan bir karışıklık matrisi tablosu örneği Şekil 31’de verilmiştir.

		GERÇEK	
		Pozitif	Negatif
TAHMİN	Pozitif	TP	FP
	Negatif	FN	TN

Şekil 31: Karışıklık matrisi

Burada;

- **Doğru Pozitif (TP):** Doğru tahmin edilen pozitif vakalar (örneğin, spam e-postalar doğru şekilde spam olarak sınıflandırılır).
- **Yanlış Pozitif (FP):** Yanlış tahmin edilen pozitif vakalar (örn. spam olmayan e-postaların yanlışlıkla spam olarak sınıflandırılması).
- **Yanlış Negatif (FN):** Yanlış tahmin edilen negatif vakalar (örn. spam olmayan olarak sınıflandırılan spam e-postalar).
- **Doğru Negatif (TN):** Doğru tahmin edilen olumsuz vakalar (ör. spam olmayan e-postalar spam olmayan olarak sınıflandırılır).

Bu çalışmada, modelleri karşılaştırmak için kullanılan performans değerlendirme ölçütleri aşağıda verilmiştir.

Doğruluk oranı: Modelin genel doğruluğunu ölçer. Sınıflar dengeli olduğunda iyi çalışır ancak dengesiz veri kümeleri için yanıltıcı olabilir. Doğruluk oranı hesaplaması Denklem 9’da verilmiştir.

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \quad (9)$$

Kesinlik: Tahmin edilen pozitif vakaların kaç tanesinin gerçekten pozitif olduğunu gösterir. Yanlış pozitif (FP) maliyetli olduğunda kullanışlıdır (örneğin, spam tespitinde). Kesinlik hesaplaması Denklem 10’da verilmiştir.

$$\text{Kesinlik} = \frac{TP}{TP+FP} \quad (10)$$

Duyarlılık: Gerçek pozitif vakaların kaçının doğru tahmin edildiğini ölçer. Yanlış negatif (FN) maliyetli olduğunda önemlidir (örneğin, tıbbi teşhislerde). Duyarlılık hesaplaması Denklem 11’de verilmiştir.

$$Duyarlılık = \frac{TP}{TP+FN} \quad (11)$$

F1-skoru: Kesinlik ve anma değerlerinin harmonik ortalamasıdır. Her iki ölçümü de dengeler, veriler dengesiz olduğunda kullanışlıdır. F1-skoru hesaplaması Denklem 12’de verilmiştir.

$$F1 - skor = 2 \times \frac{Kesinlik \times Duyarlilik}{Kesinlik + Duyarlilik} \quad (12)$$

ROC Eğrisi: Çeşitli eşiklerde Doğru Pozitif Oranı (Duyarlılık) ile Yanlış Pozitif Oranı (Özgüllük) grafik olarak gösterilir. AUC (Eğri Altındaki Alan) genel performansı ölçer (daha yüksek daha iyidir).

Çok sınıflı sınıflandırmayla (yani iki sınıftan fazla) uğraşırken, doğruluk, kesinlik, duyarlılık ve F1 puanı farklı şekillerde ortalaması alınabilir:

Mikro Ortalama: Tüm sınıflar arasında TP, FP ve FN'yi toplayarak tüm örnekler eşit davranır. Sınıf dağılımı dengeli olduğunda kullanışlıdır. Daha büyük sınıflara daha fazla ağırlık verir. Mikro ortalama performans ölçütleri Denklem 13-17’de verilmiştir.

$$Mikro Doğruluk = \frac{\sum_{i=1}^C TP_i + TN_i}{\sum_{i=1}^C TP_i + TN_i + FP_i + FN_i} \quad (13)$$

$$Mikro Kesinlik = \frac{\sum_{i=1}^C TP_i}{\sum_{i=1}^C TP_i + FP_i} \quad (14)$$

$$Mikro Duyarlilik = \frac{\sum_{i=1}^C TP_i}{\sum_{i=1}^C TP_i + FN_i} \quad (15)$$

$$Mikro F1 = \frac{2 \cdot Mikro Kesinlik \times Mikro Duyarlilik}{Mikro Kesinlik + Mikro Duyarlilik} \quad (16)$$

$$Mikro F1 = Mikro Kesinlik = Mikro Duyarlilik \quad (17)$$

Makro Ortalama: Her sınıf için ayrı ayrı performans puanı hesaplar, ardından bunların ortalamasını alır. Boyutuna bakılmaksızın tüm sınıflar eşit katkıda bulunur. Sınıf dengesizliğini hesaba katmaz. Makro ortalama performans ölçütleri Denklem 18-21’de verilmiştir.

$$Makro Doğruluk = \frac{1}{C} \sum_{i=1}^C \left(\frac{TP_i + TN_i}{TP_i + TN_i + FP_i + FN_i} \right) \quad (18)$$

$$Makro Kesinlik = \frac{1}{C} \sum_{i=1}^C \left(\frac{TP_i}{TP_i + FP_i} \right) \quad (19)$$

$$Makro Duyarlilik = \frac{1}{C} \sum_{i=1}^C \left(\frac{TP_i}{TP_i + FN_i} \right) \quad (20)$$

$$Makro F1 = \frac{1}{C} \sum_{i=1}^C \frac{2 \cdot Kesinlik_i \times Duyarlilik_i}{Kesinlik_i + Duyarlilik_i} \quad (21)$$

Ağırlıklı Ortalama: Bir sınıf için her bir metrik, o sınıftaki örnek sayısına göre ağırlıklandırılır. Daha fazla örneğe sahip sınıflara daha fazla önem

vererek sınıf dengesizliğini hesaba katar. Modelin performansına ilişkin dengeli bir görünüm sağlar. Ağırlıklı ortalama performans ölçütleri Denklem 22-25’de verilmiştir.

$$\text{Ağırlıklı Doğruluk} = \sum_{i=1}^C \left(\frac{s_i}{N} \cdot \frac{TP_i + TN_i}{TP_i + TN_i + FP_i + FN_i} \right) \quad (22)$$

$$\text{Ağırlıklı Kesinlik} = \sum_{i=1}^C \left(\frac{s_i}{N} \cdot \frac{TP_i}{TP_i + FP_i} \right) \quad (23)$$

$$\text{Ağırlıklı Duyarlılık} = \sum_{i=1}^C \left(\frac{s_i}{N} \cdot \frac{TP_i}{TP_i + FN_i} \right) \quad (24)$$

$$\text{Ağırlıklı F1} = \sum_{i=1}^C \left(\frac{s_i}{N} \cdot \frac{2 \cdot \text{Kesinlik}_i \times \text{Duyarlılık}_i}{\text{Kesinlik}_i + \text{Duyarlılık}_i} \right) \quad (25)$$

Burada; C, sınıf sayısı, TP_i , i. sınıf için doğru pozitif, TN_i , i. sınıf için doğru negatif, FP_i , i. sınıf için yanlış pozitif, FN_i , i. sınıf için yanlış negatif, s_i , i. sınıf için toplam örnek sayısı, Kesinlik_i , i. sınıfa ait kesinlik, Duyarlılık_i , i. sınıfa ait anma ve N, toplam vaka sayısıdır.

2.7.2. Çizelgeleme Optimizasyonu Performans Ölçütü

Evde sağlık hizmetleri çizelgelemesinde performans değerlendirmesi için çoklu hedeflere ve hesaplama verimliliğine odaklanılmıştır. Bu çalışmada, iki temel hedefe dayalı çözümleri karşılaştırılmıştır: toplam hizmet günü sayısını ve toplam seyahat mesafesini en aza indirmek. Günleri en aza indirmek daha hızlı bakım sunumu sağlarken, seyahat mesafesini azaltmak ulaşım maliyetleri ve bakıcı yükünü azaltır. Ek olarak, optimizasyon modellerinin pratik uygulanabilirliğini değerlendirmek için hesaplama süresi analiz edilmiştir. Çözüm kalitesini hesaplama verimliliği ile dengelemek, gerçek dünyadaki evde sağlık hizmetleri sistemlerinde etkili ve ölçeklenebilir planlama stratejileri uygulamak için çok önemlidir.

2.8. İstatistiksel Anlamlılık ve Sağlamlık Testleri

2.8.1. K-Kath Çapraz Doğrulama

K-kat çapraz doğrulamada, başlangıç verileri rastgele olarak k adet birbirini dışlayan alt kümeye veya “kata” ayrılır, $D_1, D_2, \dots, D_k$, her biri yaklaşık olarak eşit büyüklüktedir (Han et al., 2012). Eğitim ve test k kez gerçekleştirilir. Yineleme i’de D_i bölümü test kümesi olarak ayrılır ve kalan bölümler toplu olarak modeli eğitmek için kullanılır. Yani, ilk iterasyonda, alt kümeler $D_2, \dots, D_k$ alt kümeleri, D_1 üzerinde test edilen ilk modeli elde etmek için topluca

eğitim seti olarak kullanılır; ikinci iterasyon $D_1, D_3, \dots, D_k$ alt kümeleri üzerinde eğitilir ve D_2 üzerinde test edilir ve bu böyle devam eder. Sınama testi ve rastgele alt örnekleme yöntemlerinin aksine, burada her örnek eğitim için aynı sayıda ve test için bir kez kullanılır.

Çapraz doğrulamanın temel amacı, bir model eğitim verileri üzerinde çok iyi eğitildiğinde ve yeni, görünmeyen veriler üzerinde düşük performans gösterdiğinde ortaya çıkan aşırı uyumu önlemektir. Çapraz doğrulama, modeli birden fazla doğrulama kümesi üzerinde değerlendirerek modelin genelleme performansı, yani yeni, görünmeyen veriler üzerinde iyi performans gösterme yeteneği hakkında daha gerçekçi bir tahmin sağlar. Makine öğrenimi modelinin sadece eğitim verilerini ezberlemediği ve gerçek dünya verilerine uyum sağlayabildiğinin testini gerçekleştirmek için çapraz doğrulama yaygın olarak kullanılan bir tekniktir.

2.8.2. Normallik Testi

Shapiro ve Wilk'in (1965) W-testi, normallikten sapma konusunda köklü ve güçlü bir testtir. Royston (1982) testi orijinal örneklem büyüklüğü olan $n = 50$ 'den $n = 2000$ 'e genişletmiştir. Genişletme, Shapiro ve Wilk'in W'nin hesaplanmasında kullanılan katsayılarla ilişkin kendi önerdikleri yaklaşıma dayanmaktadır.

$m' = (m_1, \dots, m_n)$ standart normal sıra istatistiklerinin beklenen değerlerinin vektörünü gösterebilir ve $V = (v_{ij})$ karşılık gelen $n \times n$ kovaryans matrisi olsun (Royston, 1982);

$$E(x_i) = m_i (i = 1, \dots, n) \quad (26)$$

$$cov(x_i, x_j) = v_{ij} (i, j = 1, \dots, n) \quad (27)$$

burada $x_1 < x_2 < \dots < x_n$, standart normal dağılım $N(0, 1)$ 'den sıralı rastgele bir örnektir. $y' = (y_1, \dots, y_n)$ üzerinde W normallik testinin gerçekleştirileceği, $y_{(1)} < y_{(2)} < \dots < y_{(n)}$ sıralı rastgele bir örnek olduğunu varsayalım. O halde

$$W = [\sum_1^n a_i y_{(i)}]^2 / \sum_1^n (y_i - \bar{y})^2 \quad (28)$$

$$\hat{a} = (a_1, \dots, a_n) = \hat{m}V^{-1}[(\hat{m}V^{-1})(V^{-1}\hat{m})]^{-\frac{1}{2}} \quad (29)$$

burada; $\hat{a}$, normallik varsayımı altında y_i standardının en iyi doğrusal önyargısız tahminidir.

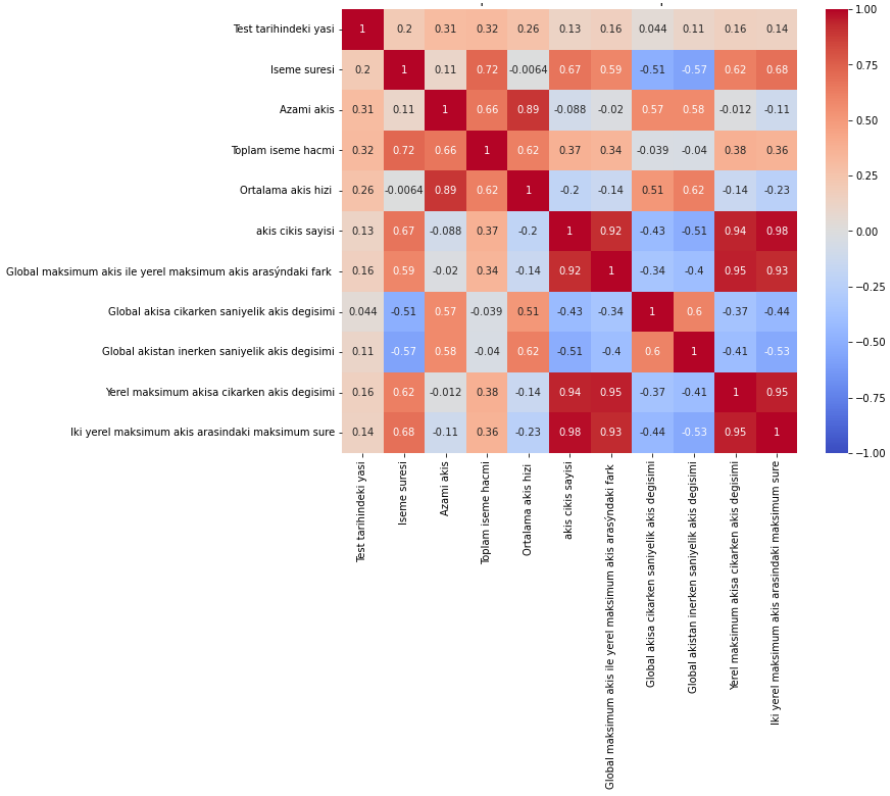
Bu çalışmada kullanılan veri seti üzerinde bir normallik testi yapılmıştır. Shapiro-Wilk normallik testi hem genel Özniteliklere hem de her bir sınıf içindeki Özniteliklere uygulanmıştır. Elde edilen p-değerleri 0,05'ten küçük olduğu için ($p < 0,05$) verilerin normal dağıldığını varsayan sıfır hipotezi (H_0) reddedilmiştir. Dolayısıyla verilerin normal bir dağılım göstermediği sonucuna varılmıştır.

