

JSR B

E-ISSN 2117- 8625

Number 6

December 2022

JOURNAL OF SCIENTIFIC REPORTS B



Kutahya Dumlupınar University Scientific Reports B
Evliya Celebi Campus Tavşanlı Road 10 KM. 43270 Kutahya

Phone : (0274) 443 19 42

E-mail : joursrb@gmail.com

gjsr.b.com

Dumlupınar University Press

gate of
science



Sahibi

Kütahya Dumlupınar Üniversitesi adına
Prof. Dr. Kazım UYSAL (Rektör)
Lisansüstü Eğitim Enstitüsü adına
Doç. Dr. Arif KOLAY (Enstitü Müdürü)

Owner

On Behalf of Kütahya Dumlupınar University
Prof. Dr. Kazım UYSAL (Rector),
On Behalf of Institute of Graduate Studies
Assoc. Prof. Dr. Arif KOLAY(Director)

Yayın Kurulu / Editorial Board

Prof. Dr. Önder UYSAL	Kütahya Dumlupınar Üniversitesi / Maden Mühendisliği
Prof. Dr. Cengiz YENİKAYA	Kütahya Dumlupınar Üniversitesi / Kimya
Prof. Dr. Cengiz KARAGÜZEL	Kütahya Dumlupınar Üniversitesi / Maden Mühendisliği
Prof. Dr. Gürsel YANIK	Kütahya Dumlupınar Üniversitesi / Jeoloji Mühendisliği
Doç. Dr. Cemal PARLAK	Ege Üniversitesi / Fizik
Doç. Dr. Nevzat BEYAZIT	Ondokuz Mayıs Üniversitesi / Çevre Mühendisliği
Doç. Dr. Levent URTEKİN	Ahi Evran Üniversitesi / Makine Mühendisliği
Prof. Dr. Fatih ŞEN	Kütahya Dumlupınar Üniversitesi / Biyokimya
Dr. Öğr. Üyesi Ümran ERÇETİN	Kütahya Dumlupınar Üniversitesi / Makine Mühendisliği
Dr. Öğr. Üyesi Durmuş ÖZDEMİR	Kütahya Dumlupınar Üniversitesi / Bilgisayar Müh.

Journal of Scientific Reports-B dergisi, yayın hayatına 2000 yılında başlayan Dumlupınar Üniversitesi Fen Bilimleri Enstitüsü Dergisinden ayrılmış olup, Haziran ve Aralık aylarında olmak üzere yılda düzenli olarak 2 kez yayımlanan ulusal hakemli bir dergidir. Derginin yazım dili Türkçe ve İngilizce'dir. Dergiye gönderilen makaleler, editör kurulu tarafından seçilen ve konusunda uzman en az iki hakem tarafından değerlendirilmektedir. Dergiye sunulan bütün makaleler çift-körleme yöntemiyle değerlendirilmektedir. Değerlendirilmek üzere dergimize gönderilen makalelerin, daha önce yayınlanmamış, yayınlanmak üzere kabul edilmemiş ve yayınlanmak için başka bir dergide değerlendirilme sürecinde olmaması gerekmektedir. Dergide yayımlanan yazıların her türlü sorumluluğu yazar(lar)ına aittir.

Dergi, fen ve mühendislik bilimlerinde ulusal ve uluslararası düzeyde yapılan bilimsel çalışmalarını bilim insanları ve kamuoyu ile paylaşmayı amaçlar. Dergiye, fen ve mühendislik bilim dallarında yapılan, özgün araştırma makaleleri, derleme makaleleri ve kısa notlar kabul edilir. Özgün araştırma makalelerinin başka dergilerde yayınlanmamış olması, teorik ve deneysel sonuçlar içermesi beklenir. Derleme makalelerinde ise belirli bir konu üzerinde bilimsel, teknolojik ve güncel gelişmelerin geniş bir kaynakça kullanılarak yansıtılması ve bunların doyurucu bir değerlendirilmesinin yapılması aranır. Kısa notlar, özgün bir çalışmanın ilk bulgularının duyurulması amacıyla yönelik hazırlanan kısa yazılar olmalıdır.

İçerik Politikası

Dergimiz açık erişim dergisi olup, makale değerlendirme süresi 1-2 aydır

Yazışma Adresi: Kütahya Dumlupınar Üniversitesi Evliya Çelebi Yerleşkesi Lisansüstü Eğitim Enstitüsü 43270 KÜTAHYA

Telefon: 0 274 443 19 42

Faks: 0 274 265 20 60

E-posta: joursrb@gmail.com

Web Sayfası: gsjsrb.com

Journal of Scientific Reports-B was separated from Journal of Science and Technology of Dumlupınar University which started its publication life in 2000 and is a national peer-reviewed journal published regularly twice a year in June and December. The language of the journal is Turkish and English. Articles submitted to the journal are evaluated by at least two referees who are experts in the subject and selected by the editorial board. All articles submitted to the journal are evaluated by the double-blind method. Articles submitted to our journal for review should not be previously published, accepted for publication and in the process of being evaluated for publication in another journal. All responsibility for the articles published in the journal belongs to the author(s).

The journal aims to share scientific studies carried out in the fields of science and engineering at national and international level with scientists and the public. Original research articles, review articles and short notes in science and engineering disciplines are accepted for the journal. Original research articles are expected to contain theoretical and experimental results and should not be published in other journals. In the review articles, it is expected that scientific, technological and current developments on a specific subject are reflected by using an extensive bibliography and made a satisfying evaluation of these. Short notes should be brief writings prepared to announce the first findings of an original study.

Editorial Policy

The journal is open access and the article evaluation period is between 1-2 months.

Correspondence Address: Kütahya Dumlupınar University Evliya Çelebi Campus Graduate School of Education 43270 KÜTAHYA

Phone: 0 274 443 19 29 - 30

Fax: 0 274 265 20 60

E-mail: joursrb@gmail.com

Webpage: gsjsrb.com

Bölüm Editörleri / Section Editors

İnşaat Mühendisliği / Civil Engineering Prof. Dr. M. Çağatay KARABÖRK	Kütahya Dumlupınar Üniversitesi
Makine Mühendisliği / Mechanical Engineering Prof. Dr. Ramazan KÖSE	Kütahya Dumlupınar Üniversitesi
Elektrik-Elektronik Mühendisliği / Electrical-Electronics Engineering Dr. Öğr. Üyesi Kadir VARDAR	Kütahya Dumlupınar Üniversitesi
Bilgisayar Mühendisliği / Computer Engineering Doç. Dr. Doğan AYDIN	Kütahya Dumlupınar Üniversitesi
Endüstri Mühendisliği / Industrial Engineering Dr. Öğr. Üyesi Kerem CİDDİ	Kütahya Dumlupınar Üniversitesi
Maden Mühendisliği / Mining Engineering Dr. Öğr. Üyesi Uğur DEMİR	Kütahya Dumlupınar Üniversitesi
Jeoloji Mühendisliği / Geology Engineering Dr. Öğr. Üyesi Muzaffer ÖZBURAN	Kütahya Dumlupınar Üniversitesi
Metalurji ve Malzeme Mühendisliği / Metallurgical and Materials Engineering Prof. Dr. İskender IŞIK	Kütahya Dumlupınar Üniversitesi
Gıda Mühendisliği / Food Engineering Prof. Dr. Muhammet DÖNMEZ	Kütahya Dumlupınar Üniversitesi
Çevre Mühendisliği / Environmental Engineering Doç. Dr. Nevzat BEYAZIT	Ondokuz Mayıs Üniversitesi
Matematik / Mathematics Dr. Öğr. Üyesi Cansu KESKİN	Kütahya Dumlupınar Üniversitesi
Fizik / Physics Doç. Dr. Huriye Sanem AYDOĞU	Kütahya Dumlupınar Üniversitesi
Kimya / Chemistry Doç. Dr. Bülent ZEYBEK	Kütahya Dumlupınar Üniversitesi
Biyoloji / Biology Dr. Öğr. Üyesi Nüket Akalın BİNGÖL	Kütahya Dumlupınar Üniversitesi
Biyokimya / Biochemistry Doç. Dr. Derya KOYUNCU ZEYBEK	Kütahya Dumlupınar Üniversitesi
İş Sağlığı ve Güvenliği / Occupational Health and Safety Prof. Dr. Cem ŞENSÖĞÜT	Kütahya Dumlupınar Üniversitesi

Danışma Kurulu / Advisory Board

Prof. Dr. Sibel AKAR	Eskişehir Osmangazi Üniversitesi / Kimya
Prof. Dr. Abdurrahman AKTÜMSEK	Selçuk Üniversitesi / Biyoloji
Prof. Dr. Mustafa ALTUNOK	Gazi Üniversitesi / Ağaç İşleri Endüstri Mühendisliği
Prof. Dr. Uğur ARİFOĞLU	Sakarya Üniversitesi / Elektrik-Elekt. Mühendisliği
Prof. Dr. Oktay ARSLAN	Balıkesir Üniversitesi / Kimya
Prof. Dr. Şükrü ASLAN	Sivas Cumhuriyet Üniversitesi / Çevre Mühendisliği
Prof. Dr. Ülfet ATAV	Selçuk Üniversitesi / Fizik
Prof. Dr. Mustafa BAYRAKTAR	TOBB Ekonomi ve Teknoloji Üniversitesi / Matematik
Prof. Dr. Niyazi BİLİM	Konya Teknik Üniversitesi / Maden Mühendisliği
Prof. Dr. İsmail BOZTOSUN	Akdeniz Üniversitesi / Fizik
Prof. Dr. Erdal ÇELİK	Dokuz Eylül Üniversitesi / Metalurji Malzeme Müh.
Prof. Dr. Hayri DAYIOĞLU	Kütahya Dumlupınar Üniversitesi / Biyoloji
Prof. Dr. Muhammet DÖNMEZ	Kütahya Dumlupınar Üniversitesi / Gıda Mühendisliği
Prof. Dr. Mehmet Ali EBEOĞLU	Kütahya Dumlupınar Üniversitesi / Elektrik-Elekt. Müh.
Prof. Dr. İsmail Göktaş EDİZ	Kütahya Dumlupınar Üniversitesi / Maden Mühendisliği
Prof. Dr. İsmail EKİNCİOĞLU	Kütahya Dumlupınar Üniversitesi / Matematik
Prof. Dr. Kaan ERARSLAN	Kütahya Dumlupınar Üniversitesi / Maden Mühendisliği
Prof. Dr. Zeynal Abiddin ERGÜLER	Kütahya Dumlupınar Üniversitesi / Jeoloji Mühendisliği
Prof. Dr. Seyhan FIRAT	Gazi Üniversitesi / İnşaat Mühendisliği
Prof. Dr. Remzi GÖREN	Sakarya Üniversitesi / Met. Malzeme Müh.
Prof. Dr. Rasim İPEK	Ege Üniversitesi / Makine Mühendisliği
Prof. Dr. Refail KASIMBEYLİ	Eskişehir Teknik Üniversitesi / Endüstri Mühendisliği
Prof. Dr. Hamdi Şükür KILIÇ	Selçuk Üniversitesi / Fizik
Prof. Dr. Yaşar KİBİCİ	Bilecik Şeyh Edebali Üniversitesi / Jeoloji Mühendisliği
Prof. Dr. İsmail KOCAÇALIŞKAN	Yıldız Teknik Üniversitesi / Moleküler Biy. ve Genetik
Prof. Dr. Mahmut KOÇAK	Eskişehir Osmangazi Üniversitesi / Mat.-Bilgisayar
Prof. Dr. Muhsin KONUK	Üsküdar Üniversitesi / Moleküler Biy. ve Genetik
Prof. Dr. Mustafa KURU	Başkent Üniversitesi / Moleküler Biy. ve Genetik
Prof. Dr. Ömer İrfan KÜFREVİOĞLU	Atatürk Üniversitesi / Biyokimya
Prof. Dr. Halim MUTLU	Ankara Üniversitesi / Jeoloji Mühendisliği
Prof. Dr. Ekrem SAVAŞ	İstanbul Ticaret Üniversitesi / Matematik
Prof. Dr. Murat TANIŞLI	Eskişehir Teknik Üniversitesi / Fizik
Prof. Dr. Ali Rehber TÜRKER	Gazi Üniversitesi / Kimya
Prof. Dr. Mustafa TÜRKMEN	Giresun Üniversitesi / Biyoloji
Prof. Dr. Abdülmecit TÜRÜT	İstanbul Medeniyet Üniversitesi / Fizik Mühendisliği
Prof. Dr. Eşref ÜNLÜOĞLU	Eskişehir Osmangazi Üniversitesi / İnşaat Mühendisliği
Prof. Dr. Nurettin YAYLI	Karadeniz Teknik Üniversitesi / Eczacılık
Prof. Dr. Yusuf YAYLI	Ankara Üniversitesi / Matematik
Prof. Dr. Elçin YUSUFOĞLU	Uşak Üniversitesi / Matematik
Prof. Dr. Hüseyin Serdar YÜCESU	Gazi Üniversitesi / Otomotiv Mühendisliği
Prof. Dr. Mehmet Tevfik ZEYREK	Orta Doğu Teknik Üniversitesi / Fizik