2.8.3. Spearman Korelasyon Analizi

Spearman sıra korelasyon katsayısı r_s , iki sıralı değişken veya bir sıralı değişken ile bir ölçüm değişkeni arasındaki keyfi monotonik ilişkinin gücünün ve yönünün parametrik olmayan veya dağılımdan bağımsız bir sıra istatistiksel ölçüsüdür (Xiao ve diğ., 2016). Prensip olarak, Spearman korelasyon katsayısı, korelasyon katsayısı hesaplamaları yapılmadan önce örneklerin sıralamaya dönüştürüldüğü durumda Pearson katsayısının özel bir durumudur. Ancak frekans dağılımı ve iki değişken arasındaki doğrusal ilişki hakkında herhangi bir varsayımda bulunmayı gerektirmez ve aralık ölçeğinde ölçülmez. İki sıralı değişken arasındaki farka dayanan r_s için basit ifade Denklem 30'daki gibidir:

$$r_s = 1 - \frac{6 \sum d_i^2}{N(N^2 - 1)} \quad (30)$$

burada; d, sıralanan değişkenlerin her bir çifti arasındaki fark ve N ise toplam örnek sayısıdır. Bu çalışmada kullanılan nümerik ve sıralı veriler için spearman korelasyon testi uygulanmış olup elde edilen değerler Şekil 3.6'daki gibidir.



Şekil 32: Öznitelikler arasındaki spearman korelasyonu

2.8.3. Kruskal Wallis Testi

Kruskal-Wallis testi, iki veya daha fazla örneğin aynı dağılımdan çekilip çekilmediğini değerlendiren parametrik olmayan bir istatistiksel testtir (Kruskal ve Wallis, 1952). Bu test verilerin normal dağıldığını varsaymaz. Mann-Whitney U testinin (iki grubu karşılaştıran) bir uzantısıdır ve tek yönlü ANOVA'nın parametrik olmayan alternatifidir (Guo ve diğ., 2013).

Her biri bir dizi değer içeren k adet örneğimiz olduğunu varsayalım. Kruskal-Wallis testini gerçekleştirmek için, önce değerlerin hangi örneğe ait olduğunu dikkate almadan tüm değerleri birlikte sıralanması, ardından her bir örnek içindeki tüm değerlerin sıralarının toplamını hesaplanması gerekir, böylece her örnek kendi sıralarının toplamına sahip olur. Eğer tüm değerler arasında bir eşitlik yoksa, H testi istatistiği Denklem 31'de verilmiştir.

$$H = \frac{12}{N(N+1)} \sum_{i=1}^k \frac{R_i^2}{n_i} - 3(N+1) \quad (31)$$

Burada N, tüm örneklerdeki toplam değer sayısı; n_i , i. örneğinde bulunan değer sayısı ve R_i , i. örneğindeki sıralamaların toplamıdır.

p-değeri, H_0 hipotezin doğru olması durumunda (yani, tüm gruplar aynı dağılımdan gelir / aynı medyana sahiptir) hesaplanan kadar uç bir H istatistiği gözlemlenebilir olasılığıdır. p-değeri, H istatistiğinin k-1 serbestlik dereceli ki-kare dağılımıyla karşılaştırılmasıyla hesaplanır; burada k grup sayısıdır. Anlamlılık düzeyi (α) 0,05 olduğunda, p-değeri α 'dan büyük veya eşitse ($p \geq 0,05$) sıfır hipotez (H_0) kabul edilir ve p-değeri α 'dan küçükse ($p < 0,05$) reddedilir.

Bu çalışmada, her bir sınıf ve öznitelik arasında kruskal-wallis testi gerçekleştirilmiş olup elde edilen p değerleri Tablo 9'daki gibidir. Sonuçlara göre p değeri 0.05'ten küçük olduğu için H_0 reddedilir ve sınıf etiketi ile öznitelikler arasında istatistiksel olarak anlamlı fark vardır.

Tablo 9: Kruskal Wallis Sınıf ve Öznitelik İlişkisi

Öznitelik	Sınıf 1	Sınıf 2	Sınıf 3	Sınıf 4	Sınıf 5
TTY	3.6E-06	1.0E-01	1.2E-01	3.0E-01	1.0E-03
İS	3.1E-23	7.8E-06	1.3E-09	3.4E-10	8.3E-07
AA	7.0E-10	8.0E-02	2.4E-05	6.5E-02	2.1E-04
TİH	1.3E-17	3.4E-04	4.2E-06	8.0E-04	1.1E-04
OAH	9.7E-09	1.1E-01	2.3E-04	1.6E-02	5.1E-03
AÇS	8.3E-32	2.4E-16	2.0E-11	1.8E-08	3.7E-09
GMAİYMAAF	7.5E-34	1.2E-16	5.0E-14	3.6E-07	3.5E-14
GMÇSAD	2.8E-23	5.3E-06	2.1E-10	5.6E-07	5.4E-08
GMİSAD	2.1E-15	8.3E-02	8.4E-06	3.0E-08	5.6E-09
YMAÇAD	6.0E-34	2.2E-16	1.6E-07	1.6E-02	3.9E-11
İYMAAMS	1.5E-32	2.6E-16	1.5E-12	3.3E-10	3.7E-11

2.9. İki Amaçlı Evde Sağlık Hizmeti Çizelgeleme Modeli

ESH genel olarak, hastalara gerekli ilaçları ve diğer ESH hizmetlerini (hemşirelik, ev idaresi ve temizlik vb.) sağlayarak evde hizmet veren hemşireler grubu olarak tanımlanır ve kabul edilir (Fathollahi-Fard ve diğ., 2018). Gelişmiş ülkelerde ortalama yaşam süresinin uzamasıyla birlikte, hastane ve bakım evleri ile sağlık personeli sayısı aynı oranda artmamıştır. Buna bağlı olarak, ESH hizmetlerine olan talep çarpıcı bir şekilde artmaktadır.

Üroflovetri testleri ile bazı çocuk hastaların işeme tipleri anormal olduğu tespit edilmiştir. İşeme tipi normal olmayan hastalar için ikinci bir üroflovetri testi yapılabilmektedir. Özellikle çocuk hastalar için bu testlerin klinikte yapılması zorlayıcı olabilmektedir. Sağlık hizmetinin artırılması için bu tür testler evde yapılabilmektedir. Hizmet kalitesinin artırılmasıyla ortaya çıkacak maliyetleri minimize etmek için doğru bir planlama yapılması gerekmektedir.

Çalışmanın ikinci aşamasında işeme tipi sınıflandırma sonuçlarına göre tekrar test istenecek hastalar belirlenmiştir. Bu hastalar için tekrar yapılacak olan testlerin evde gerçekleştirilmesi planlanmıştır. Bu plan için bir iki amaçlı çizelgeleme matematiksel modeli geliştirilmiştir. İndisler, parametreler ve karar değişkenleri Tablo 10 ve 11’de sunulmuştur:

Tablo 10: Çizelgeleme problemindeki indisler ve parametreler

İndisler
i, j : ziyaret edilecek hastalar $i, j=1, 2, \dots, n$
t : hasta ziyaret günü $t=1, 2, \dots, T$
Parametreler
d_{ij} : i. hasta ile j. hasta arasındaki mesafe
h_{ij} : i. hasta ile j. hasta arasındaki süre
A: mesai başlangıç zamanı
B: mesai bitiş zamanı
t_{si} : i. lokasyondaki test süresi
c: km başına ulaşım maliyeti
M: büyük sayı

Tablo 11: Çizelgeleme problemi karar değişkenleri

Karar Değişkenleri
x_{ijt} :
1: i.hastadan j.hastaya t.günde ziyaret gerçekleştirilecekse
0: ziyaret gerçekleştirilmeyecekse,
p_{it} :
t.gün i.hastaya varış zamanı

z_t :	1: t.gün ziyaret yapılacaksa 0: ziyaret yapılmayacaksa
u_i :	alt tur oluşmasını engelleyen karar değişkeni

Geliştirilen iki amaçlı karma tamsayılı doğrusal programlama matematiksel modeli Eşitlik 32-43'ta verilmiştir.

$$\text{Min } w1 = \sum_{t=1}^T z_t \quad (32)$$

$$\text{Min } w2 = \sum_{i=1}^n \sum_{j=1}^n \sum_{t=1}^T x_{ijt} \times d_{ij} \times c \quad i \neq j \quad (33)$$

$$\sum_{j=1}^n x_{0jt} = 1 \quad \forall t \quad (34)$$

$$\sum_{i=1}^n x_{i0t} = 1 \quad \forall t \quad (35)$$

$$\sum_{t=1}^T \sum_{j=1}^n x_{ijt} = 1 \quad \forall i, i \neq 0 \quad (36)$$

$$A \leq p_{it} + ts_i \leq B \quad \forall i, t \quad (37)$$

$$p_{jt} \geq p_{it} + h_{ij} + ts_i - (1 - x_{ijt}) \times M \quad \forall i, j, t \quad (38)$$

$$\sum_{i=1}^n \sum_{j=1}^n x_{ijt} \leq z_t \times M \quad (39)$$

$$u_i - u_j + (n - 1) \times x_{ijt} \leq n - 2 \quad \forall i, j, t, i \neq j \quad (40)$$

$$u_0 = 0 \quad (41)$$

$$x_{ijt}, z_t \in \{0,1\} \quad \forall i, j, t \quad (42)$$

$$p_{it} \geq 0 \quad \forall i, j, t \quad (43)$$

Amaç fonksiyonları olan, toplam ziyaret edilecek gün sayısı ve toplam ulaşım maliyetinin minimizasyonu Denklem 32 ve 33 ile sağlanmıştır. Denklem 34 ve 35, görevlinin göreve ofisten başlayıp, mesai bitiminde tekrar ofiste olmasını sağlayan kısıtlar. Her hastanın sadece 1 sefer ziyaret edilmesi Denklem 36 ile sağlanmıştır. Denklem 37, görevlinin mesai saatleri içerisinde çalıştığını gösterir. Denklem 38, ziyaret zamanını kontrol eden kısıttır. Denklem 39, t. günde ziyaret varsa, t. günün kullanıldığını belirten kısıttır. Denklem 40 ve 41, alt tur olmasını engelleyen kısıtlardır. Denklem 42 ve 43 ise karar değişkenleri için işaret kısıtlarıdır.

2.10. Karınca Kolonisi Optimizasyonu

Karınca Kolonisi Optimizasyonu (KKO) algoritması, karıncaların doğadaki yiyecek arama davranışlarından esinlenen olasılıksal bir

optimizasyon tekniğidir. İlk olarak 1992 yılında Marco Dorigo tarafından doktora tezinde tanıtılmıştır. Karıncalar sosyal böceklerdir. Koloniler halinde yaşarlar ve davranışları, bireylerin hayatta kalmasına odaklanmaktan ziyade koloninin hayatta kalması hedefiyle yönetilir. KKO'ya ilham veren davranış, karıncaların yiyecek arama davranışı ve özellikle de karıncaların yiyecek kaynakları ile yuvaları arasındaki en kısa yolları nasıl bulabildikleridir (Blum, 2005). Yiyecek ararken, karıncalar başlangıçta yuvalarını çevreleyen alanı rastgele bir şekilde keşfederler. Karıncalar hareket ederken yere kimyasal bir feromon izi bırakırlar. Karıncalar feromonun kokusunu alabilirler. Yollarını seçerken, olasılıkla güçlü feromon konsantrasyonları ile işaretlenmiş yolları seçme eğilimindedirler. Bir karınca bir besin kaynağı bulur bulmaz, besinin miktarını ve kalitesini değerlendirir ve bir kısmını yuvaya geri taşır. Dönüş yolculuğu sırasında, bir karıncanın yere bıraktığı feromon miktarı, yiyeceğin miktarına ve kalitesine bağlı olabilir. Karıncalar iletişim kurmak ve kolonileri ile bir besin kaynağı arasındaki en kısa yolu bulmak için feromon izlerini kullanırlar.

KKO, özellikle kombinatorial optimizasyon içeren optimizasyon problemlerini çözmek için bu davranış modelleri. KKO, gezgin satıcı problemi (Yang ve diğ., 2008), araç rotalama (Rizzoli ve diğ., 2007), çizelgeleme problemleri (Lorpenmanee ve diğ., 2007), ağ yönlendirme (Yan ve diğ., 2011), görüntü kenar algılama (Tian ve diğ., 2008), makine öğreniminde özellik seçimi (Zhang ve diğ., 2015) ve diğer problemlerde başarıyla uygulanmıştır. KKO'nun sözde kodu Algoritma 6'da verilmiştir (Dorigo ve Blum, 2005).

Algoritma 6. KKO**Başla****Girdi:**

- Problem grafiği G (düğümler ve kenarlar)
- Karınca sayısı (m)
- Iterasyon sayısı (maxIter)
- Feromon buharlaşma oranı (ρ)
- Feromon yoğunluğu (Q)
- Başlangıç feromon seviyesi (τ_0)
- Sezgisel bilgi (η)

Başlat:

- Feromon matrisini $\tau(i, j) = \tau_0$ olarak ayarla
- En iyi çözümü ve maliyeti saklamak için globalEnİyiÇözüm ve globalEnİyiMaliyet değişkenlerini tanımla

Döngü: iterasyon = 1, 2, ..., maksIter

Her karınca için ($k = 1, 2, \dots, m$):

- Karınca k için bir çözüm oluştur:
 1. Karınca, başlangıç düğümünden hareket eder
 2. Hareket olasılıkları şu şekilde hesaplanır:

$$P(i, j) = [\tau(i, j)]^\alpha * [\eta(i, j)]^\beta / \sum ([\tau(i, l)]^\alpha * [\eta(i, l)]^\beta)$$
 (α : feromon etkisi, β : sezgisel bilgi etkisi)
 3. Bir sonraki düğüm, yukarıdaki olasılığa göre seçilir
 4. Tüm düğümler ziyaret edilene kadar devam et
- Çözümün maliyetini hesapla (örneğin, toplam mesafe)
- Eğer bu çözüm globalEnİyiMaliyet'tan daha iyiyse:
 - globalEnİyiÇözüm ve globalEnİyiMaliyet'u güncelle

Feromon güncellemesi:

- Her kenardaki feromon miktarını güncelle:

$$\tau(i, j) = (1 - \rho) * \tau(i, j) + \Delta\tau(i, j)$$

$$\Delta\tau(i, j): \text{Karıncaların çözümlerine bağlı olarak feromon eklemesi}$$

$$\Delta\tau(i, j) = \sum (Q / \text{maliyet}), \text{ eğer } (i, j) \text{ bir karıncanın yolunda varsa}$$

Döngü sonu**Çıktı:**

- globalEnİyiÇözüm ve globalEnİyiMaliyet (en iyi çözüm ve maliyet)

Bitir

2.11. Uygulama Platformu ve Yazılımlar

Bu çalışmada gerçekleştirilen bibliyometrik analizi için biblioshiny paketinden yararlanılmıştır. Paket, R Core Team ve R Foundation for Statistical Computing tarafından desteklenen istatistiksel hesaplama ve grafikler için bir programlama dili olan R'de oluşturulmuştur.

Çalışmada veri ön işleme, istatistiksel testler, makine öğrenme, shap analizi ve optimizasyon uygulamaları için python programlama dili kullanılmıştır. Python, yüksek seviyeli ve genel amaçlı bir programlama dilidir. Python, tasarım felsefesi, önemli girinti kullanımı ile kod okunabilirliğini vurgular. Python sürekli olarak en popüler programlama dilleri arasında yer almaktadır ve makine öğrenimi topluluğunda yaygın bir kullanım kazanmıştır.

Python dili geliştirmek için spyder ide kullanılmıştır. Spyder, Python için Python'da yazılmış açık kaynaklı, topluluk tarafından geliştirilen bir bilimsel ortam ve IDE'dir. Bilim insanları, mühendisler ve analistler için, kapsamlı bir geliştirme aracı ve veri keşif paketinin kullanımı için geliştirilmiş etkili bir arayüzdür.

Makine öğrenme uygulamasını gerçekleştirmek için python dilinde geliştirilmiş pandas, matplotlib, numpy, scikit-learn ve torch.nn kütüphanelerinden yararlanılmıştır. Pandas, Python programlama dilinin üzerine inşa edilmiş, hızlı, güçlü, esnek ve kullanımı kolay bir açık kaynak veri analizi ve manipülasyon aracıdır. NumPy, çok boyutlu bir dizi nesnesi, çeşitli türetilmiş nesneler ve matematiksel, mantıksal, şekil manipülasyonu, sıralama, ayrık Fourier dönüşümleri, temel doğrusal cebir, temel istatistiksel işlemler, rastgele simülasyon ve çok daha fazlası dahil olmak üzere diziler üzerinde hızlı işlemler için çeşitli rutinler sağlayan bir Python kütüphanesidir. Matplotlib, python'da statik, animasyonlu ve etkileşimli görselleştirmeler oluşturmak için kullanılan kapsamlı bir kütüphanedir. scikit-learn, makine öğrenme uygulamaları gerçekleştirmek için geliştirilmiş açık kaynaklı bir kütüphanedir. torch.nn ise, sinir ağları oluşturmak ve eğitmek için kullanılan bir PyTorch modülüdür. Derin öğrenme modellerini verimli bir şekilde tanımlamak, yönetmek ve manipüle etmek için zengin bir araç koleksiyonu sağlar.

Çizelgeleme optimizasyonu için ise python dilinde gurobipy ve time kütüphaneleri kullanılmıştır. Gurobi, karışık tamsayı doğrusal ve ikinci dereceden optimizasyon problemlerini çözmek için matematiksel bir optimizasyon yazılımı kütüphanesidir.

3. BULGULAR

3.1. Global Model

Bu çalışmada, üroflovetri testinin bulgularından yola çıkılarak belirlenen 0-18 yaş çocukların işeme paternleri sınıflandırılmıştır. Sınıflandırma çalışması için merkezi ve federe öğrenme modelleri karşılaştırılmıştır. Sınıflandırma problemünde global model için bir (1H) ve iki (2H) gizli katmandan oluşan yapay sinir ağı mimarisi oluşturulmuştur. Global modelde ağırlıklar rastgele oluşturulmuş olup, gizli katmandaki nöron sayıları ve modelin öğrenme oranı AOA ile optimize edilmiştir. Model hiperparametre optimizasyonunda kullanılan değişkenler Tablo 12’de sunulmuştur.

Tablo 12: AOA parametreleri

Değişken	Değer
AOA Popülasyon Boyutu	20
AOA İterasyon Sayısı	50
Öğrenme Oranı için Sınırlar	0,01-0,35
Birinci Gizli Katman Nöron Sayısı için Sınırlar	5-100
İkinci Gizli Katman Nöron Sayısı için Sınırlar	5-100
K Kat Çapraz Doğrulama Sayısı	5
Epoch Sayısı	100

Hiperparametre optimizasyonu bulgularına göre merkezi ve federe öğrenme modellerinde kullanılan öğrenme oranı ve gizli katmandaki nöron sayıları Tablo 13’te verilmiştir.

Tablo 13: Hiperparametre optimizasyonu bulguları

Optimize Edilen Parametreler	Değerler
1H MLP modeli öğrenme oranı	0,2
2H MLP modeli öğrenme oranı	0,2
1H MLP modeli gizli katman nöron sayısı	73
2H MLP modeli gizli katman nöron sayıları	68 ve 52

3.2. Merkezi Eğitim ve Federe Öğrenme

Bu çalışmada, hastalara ait veri seti öncelikle %80 eğitim ve %20 test verisi olacak şekilde ikiye ayrılmıştır. Eğitim veri seti daha sonra iki eşit parçaya bölünerek her bir istemciye özgü eğitim verileri oluşturulmuştur. Her istemci, kendi verisiyle MLP modeli kullanarak sınıflandırma işlemini gerçekleştirmiştir. Bu doğrultuda, FedAvg ve FedDyn algoritmaları uygulanarak federe öğrenme yaklaşımlarının sınıflandırma performansları karşılaştırılmalı olarak değerlendirilmiştir.

Eğitim veri seti üç farklı şekilde bölünerek gerçekleştirilen testlerin sonuçları Tablo 14–16’da sunulmuştur. Elde edilen bulgular, federe öğrenme yaklaşımıyla gerçekleştirilen sınıflandırma işleminin, istemcilerde yapılan yerel öğrenmelere kıyasla daha yüksek performans gösterdiğini ortaya koymuştur. Makro doğruluk oranları açısından yapılan karşılaştırmada, ilk test senaryosunda istemci1 ile %76,77 doğruluk elde edilirken, FedAvg ve FedDyn algoritmaları sırasıyla %94,81 ve %94,92 doğruluk oranlarına ulaşmıştır.

Gerçekleştirilen ilk test senaryosuna ait sınıflandırma yöntemlerinin karmaşıklık matrisleri Şekil 4.1’de sunulmuştur. Analizler sonucunda, İstemci1’in plato tipi işleme paternini sınıflandırma başarımının düşük olduğu, buna karşılık İstemci2’nin ise kule tipi işleme paternini sınıflandırmada düşük doğruluk sergilediği tespit edilmiştir.

Bu sonuçlar, federe öğrenme yönteminin istemciler arasında veri dağılımının heterojen olduğu durumlarda dahi yüksek sınıflandırma başarımı sergilediğini göstermektedir. Genel olarak, tüm test senaryolarının analizine göre, işbirlikçi öğrenme yaklaşımının üroflovetri patern sınıflandırma doğruluğunu anlamlı düzeyde artırdığı tespit edilmiştir.

Tablo 14: Birinci test için yerel bazlı öğrenme ve federe öğrenme karşılaştırması


Yöntem	Mikro Ortalama		Makro Ortalama		Ağırlıklı Ortalama	
	Doğruluk Oranı	F1-skor	Doğruluk Oranı	F1-skor	Doğruluk Oranı	F1-skor
İstemci1 Öğrenme	0.8000	0.8000	0.7677	0.7610	0.8000	0.8026
İstemci2 Öğrenme	0.9083	0.9083	0.8310	0.8771	0.9083	0.9022
FedAVG	0.9583	0.9583	0.9481	0.9451	0.9583	0.9576
FedDyn	0.9750	0.9750	0.9492	0.9651	0.9750	0.9743

Tablo 15: İkinci test için yerel bazlı öğrenme ve federe öğrenme karşılaştırması

Yöntem	Mikro Ortalama		Makro Ortalama		Ağırlıklı Ortalama	
	Doğruluk Oranı	F1-skor	Doğruluk Oranı	F1-skor	Doğruluk Oranı	F1-skor
İstemci1 Öğrenme	0.7750	0.7750	0.7711	0.7686	0.7750	0.7742
İstemci2 Öğrenme	0.8083	0.8083	0.7961	0.8068	0.8083	0.8073
FedAVG	0.8167	0.8167	0.8173	0.8233	0.8167	0.8158
FedDyn	0.8333	0.8333	0.8120	0.8320	0.8333	0.8310

Tablo 16: Üçüncü test için yerel bazlı öğrenme ve federe öğrenme karşılaştırması

Yöntem	Mikro Ortalama		Makro Ortalama		Ağırlıklı Ortalama	
	Doğruluk Oranı	F1-skor	Doğruluk Oranı	F1-skor	Doğruluk Oranı	F1-skor
İstemci1 Öğrenme	0.7750	0.7750	0.7057	0.7149	0.7750	0.7755
İstemci2 Öğrenme	0.7583	0.7583	0.6192	0.6433	0.7583	0.7261
FedAVG	0.7833	0.7833	0.7077	0.7455	0.7833	0.7740
FedDyn	0.7667	0.7667	0.6967	0.7203	0.7667	0.7579



Şekil 33: Birinci test karışıklık matrisi

Çalışmanın ikinci aşamasında, merkezi öğrenme ve federe öğrenme algoritmalarının sınıflandırma performansları karşılaştırılmıştır. Model değerlendirmesi için 5 katlı çapraz doğrulama yöntemi uygulanmıştır. Yerel eğitim sürecinde, bir gizli katmandan oluşan MLP mimarisi (1H) ile iki gizli katmandan oluşan MLP mimarisi (2H) kullanılmıştır.

Yöntemlerin performansına ilişkin bulgular Tablo 17 ve Tablo 18’de sunulmuştur. Elde edilen sonuçlara göre, merkezi öğrenme ve federe öğrenme yaklaşımları arasında sınıflandırma başarımı açısından önemli bir fark olmadığı görülmüştür. Merkezi Öğrenme (1H) modeli ile %85,14 mikro doğruluk elde edilirken, MOON (1H) algoritmasıyla bu oran %84,14 olarak kaydedilmiştir. Benzer şekilde, Merkezi Öğrenme (2H) modelinde %85,64 mikro doğruluk elde edilmiş, MOON (2H) modelinde ise bu oran %83,97 olmuştur. Genel değerlendirme sonucunda, federe öğrenme yönteminin, merkezi öğrenmeye

oldukça yakın doğruluk değerleri sunduğu ve üroflovetri paterni sınıflandırmasında etkili bir alternatif oluşturduğu tespit edilmiştir.


Daha iyi performans gösteren modellere ait karışıklık matrisleri ve ROC alan eğrileri Şekil 34 ve Şekil 35’te sunulmuştur. Genel değerlendirme sonucunda, modellerin kule tipi işleme paternini sınıflandırmada görece düşük performans sergilediği görülmüştür. Buna karşılık, aralıklı işleme paterninin sınıflandırılmasında bazı modellerde %100 doğruluk oranına ulaşılmış, diğer modellerde ise bu orana oldukça yakın sonuçlar elde edilmiştir.

Tablo 17: 1H modellerin performans sonuçları


Yöntem	Mikro Ortalama		Makro Ortalama		Ağırlıklı Ortalama	
	Doğruluk Oranı	F1-skor	Doğruluk Oranı	F1-skor	Doğruluk Oranı	F1-skor
Merkezi Öğrenme(1H)	85,14	85,14	81,18	82,75	85,14	84,91
FedAvg(1H)	83,81	83,81	80,04	81,16	83,81	83,66
FedProx(1H)	83,14	83,14	76,63	79,17	83,14	82,48
FedDyn(1H)	82,80	82,80	80,19	80,34	82,80	82,73
MOON(1H)	84,14	84,14	80,64	81,63	84,14	84,01

Tablo 18: 2H modellerin performans sonuçları

Yöntem	Mikro Ortalama		Makro Ortalama		Ağırlıklı Ortalama	
	Doğruluk Oranı	F1-skor	Doğruluk Oranı	F1-skor	Doğruluk Oranı	F1-skor
Merkezi Öğrenme(2H)	85,64	85,64	81,73	83,36	85,64	85,47
FedAvg(2H)	83,81	83,81	80,62	81,28	83,81	83,72
FedProx(2H)	82,14	82,14	76,73	78,72	82,14	81,71
FedDyn(2H)	82,30	82,30	73,35	76,50	82,30	81,00
MOON(2H)	83,97	83,97	79,79	80,88	83,97	83,81




Şekil 34: Merkezi ve federe öğrenme karışıklık matrisleri




Şekil 35: Merkezi ve federe öğrenme ROC eğrileri

Modellerin kesinlik ve anma performans ölçütlerine göre karşılaştırmaları Şekil 36 ve Şekil 37’de sunulmuştur. Elde edilen bulgulara göre, genel olarak tek gizli katmanlı (1H) modellerin, iki gizli katmanlı (2H) modellere kıyasla daha yüksek performans sergilediği gözlemlenmiştir. Ayrıca, MOON algoritmasının kesinlik ve anma değerlerinin merkezi öğrenme

yaklaşımıyla oldukça benzer olduğu, bu bağlamda federe öğrenme yapısının merkezi öğrenmeye yakın düzeyde başarı sağladığı tespit edilmiştir.



Şekil 36: Mikro ve makro kesinlik değerleri




Şekil 37: Mikro ve makro duyarlılık değerleri

3.3. Deneysel Ayarların Etkisi


3.3.1. İstemci Sayısının Etkisi

Federe öğrenmedeki istemci sayısı model performansını önemli ölçüde etkileyebilir. İstemci sayısı arttıkça iletişim ek yükü, veri heterojenliği ve daha yavaş yakınsama gibi zorlukları da beraberinde getirir. Bu nedenle, FÖ ortamlarında hem verimliliği hem de model doğruluğunu optimize etmek için istemci sayısını dikkatli bir şekilde dengelemek çok önemlidir.

Federe öğrenme algoritmaları kullanılarak yürütülen bu çalışmada, istemci sayısının üroflovetri paterni sınıflandırma performansı üzerindeki etkileri incelenmiştir. Modellerin doğruluk oranları ve F-skor değerleri, farklı istemci sayıları için Şekil 38 ve Şekil 39’da sunulmuştur. Elde edilen bulgular, istemci sayısı beşe kadar arttırıldığında sınıflandırma performansının yüksek seyrettiğini göstermektedir. Ancak, istemci sayısının 10 veya daha fazla olduğu durumlarda sınıflandırma doğruluğunda belirgin bir düşüş gözlemlenmiştir. Bu düşüşün temel nedenleri arasında, her bir istemciye veri miktarının azalmasıyla birlikte modelin yeterli temsil gücünü kaybetmesi ve istemciler arası veri dağılımındaki heterojenitenin artması yer almaktadır.



Şekil 38: İstemci sayısının FÖ algoritmaları üzerindeki doğruluk oranına etkisi




Şekil 39: İstemci sayısının FÖ algoritmaları üzerindeki f1-skora etkisi

3.3.2. Federe Tur Sayısının Etkisi


Federe öğrenmedeki iletişim turlarının sayısı modelin yakınsamasını ve genel performansını doğrudan etkiler. Daha fazla tur genellikle global modelin istemcilerden gelen yerel güncellemeleri toplayarak ağırlıklarını aşamalı olarak iyileştirmesine olanak tanıyarak daha yüksek doğruluk ve istikrar sağlar. Bununla birlikte, aşırı turlar önemli performans kazanımları olmaksızın iletişim maliyetlerini ve eğitim süresini artırabilir.