JOURNAL OF SCIENTIFIC REPORTS-B

İÇİNDEKİLER / CONTENTS

ARAŞTIRMA MAKALELERİ / RESEARCH ARTICLES

- Beyin Mr Görüntülerinden Mrmr Tabanlı Beyin Tümörlerinin Sınıflandırması*** 1-9
Classification of Mrmr-Based Brain Tumors from Brain Mr Images
Burak TAŞÇI*
- Böbrek Tümörü Tespiti için Derin Öğrenme Yöntemlerinin Karşılaştırmalı Analizi*** 10-23
Comparative Analysis of Deep Learning Methods for Renal Tumor Detection
Caner KARADAĞ*, Durmuş ÖZDEMİR
- Ökseotu(Viscum Album L.) Bitkisinden Aktif Kömür Eldesi, Karakterizasyonu ve Sulu Çözeltiden Kurşun Gideriminde Kullanılabilirliğinin İncelenmesi*** 24-35
Production of Activated Carbon from Mistletoe(Viscum Album L.), Characterization and Investigation of Its Usage for Lead Removal from Aqueous Solution
Saliha ERENTÜRK*, Bircan KÖSE, Köksal ERENTÜRK



BEYİN MR GÖRÜNTÜLERİNDEN mRMR TABANLI BEYİN TÜMÖRLERİNİN SINIFLANDIRMASI

Burak TAŞCI^{1*}

^{1*}Fırat Üniversitesi Teknik Bilimler MYO. Elektrik ve Enerji. Böl., Hibrid ve Elektrikli Taşıtlar Teknolojisi Programı, Elazığ, btasci@firat.edu.tr, ORCID: 0000-0002-4490-0946

Geliş Tarihi(Received Date):29.07.2022

Kabul Tarihi(Accepted Date):19.09.2022

ÖZ

Beyin tümörleri nedeniyle ölen kişilerin sayısı gün geçtikçe artmaktadır. Beyin tümörünün tedavi planlamasında ve tedavi sonucunun değerlendirilmesinde erken teşhis çok önemlidir. Beyin tümörü olan bir hastanın, hastalığının erken teşhis edilmesi sayesinde doğru tedavi yöntemleri uygulanarak hayatta kalma ihtimali artabilir. Manyetik rezonans (MR) görüntüleme beyin tümörlerinin tanı ve teşhisinde önemli bir role sahiptir. Bununla birlikte, MR görüntüleri kullanarak beyin tümörlerini sınıflandırması beyin yapısının karmaşıklığı ve içindeki dokuların iç içe geçmesi nedeniyle zordur. Bu çalışma, DenseNet201 ön eğitilmiş modelinin avg_pool ve fc1000 katmanlarından elde edilen 2920 özneteliğin 500 adeti mRMR algoritması kullanılarak seçilmiştir. Öznetelik seçimi yapılmadan %95.00 doğruluk, mRMR öznetelik seçimi yapılarak %95.76 doğruluk elde edilmiştir.

Anahtar kelimeler: *MR görüntüleri , sınıflandırma , beyin tümörü,DVM, K-EYK, mRMR*

CLASSIFICATION OF mRMR-BASED BRAIN TUMORS from BRAIN MR IMAGES

ABSTRACT

The number of persons who pass away from brain tumors continues to rise on a daily basis. The planning of treatment and the assessment of the treatment's effectiveness are both significantly aided by an early detection of a brain tumor. A person with a brain tumor may have a better chance of living if the disease is found and treated early and in the right way. Imaging with magnetic resonance, sometimes known as MR imaging, plays an essential part in the detection and diagnosis of brain cancers. However, due to the intricate nature of the brain's structure and the interconnectedness of its tissues, classification of brain tumors using MR imaging can be a challenging endeavor. In this study, 500 of 2920 features obtained from avg_pool and fc1000 layers of DenseNet201 pre-trained model were selected using mRMR algorithm. 95.00% accuracy was obtained without feature selection, and 95.76% accuracy was obtained by mRMR feature selection.

Keywords: *MR images, classification, brain tumor, SVM, kNN, mRMR*

1. GİRİŞ

Beyin insan vücudunda karmaşık bir organdır. Beyindeki anormal hücrelerin büyümesi beyin tümörü olarak bilinir ve çeşitli tiplerde ortaya çıkabilir. Tümör, beyin herhangi bir yerinde herhangi bir boyutta ortaya çıkabilir. Beyindeki anormal hücrelerin büyümesi, kafatası içinde yüksek basınca neden olur ve vücudumuzda birçok tehlikeli sağlık sorunu yaratır. İyi huylu tümörler kanserli olmayan tümörlerdir. Ancak bazı tümörler kötü huylu (malign) olabilir ve teşhis edilmesi zordur ve hayatta kalma şansı en azdır. Malign beyin tümörü insanlarda ölümün başlıca nedenlerinden biridir ve her yaşta insanı etkileyen en yaygın onuncu tümör türüdür. Ancak erken teşhis edilirse en tedavi edilebilir tümör türlerinden biridir. Beyin tümörünün tedavi maliyeti çoğu hasta tarafından karşılanamamaktadır. Beyin tümörünün tedavisi tümörün boyutuna, tümörün tipine ve tümörün büyüme evresine göre yapılır. MR görüntüleri kullanılarak ilişkili rahatsızlıklar otomatik tanımlanabilmekte ve yapay zeka yöntemleri kullanılarak sınıflandırılabilir. Medikal görüntülerde ve sinyallerde derin öğrenme yöntemleri kullanılarak hastalık teşhisinde doktorlara destek olunması mümkündür[1, 2]. Literatürde MR görüntülerinin kullanıldığı beyin tümör sınıflandırması ile ilgili bazı çalışmalar aşağıda sunulmuştur.

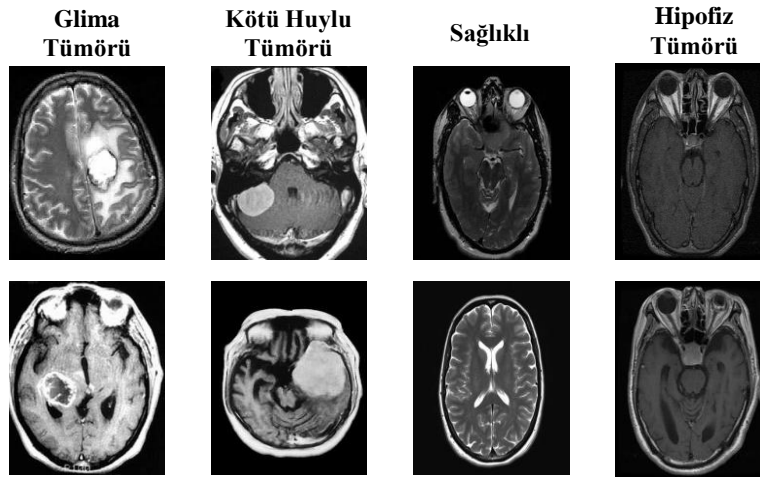
Lakshmi ve arkadaşları [3], Inception-v3 evrişim sinir ağını kullanarak eğitim verilerinde %99.34 ve doğrulama verilerinde %89.00 doğruluk elde etmişlerdi. Veeramuthu ve arkadaşları [4], birleşik özellik ve görüntü tabanlı sınıflandırıcı kullanmışlardı. Çalışmada sırasıyla %98.86, %97.14 ve %98.97 duyarlılık, özgüllük ve doğruluk değerlerini elde etmişlerdi. Li ve arkadaşları [5], Brats 2018 veri setini kullanarak beyin tümör sınıflandırma çalışması yapmışlardı. Çalışmada bilgi füzyonu ve ESA modeli kullanarak %99.81 hassasiyet ve %92.7 kesinlik elde etmişlerdi. Singh [6], Fuzzy-C-Means ve DVM temelli hibrit bir yöntem geliştirilmiştir. Önışlem aşamasında çift eşikleme ve morfolojik işlemlerle kafatası çıkarımı yapılmıştır. Özellik çıkarımı için gri seviyeli çalışma uzunluk matrisi kullanılmış ve özellikler DVM sınıflandırıcısını kullanarak sırasıyla duyarlılık, özgüllük ve doğruluk için %83.33, %100 ve %91.66 elde etmişlerdi. Parveen ve Agrawal [7]'te, Brats2013 veri setini kullanmışlardı. MR görüntülerinde beyin tümör tespiti için önışlemler uygulanmıştı. Sınıflayıcı aşamasında en küçük kareler destek vektör makinesi sınıflandırıcısını kullanarak sırasıyla özgüllük ve doğruluk için %81.33, ve %96.63 elde etmişlerdi. Thirumurugan ve arkadaşları [8]'da, Brats 2012-2013-2014 veri setlerindeki MR görüntülerinde Glioblastoma tümörü tespiti üzerine bir yöntem önerilmişti. Yaptıkları deneysel çalışmalarda sırasıyla duyarlılık, özgüllük ve doğruluk için %95.7, %97.8 ve %98.6 elde etmişlerdi. Chen ve Konukoglu [9]'de, HCP ve BrasTs2015 veri setlerindeki sağlıklı beyin MR görüntülerinin veri dağılımını öğrenmek için çekışmeli kullanmışlardı. Denetimsiz öğrenme ile uygulanan yöntem sayesinde %92.0 AUC değerini elde etmişlerdi. Chen ve arkadaşları [10]'de, Brats 2015 ve atlas datasetlerini kullanarak deęişimsel otokodlayıcıların ve çekışmeli otokodlayıcıların tıbbi görüntüleme anomalisi tespit etmeye çalışmışlardı. Yaptıkları çalışmada %70 doğruluk elde etmişlerdi.

2. MATERYAL VE YÖNTEM

2.1. Veri Seti

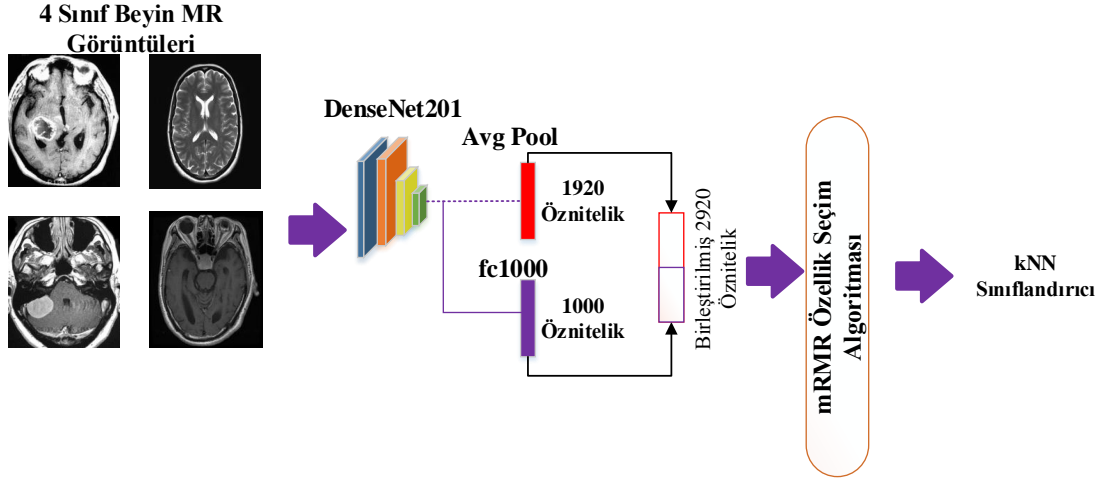
Bu çalışmada kaggle sitesinde yer alan 4 sınıflı 3443 görüntüden oluşan veri seti kullanılmıştır [11]. Veri seti, 978 adet glioma tümörü, 990 adet kötü huylu tümör, 538 adet sağlıklı ve 937 adet hipofiz tümörü görüntülerinden oluşmaktadır. Veri setindeki her örnek farklı boyutlardaki görüntülerden oluşmaktadır. Veri setindeki görüntüleri DenseNet201'in girişinde kullanabilmek için tüm

görüntülerin genişliği ve yüksekliği 224x224 olarak değiştirilmiştir. Veri setindeki dört sınıfa ait görüntü örnekleri şekil 1’de verilmiştir.



Şekil 1. Veri setindeki sınıflardan örnekler.

Bu çalışmada ön eğitilmiş modellerden özellik çıkarılarak beyin tümör çalışması yapılmıştır. Ön eğitilmiş modelin ve sınıflandırıcıyı seçmek için tablo 1’de verildiği gibi 19 ön eğitilmiş modelin DVM ve K-en Yakın Komşuluk (K-EYK) sonuçları incelenmiştir. Tablo 1’de görüldüğü gibi DenseNet201 ön eğitilmiş modelden elde edilen özneteliklerin K-EYK sınıflandırıcı ile sınıflandırılması ile en iyi sınıflandırma sonucu elde edilmiştir. Önerilen yöntemin temsili gösterimi Şekil 2’de verilmiştir. Önerilen yöntemin ilk aşamasında MR görüntülerinden öznetelik çıkarmak için DenseNet201 modeli kullanılmıştır. DenseNet201’in “avg_pool” katmanından 1920 adet öznetelik, “fc1000” katmanından 1000 adet öznetelik alınarak birleştirilmiştir. Toplamda 2920 adet öznetelik elde edilmiştir. Birleştirilen özneteliklerden 500 tanesi mRMR öznetelik seçim algoritması yardımıyla seçilmiştir. Elde edilen 500 öznetelik K-EYK algoritmasında sınıflandırılmıştır.



Şekil 1. Önerilen yöntemin blok diyagramı.

3. DENEYSEL ÇALIŞMA

Bu bölümde, sunulan modeli uygulamak için kullanılan ortam sunulmuştur. Önerilen metodun karşılaştırmasının yapılması için 19 ön eğitilmiş modelden özellik çıkarılmıştır. Çıkarılan özellikler DVM ve K-EYK sınıflandırıcı ile tablo 1'deki gibi sınıflandırılmıştır.

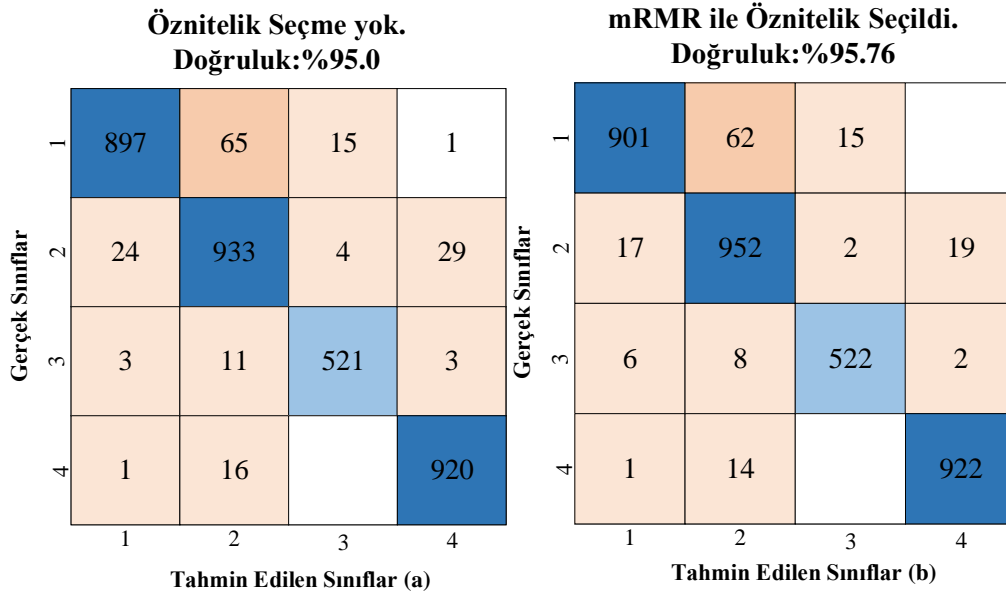
Tablo 1. 19 Ön-eğitilmiş modelin sınıflandırma sonuçları.

Ön Eğitilmiş Model	DVM(%)	K-EYK(%)
GoogleNet [12]	89.6	88.0
DarkNet53 [13]	91.0	89.6
Inceptionv3 [14]	89.9	89.0
NasnetLarge [15]	89.7	87.9
NasnetMobile [15]	88.6	85.0
VGG19 [16]	88.5	88.8
VGG16 [16]	89.5	88.2
Resnet101 [17]	91.3	91.5
Inceptionresnetv2 [18]	91.0	88.3
AlexNet [19]	92.6	90.6
ShuffleNet [20]	92.1	90.9
Resnet50 [17]	92.2	90.5
Xception [21]	91.2	90.4
Resnet18 [17]	90.9	90.2
Darknet19 [13]	90.5	89.9

MobileVnet2 [22]	91.4	92.2
DenseNet201 [23]	92.8	93.7
SqueezeNet [24]	91.9	90.2
Efficient b0 [25]	93.1	93.6

En yüksek doğruluğu DenseNet201 10 kat çapraz doğrulama ile K-EYK seçilmiştir. MATLAB2021b sınıflandırma aracı kullanılarak sınıflandırıcılar test edilmiştir. K-EYK en iyi sonucu verdiği için seçilmiştir. Modellerimizi uygulamak için 1512 GB sabit disk, Windows 10.1 pro OS, 64 GB belleğe ve intel i9 9900 işlemciye sahip bir bilgisayar kullanılmıştır.

DenseNet201'in "avg_pool" katmanından 1920 adet öznitelik, "fc1000" katmanından 1000 adet öznitelik alınarak birleştirilmiştir. Toplamda 2920 adet öznitelik elde edilmiştir. mRMR öznitelik seçim algoritması yardımıyla 500 öznitelik seçilmiştir. Elde edilen 500 öznitelik K-EYK algoritmasında sınıflandırılmıştır. Öznitelik seçimi yapılmadan %95.00 doğruluk elde edilmiştir. mRMR ile 500 öznitelik seçilerek %95.76 doğruluk elde edilmiştir. Bu her iki durum için K-EYK sınıflandırıcısının karmaşıklık matrisi sonuçları Şekil 3'te verilmiştir. Şekil 3(a)'da öznitelik seçimi yapılmamıştır ve Şekil 3(b)'de öznitelik seçimi yapılmıştır.



Şekil 2. K-EYK sınıflandırıcısı karmaşıklık matrisleri.

Şekil 3'de verilen karmaşıklık matrisi sonuçları kullanılarak duyarlılık, özgüllük, kesinlik, ve F-skor metrik sonuçları Tablo 2'de verilmiştir. Öznitelik seçimi yapılmadan %95.00 doğruluk elde edilmiştir. mRMR ile 500 öznitelik seçilerek %95.76 doğruluk elde edilmiştir.

Tablo 2. K-EYK sınıflandırıcısının duyarlılık, özgüllük, kesinlik, F1-skor metrikleri.

	Doğruluk	Duyarlılık(%)	Özgüllük(%)	Kesinlik(%)	F1-Skor(%)
Öznitelik Seçimi	%95.0	91,72	98,86	96,97	94,27
		94,24	96,25	91,02	92,61
		96,84	99,35	96,48	96,66
		98,19	98,68	96,54	97,35
mRMR Öznitelik Seçimi	%95.76	92,13	99,03	97,41	94,69
		96,16	96,58	91,89	93,98
		97,03	99,41	96,85	96,94
		98,40	99,16	97,77	98,09

Ayrıca, Tablo 3’de beyin tümör sınıflandırması ile ilgili yapılan çalışmalar verilmiştir.

Tablo 3. Bazı yöntemlerin performans karşılaştırmaları.

Referans	Dataset	Yöntem	Doğruluk(%)
Ghassemi vd.[26]	Figshare	ESA-ÇÜA	88.00
Çıtak vd.[27]	Klinik	DVM,ÇKA,LR	93.00
Shahzadi vd.[28]	Brats 2015	VGG,UKSB	84.00
Önerilen Yöntem	Kaggle	DenseNet201, mRMR	95.76

Ghassemi vd. [26] meningeoma (708 görüntü), glioma (1426 görüntü) ve hipofiz(930 görüntü) tümöründen oluşan veri setini kullanmıştı. çekişmeli üretken ağ (ÇÜA) kullanarak aşırı uyumun üstesinden gelmek için denetimsiz bir ön eğitim yöntemi kullanmıştı. 5-katlı çapraz doğrulama ile %93.01 doğruluk elde etmişti. Çıtak vd. [27] 43 hasta dahil edildiği gliomaların derecelendirilmeye çalışmışlardı.Çalışmada %86,70 özgüllük ile %93.00 doğruluk elde etmişti. Shahzadi vd. [28], yüksek dereceli (HG) ve düşük dereceli (LG)’yi sınıflandırmışlardı. VGG-16’dan gelen özellikler çıkardıktan sonra 3D beyin tümörü hacimlerini HG ve LG’yi sınıflandırmak için özellik temsillerini öğrenmek için Uzun Kısa Süreli Bellek (UKSB) ağını beslemişlerdi. Önerdikleri yöntem ile % 84.00 doğruluk elde etmişlerdi. Ayrıca, Tablo 3’teki ESA modellerinin kullanıldığı [26],[27] ve [28] referanslı çalışmalar ile karşılaştırıldığında daha hafif ağırlıklı olan DenseNet201 modeli ile daha yüksek bir sınıflandırma doğruluğu elde edilmesi önerilen yöntemin başarısını göstermektedir.

4. SONUÇLAR

Bu çalışmada MR görüntüleri kullanılarak beyin tümör sınıflandırılması yapılmıştır. Çalışmada 4 sınıflı 3443 görüntüden oluşan veri seti kullanılmıştır. 19 ön eğitilmiş modelden DenseNet201 modelinden çıkarılan öznitelikler en yüksek doğruluk sonucu vermiştir. Önerilen yöntemde DenseNet201’in “avg pool” katmanından 1920 adet öznitelik, “fc1000” katmanından 1000 adet öznitelik alınarak birleştirilmiştir.Öznitelik seçimi yapılmadan %95.00 doğruluk, mRMR öznitelik seçimi yapılarak %95.76 doğruluk elde edilmiştir.mRMR öznitelik seçme algoritması ile %0.76 doğruluk metriğinde artış sağlanmıştır. Bilgisayar destekli tanı sistemi özellikle teşhis ve tanı da önemli rol oynamaktadır. Beyin analizi çeşitli yaklaşımlarla bulgular ve anatomik bölgelerin doğru

sınıflandırılmasına dayanır. Bu çalışmada insan hayatını olumsuz yönde etkileyen bir hastalığın teşhisine yönelik yöntem geliştirilmiştir.

Gelecekteki çalışmalarımızda, farklı beyin tümörlerini tespit etmek için daha fazla sınıflı ve daha fazla veriye sahip veri kümeleri üzerinde yeni bir model oluşturulması planlanmaktadır.

TEŞEKKÜR

Yazarın teşekkür edeceği herhangi bir kişi ve ya kuruluş bulunmamaktadır.