Epoch sayısı 5 ve istemci sayısı 2 olarak sabitlenerek, federe tur sayısına göre sınıflandırma performansı analiz edilmiştir. Testlerden elde edilen bulgular Şekil 40 ve 41'deki gibidir. Yapılan değerlendirme sonucunda, yalnızca üç federe tur ile doğruluk oranının %60 seviyelerinde kaldığı, ancak federe tur sayısı 10 ve üzerine çıktığında doğruluğun %80'in üzerine yükseldiği gözlemlenmiştir. Bununla birlikte, 20 federe turdan sonra model performansında belirgin bir artış olmadığı, doğruluk oranının nispeten sabit kaldığı tespit edilmiştir. Bu durumda belirli bir optimizasyon seviyesine belirli bir federe tur sayısından sonra ulaşılmış olup, yüksek federe tur sayıları

performansa anlamlı bir katkı sunmamakta ve yalnızca iletişim maliyetini artırmaktadır.



Şekil 40: Federe tur sayısının FÖ algoritmaları üzerindeki doğruluk oranına etkisi




Şekil 41: Federe tur sayısının FÖ algoritmaları üzerindeki f1-skoruna etkisi


3.3.3. Epoch Sayısının Etkisi

Federe öğrenmedeki epoch sayısı, her bir istemcinin sunucuya güncelleme göndermeden önce kendi modelini ne kadar eğiteceğini etkiler. Epoch sayısının artırılması daha iyi yerel model yakınsamasına yol açarak potansiyel olarak global model doğruluğunu artırabilir. Ancak çok fazla epoch, istemci modellerinin kendi verilerine aşırı uyum sağlamasına ve veri heterojenliği nedeniyle sapmaya neden olabilir.

İstemci sayısı 2 ve federe tur sayısı 3 olarak sabitlenerek, yerel öğrenmede farklı epoch sayılarının sınıflandırma performansı üzerindeki etkisi incelenmiştir. Modellerin doğruluk oranları ve F-skör değerleri, farklı epoch sayıları için Şekil 42 ve Şekil 4.3'te sunulmuştur. Yapılan analizler sonucunda, 3 epoch ile eğitilen ve tek gizli katmana sahip sinir ağı modelleri yaklaşık %70 doğruluk oranı elde ederken, iki gizli katman içeren modellerde doğruluk oranının %55 civarında kaldığı gözlemlenmiştir. Bununla birlikte, tüm federe öğrenme modellerinde epoch sayısının 20 ve üzerine çıkarılmasıyla doğruluk oranlarının %80'in üzerine ulaştığı tespit edilmiştir. Bu sonuçlar, model karmaşıklığı ve eğitim süresi arasındaki dengeye dikkat edilmesi gerektiğini, yetersiz epoch sayısının özellikle daha derin ağlarda öğrenmeyi olumsuz etkileyebileceğini göstermektedir.



Şekil 42: Epoch sayısının FÖ algoritmaları üzerindeki doğruluk oranına etkisi




Şekil 43: Epoch sayısının FÖ algoritmaları üzerindeki f1-skoruna etkisi


3.3.4. Hiperparametre Optimizasyon Etkisi

Hiperparametre optimizasyonu, sinir ağlarının performansını ve genelleme yeteneğini artırmada kritik bir rol oynar. Sinir ağındaki öğrenme oranı ve gizli katmanlardaki nöron sayısı, eğitim dinamiklerini ve tahmin doğruluğunu önemli ölçüde etkiler. Uygun olmayan bir öğrenme oranı, modelin yavaş yakınsamasına veya sapmasına yol açabilirken, optimum bir değer verimli ve istikrarlı eğitimi kolaylaştırır. Benzer şekilde, nöron sayısı modelin karmaşık örüntüleri öğrenme kapasitesini belirler; çok az sayıda nöron yetersiz uyuma neden olabilirken, çok fazla sayıda nöron aşırı uyuma ve gereksiz hesaplama yüküne neden olabilir.

AOA kullanılarak gerçekleştirilen hiperparametre optimizasyonunun ve rastgele seçilen parametrelerin model performansına etkileri Şekil 44 ve 45'te sunulmaktadır. Yapılan analizler, hiperparametrelerin rastgele seçilmesi durumunda modelin sınıflandırma doğruluğunun %80'in altına düşebileceğini ortaya koymuştur. Optimizasyon süreci sonucunda, tek gizli katman (1H) içeren federe öğrenme mimarileri için optimal hiperparametre değerleri öğrenme oranı 0.2 ve nöron sayısı 73 olarak belirlenmiştir. İki gizli katmana sahip (2H) modellerde ise öğrenme oranı yine 0.2 olarak sabit kalırken, gizli katmanlardaki optimal nöron sayıları sırasıyla 68 ve 50 olarak tespit edilmiştir.



Şekil 44: Hiperparametre optimizasyonunun 1H FÖ algoritmaları üzerindeki doğruluk



Şekil 45: Hiperparametre optimizasyonunun 2H FÖ algoritmaları üzerindeki f1-skoruna etkisi

3.4. SHAP ve İstatistiksel Bulgular

Bu çalışmada, eğitim ve test örneklerinin seçiminden kaynaklanan model rastgeleliğini azaltmak amacıyla, verilerin rastgele seçildiği on ayrı deney gerçekleştirilmiştir. Her bir deney için sekiz farklı değerlendirme ölçütü hesaplanmıştır. İstemcilerin yerel öğrenmeleri ile federe öğrenme arasında performans açısından anlamlı bir fark olup olmadığını belirlemek amacıyla öncelikle verilerin normal dağılıma uyup uymadığı normallik testi ile analiz edilmiştir. Verilerin normal dağılmadığı tespit edildikten sonra, %5 anlamlılık düzeyinde Kruskal-Wallis testi uygulanmıştır. Kruskal-Wallis testi, tüm grup seviyelerinde bağımlı bir değişkenin popülasyon medyanları arasındaki farklılıkların anlamlılığını değerlendirir. Bu kapsamda sıfır hipotezi (H_0), yöntemler arasında anlamlı bir fark olmadığını; alternatif hipotez (H_1) ise en az bir yöntem ile diğerleri arasında anlamlı bir fark olduğunu ifade etmektedir.

Tablo 19 incelendiğinde, tüm metrikler için anlamlılık düzeyinin (p) 0.05'in altında olduğu görülmüş ve bu nedenle sıfır hipotezi reddedilmiştir. Test sonuçları, farklı öğrenme yöntemlerinin sınıflandırma performansları üzerinde anlamlı farklılıklar olduğunu ortaya koymuştur. Mikro, makro ve ağırlıklı doğruluk oranlarına ilişkin p -değerleri sırasıyla 0.0016, 0.0144 ve 0.0016


olarak bulunmuş; benzer şekilde mikro, makro ve ağırlıklı F1-skorları için p-değerleri sırasıyla 0.0016, 0.004 ve 0.0032 olarak hesaplanmıştır. Ortalama sıra değerleri incelendiğinde, FedAvg yönteminin her iki metrik türünde de en yüksek performansı sağladığı görülmektedir. Bu durum, FedAvg yaklaşımının daha etkili sınıflandırma sonuçları ürettiğini göstermektedir.

Tablo 19: Kruskal-Wallis anlamlılık testi sonuçları

	Mikro Doğruluk Oranı			Makro Doğruluk Oranı			Ağırlıklı Doğruluk Oranı		
	İstemci 1 Öğrenme	İstemci 2 Öğrenme	FedAvg	İstemci 1 Öğrenme	İstemci 2 Öğrenme	FedAvg	İstemci 1 Öğrenme	İstemci 2 Öğrenme	FedAvg
Ortalama Sıra	9.9	13.25	23.35	10.6	14.1	21.8	9.9	13.25	23.35
Kruskal-Wallis H Ist.	12.8395			8.4741			12.8395		
p (Asymp. Sig.)	0.0016			0.0144			0.0016		

	Mikro F1-Skor			Makro F1-Skor			Ağırlıklı F1-Skor		
	İstemci 1 Öğrenme	İstemci 2 Öğrenme	FedAvg	İstemci 1 Öğrenme	İstemci 2 Öğrenme	FedAvg	İstemci 1 Öğrenme	İstemci 2 Öğrenme	FedAvg
Ortalama Sıra	9.9	13.25	23.35	9.4	14.7	22.4	10.2	13.3	23
Kruskal-Wallis H Ist.	12.8395			11.0271			11.5071		
p (Asymp. Sig.)	0.0016			0.004			0.0032		

SHAP yöntemi, 13 bağımsız değişkenin sınıflandırma üzerindeki katkı düzeylerini hesaplamak amacıyla kullanılmıştır. Bu sayede, her bir özelliğin farklı işleme paterni sınıflarının tahminine olan etkisi analiz edilebilmiştir. Şekil 46, bağımlı değişken olan işleme paterni sınıfının tahmininde kullanılan 13 bağımsız değişkenin görece önem düzeylerini göstermektedir. Analiz sonuçlarına göre, GAİSD değişkeninin sınıflandırma sürecinde diğer tüm değişkenlere kıyasla en yüksek etkiye sahip olduğu tespit edilmiştir. Maksimum akıştan akışın sona erdiği ana kadar olan akış değişimi, üroflovetri eğrisinin çan, kule veya plato paterni olarak sınıflandırılmasında belirleyici bir rol oynamaktadır. Akışın kısa sürede keskin bir şekilde düşmesi genellikle "kule" paternini işaret ederken, bu düşüşün uzun bir zaman aralığına yayılması durumunda "plato" paterni gözlenmektedir. Aralıklı işleme paterninde ise özellikle ASD değişkeni belirgin hale gelmektedir; zira işleme sırasında akışın sifra düştüğü tekrar eden durumlar, akış tipinin aralıklı olarak sınıflandırılmasına neden olmaktadır.



Şekil 46: SHAP analizi

3.5. Çizelgeleme Bulguları


Çalışmanın optimizasyon aşamasında, üroflovetri paterni normal olmayan (çan paterni dışındaki) çocuk hastalara ikinci bir üroflovetri testi yapılmasını planlamak amacıyla, evde sağlık hizmeti kapsamında matematiksel formülasyonu sunulan bir çizelgeleme modeli geliştirilmiştir. Geliştirilen model, farklı hasta sayıları için test edilmiştir. Kişisel Verilerin Korunması Kanunu (KVKK) gereğince hastaların adres bilgileri rastgele üretilmiş ve bu doğrultuda testler gerçekleştirilmiştir. Modelin çözümünde, ticari bir çözücü kullanılmış; ancak problem boyutunun artmasıyla çözüm süresinin uzayabileceği endişesi nedeniyle Karınca Kolonisi Optimizasyonu tabanlı bir metasezgisel algoritma da alternatif olarak uygulanmıştır. Optimizasyonda kullanılan parametreler Tablo 20’de verilmiştir. Elde edilen sonuçlar Tablo 21’de sunulmuştur. Testler sonucunda, ticari çözücünün kısa süre içerisinde optimum çözüme ulaşabildiği gözlemlenmiştir. Ayrıca, evde sağlık hizmeti kapsamında oluşturulan örnek bir ziyaret rotası Şekil 47’de görselleştirilmiştir.

Tablo 20: KKO ve optimizasyon parametreleri

Parametre Adı	Değeri
Hizmet süresi	30 dakika
Günlük çalışma süresi	420 dakika
Karınca Sayısı	20
Feromon etkisi	1
Sezgisel bilgi ekisi	2
Feromon buharlaşma oranı	0,1
Feromon yoğunluğu	100
İterasyon sayısı	100

Tablo 21: Çizelgeleme optimizasyon sonuçları

Problem Boyutu	GUROBI			KKO				
	Amaç Fonk.. (Gün)	Amaç Fonk. (Km)	Zaman (Sn)	Amaç Fonk.. (Gün)	Amaç Fonk. Ortalama (Km)	Amaç Fonk. Min (Km)	Amaç Fonk. Maks (Km)	Zaman (Sn)Ortalama (Sn)
15 Hasta	2	47,1	0,09	2	48,2	47,6	49,4	2,15
20 Hasta	2	56	0,09	2	61,29	58,1	64,7	2,97
25 Hasta	3	64,6	0,20	3	65,53	64,9	66,3	3,90
40 Hasta	4	129	0,60	4	140	134	136,6	6,73



Şekil 47: ESH rota örneği

4. TARTIŞMA

4.1. Araştırma Sonuçlarının Tartışılması

Bu çalışmada federe öğrenme sisteminde üroflovetri testi raporlarından elde edilen bilgiler ile işleme paterni sınıflandırma çalışması gerçekleştirilmiştir.

Sağlık sektöründe federe öğrenmenin gelişimini ve araştırma eğilimlerini incelemek için bibliyometrik bir analiz yapılmıştır. Bu alandaki en erken yayın 2018 yılında ortaya çıkmış ve 2024 yılında ise yayımlanan makale sayısı 544 olmuştur. Özellikle Çin, analiz edilen yayınların yaklaşık %42'sini oluşturarak bu alana en çok katkıda bulunan ülke olarak öne çıkmıştır. Federal öğrenme makalelerinin başlıklarından çıkarılan bigramlar kullanılarak bir tematik harita oluşturulmuş ve birkaç baskın araştırma teması ortaya çıkarılmıştır. Belirlenen temel temalar arasında “deep learning”, “faul diagnosis”, “disease diagnosis” yer almaktadır. Hem yüksek merkeziliği hem de yoğunluğu gösteren motor temalar, “lung cancer” ve “cancer diagnosis” konularını kapsarken daha fazla gelişme için güçlü potansiyele sahip alanlar olarak kabul edilen niş temalar “blockchain technology” ve “health data” konularını içerir. Buna karşılık, “reinforcement learning” ve “scalable federated” gibi konular, gelecekteki önemleri konusunda belirsizliğe işaret eden, gelişmekte olan veya azalan temalar olarak kategorize edilmiştir.

Literatür, sağlık sektöründe birleştirilmiş öğrenmenin çok çeşitli uygulamalarını ortaya koymaktadır. Özellikle federe öğrenmenin gizlilik mekanizması nedeniyle bu alandaki çalışmalar diğer alanlara kıyasla daha fazladır. Çok sayıda çalışma, kanser teşhisi (Tan ve diğ., 2023), COVID-19 tespiti (Zhang W ve diğ., 2021), bitki hastalığı sınıflandırması (Mehta ve diğ., 2023), kalp hastalığı tahmini (Linardos ve diğ., 2022) gibi görevler için federe öğrenmeyi başarıyla kullanmıştır. Bununla birlikte, üroloji alanındaki literatür incelendiğinde bu alandaki araştırmaların yok denecek kadar az olduğu görülmektedir. Var olan sınırlı çalışmalar öncelikle prostat kanseri teşhisine (Rajagopal ve diğ., 2023; Kong ve diğ., 2024; Salma ve diğ., 2022) odaklanmıştır ve diğer ürolojik koşullarda federe öğrenme uygulamalarının daha fazla araştırılması için önemli bir boşluğu ve fırsatı vurgulamaktadır.