KAYNAKÇA

- [1] Abiwinanda, N., Hanif, M., Hesaputra, S. T., Handayani, A., and Mengko, T. R. (2019). Brain tumor classification using convolutional neural network. In World congress on medical physics and biomedical engineering 2018. Springer, Singapore. 183-189.
- [2] Seetha, J., and Raja, S. S. (2018). Brain tumor classification using convolutional neural networks. Biomedical and Pharmacology Journal, 11(3), 1457.
- [3] Lakshmi, M. J., and Nagaraja Rao, S. (2022). Brain tumor magnetic resonance image classification: a deep learning approach. Soft Computing, 1-9.
- [4] Veeramuthu, A., Meenakshi, S., Mathivanan, G., Kotecha, K., Saini, J. R., Vijayakumar, V., and Subramaniaswamy, V. (2022). MRI brain tumor image classification using a combined feature and image-based classifier. Frontiers in Psychology, 13.
- [5] Li, M., Kuang, L., Xu, S., and Sha, Z. (2019). Brain tumor detection based on multimodal information fusion and convolutional neural network. IEEE Access, 7, 180134-180146.
- [6] Singh, A. (2015, February). Detection of brain tumor in MRI images, using combination of fuzzy c-means and SVM. In 2015 2nd international conference on signal processing and integrated networks (SPIN) , IEEE. 98-102.
- [7] Praveen, G. B., and Agrawal, A. (2015, November). Hybrid approach for brain tumor detection and classification in magnetic resonance images. In 2015 Communication, Control and Intelligent Systems (CCIS), IEEE. 162-166.
- [8] Thirumurugan, P., Ramkumar, D., Batri, K., and Siva Sundhara Raja, D. (2016). Automated detection of glioblastoma tumor in brain magnetic imaging using ANFIS classifier. International Journal of Imaging Systems and Technology, 26(2), 151-156.
- [9] Chen, X., and Konukoglu, E. (2018). Unsupervised detection of lesions in brain MRI using constrained adversarial auto-encoders. arXiv preprint arXiv:1806.04972.

- [10] Chen, X., Pawlowski, N., Rajchl, M., Glocker, B., and Konukoglu, E. (2018). Deep generative models in the real-world: an open challenge from medical imaging. arXiv preprint arXiv:1806.05452.
- [11] (2022, 19.06.2022). *Brain Tumor MRI Image Classification* (<https://www.kaggle.com/datasets/iashiquil/brain-tumor-mri-image-classification>).
- [12] Szegedy, C., Zaremba, W., Sutskever, I., Bruna, J., Erhan, D., Goodfellow, I., and Fergus, R. (2013). Intriguing properties of neural networks. arXiv preprint arXiv:1312.6199.
- [13] Redmon, J., and Farhadi, A. (2017). YOLO9000: better, faster, stronger. In Proceedings of the IEEE conference on computer vision and pattern recognition, 7263-7271.
- [14] Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., and Wojna, Z. (2016). Rethinking the inception architecture for computer vision. In Proceedings of the IEEE conference on computer vision and pattern recognition, 2818-2826.
- [15] Zoph, B., Vasudevan, V., Shlens, J., and Le, Q. V. (2018). Learning transferable architectures for scalable image recognition. In Proceedings of the IEEE conference on computer vision and pattern recognition , 8697-8710.
- [16] Simonyan, K., and Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556.
- [17] He, K., Zhang, X., Ren, S., and Sun, J. (2016). Deep residual learning for image recognition. In Proceedings of the IEEE conference on computer vision and pattern recognition, 770-778.
- [18] Szegedy, C., Ioffe, S., Vanhoucke, V., and Alemi, A. A. (2017, February). Inception-v4, inception-resnet and the impact of residual connections on learning. In Thirty-first AAAI conference on artificial intelligence.
- [19] Krizhevsky, A., Sutskever, I., and Hinton, G. E. (2017). Imagenet classification with deep convolutional neural networks. Communications of the ACM, 60(6), 84-90.
- [20] Zhang, X., Zhou, X., Lin, M., and Sun, J. (2018). Shufflenet: An extremely efficient convolutional neural network for mobile devices. In Proceedings of the IEEE conference on computer vision and pattern recognition, 6848-6856.
- [21] Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions. In Proceedings of the IEEE conference on computer vision and pattern recognition , 1251-1258.
- [22] Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., and Chen, L. C. (2018). Mobilenetv2: Inverted residuals and linear bottlenecks. In Proceedings of the IEEE conference on computer vision and pattern recognition, 4510-4520.

- [23] Huang, G., Liu, Z., Van Der Maaten, L., and Weinberger, K. Q. (2017). Densely connected convolutional networks. In Proceedings of the IEEE conference on computer vision and pattern recognition, 4700-4708.
- [24] Iandola, F. N., Han, S., Moskewicz, M. W., Ashraf, K., Dally, W. J., and Keutzer, K. (2016). SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and < 0.5 MB model size. arXiv preprint arXiv:1602.07360.
- [25] Tan, M., and Le, Q. (2019, May). Efficientnet: Rethinking model scaling for convolutional neural networks. In International conference on machine learning, PMLR. 6105-6114.
- [26] Ghassemi, N., Shoeibi, A., and Rouhani, M. (2020). Deep neural network with generative adversarial networks pre-training for brain tumor classification based on MR images. Biomedical Signal Processing and Control, 57, 101678.
- [27] Citak-Er, F., Firat, Z., Kovanlikaya, I., Ture, U., and Ozturk-Isik, E. (2018). Machine-learning in grading of gliomas based on multi-parametric magnetic resonance imaging at 3T. Computers in biology and medicine, 99, 154-160.
- [28] Shahzadi, I., Tang, T. B., Meriadeau, F., and Quyyum, A. (2018, December). CNN-LSTM: cascaded framework for brain tumour classification. In 2018 IEEE-EMBS Conference on Biomedical Engineering and Sciences (IECBES), IEEE. 633-637.



BÖBREK TÜMÖRÜ TESPİTİ İÇİN DERİN ÖĞRENME YÖNTEMLERİNİN KARŞILAŞTIRMALI ANALİZİ

Caner KARADAĞ¹, Durmuş ÖZDEMİR²

¹Dumlupınar Üniversitesi, Lisansüstü Eğitim Enstitüsü, Bilgisayar Mühendisliği Bölümü, Kütahya,
caner.karadag0@ogr.dpu.edu.tr, ORCID: 0000-0003-1856-2880

²Dumlupınar Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Kütahya, durmus.ozdemir@dpu.edu.tr,
ORCID: 0000-0002-9543-4076

Geliş Tarihi(Received Date):24.09.2022

Kabul Tarihi(Accepted Date):02.12.2022

ÖZ

Günümüzde böbrek tümörü vakalarına oldukça sık rastlanmaktadır. Hastanın böbreğindeki tümör; büyüklük ve bölgesel olarak farklılık gösterebilir. Tümörün bir uzman tarafından doğru tespit edilememesi, geç teşhis ve erken tedavi uygulanmaması halinde hastalar çok ciddi riskler ile karşı karşıyadır. Doğru ve hızlı teşhis için literatürde yapay zeka teknolojilerine dayalı karar destek sistemlerinin önemli çözüm önerileri sunduğu görülmektedir. Tıp alanı yapay zekanın en çok kullanıldığı alanların başını çekmektedir. Böbrek tümörlerin tespitinde bilgisayarlı tomografi tıbbi görüntüleme cihazları yaygın olarak kullanılmaktadır. Bu çalışma kapsamında, bilgisayarlı tomografi cihazı tarafından üretilen görüntüler kullanılmıştır. Böbrek tümörü tespit analizi için sınıflandırıcı model olarak Convolutional Neural Network (CNN) kullanılmıştır. VGG16, VGG19 ve ResNET50 modelleri kullanarak aralarındaki performans karşılaştırma analizi yapılmıştır. Uygulamanın yazılım dili olarak Python ile Tensorflow, Keras ve OpenCV kütüphaneleri kullanılmıştır. Yapılan analiz tespiti sonucunda böbrek tümörlerinin saptanmasında %85'lere varan oranda tespitin başarılı şekilde gerçekleştirildiği görülmüştür.

Anahtar kelimeler: *Görüntü İşleme, Derin Öğrenme, Yapay Zekâ, Böbrek Tümörü*

COMPARATIVE ANALYSIS OF DEEP LEARNING METHODS FOR RENAL TUMOR DETECTION

ABSTRACT

Kidney tumors are very common nowadays. Tumor in the patient's kidney; may vary in size and region. If the tumor cannot be detected correctly by a specialist, late diagnosis and early treatment are not applied, patients are at risk of death. In such cases, the importance of technology becomes clear. With the rapid development of technology, the concept of artificial intelligence has become the center of our lives in recent years. Medicine is also one of the areas where this concept is used the most. Computed tomography medical imaging devices are widely used in the detection of kidney tumors. Within the scope of this study, images obtained by computerized tomography device were used. Convolutional Neural Network (CNN) was used as the classifier model for kidney tumor detection analysis. Performance comparison analysis between them was made using VGG16, VGG19 and

ResNET50 models. Python and Tensorflow, Keras and OpenCV libraries were used as the software language of the application. As a result of the analysis, it was seen that it was successfully performed in the detection of kidney tumors.

Keywords: *Image Processing, Deep Learning, Artificial Intelligence, Kidney Tumor*

1. GİRİŞ

Dünya da gelişen teknoloji ile birlikte yapay zekâ ve alt kümesi olan derin öğrenme teknolojileri birçok farklı alanda hayatımızı kolaylaştıran bir unsur haline gelmiştir. Derin öğrenme, beyindeki nöron ağını taklit eden bir bilgisayar yazılımıdır. Derin öğrenme ifadesi 2012 yılında Hinton tarafından çok katmanlı yapay sinir ağlarının verimli bir şekilde eğitilebileceği ortaya koyulduktan sonra literatürde kullanılmaya başlanmıştır [1]. Sağlık hizmetleri faaliyet alanı da bunlardan biridir. Tıbbi alanda kullanılan yapay zekâ, medikal görüntüleme cihazlarından elde edilmiş görüntülerden çıkarım yapmamıza olanak sağlamaktadır. Medikal görüntüleme tekniklerinde yapay zekâ ile birlikte klinikteki verimliliği artırıp daha etkin kullanılması hedeflenmiştir [2].

Çevresel faktörlerin yanı sıra genetik olarak gelen bazı hastalıkların artmasıyla birlikte günümüzde sağlık hizmetlerinde medikal cihazların da kullanımında artış olmuştur. Ayrıca herhangi bir hastalığı olan bireyin medikal görüntüsünün uzman tarafından incelenmesinin yanında, yapay zekâ ve derin öğrenme teknolojileri içeren yazılım ile ilgili uzmanı destekleyici analizler yapıp verdiği rapor ile teşhis, tedavi ve karar süreçlerine destek veren yazılımlar bulunmaktadır [3].

Radyoloji, tıbbın alt ve önemli dallarından biridir. Bu alanda içinde farklı problemler ve anormalliklerin teşhislerine yardımcı olabilmek için hekimlerin kullandığı farklı tanısal medikal görüntüleme sistemleri mevcuttur. Medikal görüntüleme sistemi tercihi, hastanın semptomlarına, yöntemin maliyetine ve görüntüleme yapılan ilgili bölgeye ve kullanılabilirliğine bağlı olarak değişmektedir. Tespit edilen tümör hücreleri, büyüklüğü ve kıvamı gibi birçok farklı morfolojik özelliğe sahip olmaktadır. Tümörlü hücrelerin çoğunluğu beyin bölgesinde görülmekte olup, diğer hücrelere bakıldığında farklı bir yapıya sahiptirler. Böbrek bölgesinde bulunan tümörlerin analizi ve tespiti için Bilgisayarlı Tomografi (BT) taramaları ve Manyetik Rezonans (MR) taramaları en çok kullanılan medikal tespit görüntüleme türlerindedir [4].

Genel olarak böbrek tümörleri iyi veya kötü olarak tanılandırılsa da aralarında birçok fark bulunmaktadır. Bunların en önemli olanı iyi huylu tümörlerin kanserli hücreler olmamasıdır. Burada iyi huylu olan böbrek tümörlerinin boyutlarının belli olması, tedavi edilmesini daha kolaylaştıracaktır. Diğer doku ve organlara dağılmayıp etkili oldukları alan kısıtlıdır. Böbrek tümörleri eğer kötü huylu bir tümör ise bunlar kanserli hücreler olmaktadır. Kanserli hücreler çok hızlı bir şekilde büyüyüp çoğaldığı için buldukları organda ve vücudun diğer alanlarında ciddi tahribata neden olmaktadır [5].

Medikal görüntüleme teknikleri beyin tümörü, böbrek ve meme kanseri, böbrek taşı tespiti gibi birçok tıbbi alanda yaygın olarak kullanılmaktadır [6]. Tıbbi cihazlardan elde edilmiş büyük medikal görüntü veri setlerini hızlı ve kolay bir şekilde yapay zekâ teknolojilerini kullanarak, hastalıkların teşhisi ve tedavi süreçleri çok önemli bir yere sahip olmaya başlanmıştır.