Üroflovetri alanında, kadınlara yönelik üroflovetri sonuçlarının değerlendirilmesi (Choo ve diğ., 2022), ses temelli üroflovetri sınıflandırması (Alvarez ve diğ., 2024) ve mesane çıkış obstrüksiyonu tahmini (Su ve diğ., 2025) gibi sınırlı sayıda makine öğrenimi temelli çalışma bulunmaktadır.

Ancak mevcut literatürde, bu alanda federe öğrenme yaklaşımına dayalı herhangi bir uygulamaya rastlanmamıştır.

İşeme paterni sınıflandırmasında, üroflovetri test raporlarından elde edilen özelliklerle eğitilen sinir ağı modeli %85,64 doğruluk oranına ulaşmıştır. Aynı sınıflandırma görevi üç farklı uzman hekim tarafından manuel olarak yapıldığında ise sırasıyla %83,4, %80,2 ve %84,2 başarı elde edilmiştir. Vaka bazlı analizde, olguların yaklaşık %40'ında en az bir hekimin diğerlerinden farklı bir sınıflandırma yaptığı gözlemlenmiştir. Bu üç uzmanın dışında başka klinisyenlerin değerlendirmeleriyle birlikte, hem bireysel doğruluk hem de vaka bazında uzlaşma oranlarının daha da düşmesi olasıdır. Bu durum, makine öğrenimi tabanlı yaklaşımların daha tutarlı ve güvenilir teşhis desteği sağlama potansiyelini ortaya koymaktadır.

Federe öğrenmenin etkinliğini değerlendirmek için veri kümesi iki alt kümeye bölünerek yerel istemciler arasında dağıtılmış veriler simüle edilmiştir. Sonuçlar, birleştirilmiş öğrenmenin yalnızca bireysel istemciler üzerinde gerçekleştirilen eğitimden daha iyi performans gösterdiğini ortaya koymaktadır. On bağımsız çalıştırma üzerinden gerçekleştirilen istatistiksel anlamlılık testi ile federe öğrenme ve yerel istemci modelleri arasındaki performans farkının istatistiksel olarak anlamlı olduğu doğrulanmıştır. Ayrıca, merkezi öğrenme ile federe öğrenme arasında yapılan bir karşılaştırma, birbirine yakın sonuçlar ortaya koymuştur; özellikle MOON (1H) modeli, federe öğrenme çerçevesinde %84,11'lik bir doğruluk elde etmiştir.

Deneysel bulgular, federe öğrenme sürecinde istemci sayısı, federe turu sayısı ve epoch sayısının sınıflandırma doğruluğu üzerinde önemli etkiler yarattığını ortaya koymaktadır. Özellikle istemci sayısı beşe kadar olan senaryolarda yüksek sınıflandırma doğruluğu gözlemlenmişken, bu sayı 10 ve üzerine çıktığında doğruluk oranlarında belirgin düşüşler yaşanmıştır. Bu düşüş, verinin daha fazla istemciye bölünmesiyle modelin genel temsil gücünün zayıflamasına bağlanmaktadır. Benzer şekilde, federe turu sayısı üç olduğunda doğruluk %60 seviyesinde kalırken, 10 tura ulaşıldığında doğruluk %80'in üzerine çıkmıştır. Ancak 20 tur sonrasında doğruluk artışında bir gelişme gözlenmemiş, bu da modelin öğrenme sürecinde doygunluğa ulaştığını göstermektedir. Epoch sayısına ilişkin analizlerde ise, üç federe tur sayısı ile düşük epoch sayılarında model performansı %70' doğruluğun altında kalarak yeterli seviyeye ulaşamazken, 20 epoch ile optimal doğruluk elde edilmiştir.

Ancak epoch ve tur sayısındaki aşırı artışlar, hesaplama maliyetini artırmakta ve modelde ek bir performans iyileşmesi sağlamamaktadır. Bu nedenle, federe öğrenme uygulamalarında öğrenme parametrelerinin dikkatli bir şekilde optimize edilmesi gerekmektedir.

Hiperparametre optimizasyonunun model performansı üzerinde belirleyici bir etkisi olduğu bilinmektedir. Bu çalışmada, AOA metasezgiseli kullanılarak nöron sayısı ve öğrenme oranı gibi kritik hiperparametreler optimize edilmiştir. Rastgele belirlenen hiperparametrelerle yapılan denemelerde modelin doğruluk oranının %80'in altına düştüğü gözlemlenmiş, bu da uygun parametre seçiminin model başarımını artırmada ne denli önemli olduğunu ortaya koymuştur.

Evde sağlık hizmetleri kapsamında, anormal işeme paternleri sergileyen hastalar için ikincil üroflovetri testlerini planlamak üzere matematiksel bir planlama modeli geliştirilmiştir. Modelin temel amacı, planlanan tüm testleri tamamlamak için kat edilen toplam mesafeyi ve gereken toplam gün sayısını en aza indirmektir. Değişen hasta grubu büyüklükleri için, ticari bir çözücü kullanılarak optimum çözümler verimli bir şekilde elde edilmiştir. Ayrıca, problem boyutunun büyüklüğüne ilişkin endişeler nedeniyle KKO metasezgisel yöntemi kullanılmıştır. Sonuçlar, KKO tabanlı çözümlerin optimal çözümlere çok yaklaştığını göstermiş ve kesin yöntemlerin hesaplama açısından uygunsuz hale gelebileceği daha büyük problem örnekleri için etkinliğini ortaya koymuştur.

4.2. Araştırma Kısıtları ve Sınırlılıklarının Tartışılması

Bu çalışmada, 599 hastadan oluşan bir veri kümesi için işeme paterni sınıflandırması yapılmıştır. Ancak, veri kümesi boyutu arttıkça yerel öğrenme, birleştirilmiş öğrenme ve merkezi öğrenmenin performansının nasıl değişeceği belirsizliğini korumaktadır. Federe öğrenme, veri gizliliği ve çeşitliliği açısından önemli avantajlar sağlarken, model eğitimi ve parametre toplama ile ilgili önemli zorlukları da beraberinde getirmektedir. Temel zorluklardan biri, özellikle veriler bağımsız olmadığında ve özdeş olmayan bir şekilde dağıtıldığında (IID olmayan), istemciler arasında tutarlı model performansının sürdürülmesinde yatmaktadır. Bu tür heterojenliklerin ele alınması, sağlam ve genelleştirilebilir federe öğrenme sonuçlarının elde edilmesi için kritik öneme sahiptir.

Federe öğrenme yaklaşımının ölçeklenebilirliği ve modellerin birden fazla istemci arasında eğitilmesi ve toplanması için gereken hesaplama kaynakları, gerçek dünya uygulamalarında kritik bir hususu temsil eder. Özellikle, model güncellemelerinin istemciler ve merkezi sunucu arasında iletilmesiyle ilişkili iletişim ek yükü, sistem verimliliğini önemli ölçüde etkileyebilir. Dahası, yerel ve federe öğrenme arasındaki ödünleşimleri yalnızca iletişim maliyetleri açısından değil, aynı zamanda potansiyel yanlış teşhis maliyeti açısından da değerlendirmek önemlidir. Böyle bir değerlendirme, sağlık hizmetleri gibi hassas alanlarda federe öğrenmenin genel uygulanabilirliğini ve güvenilirliğini belirlemek için çok önemlidir.

Evde sağlık hizmetleri için yapılan optimizasyon çalışmasında, KVKK getirdiği kısıtlamalar nedeniyle hasta adres bilgilerine erişilememiştir. Sonuç olarak, simülasyonlar için rastgele sentetik adres verileri üretilmiştir. Sonuç olarak, optimizasyon sonuçları gerçek dünya senaryolarında ortaya çıkabilecek gerçek operasyonel maliyetleri doğru bir şekilde yansıtamamış ve tamamen gerçekçi bir maliyet analizi yapma kabiliyetini sınırlamıştır.

5. SONUÇ VE ÖNERİLER

Federe öğrenme, gizliliği artıran ve ölçeklenebilir akıllı sağlık ağları ve uygulamaları gerçekleştirmek için son derece ilgi uyandıran, gelişmekte olan bir işbirlikçi yapay zeka yaklaşımıdır. Gerçekleştirilen bibliyometrik analiz sonucunda, çalışma sayısı sınırlı olmakla birlikte, akıllı sağlık hizmetleri alanında FÖ uygulamalarının yıllar içerisinde hızlı bir artış gösterdiği gözlemlenmiştir. FÖ'nün önümüzdeki yıllarda büyük ölçekli ve işbirliğine dayalı sağlık sistemlerinin hayata geçirilmesinde kilit bir rol oynaması ve merkezi sağlık verileri analizinden gizlilik bilincine sahip dağıtılmış sağlık operasyonlarına geçişe olanak sağlaması beklenmektedir. Bu çalışma kapsamında gerçekleştirilen bibliyometrik analizin literatüre önemli bir katkı sağlayacaktır.

Bu çalışma kapsamında, bir üroloji polikliniğinde gerçekleştirilen üroflovetri testlerinden elde edilen veriler kullanılarak çocuk hastaların işeme paternleri sınıflandırılmıştır. Üroflovetri raporlarında yer alan akış hızı ve işenen hacim grafiklerinden çeşitli öznitelikler türetilmiş ve bu özniteliklere dayalı özgün bir sınıflandırma modeli geliştirilmiştir. Çalışmada, federatif öğrenme çerçevesinde AOA ile optimize edilmiş MLP mimarisi kullanılarak dağıtık bir sınıflandırma süreci yürütülmüştür. Elde edilen bulgulara göre veriler farklı istemcilere bölünmüş olsa da federe öğrenme'nin merkezi öğrenme'ye oldukça yakın bir sınıflandırma performansı sergilediği tespit edilmiştir. Yapılan model performans ve anlamlılık testleri ile federe öğrenmenin istemci bazlı yerel öğrenmelerden üstün olduğu belirlenmiştir. MOON algoritması ile %84 doğruluk oranı elde edilmiştir.

Aynı sınıflandırma görevi, üç farklı uzman hekim tarafından manuel olarak gerçekleştirildiğinde sırasıyla %83,4, %80,2 ve %84,2 oranlarında doğruluk elde edilmiştir. Vaka bazlı yapılan analizlerde, olguların yaklaşık %40'ında en az bir hekimin diğerlerinden farklı bir sınıflandırma yaptığı belirlenmiştir. Bu bulgular, makine öğrenimi temelli yaklaşımın sübjektif değerlendirmelere göre önemli avantajını vurgulamakta ve klinik uygulamada tanısal tutarlılığı ve güvenilirliği artırma potansiyelini ortaya koymaktadır.

En iyi performans gösteren tahmin modeli aracılığıyla işeme paterni normal olmayan hastalar belirlenmiş ve bu hastalara ikinci testlerin uygulanabilmesi amacıyla elde edilen çıktılar, evde sağlık hizmeti çözelgelemesine yönelik geliştirilen matematiksel modele girdi olarak

kullanılmıştır. Oluşturulan çizelgeleme problemi, hem ticari bir çözücü hem de KKO algoritması ile kısa sürede başarıyla çözülmüştür.

Bu çalışma, federe öğrenme temelli sınıflandırma sonuçlarının operasyonel karar destek sistemlerine entegre edilerek gerçek dünyadaki sağlık hizmeti süreçlerinde etkin bir şekilde kullanılabileceğini ortaya koymuştur. Veri gizliliğini koruyan, yüksek doğrulukta tahminler üretebilen ve bu tahminleri evde sağlık hizmetlerinin çizelgelenmesinde değerlendiren uçtan uca bir karar destek sistemi geliştirilerek, hem yapay zekâ uygulamaları hem de sağlık hizmeti planlama literatürüne önemli bir katkı sunulmuştur. Veri gizliliğini esas alan öğrenme modellerinin sağlık hizmetlerine yönelik pratik çözümler sunabildiği ortaya konmuştur.

Önerilen sınıflandırma modeli mevcut sistemden daha iyi performans göstermesine rağmen, %90 veya daha yüksek bir doğruluk seviyesine ulaşmak için daha fazla iyileştirme yapılması gerekmektedir. Bu amaçla, gelecekteki çalışmalar girdi öznetelikleri kümesini genişletmeye ve model performansını artırmak için ek analizler yapmaya odaklanacaktır. Mevcut sinir ağı modelinin yerini almak üzere daha gelişmiş derin öğrenme mimarileri araştırılacak ve performansları sistematik olarak değerlendirilecektir. Bununla birlikte, mevcut hasta bilgilerini zenginleştirerek, üroflovetri patern eğrisini etkileyen temel değişkenleri belirlemek için makine öğrenimi tabanlı nedensellik analizi kullanılacak ve böylece daha yorumlanabilir ve klinik olarak anlamlı bir karar destek sistemine katkıda bulunulacaktır. Ayrıca, farklı kurumlar veya birimler arasında hasta bilgileri yatay olarak değil, öznetelik düzeyinde bölünmüş biçimde tutulduğunda ortaya çıkan veri dağılımı göz önünde bulundurularak, dikey federe öğrenme yöntemlerinin uygulanması planlanmaktadır.

KAYNAKLAR

- Abdul Salam, M., Fouad, K. M., Elbably, D. L., and Elsayed, S. M., 2024, Federated learning model for credit card fraud detection with data balancing techniques, *Neural Computing and Applications*, 36(11), 6231-6256.
- Abrams, P., Cardozo, L., Fall, M., Griffiths, D., Rosier, P., Ulmsten, U., ... and Wein, A., 2003, The standardisation of terminology in lower urinary tract function: report from the standardisation sub-committee of the International Continence Society, *Urology*, 61(1), 37-49.
- Acar, D. A. E., Zhao, Y., Navarro, R. M., Mattina, M., Whatmough, P. N., and Saligrama, V., 2021, Federated learning based on dynamic regularization, *arXiv preprint arXiv:2111.04263*.
- Ahmadzai, M., and Nguyen, G., 2023, Federated Learning with Differential Privacy on Personal Opinions: A Privacy-Preserving Approach, *Procedia Computer Science*, 225, 543-552.
- Ahmed, S., Groenli, T. M., Lakhan, A., Chen, Y., and Liang, G., 2023, A reinforcement federated learning based strategy for urinary disease dataset processing, *Computers in Biology and Medicine*, 163, 107210.
- Ahmed, U., Lin, J. C. W., and Srivastava, G., 2022, Hyper-graph attention based federated learning methods for use in mental health detection. *IEEE Journal of Biomedical and Health Informatics*, 27(2), 768-777.
- Ala, A., Alsaadi, F. E., Ahmadi, M., and Mirjalili, S., 2021, Optimization of an appointment scheduling problem for healthcare systems based on the quality of fairness service using whale optimization algorithm and NSGA-II, *Scientific Reports*, 11(1), 19816.
- Ala, A., Simic, V., Pamucar, D., and Tirkolaei, E. B., 2022, Appointment scheduling problem under fairness policy in healthcare services: fuzzy ant lion optimizer, *Expert systems with applications*, 207, 117949.
- Alanazi, A., 2022, Using machine learning for healthcare challenges and opportunities, *Informatics in Medicine Unlocked*, 30, 100924.
- Allothmany, N., Mosli, H., Shokouinejad, M., Alkashgari, R., Chiang, M., and Webster, J. G., 2018, Critical review of uroflowmetry methods, *Journal of Medical and Biological Engineering*, 38, 685-696.