Medikal görüntüleme Wilhelm Conrad Roentgen'in 1895 yılında tesadüfen X-ışınlarını keşfetmesi ile başlamıştır ve günümüzde radyografi, nükleer medikal görüntüleme, ultrasonografi, bilgisayarlı tomografi ve manyetik rezonans gibi farklı görüntüleme teknikleri ile gelişmeye devam etmektedir.

Her bir görüntüleme tekniğinin amacı hasta vücuduna ait bir parametrenin, özelliğın veya işlevin uzaysal haritalamasını yapmaktır [7].

Shi Yin vd., otomatik ultrason görüntüsü böbrek segmentasyonu için Müteakip Sınır Mesafesi ve Pixelwise Sınıflandırma ağlarını (SBD-PCN) önerdi. İlk olarak, Yazarlar, Ultrason (ABD) görüntülerinden yüksek seviyeli görüntüler için görüntüleri sınıflandırmak için önceden eğitilmiş derin sinir ağlarını bildirdiler, daha sonra bu işlevleri bir orta mesafe regresyon ağı ile böbrek sınırları haritalarının öğrenilmesi için girdi olarak kullandılar ve son olarak tanınanları sınıflandırdılar. Sınır mesafesi, bir piksel sınıflandırma ağı ile böbrek piksellerine dönüştürülür. Böbrek görüntüsünün segmentasyonu, nihai bir öğrenme yöntemiyle böbrek ve böbrek sınırlarını tahmin etmek için derin CNN'lere dayanmaktadır [8].

Njoud Abdullah Almansour vd., kronik böbrek hastalığının tahmini için Yapay Sinir Ağı ve Destek vektör makinesini (ANN-SVM) önerdi. Tüm eksik veri değerleri, gerçekleştirilecek deneyler için ilgili özniteliklerin ortalaması ile değiştirilmiştir. Daha sonra, sayısal analize dayalı olarak Yapay Sinir Ağı (YSA) ve Destek Vektör Makineleri (SVM) ile optimal parametreler hesaplanır. Ayrıca, Destek Vektörü ve Yapay Sinir Ağı için Optimize edilmiş parametreler belirlendi [9].

Tıbbi uygulamalarda Thong, Kadoury, Piché ve Pal [10] sağlıklı böbreklerin segmentasyonunu gerçekleştirmek için CNN'yi kullanmıştır. Ağları tamamen evrişimli değildir ve her pikseli bir pencere aracılığıyla ayrı ayrı sınıflandırır. Böbreğin tüm kısımlarını segmentlere ayırmak için bu pencereyi görüntü boyunca hareket etmesini sağladılar. Zhou vd. [11], organların bulanık lokalizasyonu (sınırlayıcı kutu), her 2B dilimin segmentasyonu ve çoğunluk oylaması yoluyla 2B dilimlerden bilgisayarlı tomografi taramalarının üç yönde 3B segmentasyonunu önermektedir. Sonuçlar iyiydi, ancak tümör bir böbreği segmentlere ayırma girişiminde bulunulmadı, bu nedenle bir zorluk ortaya çıktı. Evrişimsel ağlar, bu organların şekillerini tanımak için önce eğitilmelidir.

Yang vd. [17] böbrek tümörlerinin değerlendirilmesi için SCNN kullanımını tartıştıkları bir çalışma yayınladılar. Ağ yapısını ve Piramit ayrıştırma modülünü oluşturduktan sonra, daha fazla veri bulmak için iki yönlü bir segmentasyon tekniği kullandılar. Kayıp fonksiyonu hesaplandıktan sonra sınıflandırma için VGG16, ResNet vb. gibi farklı türde algoritmalar kullanılmıştır.

Attic Khan vd. [18] beyin tümörü sınıflandırması için transfer öğrenme tabanlı bir DL çerçevesi önerdi. Otomatik öznitelik çıkarımı için iyi bilinen iki önceden eğitilmiş ağ, yani VGG16 ve VGG19 kullandılar. Deney için popüler Beyin Tümörü Segmentasyonu (BraTs) veri seti kullanıldı. Ayrıca, uygun öznitelik seçimi için korrentropi ve kısmi en küçük kare tabanlı yöntem kullanılmış ve tek bir matriste birleştirilmiştir. Son olarak, ekstrem öğrenme makinesi (ELM) tabanlı bir sınıflandırıcı kullanılmış ve BraTs2015, BraTs2017 ve BraTs2018 veri setlerinde sırasıyla %97.8, %96.9, %92.5'lik en yüksek doğruluk elde edilmiştir.

Shen Li vd. mamogramlar kullanarak meme kanserini tespit etmek için bir evrişim sinir ağı yöntemine dayalı bir derin öğrenme algoritması oluşturdu. Bulguları, heterojen mamografi platformlarında gelişmiş performans ve doğruluk gösterdi. Deneyleri CBIS-DDSM veri setinden sayısallaştırılmış film mamogramları üzerinde gerçekleştirdiler. VGG16 ve ResNet50 kombinasyonunu ve sınıflandırıcılar [19], [20] olarak dört en iyi model kombinasyonundan oluşan bir başka topluluğu kullanarak gerçekleştirmiştir.

Bu çalışmada böbrek tümörü bulunan hastalara yönelik Python tabanlı derin öğrenme uygulaması geliştirilmiştir. Uygulamanın dili Python olduğu için web, masaüstü veya mobil uygulama gibi farklı platformlara entegre edilebilecek şekilde geliştirilmesi sağlanabilir. Uygulamanın asıl amacı; teşhis sırasında oluşan zaman kaybı ve hataların önüne geçmek ve ilgili uzmanın gözünden kaçabilecek herhangi bir bulguyu daha öncesinden analiz edip karar destek ve hastalığın tespit edilmesi süreçlerine katkı sağlamaktır.

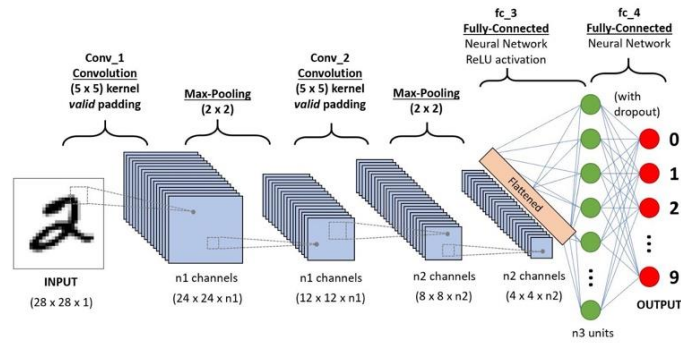
2. DENEYSEL ÇALIŞMALAR ve DEĞERLENDİRME

2.1. Kullanılan Yöntemler

Bu çalışmada böbrek analizi için derin öğrenme sınıflandırıcı model olarak Convolutional Neural Network (CNN) ve aktivasyon fonksiyon olarak softmax kullanılmıştır. Sınıflandırıcı modellerin arasındaki performans analizini tespit etmek için VGG16, VGG19 ve ResNET50 modelleri kullanılmıştır.

2.1.1. CNN model

Bilgisayarlar, görüntüleri piksellerinin değerlerine göre işlemektedir. 30×30 renkli bir görüntünün (RGB olarak) işlenmesi 2700 piksel ($30 \times 30 \times 3$) gerektirir. Bir veri parçasındaki temel ilişkiler, nöron katmanlarından oluşan bir sinir ağı kullanılarak bulunur. Tam bağlantılı sinir ağlarında, $30 \times 30 \times 3$ piksellik bir giriş görüntüsü için ilk gizli katmandaki ağırlık sayısı 2700'dür. $250 \times 250 \times 3$ piksellik bir giriş görüntüsü kullanan ilk gizli katman, 187.500 değerinde ağırlığa sahip olacaktır. Sonuç olarak, birçok parametreyle uğraşmak ve derin ağlardaki nöron sayısını artırmak zorunda kalınmaktadır. Bir CNN'nin yönetmesi gereken daha az ağırlığı ve daha az nöronu vardır. Çünkü her nöron önceki katmandaki tüm nöronlardan ziyade sadece az sayıda nörona bağlanır. Böylece CNN, görüntü sınıflandırmasında tam bağlantılı sinir ağlarından daha iyi performans gösterir [15]. CNN mimarisi iki katman gerektirir. Bunlar evrişim katmanları ve havuz katmanlarıdır. Aşağı havuzlama katmanı, öznetelik haritalarını, çıkarmak için evrişimsel katman tarafından evrişimsel olarak işlendikten sonra örnekleme yapar. Evrişimli sinir ağlarında çoklu gizli katmanlar ve çok sayıda parametre, görüntüler için sınıflandırma görevlerinde son derece iyi performans gösterir [16].




Şekil 1. CNN Mimarisi [21].


2.1.2. VGG16 ve VGG19 model

VGG16, Simonyan ve Zisserman [14] tarafından geliştirilmiş bir CNN modelidir. ILSVRC 2014 yarışmasına sunulan en dikkat çekici modellerden biridir. Bu model, ImageNet veri setinde %92,7'lik

ilk 5 test doğruluğuna ulaşır. Toplamda, ağıın 16 katmanı vardır [14]. VGG16, daha önceki modellerde kullanılan büyük çekirdek boyutlu filtrelerin yerini alan birden fazla 3X3 çekirdek boyutunda filtreyi birbiri ardına tanıttı. Birden çok çekirdek katmanı, sinir ağıının derinliğinin artmasına neden olur. Bu, sinir ağıının daha karmaşık özellikleri ve kalıpları anlamasını ve tanımasını sağlar. Vgg16, 3x3 boyutlu evrişimli katmanları, 2x2 boyutlu ortalama havuzlama katmanlarını ve tam bağlantılı katmanları içerir. Sinir ağıının ilk genişliği 64'tür. Sinir ağıının genişliği her bir havuzlama katmanından sonra ikiye katlanır. İlk iki tam bağlantılı katman, her biri 256 kanala sahiptir ve üçüncü katman iki kanala sahiptir. İlk iki gizli katman, ReLU etkinleştirme işlevini kullanır ve son katman, bir softmax etkinleştirme işlevini kullanır. Her 256 kanal yoğun katmandan sonra bırakma uygulanmıştır. Ağıın öğrenme oranı 0.0001'dir. VGG16'nın bir varyantı olan Vgg19, esas olarak görüntü sınıflandırması için kullanılan 19 katmanlı bir evrişimsel sinir ağıdır. Temel mimarisi VGG16'ninkine benzer [14]. VGG19'daki tek fark, 256 ve iki kanallı 2 yoğun katmanın kullanılması ve öğrenme oranının 0,00001'e düşürülmesidir. VGG16 mimarisi Şekil 2, VGG19 mimarisi Şekil 3'de yer verilmiştir.



Şekil 2. VGG16 Mimarisi [22].

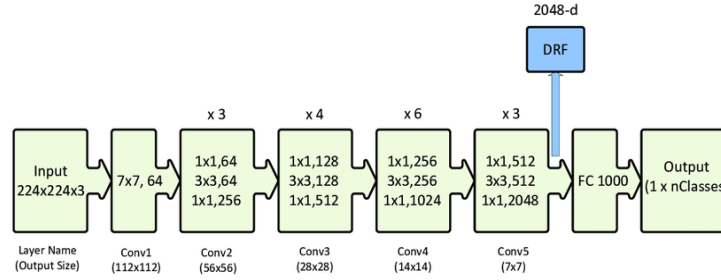


Şekil 3. VGG19 Mimarisi [23].

2.1.3. ResNET50 model

CNN öznetelikleri konvolüsyonel filtreler yoluyla çıkardıkları ve geri yayılım yoluyla parametreleri eğittikleri için temsil öğrenmede çok etkili olduklarını kanıtladığından, ImageNet veri kümesinde önceden eğitilmiş, son teknoloji evrişimli sinir ağı ResNet50[13] kullanılır. Resimler, ResNet50'nin giriş gereksinimlerine uyması için 224x224 olarak yeniden boyutlandırılır. Öznetelikler, 2048 boyutlu

öz nitelik vektörünü elde etmek için son tam bağlı katman kaldırılarak elde edilir. Bu özellik vektörleri, fazla hesaplama gücü kullanılmadan kolayca elde edilir. ResNET50 mimarisi Şekil 4'te gösterilmiştir.



Şekil 4. ResNET50 Mimarisi [24].

2.2. Kullanılan Görüntü Veri Seti

Tümörlerin segmentasyonunu ve sınıflandırılmasını sağlamak için Kaggle'da açık kaynak olarak bulunan (Kidney Disease Classifier) veri seti kullanılmıştır [12]. Veri seti eğitim için normal tümörsüz 4560 ve tümörlü 2054 görüntü, testi için ise normal tümörsüz 255 ve 155 tümörlü görüntüsü içermektedir. Yalnızca tümör görüntülerinden oluşturulmuş yüksek kaliteli, dengeli bir test ve doğrulama veri seti oluşturulmuştur. Bu nokta çok önemlidir, çünkü modelin belirli bir tümörün görüntüsünden öğrenirse, aynı tümörün başka bir görüntüsü üzerinde kontrol edilirse doğruluğumuz gerçekçi olmayacaktır.

2.3. Sağlıklı Böbrek


Uygulama için daha önce tespit edilmiş sağlıklı böbrek bilgisayarlı tomografi cihazından elde edilmiş farklı sağlıklı bireylerin böbrek görüntüleri Şekil 5'te yer verilmiştir.



Şekil 5. Sağlıklı Böbrek Görüntüleri [12].

2.4. Böbrek Tümör Olan Görüntüler

Burada 3 farklı bireye ait tomografi görüntüsü bulunmaktadır. Farklı noktalarda böbreklerin tümörlü olduğu görülmektedir.



Şekil 6. (a) da sol böbreğin alt bölümünde, şekil (b) de sağ böbreğin tamamını ve vücudun büyük bölümünü, şekil (c) de ise böbreğin sağ alt kısmında tümörlü alan işaretlenmiştir [12].

2.5. Parametrelerin Belirlenmesi

Uygulamada CNN, VGG16, VGG19 ve ResNet50 sınıflandırıcı modellerinin parametreleri Çizelge 1’de gösterilmiştir.

Çizelge 1. Parametre Değerleri.

Giriş Boyutu	Model	Parti Boyutu	Eğitim Sayısı	Tur Sayısı	Toplam Sınıf Sayısı	Sınıf Ayrıntılı	Test Boyutu	Rastgele Durum	Karıştırma
224	CNN	20	5	5	5	1	0.3	0	false
224	VGG16	20	5	5	5	1	0.3	0	false
224	VGG19	20	5	5	5	1	0.3	0	false
224	ResNet50	20	5	5	5	1	0.3	0	false

2.6. Model’in Eğitilmesi

Modelin eğitilmesi için aktivasyon fonksiyonu softmax kullanarak Convolutional Neural Network (CNN) sınıflandırıcı modeli ile eğitilmiştir. Eğitilecek olan verilerin sağlıklı bireylerden 1500 tane ve böbrek tümörü olan 1500 tane bireyin bilgisayarlı tomografi görüntüsü sisteme eklenir. İlk etapta eğitilen veri seti başlangıçta ortalama %59’lük doğruluğa sahip olmasına karşın son aşamaya geldiğinde eğitilmiş veri seti %79 doğruluğa ulaşmaktadır. Eğitilen veri setinde kayıp değeri ise başlangıçta %67 iken son aşamaya geldiğinde %47’lik bir kayıp değerine ulaşmıştır. (CNN) sınıflandırıcı modeline ait eğitim sonuçları Çizelge 2’de gösterilmiştir.


Çizelge 2. Eğitim Sonuçları.

Eğitim Sayısı	Tur Kayıp Değeri	Doğruluk	Doğrulama Kaybı	Doğrulama Doğruluğu
1	0.6731	0.5971	0.6302	0.6566
2	0.6249	0.6721	0.5926	0.6591
3	0.5724	0.7259	0.5315	0.7855
4	0.5190	0.7626	0.4746	0.8279

5 0.4778 0.7912 0.4040 0.8532

2.7. Kayıp Grafiği


CNN modeli ve softmax aktivasyon fonksiyonu ile eğitilen verilerin eğitim sırasında oluşan kayıp değerleri Şekil 7’de ki grafikte yer verilmiştir. Burada görüldüğü gibi eğitim tur sayımı attıkça kayıp değeri 0 değerine yaklaştığı görülmüştür.



Şekil 7. Böbrek Tümörü Kayıp Grafiği.

2.8. Doğruluk Grafiği

CNN model ve aktivasyon fonksiyonu softmax ile eğitilen verilerin eğitim sırasında oluşan doğruluk değerleri Şekil 8’de ki grafikte yer verilmiştir. Başlangıçta test değeri yaklaşık %65 seviyede gitmesine karşın eğitim tur sayısı 1 değerine geldikten sonra doğruluk değeri yaklaşık %84’ten yukarı doğru gittiği görülmüştür. Bununla birlikte oluşun metrik sonuçları Çizelge 3’te gösterilmiştir.



Şekil 8. Böbrek Tümörü Doğruluk Grafiği.

Çizelge 3. Metrik Sonuçları.

	Keskinlik	Geri Çağırma	F1 Puanı	Destek
Sağlıklı	0.88	0.90	0.89	805
Tümörlü	0.79	0.77	0.78	421
Doğruluk	-	-	0.85	1226
Makro Ortalama	0.84	0.83	0.84	1226
Ağırlıklı Ortalama	0.85	0.85	0.85	1226

2.9. Böbrek Tümörü İçin Sınıflandırıcı Aralarındaki Performans Farkları


Uygulamada 4 farklı sınıflandırıcı modelin yanı sıra aktivasyon fonksiyonu softmax kullanılmıştır. Burada softmax aktivasyon fonksiyonu ile sınıflandırıcı modeller aralarındaki performans analiz sonuçları Çizelge 4’de gösterilmiştir.

Çizelge 4. Sınıflandırıcı Performans Sonuçları.

Sınıflandırıcı	Kayıp Değeri	Doğruluk Değeri	Doğrulama Kaybı	Doğrulama Doğruluğu
CNN	0.4778	0.7912	0.4040	0.8532
VGG 16	0.0952	0.9793	0.0846	0.9794
VGG 19	0.0101	0.9991	0.0088	0.9980
ResNet50	0.4559	0.7955	0.4984	0.7443

2.10. Tümör Olup Olmadığı Tespiti


Softmax aktivasyon fonksiyonu ile eğitilen modelin eğildikten sonra böbrekte herhangi bir tümörlü bölge olup olmadığının tespiti Şekil 9’da yer verilmiştir. Şekilde görüldüğü gibi 12 farklı bireyin eğitilmiş verinin analizi sonucunda böbrek tümörlü ise (evet), tümörlü değilse (hayır) olacak şekilde gösterilmesi sağlanmıştır.



Şekil 9. Böbrek Tümörü Analiz Sonuçları.

2.11. Tümörün Konum Tespiti


Softmax aktivasyon çıkış fonksiyonu kullanılarak CNN sınıflandırıcı eğitilen modelin böbrekte tümörlü bölgenin tespit edilmesi için 9 adım da maskeleme ve filtreleme işlemleri uygulanarak tümör konumun tespiti aşamaları Şekil 10'da yer verilmiştir.



Şekil 10. Böbrek Tümörü Analiz Sonuçları.

2.12. Tümör Konum ve Ölçüm Tespiti

Uygulamanın son aşamasında tümörün böbrek bölgesindeki yerinin tespiti, genişliği ve yüksekliği bulunması sağlanmıştır. Aktivasyon fonksiyonu softmax ile eğitilen modelin, tümör konumu ve diğer ölçüm değerleri Şekil 11’de yer verilmiştir. Burada görüldüğü gibi tümörün genişliği 9,9 cm olmasına karşında yüksekliği 7,7 cm olarak bulunmuştur.



Şekil 11. Böbrek Tümörü Ölçüm Tespiti.

3. SONUÇ ve TARTIŞMA

Derin öğrenme ve yapay zekâ günümüz teknolojisinin vazgeçilmez bir parçası olmuştur. Birçok alanda kullanıldığı gibi tıp alanındaki uygulamalarında başarılı sonuçlar üretmektedir. Görüntü işleme, yapay zekâ ve derin öğrenme doğru bir şekilde uygulandığında tıp alanındaki uygulamalarda çok başarılı sonuçlar verebilir.

Tıbbi kaynakların kısıtlı ve radyologların yetersiz olduğu yerlerde geliştirilen derin öğrenme uygulamalarıyla böbrek tümörü veya böbrek taşı tespit etme çabasını en hızlı ve en doğru ortaya çıkartmasına yardımcı olabilir. Günümüzde de çevresel faktörlerin yanı sıra nüfusun fazla olmasıyla birlikte hastaneler de doktorların muayene yoğunluklarından dolayı ya da muayene sırasında doktorun gözden kaçabilecek bulguların önüne geçebilir. Bu sayede daha doğru sonuçlar elde edilip, hızlıca tedavi sürecine başlanacaktır.

Bu çalışmada böbrek tümörü ile sağlıklı bireylerin bilgisayarlı tomografi görüntü içeren veri seti kullanılıp derin öğrenme ile analiz edilmesi sağlanmıştır. Böbrek tümörü analiz için 1500 taneden fazla sağlıklı bireyin yanı sıra 1500 taneden fazla tümörlü BT görüntüsü kullanılmıştır. CNN model kullanılarak böbrek tümör verisini softmax aktivasyon fonksiyonu ile eğittiğimizde başlangıçta %59 doğruluk olmasına karşın son aşamaya gelindiğinde %79’luk bir doğruluğa ulaşılmıştır.

Sonuç olarak derin öğrenme ve medikal görüntülerden böbrek tümörü tespit etmek için ikili sınıflandırıcı oluşturuldu. Sınıflandırıcı olarak CNN (%85), aktivasyon transfer fonksiyonu olarak ise softmax kullanıldı. Bununla birlikte VGG16 (%97), VGG19 (%99) ve ResNet50 (%74) sınıflandırıcı modelleri kullanılarak aralarındaki performans farkları bulunması sağlandı. Gelecekte derin öğrenme ve medikal görüntüleme analiz yapıları tıp alanının vazgeçilmez bir parçası haline gelecektir.

Sonraki yapılacak çalışmalarda (Batch Size) değerini arttırdığımızda doğruluk değeri yüksek çıktığı görülmüştür. Doğruluk değerini yükseltmek için eğitim tur sayısını ve (Batch Size) arttırabiliriz. Fakat uygulamanın kurulduğu ortama veya performansına bağlı olarak eğitim zamanı uzadığı görülmüştür. Bununla birlikte derin öğrenme için daha fazla hasta kişinin verisi sisteme yüklendiğinde sistemin başarı oranını arttıracaktır.

TEŞEKKÜR

Bu çalışma, Kütahya Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalında Dr. Öğr. Üyesi Durmuş ÖZDEMİR Danışmanlığında Yüksek Lisans yapan Caner KARADAĞ'ın yüksek lisans tez çalışmalarından üretilmiştir

KAYNAKÇA

- [1] Hinton, G. Deng, L. Yu, D. Dahl, G.E. Mohamed, A.-r. Jaitly, N. Senior, A. Vanhoucke, V. Nguyen, P. ve Sainath, T.N., (2012). "Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups", IEEE Signal Processing Magazine, 29: 82-97.
- [2] Özdemir, D., Arslan, N. N., (2021), Analysis of Deep Transfer Learning Methods for Early Diagnosis of the Covid-19 Disease with Chest X-ray Images, 630p, 2021.
- [3] Canbay, P., (2020), Sağlıkta yapay zeka: derin öğrenme teknikleri ve uygulamaları, pp. 25-26
- [4] Dandil, E., (2015), Mr görüntüleri ve mr spektroskopisi verileri ile yapay öğrenme tabanlı beyin tümörü tespit yöntemi ve uygulaması, pp. 4-7
- [5] Böbrek Kanseri, Erişim Adresi: <https://www.medicalpark.com.tr/bobrek-kanseri-nedir/hg-1812>, Erişim: 24.03.2022.
- [6] Eker, A. G., Duru, N., (2021), Medikal görüntü işlemede Derin öğrenme uygulamaları, pp. 460-466, 2021.
- [7] Yıldırım, (2008), Medikal Görüntüleme Sistemleri İçin Yarıiletken Matris Dedektör Tasarımı ve Geliştirilmesi, 1p,7p.
- [8] Shi Yin, vd., (2020), Automatic kidney segmentation in ultrasound images using subsequent boundary distance regression and pixelwise classification networks, Med. Img. Anal. 60, 101602.