- Altay, O., and Varol Altay, E., 2023, A novel hybrid multilayer perceptron neural network with improved grey wolf optimizer, *Neural Computing and Applications*, 35(1), 529-556.
- Altıntaş, E., Şahin, A., Babayev, H., Gül, M., Batur, A. F., Kaynar, M., ... and Göktaş, S., 2024, Machine learning algorithm predicts urethral stricture following transurethral prostate resection, *World Journal of Urology*, 42(1), 324.
- Alvarez, M. L., Arjona, L., Iglesias Martínez, M. E., and Bahillo, A., 2024, Automatic classification of the physical surface in sound uroflowmetry using machine learning methods, *EURASIP Journal on Audio, Speech, and Music Processing*, 2024(1), 12.
- An, Q., Rahman, S., Zhou, J., and Kang, J. J., 2023, A comprehensive review on machine learning in healthcare industry: classification, restrictions, opportunities and challenges, *Sensors*, 23(9), 4178.
- Anusha, P. V., Anuradha, C., Murty, P. C., and Kiran, C. S., 2019, Detecting outliers in high dimensional data sets using Z-score methodology, *International Journal of Innovative Technology and Exploring Engineering*, 9(1), 48-53.
- Auffenberg, G. B., Ghani, K. R., Ramani, S., Usoro, E., Denton, B., Rogers, C., ... and Collaborative, M. U. S. I., 2019, askMUSIC: leveraging a clinical registry to develop a new machine learning model to inform patients of prostate cancer treatments chosen by similar men, *European urology*, 75(6), 901-907.
- Aziz, R., Banerjee, S., Bouzeffrane, S., and Le Vinh, T., 2023, Exploring homomorphic encryption and differential privacy techniques towards secure federated learning paradigm, *Future internet*, 15(9), 310.
- Badawy, M., Ramadan, N., and Hefny, H. A., 2023, Healthcare predictive analytics using machine learning and deep learning techniques: a survey, *Journal of Electrical Systems and Information Technology*, 10(1), 40.
- Bajwa, J., Munir, U., Nori, A., and Williams, B., 2021, Artificial intelligence in healthcare: transforming the practice of medicine, *Future healthcare journal*, 8(2), e188-e194.
- Banditori, C., Cappanera, P., and Visintin, F., 2013, A combined optimization–simulation approach to the master surgical scheduling problem, *IMA Journal of Management Mathematics*, 24(2), 155-187.

- Bang, S., Tukhtaev, S., Ko, K. J., Han, D. H., Baek, M., Jeon, H. G., ... and Lee, K. S., 2022, Feasibility of a deep learning-based diagnostic platform to evaluate lower urinary tract disorders in men using simple uroflowmetry, *Investigative and Clinical Urology*, 63(3), 301.
- Baqain, L., Haddad, S., Baqain, R., El Hout, Y., and Shahait, M., 2024, Post-Graduate Urology Training in Low-and Middle-Income Countries, *Société Internationale d'Urologie Journal*, 5(5), 339-348.
- Bargetto, R., Garaix, T., and Xie, X., 2023, A branch-and-price-and-cut algorithm for operating room scheduling under human resource constraints, *Computers & Operations Research*, 152, 106136.
- Barua, R., Das, S., and Mondal, J., 2023, Emerging Applications of Artificial Intelligence (AI) and Machine Learning (ML) in Modern Urology, Exploring the Convergence of Computer and Medical Science Through Cloud Healthcare, 117-133.
- Basile, L. J., Carbonara, N., Pellegrino, R., and Panniello, U., 2023, Business intelligence in the healthcare industry: The utilization of a data-driven approach to support clinical decision making, *Technovation*, 120, 102482.
- Bebortta, S., Tripathy, S. S., Basheer, S., and Chowdhary, C. L., 2023, Fedehr: A federated learning approach towards the prediction of heart diseases in iot-based electronic health records, *Diagnostics*, 13(20), 3166.
- Belete, D. M., and Huchaiah, M. D., 2022, Grid search in hyperparameter optimization of machine learning models for prediction of HIV/AIDS test results, *International Journal of Computers and Applications*, 44(9), 875-886.
- Bian, J., Huang, J., Ji, S., Liao, Y., Li, X., Wang, Q., ... and Xiong, H., 2023, Feynman: Federated learning-based advertising for ecosystems-oriented mobile apps recommendation, *IEEE Transactions on Services Computing*, 16(5), 3361-3372.
- Blum, C., 2005, Ant colony optimization: Introduction and recent trends, *Physics of Life reviews*, 2(4), 353-373.
- Brisimi, T. S., Chen, R., Mela, T., Olshevsky, A., Paschalidis, I. C., and Shi, W., 2018, Federated learning of predictive models from federated electronic health records, *International journal of medical informatics*, 112, 59-67.

- Cacciamani, G. E., Chen, A., Gill, I. S., and Hung, A. J., 2024, Artificial intelligence and urology: ethical considerations for urologists and patients, *Nature Reviews Urology*, 21(1), 50-59.
- Cao, D., Wang, C., Sun, H., Cao, C., Kang, M., Zheng, H., ... and Tong, Q., 2023, Multiinstitutional Lung Image Classification Using Privacy-Preserving Horizontal Federated Learning with Homomorphic Encryption, In 2023 IEEE International Conference on E-health Networking, Application & Services (Healthcom), IEEE, pp. 131-136.
- Cao, K., Zou, Y., Zhang, C., Zhang, W., Zhang, J., Wang, G., ... and Huang, B., 2024, A multicenter bladder cancer MRI dataset and baseline evaluation of federated learning in clinical application, *Scientific Data*, 11(1), 1147.
- Cha, D., Sung, M., and Park, Y. R., 2021, Implementing vertical federated learning using autoencoders: Practical application, generalizability, and utility study, *JMIR medical informatics*, 9(6), e26598.
- Chen, S., Jin, T., Xia, Y., and Li, X., 2023, Metadata and Image Features Co-aware Semi-supervised Vertical Federated Learning With Attention Mechanism, *IEEE Transactions on Vehicular Technology*, 73(2), 2520-2532.
- Cheng, K., Fan, T., Jin, Y., Liu, Y., Chen, T., Papadopoulos, D., and Yang, Q., 2021, Secureboost: A lossless federated learning framework, *IEEE intelligent systems*, 36(6), 87-98.
- Choo, M. S., Ryu, H. Y., and Lee, S., 2022, Development of an automatic interpretation algorithm for uroflowmetry results: application of artificial intelligence, *International Neurourology Journal*, 26(1), 69.
- Choo, M. S., Uhm, S., Kim, J. K., Han, J. H., Kim, D. H., Kim, J., and Lee, S. H., 2018, A prediction model using machine learning algorithm for assessing stone-free status after single session shock wave lithotripsy to treat ureteral stones, *The Journal of urology*, 200(6), 1371-1377.
- Clothier, J. C., and Wright, A. J., 2018, Dysfunctional voiding: the importance of non-invasive urodynamics in diagnosis and treatment, *Pediatric Nephrology*, 33, 381-394.
- Da Costa, L. F., Furtado, L. S., Rocha, P. H., Rego, P. A., and Trinta, F. A., 2023, Time series prediction in IoT: a comparative study of federated versus centralized learning. In 2023 IEEE 20th Consumer Communications & Networking Conference (CCNC), IEEE, pp. 993-994.

- Desai, M., and Shah, M., 2021, An anatomization on breast cancer detection and diagnosis employing multi-layer perceptron neural network (MLP) and Convolutional neural network (CNN), *Clinical eHealth*, 4, 1-11.
- de Souza, L. A. C., Rebello, G. A. F., Camilo, G. F., Guimarães, L. C., and Duarte, O. C. M., 2020, Dfedforest: Decentralized federated forest. In 2020 IEEE International conference on blockchain (blockchain), IEEE, pp. 90-97.
- Divya, Anand, N., and Sharma, G., 2024, Convolutional neural network (CNN) and federated learning-based privacy preserving approach for skin disease classification, *The Journal of Supercomputing*, 80(16), 24559-24577.
- Dorigo, M., 1992, Optimization, learning and natural algorithms, Thesis (PhD), Politecnico di Milano.
- Dorigo, M., and Blum, C., 2005, Ant colony optimization theory: A survey, *Theoretical computer science*, 344(2-3), 243-278.
- Durak, Z., and Mutlu, O., 2024, Home health care nurse routing and scheduling problem considering ergonomic risk factors, *Heliyon*, 10(1).
- Ek, S., Portet, F., Lalanda, P., and Vega, G., 2022, Evaluation and comparison of federated learning algorithms for human activity recognition on smartphones, *Pervasive and Mobile Computing*, 87, 101714.
- Eriskin, L., Karatas, M., and Zheng, Y. J., 2024, A robust multi-objective model for healthcare resource management and location planning during pandemics, *Annals of Operations Research*, 335(3), 1471-1518.
- Fathollahi-Fard, A. M., Hajiaghahi-Keshteli, M., and Tavakkoli-Moghaddam, R., 2018, A bi-objective green home health care routing problem, *Journal of Cleaner Production*, 200, 423-443.
- Fernandez, S., Jenkins, P., and Vieira, B., 2020, Europe's digital migration during COVID-19: Getting past the broad trends and averages, *McKinsey Digital*, 24.
- Garapati, S. S., Hadjiiski, L., Cha, K. H., Chan, H. P., Caoili, E. M., Cohan, R. H., ... and Zhou, C., 2017, Urinary bladder cancer staging in CT urography using machine learning, *Medical physics*, 44(11), 5814-5823.
- García, S., Ramírez-Gallego, S., Luengo, J., Benítez, J. M., and Herrera, F., 2016, Big data preprocessing: methods and prospects, *Big data analytics*, 1, 1-22.

- Gentry, C., 2009, Fully homomorphic encryption using ideal lattices. In Proceedings of the forty-first annual ACM symposium on Theory of computing, pp. 169-178.
- Geraghty, R. M., Thakur, A., Howles, S., Finch, W., Fowler, S., Rogers, A., ... and Somani, B. K., 2024, Use of temporally validated machine learning models to predict outcomes of percutaneous nephrolithotomy using data from the British association of urological surgeons percutaneous nephrolithotomy audit, *European Urology Focus*, 10(2), 290-297.
- Ghelichi, Z., Gentili, M., and Mirchandani, P. B., 2021, Logistics for a fleet of drones for medical item delivery: A case study for Louisville, KY, *Computers & Operations Research*, 135, 105443.
- Guo, K., Chen, T., Ren, S., Li, N., Hu, M., & Kang, J., 2022, Federated learning empowered real-time medical data processing method for smart healthcare, *IEEE/ACM Transactions on Computational Biology and Bioinformatics*.
- Guo, S., Zhong, S., & Zhang, A., 2013, Privacy-preserving kruskal-wallis test, *Computer methods and programs in biomedicine*, 112(1), 135-145.
- Gupta, D. K., Sankhwar, S. N., and Goel, A., 2013, Uroflowmetry nomograms for healthy children 5 to 15 years old, *The Journal of urology*, 190(3), 1008-1014.
- Gupta, H., Patel, D., Makade, A., Gupta, K., Vyas, O. P., and Puliafito, A., 2022, Risk prediction in the life insurance industry using federated learning approach. In 2022 IEEE 21st Mediterranean Electrotechnical Conference (MELECON), IEEE, pp. 948-953.
- Hamer, J., Mohri, M., and Suresh, A. T., 2020, Fedboost: A communication-efficient algorithm for federated learning, In *International Conference on Machine Learning*, PMLR, pp. 3973-3983.
- Han, J.W., Kamber, M. and Pei, J., 2012, *Data Mining Concepts and Techniques*, 3rd Edition, Morgan Kaufmann Publishers, Waltham.
- Hashim, F. A., Hussain, K., Houssein, E. H., Mabrouk, M. S., and Al-Atabany, W., 2021, Archimedes optimization algorithm: a new metaheuristic algorithm for solving optimization problems, *Applied intelligence*, 51, 1531-1551.

- He, D., Du, R., Zhu, S., Zhang, M., Liang, K., and Chan, S., 2021, Secure logistic regression for vertical federated learning, *IEEE Internet Computing*, 26(2), 61-68.
- Heiyanthuduwege, S. R., Altas, I., Bewong, M., Islam, M. Z., and Deho, O. B., 2024, Decision trees in federated learning: Current state and future opportunities, *IEEE Access*.
- Hiermann, G., Prandtstetter, M., Rendl, A., Puchinger, J., & Raidl, G. R., 2015, Metaheuristics for solving a multimodal home-healthcare scheduling problem, *Central European Journal of Operations Research*, 23, 89-113.
- Hobbs, K. T., Choe, N., Aksenov, L. I., Reyes, L., Aquino, W., Routh, J. C., and Hokanson, J. A., 2022, Machine learning for urodynamic detection of detrusor overactivity. *Urology*, 159, 247-254.
- Hossen, M. N., Panneerselvam, V., Koundal, D., Ahmed, K., Bui, F. M., and Ibrahim, S. M., 2022, Federated machine learning for detection of skin diseases and enhancement of internet of medical things (IoMT) security, *IEEE journal of biomedical and health informatics*, 27(2), 835-841.
- Huang, C. T., Wang, T. J., Kuo, L. K., Tsai, M. J., Cia, C. T., Chiang, D. H., ... and Wu, C. L., 2023, Federated machine learning for predicting acute kidney injury in critically ill patients: a multicenter study in Taiwan, *Health Information Science and Systems*, 11(1), 48.
- Huang, W. T., Chen, P. S., Liu, J. J., Chen, Y. R., and Chen, Y. H., 2018, Dynamic configuration scheduling problem for stochastic medical resources, *Journal of biomedical informatics*, 80, 96-105.
- Iwamura, H., Mizuno, K., Akamatsu, S., Hatakeyama, S., Tobisawa, Y., Narita, S., ... and Yoneyama, T., 2022, Machine learning diagnosis by immunoglobulin N-glycan signatures for precision diagnosis of urological diseases, *Cancer Science*, 113(7), 2434-2445.
- İpekçi, T., Yüksel, M., and Tunçkiran, A., 2017, Top cited articles in urology from Turkey, *Turkish Journal of Urology*, 43(1), 62.
- Jalal, S. M., Hasan, M. R., Haque, M. A., and Alam, M. G. R., 2022, A horizontal federated random forest for heart disease detection from decentralized local data. In *2022 IEEE 10th Region 10 Humanitarian Technology Conference (R10-HTC)*, IEEE, pp. 191-196.
- Jatain, D., Singh, V., and Dahiya, N., 2022, A contemplative perspective on federated machine learning: Taxonomy, threats & vulnerability