- [9] Njoud Abdullah Almansour, vd., (2019), Neural network and support vector machine for the prediction of chronic kidney disease: A comparative study, *Comput. Biol. Med.* 109 101–111.
- [10] Thong, W., Kadoury, S., Piché, N., ve Pal, C. J. (2016). Convolutional networks for kidney segmentation in contrast-enhanced ct scans. *Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization*, 1–6. doi:10.1080/21681163.2016.1148636.
- [11] Zhou, X., Takayama, R., Wang, S., Zhou, X., Hara, T., ve Fujita, H. (2017). Automated segmentation of 3d anatomical structures on ct images by using a deep convolutional network based on end-to-end learning approach. In *Medical imaging 2017: Image processing*: 10133 (p. 1013324). International Society for Optics and Photonics. doi:10.1117/12.2254201.
- [12] Kidney Tumor and Stone MRI Images, Erişim Adresi: <https://www.kaggle.com/code/ahmedbadr22/kidney-disease-classifier-with-99-cnn/data>, Erişim: 26.04.2022
- [13] He, X. Zhang, S. Ren, and J. Sun, (2016), “Deep residual learning for image recognition”. In *CVPR*,
- [14] Simonyan, K., Zisserman, A., (2014), Very deep convolutional networks for large-scale image recognition, arXiv preprint arXiv:1409.1556
- [15] Bu X, Peng J, Yan J, Tan T, Zhang Z. GAIA: A transfer learning system of object detection that fits your needs. In: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*; 2021. p. 274–83.
- [16] Azeez RA, Abdul-Hussein MK, Mahdi MS, ALRikabi HTHS, (2021), Design a system for an approved video copyright over cloud based on biometric iris and random walk generator using watermark technique. *Period Eng Nat Sci* 10(1):178–87.
- [17] Pan, T., Yang, G., Wang, C., et al., (2019), “A multi-task convolutional neural network for renal tumor segmentation and classification using multi-phasic ct images,” in *2019 IEEE International Conference on Image Processing (ICIP)*, pp. 809–813. doi: 10.1109/ICIP.2019.8802924.
- [18] Khan, M.A., Ashraf, I., Alhaisoni, M., Damaševičius, R., Scherer, R., Rehman, A., S.Bukhari, S. A. C., (2020), Multimodal brain tumor classification using deep learning and robust feature selection: a machine learning application for radiologists *Diagnostics*, 10 (8) p. 565, 10.3390/diagnostics10080565
- [19] Sahu, B. P., Mohanty, S. N., Rout, S. K., (2019), A hybrid approach for breast cancer classification and diagnosis *EAI Endorsed Trans. Scalable Inf. Syst.*, 6(20) pp. 1-8
- [20] Sahu, B. P., Das, S., Mohanty, S. N., Rout, S. K., (2018), Ensemble comparative study for diagnosis of breast cancer data set *Int. J. Eng. Technol.*, 7 pp. 281-288
- [21] CNN mimarisi, Erişim Adresi: <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>, Erişim: 19.10.2022.

Karadağ, C. ve Özdemir, D., Journal of Scientific Reports-B, Sayı 6, 10-23, Aralık 2022.
Karadağ, C. and Özdemir, D., Journal of Scientific Reports-B, Number 6, 10-23, December 2022.

- [22] VGG16 mimarisi, Erişim Adresi: <http://www.cs.toronto.edu/~frossard/post/vgg16/>, Erişim: 19.10.2022.
- [23] VGG19 mimarisi, Erişim Adresi: https://www.researchgate.net/figure/illustration-of-the-network-architecture-of-VGG-19-model-conv-means-convolution-FC-means_fig2_325137356, Erişim: 19.10.2022.
- [24] ResNET50 mimarisi, Erişim Adresi: https://www.researchgate.net/figure/ResNet-50-architecture-26-shown-with-the-residual-units-the-size-of-the-filters-and_fig1_338603223, Erişim: 19.10.2022.



**ÖKSEOTU (*VISCUM ALBUM L.*) BİTKİSİNDEN AKTİF KÖMÜR ELDESİ,
KARAKTERİZASYONU ve SULU ÇÖZELTİDEN KURŞUN GİDERİMİNDE
KULLANILABİLİRLİĞİNİN İNCELENMESİ**

Saliha ERENTÜRK^{1*}, Bircan KÖSE¹, Köksal ERENTÜRK²

^{1*}Atatürk Üniversitesi, Mühendislik Fakültesi, Kimya Mühendisliği Bölümü, Erzurum, : serenturk@atauni.edu.tr
ORCID:0000-0003-0824-7529

¹Atatürk Üniversitesi, Mühendislik Fakültesi, Kimya Mühendisliği Bölümü, Erzurum, bircank28@gmail.com,
ORCID:0000-0002-8895-5455

²Atatürk Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Erzurum, keren@atauni.edu.tr
ORCID: : 0000-0001-7536-1351

Geliş Tarihi(Received Date):06.10.2022

Kabul Tarihi(Accepted Date):01.12.2022

ÖZ

Bu çalışmada dünyada birçok ağaçta asalak olarak yaşayan buna rağmen içeriği bakımından birçok araştırmaya konu olan ökseotu (*Viscum album L.*) bitkisinin adsorbent olarak değerlendirilebilirliğini araştırmak amaçlanmıştır. Ökseotu bitkisi öncelikle sap ve yapraklarıyla birlikte kurutulmuştur. Daha sonra HCl ile muamele edilmiş ve termal metotla aktifleştirme işlemi gerçekleştirilmiştir. Aktifleştirme işlemi azot atmosferinde yüksek fırında 400 °C’ de gerçekleştirilmiştir. Elde edilen aktif kömürün karakterizasyonu kimyasal, Fourier Transform Infrared Spectroscopy (FTIR), Termal Analiz, Brunauer–Emmett–Teller (BET) ve Taramalı Elektron Mikroskopu(SEM) analiz metodları kullanılarak gerçekleştirilmiştir. Karakterize edilen aktif kömür sulu çözeltide bulunan kurşunun (Pb⁺²) giderilmesinde kullanılmış ve etkinliği test edilmiştir. Denemeler kesikli proseste gerçekleştirilmiştir. Kurşun gideriminde çözelti pH’ının etkisinin incelenmesi amacıyla altı farklı pH’da (1-6) denemeler yapılmış ve en iyi giderimin qe:50.78 mg/g ile pH: 5 te olduğu tespit edilmiştir. Sıcaklığın kurşun giderimine etkisi incelenirken üç farklı adsorpsiyon sıcaklığında(26°C-45°C) denemeler gerçekleştirilmiş sıcaklığın artışı ile giderimin arttığı ve çalışılan sıcaklıklarda en iyi giderimin 45°C olduğu belirlenmiştir. Katı/sıvı oranının giderime etkisi ise üç farklı katı/sıvı oranı(0.4-1g/l) için belirlenmiş olup en yüksek giderim yüzdesini 1g/l lik katı sıvı oranında elde edilirken en iyi adsorpsiyon kapasitesi 0.4g/l lik katı/sıvı oranında belirlenmiştir. Yapılan denemeler sonunda ökseotundan termal metotla aktifleştirilerek elde edilen aktif kömürün kurşun gideriminde ucuz, kolay hazırlanabilir ve kolay temin edilebilir bir adsorbent olarak kullanılabileceği belirlenmiştir.

Anahtar kelimeler: *Ökseotu, Aktif Karbon, Karakterizasyon, Adsorpsiyon, Kurşun*

**PRODUCTION of ACTIVATED CARBON from MISTLETOE(VISCUM ALBUM L.),
CHARACTERIZATION and INVESTIGATION of ITS USAGE for LEAD REMOVAL from
AQUEOUS SOLUTION**

ABSTRACT

In this study, it was aimed to investigate the applicability of mistletoe (*Viscum album L.*) plant, which is parasitic on many trees in the world, but which is the subject of many studies in terms of its content, as an adsorbent. The mistletoe plant is first dried together with its stem and leaves. It was then treated with HCl and activated by thermal method. The activation process was carried out at 400 °C in a blast furnace in a nitrogen atmosphere. The characterization of the obtained activated charcoal was carried out using chemical, Fourier Transform Infrared Spectroscopy (FTIR), Thermal Analysis, Brunauer–Emmett–Teller (BET) and Scanning Electron Microscope (SEM) analysis methods. Characterized activated charcoal was used to remove lead (Pb^{+2}) in aqueous solution and its effectiveness was tested. The experiments were carried out in batch process. In order to examine the effect of solution pH on lead removal, experiments were carried out at six different pH (1-6) and it was determined that the best removal was at pH: 5 with q_e : 50.78 mg/g. While examining the effect of temperature on lead removal, experiments were carried out at three different adsorption temperatures (26oC-45oC). The effect of solid/liquid ratio on removal was determined for three different solid/liquid ratios (0.4-1g/l), and the highest removal percentage was obtained at 1g/l solid/liquid ratio, while the best adsorption capacity was determined at 0.4g/l solid/liquid ratio. At the end of the trials, it was determined that the activated charcoal obtained from the mistletoe by the thermal method can be used as a cheap, easily prepared and easily available adsorbent in lead removal.

Keywords: *Mistletoe, Activated Carbon, Characterization, Adsorption, Lead*

1. GİRİŞ

Dünyamız doğal ve yeraltı kaynakları bakımından eşsiz zenginliğe sahiptir. İnsanlığın ve bilimin gelişimi sürecinde kaynakların farklı kullanım alanları keşfedilmiş, dünya nüfusu artmış ihtiyaçlar artmış, gereksinimler değişmiş ve neticesinde sanayileşme kaçınılmaz olmuştur. Dünya nüfusunun artışı ve sanayileşme beraberinde çevresel kirliliği ve sonucunda doğal kaynakların kaybedilmesi tehdidini oluşturmuştur. Doğal kaynakların korunmasının önemi yanında kirleticilerin bertarafı da kaynakların sürdürülebilir olarak kullanılmasında önemli bir rol oynamaktadır. Canlı varlığının temel yapıtaşı olan su, sanayi tarafından en çok kirleticilere maruz bırakılan kaynaktır. Çünkü birçok üretim tesisi proseslerinde suyu ya doğrudan kullanarak ya da dolaylı yoldan kullanarak üretimlerini gerçekleştirmektedir. Bunların sonucunda da çok çeşitli kirleticilerle yüklenmiş atıksular oluşmaktadır. Çevre bilicinin gelişmesiyle eskiden doğrudan akarsulara göllere veya denizlere deşarj edilen bu atıksuların arıtılmadan doğaya salınımı kanuni düzenlemeler ile engellenmektedir.

Atık sularda kirleticilerin başında kurşun gelmektedir. Çünkü kurşun sanayiinin birçok dalında özellikle tekstil, petrol rafinerisi, tabakhaneler, akümülatör üretimi, yakıtlar, patlayıcı üretimi, fotoğraf malzemeleri, kaplama, havacılık, otomobil, maden işleme ve çelik endüstrileri gibi birçok endüstriyel uygulamada yaygın olarak kullanılmaktadır[1-2]. Bu endüstriler, yüzey ve yeraltı sularının Pb(II) iyonları ile kirlenmesine neden olabilir. Kurşun, kanserojen ve biyolojik olarak parçalanamayan bir maddedir içme suyunda düşük konsantrasyonlarda bile kurşun bulunması vücutta kurşun birikmesine neden olabilir ve bu da kansızlığa, böbrek fonksiyon bozukluğuna, beyin doku hasarına

ve hatta ölüme neden olabilir. [1-2].Kurşunun sudan uzaklaştırılması önemli bir sorundur ve bu sorunu çözmek için kimyasal çöktürme, iyon değişimi, filtrasyon, elektrokimyasal arıtma, membran teknikleri, buharlaştırma ve adsorpsiyon yoluyla geri kazanım gibi çeşitli yöntemler vardır [3-4]. Adsorpsiyon dışındaki tüm bu yöntemler, ya ekonomik olarak elverişsiz ya da teknik olarak karmaşık oldukları için sadece özel durumlarda kullanılmaktadır. Atıksuların arıtılmasında adsorpsiyon en çok çalışılan ve kullanılan kolay ve ucuz bir yöntemdir. Adsorpsiyon yöntemi, birçok atık malzemenin değerlendirilmesine olanak sağlar. Adsorpsiyonda kullanılan adsorbanlar, genellikle tarımsal atıklar gibi karbon yapısını içeren doğal malzemelerden üretilen, düşük maliyetli ve kolayca temin edilebilen malzemelerdir [5]. Literatürde adsorpsiyon metodunda çok farklı adsorbentler kullanılmaktadır bunlara Fındık ve badem kabukları [5], zeytin çekirdeği[6], Ceviz, fındık, badem, fıstık kabuğu ve kayısı çekirdeği [7], Melocanna baccifera Roxburgh (bambu) [8], tütün kökleri [9], Modifiye ceviz kabuğu [10],Hindistan cevizi kabukları [11], Sitrik Asit Modifiye Çam Talaşı [12], ayçiçeği çekirdeği kabuğu [13], hurma ağacı yaprakları[14] , okaliptüs çekirdeği [15], çay atığı biyokütlesi[16] örnek verilebilirler. Herbirinin birbirine üstün ve üstün olmayan yönleri mevcut olmakla birlikte coğrafi bölgelerin farklılıklarına göre de adsorbent seçimi yapılabilir.