- assessment and challenges, *Journal of King Saud University-Computer and Information Sciences*, 34(9), 6681-6698.
- Jiménez-Sánchez, A., Tardy, M., Ballester, M. A. G., Mateus, D., and Piella, G., 2023, Memory-aware curriculum federated learning for breast cancer classification, *Computer Methods and Programs in Biomedicine*, 229, 107318.
- Kairouz, P., McMahan, H. B., Avent, B., Bellet, A., Bennis, M., Bhagoji, A. N., ... and Zhao, S., 2021, Advances and open problems in federated learning, *Foundations and trends® in machine learning*, 14(1–2), 1-210.
- Karagöz, B., Ünsal, A., Arslantaş, D., Koç, S. D. G., and Tepetaş, M., 2024, 40-70 Yaş Grubu Erkekler Arasında Prostat Kanseri Bilgi Düzeyi ve Benlik Saygısı Düzeyinin Değerlendirilmesi, *Osmangazi Tıp Dergisi*, 46(6), 889-899.
- Kashima, T., Kishida, I., Amma, A., and Nakayama, H., 2024, FedFit: Server Aggregation through Linear Regression in Federated Learning, *IEEE Access*, 12, 22803-22812.
- Kaur, D., Misra, A., and Vyas, O. P., 2024, Learning Salient Features for Speech Emotion Recognition using Attention-based Residual Bidirectional LSTM with Federated Learning, In 2024 Fourth International Conference on Advances in Electrical, Computing, Communication and Sustainable Technologies (ICAECT), IEEE, pp. 1-7.
- Kavoussi, N. L., Floyd, C., Abraham, A., Sui, W., Bejan, C., Capra, J. A., and Hsi, R., 2022, Machine learning models to predict 24 hour urinary abnormalities for kidney stone disease, *Urology*, 169, 52-57.
- Kaya, M. S., and İnce, K., 2021, Nesnelerin İnternetinde Çok Katmanlı Algılayıcı Kullanarak Zamanlama Analizi Saldırısı ile Özel Anahtar Tahminlemesi, *Computer Science, (Special)*, 385-390.
- Kim, J. K., McCammon, K., Robey, C., Castillo, M., Gomez, O., Pua, P. J. L., ... and Chua, M. E., 2022, Identifying urethral strictures using machine learning: a proof-of-concept evaluation of convolutional neural network model, *World Journal of Urology*, 40(12), 3107-3111.
- Khan, A. A., Shaikh, Z. A., Baitenova, L., Mutaliyeva, L., Moiseev, N., Mikhaylov, A., ... and Alshazly, H., 2021, QoS-ledger: Smart contracts and metaheuristic for secure quality-of-service and cost-efficient scheduling of medical-data processing, *Electronics*, 10(24), 3083.

- Koh, H. J. W., Gašević, D., Rankin, D., Heritier, S., Frydenberg, M., and Talic, S., 2024, Variational Bayes machine learning for risk adjustment of general outcome indicators with examples in urology, *npj Digital Medicine*, 7(1), 249.
- Kong, F., Wang, X., Xiang, J., Yang, S., Wang, X., Yue, M., ... and Liu, Y, 2024, Federated attention consistent learning models for prostate cancer diagnosis and Gleason grading, *Computational and Structural Biotechnology Journal*, 23, 1439-1449.
- Kruskal, W. H., & Wallis, W. A., 1952, Use of ranks in one-criterion variance analysis, *Journal of the American statistical Association*, 47(260), 583-621.
- Kujur, A., Bharathi, S. V., and Pramod, D., 2023, Application of Horizontal Federated Learning for Critical Resource Allocation-Lessons from the COVID-19 Pandemic, In 2023 International Conference on Advancement in Computation & Computer Technologies (InCACCT), IEEE, pp. 101-106.
- Lakhan, A., Grønli, T. M., Muhammad, G., and Tiwari, P., 2023, EDCNNS: Federated learning enabled evolutionary deep convolutional neural network for Alzheimer disease detection, *Applied Soft Computing*, 147, 110804.
- Lee, D., and Yoon, S. N., 2021, Application of artificial intelligence-based technologies in the healthcare industry: Opportunities and challenges, *International journal of environmental research and public health*, 18(1), 271.
- Leyh-Bannurah, S. R., Tian, Z., Karakiewicz, P. I., Wolfgang, U., Sauter, G., Fisch, M., ... and Budäus, L., 2018, Deep learning for natural language processing in urology: state-of-the-art automated extraction of detailed pathologic prostate cancer data from narratively written electronic health records, *JCO clinical cancer informatics*, 2, 1-9.
- Li, L., Fan, Y., Tse, M., and Lin, K. Y., 2020, A review of applications in federated learning, *Computers & Industrial Engineering*, 149, 106854.
- Li, Q., He, B., and Song, D., 2021, Model-contrastive federated learning, In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, pp. 10713-10722.

- Li, T., Sahu, A. K., Zaheer, M., Sanjabi, M., Talwalkar, A., and Smith, V., 2020, Federated optimization in heterogeneous networks, *Proceedings of Machine learning and systems*, 2, 429-450.
- Li, Z., Xu, X., Cao, X., Liu, W., Zhang, Y., Chen, D., and Dai, H., 2022, Integrated CNN and federated learning for COVID-19 detection on chest X-ray images, *IEEE/ACM Transactions on Computational Biology and Bioinformatics*.
- Linardos, A., Kushibar, K., Walsh, S., Gkontra, P., and Lekadir, K., 2022, Federated learning for multi-center imaging diagnostics: a simulation study in cardiovascular disease, *Scientific Reports*, 12(1), 3551.
- Liu, C., Yang, W. Y., Cheng, F., Chien, C. W., Chuang, Y. C., and Jin, Y, 2024, Identification of key risk factors for venous thromboembolism in urological inpatients based on the Caprini scale and interpretable machine learning methods, *Thrombosis Journal*, 22(1), 76.
- Lo, J., Timothy, T. Y., Ma, D., Zang, P., Owen, J. P., Zhang, Q., ... and Sarunic, M. V., 2021, Federated learning for microvasculature segmentation and diabetic retinopathy classification of OCT data, *Ophthalmology Science*, 1(4), 100069.
- Lorpunmanee, S., Sap, M. N., Abdullah, A. H., and Chompoo-inwai, C., 2007, An ant colony optimization for dynamic job scheduling in grid environment, *International Journal of Computer and Information Science and Engineering*, 1(4), 207-214.
- Lundberg, S. M., and Lee, S. I., 2017, A unified approach to interpreting model predictions, *Advances in neural information processing systems*, 30.
- McMahan, B., Moore, E., Ramage, D., Hampson, S., and y Arcas, B. A., 2017, Communication-efficient learning of deep networks from decentralized data, In *Artificial intelligence and statistics*, PMLR, pp. 1273-1282.
- Mehta, S., Kukreja, V., and Yadav, R., 2023, Advanced mango leaf disease detection and severity analysis with federated learning and cnn, In *2023 3rd International Conference on Intelligent Technologies (CONIT)*, IEEE, pp. 1-6.
- Mohammed, M. A., Lakhan, A., Abdulkareem, K. H., Deveci, M., Dutta, A. K., Memon, S., ... and Martinek, R., 2024, Federated-Reinforcement Learning-Assisted IoT Consumers System for Kidney Disease Images, *IEEE Transactions on Consumer Electronics*.

- Nematzadeh, S., Kiani, F., Torkamanian-Afshar, M., and Aydin, N., 2022, Tuning hyperparameters of machine learning algorithms and deep neural networks using metaheuristics: A bioinformatics study on biomedical and biological cases, *Computational biology and chemistry*, 97, 107619.
- Nergiz, M., 2022, İşbirlikçi Yapay Zeka Konsepti: Federe Öğrenmeye Genel Bir Bakış, *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 13(2), 279-286.
- Nergiz, M., 2023, Federe Öğrenmede Birleştirme Algoritmalarının Model Performansına Etkisi, *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 14(1), 65-73.
- Nguyen, D. C., Pham, Q. V., Pathirana, P. N., Ding, M., Seneviratne, A., Lin, Z., ... and Hwang, W. J., 2022, Federated learning for smart healthcare: A survey, *ACM Computing Surveys (Csur)*, 55(3), 1-37.
- Nikolaenko, V., Weinsberg, U., Ioannidis, S., Joye, M., Boneh, D., and Taft, N., 2013, Privacy-preserving ridge regression on hundreds of millions of records, In *2013 IEEE symposium on security and privacy*, IEEE, pp. 334-348.
- Nilsson, A., Smith, S., Ulm, G., Gustavsson, E., and Jirstrand, M., 2018, A performance evaluation of federated learning algorithms, In *Proceedings of the second workshop on distributed infrastructures for deep learning*, pp. 1-8.
- Noman, A. A., Rahaman, M., Pranto, T. H., and Rahman, R. M., 2023, Blockchain for medical collaboration: A federated learning-based approach for multi-class respiratory disease classification, *Healthcare Analytics*, 3, 100135.
- Öztürk, R., and Murt, A., 2020, Epidemiology of urological infections: a global burden, *World journal of urology*, 38, 2669-2679.
- Panahi, O., 2025, The Future of Healthcare: AI. Public Health and the Digital Revolution, *Medi Clin Case Rep J*, 3(1), 763-766.
- Panicker, J. N., Fowler, C. J., & Kessler, T. M., 2015, Lower urinary tract dysfunction in the neurological patient: clinical assessment and management, *The Lancet Neurology*, 14(7), 720-732.
- Park, J., and Lim, H., 2022, Privacy-preserving federated learning using homomorphic encryption, *Applied Sciences*, 12(2), 734.

- Peng, L., Luo, G., Zhou, S., Chen, J., Xu, Z., Sun, J., and Zhang, R., 2024, An in-depth evaluation of federated learning on biomedical natural language processing for information extraction, *NPJ Digital Medicine*, 7(1), 127.
- Pessoa, R., and Kim, F. J., 2018, Urodynamics and voiding dysfunction, *Abernathy's surgical secrets*, 452-454.
- Pham, G., and Milazzo, P., 2025, A comprehensive review of the use of Shapley value to assess node importance in the analysis of biological networks, *Computer Methods and Programs in Biomedicine Update*, 100185.
- Polato, M., Esposito, R., and Aldinucci, M., 2022, Boosting the federation: Cross-silo federated learning without gradient descent, In 2022 International Joint Conference on Neural Networks (IJCNN), IEEE, pp. 1-10.
- Qi, P., Chiaro, D., Guzzo, A., Ianni, M., Fortino, G., and Piccialli, F., 2024, Model aggregation techniques in federated learning: A comprehensive survey, *Future Generation Computer Systems*, 150, 272-293.
- Rahman, M. M., Kundu, D., Suha, S. A., Siddiqi, U. R., and Dey, S. K., 2022, Hospital patients' length of stay prediction: A federated learning approach, *Journal of King Saud University-Computer and Information Sciences*, 34(10), 7874-7884.
- Rajagopal, A., Redekop, E., Kemisetti, A., Kulkarni, R., Raman, S., Sarma, K., ... and Larson, P. E., 2023 Federated learning with research prototypes: Application to multi-center MRI-based detection of prostate cancer with diverse histopathology, *Academic radiology*, 30(4), 644-657.
- Rayhan, A., Rayhan, R., and Rayhan, S., 2023, The role of AI in healthcare: revolutionizing patient care and well-being, DOI: 10.13140/RG. 2.2, 22601.
- Reyes-Amezcu, I., Rojas-Ruiz, M., Ochoa-Ruiz, G., Mendez-Vazquez, A., and Daul, C., 2024, Leveraging Pre-trained Models for Robust Federated Learning for Kidney Stone Type Recognition, In Mexican International Conference on Artificial Intelligence, Cham: Springer Nature Switzerland, pp. 168-181.
- Republic of Türkiye. International Monetary Fund, 2024, Erişim: 24 Aralık 2024, <https://www.imf.org/en/Countries/TUR>.

- Rivest, R. L., Adleman, L., and Dertouzos, M. L., 1978, On data banks and privacy homomorphisms, *Foundations of secure computation*, 4(11), 169-180.
- Rizzoli, A. E., Montemanni, R., Lucibello, E., and Gambardella, L. M., 2007, Ant colony optimization for real-world vehicle routing problems: from theory to applications, *Swarm Intelligence*, 1, 135-151.
- Roppelt, J. S., Kanbach, D. K., and Kraus, S., 2024, Artificial intelligence in healthcare institutions: A systematic literature review on influencing factors, *Technology in society*, 76, 102443.
- Rosenblatt, F., 1958, The perceptron: a probabilistic model for information storage and organization in the brain, *Psychological review*, 65(6), 386.
- Royston, J. P., 1982, An extension of Shapiro and Wilk's W test for normality to large samples, *Journal of the Royal Statistical Society: Series C (Applied Statistics)*, 31(2), 115-124.
- Rumelhart, D. E., Hinton, G. E., and Williams, R. J., 1986, Learning representations by back-propagating errors, *nature*, 323(6088), 533-536.
- Sakib, S. K., and Das, A. B., 2024, Explainable Vertical Federated Learning for Healthcare: Ensuring Privacy and Optimal Accuracy, In *2024 IEEE International Conference on Big Data (BigData)*, IEEE, pp. 5068-5077.
- Salma, S. U., Sakib, M. S., Yasaar, N., Alvee, M. M. M., Reza, M. T., and Parvez, M. Z., 2022, Privacy focused classification of prostate cancer using federated learning, In *International Conference on Information Technology and Applications*, Singapore: Springer Nature Singapore, pp. 265-281.
- Sannara, E. K., Portet, F., Lalanda, P., and German, V. E. G. A., 2021, A federated learning aggregation algorithm for pervasive computing: Evaluation and comparison, In *2021 IEEE International Conference on Pervasive Computing and Communications (PerCom)*, IEEE, pp. 1-10.
- Savazzi, S., Nicoli, M., and Rampa, V., 2020, Federated learning with cooperating devices: A consensus approach for massive IoT networks, *IEEE Internet of Things Journal*, 7(5), 4641-4654.
- Sekerci, C. A., Tanidir, Y., Tarcan, T., and Yucel, S., 2023, Consistency of uroflowmetry analysis in children among observers, *Neurourology and Urodynamics*, 42(3), 662-668.

- Shajimon, S., Shukla, R. M., and Patra, A. N., 2023, Precision at Heart: An IoT-based Vertical Federated Learning Approach for Heterogeneous Data-Driven Cardiovascular Disease Risk Prediction, Authorea Preprints.
- Shapiro, S., and Wilk, M. B. J. B., 1965, An analysis of variance test for normality, *Biometrika*, 52(3), 591-611.
- Shi, Y., Zhang, J., Xue, M., Zeng, Y., Jia, G., Yu, Q., and Li, M., 2025, Vertical federated learning based on data subset representation for healthcare application, *Computer Methods and Programs in Biomedicine*, 108623.
- Shrestha, R., Mohammadi, M., Sinaei, S., Salcines, A., Pampliega, D., Clemente, R., ... and Lindgren, A., 2024, Anomaly detection based on lstm and autoencoders using federated learning in smart electric grid, *Journal of Parallel and Distributed Computing*, 193, 104951.
- Simić, N., Suzić, S., Milošević, N., Stanojev, V., Nosek, T., Popović, B., and Bajović, D., 2024, Enhancing Emotion Recognition through Federated Learning: A Multimodal Approach with Convolutional Neural Networks, *Applied Sciences*, 14(4), 1325.
- Singh, D., and Singh, B., 2020 Investigating the impact of data normalization on classification performance, *Applied Soft Computing*, 97, 105524.
- Sinha, S., 2024, The Use of Uroflowmetry as a Diagnostic Test, *Current Urology Reports*, 25(5), 99-107.
- Sorel, M. R., Reitsma, H. J., Rosier, P. F., Bosch, R. J., and de Kort, L. M., 2017, Uroflowmetry in healthy women: A systematic review, *Neurourology and urodynamics*, 36(4), 953-959.
- Štrumbelj, E., and Kononenko, I., 2014, Explaining prediction models and individual predictions with feature contributions, *Knowledge and information systems*, 41, 647-665.
- Su, Y. W., Huang, Y. H., Cheng, W. M., and Fan, Y. H., 2025, Mp34-02 Using Uroflowmetry to Predict Female Bladder Outlet Obstruction by Machine Learning, *The Journal of Urology*, 213(5S), e1207.
- Suarez-Ibarrola, R., Hein, S., Reis, G., Gratzke, C., and Miernik, A., 2020, Current and future applications of machine and deep learning in urology: a review of the literature on urolithiasis, renal cell carcinoma, and bladder and prostate cancer, *World journal of urology*, 38(10), 2329-2347.

- Sun, F., and Rapp, D. E., 2023, Global Urology: A Review of Global Urologic Initiatives and Future Opportunities, *Current Surgery Reports*, 11(12), 315-321.
- Sun, L., Wu, J., Xu, Y., and Zhang, Y., 2023, A federated learning and blockchain framework for physiological signal classification based on continual learning, *Information Sciences*, 630, 586-598.
- Sun, W., Chen, Y., Yang, X., Cao, J., and Song, Y., 2021, FedIO: Bridge inner- and outer-hospital information for perioperative complications prognostic prediction via federated learning, In 2021 IEEE International Conference on Bioinformatics and Biomedicine (BIBM), IEEE, pp. 3215-3221.
- Tan, Y. G., Fang, A. H., Lim, J. K., Khalid, F., Chen, K., Ho, H. S., ... and Tay, K. J., 2022, Incorporating artificial intelligence in urology: Supervised machine learning algorithms demonstrate comparative advantage over nomograms in predicting biochemical recurrence after prostatectomy, *The Prostate*, 82(3), 298-305.
- Tan, Y. N., Tinh, V. P., Lam, P. D., Nam, N. H., and Khoa, T. A., 2023, A transfer learning approach to breast cancer classification in a federated learning framework, *IEEE Access*, 11, 27462-27476.
- Tang, F., Liang, S., Ling, G., and Shan, J., 2023, IHVFL: a privacy-enhanced intention-hiding vertical federated learning framework for medical data, *Cybersecurity*, 6(1), 37.
- T.C. Sağlık Bakanlığı., 2023, Sağlık İstatistikleri Yıllığı 2023, <https://dosyasb.saglik.gov.tr/Eklenti/50500/0/siy202307032025pdf.pdf>
- Tian, J., Yu, W., and Xie, S., 2008, An ant colony optimization algorithm for image edge detection, In 2008 IEEE congress on evolutionary computation (IEEE world congress on computational intelligence), IEEE, pp. 751-756.
- Toğaçar, M., 2022, Arşimet Optimizasyon Algoritması ile Trafo Tabanlı Evrişimsel Sinir Ağı Modelini Kullanarak Yazılım Tanımlı Ağ Teknolojisi Verilerinde Saldırı Tespiti, *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 34(1), 341-349.
- Topaloglu, S., and Ozkarahan, I., 2011, A constraint programming-based solution approach for medical resident scheduling problems, *Computers & Operations Research*, 38(1), 246-255.

- Topbaş, E., 2015, Kronik böbrek hastalığının önemi, evreleri ve evrelere özgü bakımı, *Nefroloji Hemşireliği Dergisi*, 10(1), 53-59.
- Umoren, I. J., Etuk, U. E., Ekong, A. P., and Udonyah, K. C., 2021, Healthcare logistics optimization framework for efficient supply chain management in Niger Delta Region of Nigeria, *International Journal of Advanced Computer Science and Applications*, 12(4), 593-604.
- Vahedi-Nouri, B., Tavakkoli-Moghaddam, R., Hanzálek, Z., and Dolgui, A., 2022, Workforce planning and production scheduling in a reconfigurable manufacturing system facing the COVID-19 pandemic, *Journal of Manufacturing Systems*, 63, 563-574.
- Vali, M., Salimifard, K., Gandomi, A. H., and Chaussalet, T. J., 2022, Application of job shop scheduling approach in green patient flow optimization using a hybrid swarm intelligence, *Computers & industrial engineering*, 172, 108603.
- Vasan, K. K., and Surendiran, B., 2016, Dimensionality reduction using principal component analysis for network intrusion detection, *Perspectives in Science*, 8, 510-512.
- Verit, A., Urkmez, A., and Tellaloglu, S., 2018, History of establishment and evaluation of Ottoman-Turkish urology inside the surgical science, *Northern Clinics of İstanbul*, 6(3), 317-319.
- Walfish, S., 2006, A review of statistical outlier methods, *Pharmaceutical technology*, 30(11), 82.
- Wang, Q., He, M., Guo, L., and Chai, H., 2023, AFEI: adaptive optimized vertical federated learning for heterogeneous multi-omics data integration, *Briefings in Bioinformatics*, 24(5), bbad269.
- Welvaars, K., van den Bekerom, M. P., Doornberg, J. N., van Haarst, E. P., and OLVG Urology Consortium van der Zee JA van Andel GA Lagerveld BW Hovius MC Kauer PC Boevé LMS., 2023, Evaluating machine learning algorithms to Predict 30-day Unplanned REadmission (PURE) in Urology patients, *BMC Medical Informatics and Decision Making*, 23(1), 108.
- Wood, A., Najarian, K., and Kahrobaei, D., 2020, Homomorphic encryption for machine learning in medicine and bioinformatics, *ACM Computing Surveys (CSUR)*, 53(4), 1-35.

- World Health Organization, 2024, World health statistics 2024: monitoring health for the SDGs, sustainable development goals, World Health Organization.
- Xiao, C., Ye, J., Esteves, R. M., & Rong, C., 2016, Using Spearman's correlation coefficients for exploratory data analysis on big dataset, *Concurrency and Computation: Practice and Experience*, 28(14), 3866-3878.
- Xu, J., Glicksberg, B. S., Su, C., Walker, P., Bian, J., and Wang, F., 2021, Federated learning for healthcare informatics, *Journal of healthcare informatics research*, 5, 1-19.
- Yağmur, İ., 2016, Normal idrar akım eğrisi, *Çocuk Cerrahisi Dergisi*, Kasım, 571-576.
- Yan, J. F., Gao, Y., and Yang, L., 2011, Ant colony optimization for wireless sensor networks routing, In 2011 International conference on machine learning and cybernetics, IEEE, Vol. 1, pp. 400-403.
- Yang, C., Chen, M., and Yuan, Q., 2021, The application of XGBoost and SHAP to examining the factors in freight truck-related crashes: An exploratory analysis, *Accident Analysis & Prevention*, 158, 106153.
- Yang, J., Huang, H., Yin, L., Qu, J., and Xie, W., 2024, Privacy-Preserving Federated Deep Learning Diagnostic Method for Multi-Stage Diseases, *CMES-Computer Modeling in Engineering & Sciences*, 139(3).
- Yang, J., Shi, X., Marchese, M., and Liang, Y., 2008, An ant colony optimization method for generalized TSP problem, *Progress in natural science*, 18(11), 1417-1422.
- Yang, Q., Fan, L., and Yu, H. (Eds.), 2020, *Federated learning: Privacy and incentive* (Vol. 12500), Springer Nature.
- Yang, Q., Liu, Y., Cheng, Y., Kang, Y., Chen, T., Yu, H., 2022, *Federated Learning*, İsviçre: Springer International Publishing.
- Yavuzsan, A. H., Türk, S., Bursalı, K., Baloğlu, İ. H., Hacıosmanoğlu, T., Türkmen, N., ... and Horasanlı, K., 2022, Sağlık Kuruluna Başvuran Hastalarda Tespit Edilen Ürolojik İşlevsel Kayıp Nedenleri, Sıklıkları ve Derecesi, *Mersin Üniversitesi Tıp Fakültesi Lokman Hekim Tıp Tarihi ve Folklorik Tıp Dergisi*, 12(1), 209-217.

- Ye, J., and Ji, S., 2010, Discriminant analysis for dimensionality reduction: An overview of recent developments, *Biometrics: Theory, Methods, and Applications*, Wiley-IEEE Press, New York.
- Zeng, T., Semiari, O., Chen, M., Saad, W., and Bennis, M., 2022, Federated learning on the road autonomous controller design for connected and autonomous vehicles, *IEEE Transactions on Wireless Communications*, 21(12), 10407-10423.
- Zhang, C., Meng, X., Liu, Q., Wu, S., Wang, L., and Ning, H., 2023, FedBrain: A robust multi-site brain network analysis framework based on federated learning for brain disease diagnosis, *Neurocomputing*, 559, 126791.
- Zhang, C., Xie, Y., Bai, H., Yu, B., Li, W., and Gao, Y., 2021, A survey on federated learning, *Knowledge-Based Systems*, 216, 106775.
- Zhang, G., Zhu, S., and Bai, X., 2022, Federated learning-based multi-energy load forecasting method using CNN-Attention-LSTM model, *Sustainability*, 14(19), 12843.
- Zhang, R., Li, H., Hao, M., Chen, H., & Zhang, Y., 2022, Secure feature selection for vertical federated learning in ehealth systems, In *ICC 2022-IEEE International Conference on Communications*, IEEE, pp. 1257-1262.
- Zhang, S., Huang, J., Zhang, Z., Li, P., and Qi, C., 2023, Compromise privacy in large-batch Federated Learning via model poisoning, *Information Sciences*, 647, 119421.
- Zhang, W., Zhou, T., Lu, Q., Wang, X., Zhu, C., Sun, H., ... and Wang, F. Y., 2021, Dynamic-fusion-based federated learning for COVID-19 detection, *IEEE Internet of Things Journal*, 8(21), 15884-15891.
- Zhang, X., Chen, W., Wang, B., and Chen, X., 2015, Intelligent fault diagnosis of rotating machinery using support vector machine with ant colony algorithm for synchronous feature selection and parameter optimization, *Neurocomputing*, 167, 260-279.
- Zhao, L., Ni, L., Hu, S., Chen, Y., Zhou, P., Xiao, F., and Wu, L., 2018, Inprivate digging: Enabling tree-based distributed data mining with differential privacy, In *IEEE INFOCOM 2018-IEEE Conference on Computer Communications*, IEEE, pp. 2087-2095.


- Zhou, Y., Ye, Q., and Lv, J., 2021, Communication-efficient federated learning with compensated overlap-fedavg, IEEE Transactions on Parallel and Distributed Systems, 33(1), 192-205.
- Zi, H., Liu, M. Y., Luo, L. S., Huang, Q., Luo, P. C., Luan, H. H., ... and Zeng, X. T., 2024, Global burden of benign prostatic hyperplasia, urinary tract infections, urolithiasis, bladder cancer, kidney cancer, and prostate cancer from 1990 to 2021, Military Medical Research, 11(1), 64.

EKLER

Bibliyometrik analiz kısmında kullanılan programın dilinin İngilizce olmasından dolayı analiz bulguları çalışmada İngilizce olarak ele alınmış olup Türkçe anlamları EK 1’de verilmiştir.

EK 1. İngilizce kelimelerin Türkçe karşılığı

Architecture: Mimari	Disease diagnosis: Hastalık teşhisi
Attention: Dikkat	Disease prediction: Hastalık tahmini
Blockchain: Blokzincir	Distributed machine learning: Dağıtılmış makine öğrenmesi
Blockchain technology: Blokzincir teknolojisi	Durg: İlaç
Cancer: Kanser	Edge: Uç
Cancer classification: Kanser sınıflandırma	Electrocardiography: Elektrokardiyografi
Cancer diagnosis: Kanser teşhisi	Electronic health records: elektronik sağlık kayıtları
Challenges: Zorluklar	Ensemble learning: Topluluk öğrenmesi
Classification: Sınıflandırma	Fault diagnosis: Arıza teşhisi
Clinical: Klinik	Federated learning framework: Federe öğrenme çerçevesi
Cloud: Bulut	Federated semi-supervised: Federe yarı denetimli
Contrastive learning: Karşıtlıklı öğrenme	Framework: Çerçeve
Convolutional neural network: Evrişimsel Sinir Ağları	Health data: Sağlık verisi
Covid 19 detection: Covid-19 teşhisi	Health: Sağlık
Data models: Veri modelleri	Healthcare: Sağlık hizmetleri
Deep learning: Derin öğrenme	Hospital: Hastane
Design: Tasarım	Identically distributed: Özdeş olarak dağıtılmış
Diabetic retinopathy: Diyabetik retinopati	Internet: İnternet
Diagnosis: Teşhis	Learning approach: Öğrenme yaklaşımı
Learning framework: Öğrenme çerçevesi	Patient care: Hasta bakımı
Lung cancer: Akciğer kanseri	Preserving data privacy: Veri gizliliğinin komması
Machine learning models: makine öğrenme modelleri	Privacy: Gizlilik
Medical: Tıbbi	Regression: Regresyon
Medical data: Tıbbi veri	Reinforcement learning: Pekiştirmeli öğrenme
Medical image: Tıbbi görüntü	Resource-allocation: Kaynak tahsisi
Medical image analysis: Tıbbi görüntü analizi	Scalable federated: Ölçeklenebilir federe
Medical services: Tıbbi hizmetler	Secure: Güvenli
Medicine: Tıp	Segmentation: Bölümlendirme
Model: Model	Smart city: Akıllı şehir
Networks: Ağlar	Vertical federated learning: Dikey federe öğrenme
Neural-network: Sinir ağı	Wearable sensors: Giyilebilir sensörler
Optimization: Optimizasyon	



ISBN: 978-625-378-408-9