2. MALZEME VE YÖNTEM

2.1. Ökseotunun Aktifleştirilmesi ve Adsorpsiyon Deneyleri

Aktifleştirilmek amacıyla ökseotu (armut ağacından) Giresun ilinden temin edilmiştir. Kurşun giderimi için yapılan ön denemeler sonucunda aktifleştirilmiş ökseotunun hazırlanan çözeltinin pH'sını yükselttiği ve sulu çözeltinin bazik olmasına neden olduğu tespit edilmiştir. Ortam pH'ı'nın ayarlanabilmesi amacıyla ısıtılma işleminden önce ökseotu bitkisi %10'luk Hidroklorikasit çözeltisinde 3 saat muamele edilmiş, sonrasında süzülerek saf su ile yıkanmış ve 105°C lik etüvde kurutulmuştur [17-18]. Kurutulan ökseotu aktifleştirilmek amacıyla 400°C sıcaklıktaki fırında azot atmosferinde gerçekleştirilmiştir. Karbonize edilen bitki nötralizasyon amacıyla% 1 lik NaHCO₃ çözeltisi ile 8 saat muamele edilmiştir. Karbonize edilen ökseotu saf su ile yıkanmış, yıkama suyu pH sı 6.5 olana kadar yıkama işlemi tekrarlanmıştır. Yıkama süzülen ökseotu karbonizasyon ürünü etüvde 105°C'de 24 saat kurutulmuş ve kuru ürün porselen havanda 170-200 mesh aralığına öğütülüp elenmiştir.

Kurşun adsorpsiyonu için denemelerde kullanılacak olan çözeltiler, Pb(NO₃)₂ dan hesaplanan miktarda tartılarak hazırlanmış olan Pb⁺² stok çözeltisinden gerekli seyreltmeler yapılarak elde edilmiştir. Öncelikle 1000 mg/L Pb(II) iyonu içeren stok çözelti, hesaplanan miktarda Pb(NO₃)₂'nin saf suda çözülmesiyle hazırlanmıştır. Denemelerde kullanılan çözeltiler stok çözeltiden seyreltilerek hazırlanmıştır. Herbir denemede istenen konsantrasyonda hazırlanan çözelti çalışılan pH'a ayarlandıktan sonra çalışılacak olan sıcaklığa ayarlanmıştır. Ayarlı çözeltilere incelenecek olan katı/sıvı oranında adsorbent eklenmiştir. Adsorpsiyon deneyleri, 200 rpm çalkalama hızına sahip termostatik bir inkübatör çalkalayıcıda kesikli sistemde gerçekleştirilmiştir. Adsorpsiyon işleminden sonra çözelti süzgeç kağıdından süzülmuş ve elde edilen berrak çözeltide kalan Pb(II) iyonu konsantrasyonu, Atomik Adsorpsiyon (Shimadzu AA 670/Germany)spektrofotometresi kullanılarak ölçülmüştür. Hesaplamalar aşağıdaki eşitliklerle yapılmıştır[28].

Pb(II) iyonlarının giderim verimliliği,

$$\% \text{ Giderim} = \frac{C_0 - C_e}{C_0} \times 100$$

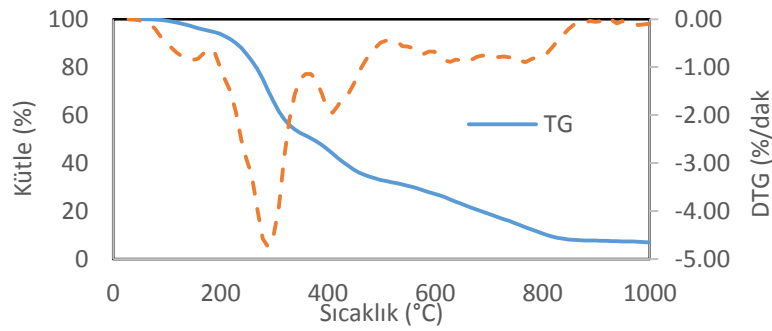
Dengede adsorbe edilen Cu(II) iyonları miktarı,

$$q_e = \frac{(C_0 - C_e)V}{m}$$

qe:adsorbantın kütle birimi başına adsorbe edilen iyon miktarı (mg/g), C₀:başlangıç Pb(II) konsantrasyonu (mg/L), C_e:dengedeki Pb(II) konsantrasyonu (mg/L), V: çözeltilinin hacmi (L), m: adsorbant kütlesi (g)

2.2. Termogravimetrik Analiz

Denemeler 10°C/dak ısıtma hızında ve 30 ml/dak N₂ gazı akış hızında 25°C ile 1000°C sıcaklık aralığında gerçekleştirilmiştir.



Şekil 1.Ökseotu bitkisi yaprakları için TG ve DTG analizi.

Şekil 1’de ökseotu bitkisi karbonizasyon işleminden önce yapılan TG ve DTG analizleri verilmiştir. TG-DTG eğrileri gözlemlenen olayların sıcaklıklarını göstermektedir. Şekle göre I. bölge de 100-150°C aralığında yapraktaki nem kaybını göstermektedir. Bu bölgede gözlenen ağırlık kaybı % 3.76 olarak tespit edilmiştir. Ağırlık kaybının gerçekleştiği II. bölgede % 38.26’lık bir ağırlık kaybı 228-328°C sıcaklık aralığında gerçekleşmiş ve DTG eğrisinin en keskin pikini de içine alan bölge olmuştur. Bu bölge ökseotu bitkisinin makromoleküllerinin bozunduğu depolimerize olduğu bölgedir. III. bölge 488-828°C sıcaklık aralığında gerçekleşmiş olup bu bölgede % 59.63’lük bir ağırlık kaybı tespit edilmiştir Meydana gelen üçüncü olay organik maddenin sabit mineral kalıntılarının karbonlaşması ve oluşumu ile ilgilidir. Bu sebeple ökseotu bitkisi aktifleştirilirken 400°C de işleme tabi tutulmuştur.

2.3. Karakterizasyon

Aktifleştirme işleminden sonra elde edilen aktif kömürün nem, kül uçucu madde sabit karbon içerikleri uygun standartlara göre belirlenmiş olup sonuçlar çizelge1’ de gösterildiği gibidir.


Çizelge1. Aktifleştirilmiş ökseotunun Nem, kül, uçucu madde, sabit karbon içerikleri.

Nem (%)	Kül(%)	Uçucu Madde(%)	Sabit Karbon(%)
3.8	7.3	12.1	76.8

2.4. Taramalı Elektron Mikroskopu (SEM) Görüntüleri

Elde edilen aktif kömürün SEM fotoğrafları 4000- 16000 kat büyütülmüş olarak şekil 2’de verilmiştir. SEM fotoğraflarından da görüleceği üzere aktif kömürün yüzeyinde oldukça fazla pürüzler, girintiler

çıkıntılar ve kanalların olduğu görülmektedir. Ayrıca gözenek çaplarının oldukça heterojen yapıda ve farklı boyutta olduğu gözlenmektedir.



Şekil 2. Ökseotundan elde edilen aktif kömürün Taramalı Elektron Mikroskopi (SEM) görüntüleri.

2.5. BET Yüzey Alanı ve Gözenek Boyutu Dağılımı

Adsorbent adsorbat etkileşimlerinde adsorpsiyon verimi açısından adsorbentin yüzey alanı önemli bir parametredir. Yüzey alanı büyüklüğü yanında gözeneklerin boyut dağılımı ve heterojenliği seçilen adsorbentin türüne ve uygulanan işlemlere (sıcaklık, pH, süre) göre değişiklik göstermektedir. Ökseotundan elde edilen aktif kömür için BET yüzey alanı ölçümü Malvern Mastersizer 2000 Hydro 2000MU marka cihazla gerçekleştirilmiş olup. BET yüzey alanı SBET: 2.97 m²/g, toplam gözenek hacmi V_{toplam}:0.01 cm³/g olarak tespit edilmiştir.

2.6. Elementel Analiz


Ökseotundan elde edilen aktif kömür için yapılan elementel analiz sonuçları çizelge2’de verilmiştir. Buna göre ökseotu yapraklı bir bitki olmasına rağmen % 62.8 karbon, %31.87 O içerdiği tespit edilmiştir.

Çizelge2. Karbonizasyon sonucu oluşan ürünün elementel analizi.

Elementel Bileşenler (yaş temel %)				
C	H	N	S	O
62.80	5.05	0.21	0.07	31.87

2.7. FT-IR Analizleri

FT-IR spektroskopisi ile karbon yüzeyinde bulunan fonksiyonel grupların kimyası hakkında bilgi edinilebilir.



Şekil 3. Ökseotundan elde edilen aktif kömür için FT-IR spektrumu.

Ökseotundan elde edilen aktif kömür FTIR spektrumu sonucunda elde edilen grafik şekil 3'te verilmiştir. Şekil 3'te 752 ile 814 cm^{-1} arasında görülen pik C-H gerilmelerini, 2800-3000 cm^{-1} aralığında gözlenen pik alifatik C-H gerilme titreşimlerini, 1510-1590 cm^{-1} aralığındaki pik aromatik C=C çift bağlarını, 1060 cm^{-1} civarındaki yoğun C-O titreşim piki, ligninin varlığını destekler. 1070-1170 cm^{-1} arasında görülen pik ise C-C-C bağlarını gösterir [19-20].


3. BULGULAR VE TARTIŞMA

3.1. Kurşun Adsorpsiyonu

Adsorpsiyon denemelerinde elde edilen aktif kömürün sulu çözeltide bulunan Pb^{+2} 'yi adsorplama potansiyeli pH'ya, sıcaklığa, adsorbent dozuna bağlı olarak laboratuvar ortamında kesikli sistemde gerçekleştirilmiştir. En iyi Katı/ Sıvı karışımını sağlayan en düşük karıştırma hızı 200 rpm olarak tespit edilmiştir. Bu sebeple adsorpsiyon deneylerinde bu karıştırma hızı kullanılmıştır. Kurşun adsorpsiyonu için denemelerde kullanılacak olan çözeltiler, $\text{Pb}(\text{NO}_3)_2$ dan hazırlanmış olan stok çözelti seyreltilerek elde edilmiştir.

3.2. Kurşun Adsorpsiyonuna pH'nın Etkisi

Çözelti pH'sı adsorpsiyon sürecini etkileyen ana değişkenlerden biridir. Adsorpsiyonda sadece metal iyonlarının yüklerini değil, aynı zamanda adsorbentün yüzey yükünü ve reaksiyon sırasında adsorbentin iyonizasyon derecesini de etkiler. Bu sebeple adsorpsiyon işlemlerinde adsorbent ve adsorbentin cinsine bağlı olarak adsorpsiyonun en iyi dercede gerçekleştiği pH değeri belirlenmelidir. Bu amaçla farklı pH'larda (1-6) yapılan adsorpsiyon denemelerinin sonuçları şekil 4'te gösterildiği gibidir. Şekilde de görüldüğü gibi çalışılan aralıkta en iyi giderim pH 5'ten sonra gerçekleşmiştir. pH 6'nın üzerine çıktığında kurşun çöktüğü için pH 6'nın üzerinde deneme yapılmamıştır.



Şekil 4. Pb⁺² adsorpsiyonuna pH etkisi (37°C, 0.4 g/1,50 mg/l).


Adsorbent kapasitesi pH:1 de 5.75 mg/g dan pH:6 da 50.78 mg/g' a yükselmiştir. En yüksek adsorpsiyon pH 5 tespit edilmiş olup diğer adsorpsiyon denemelerinde pH 5 kullanılmıştır.

pH çok düşük değerlerde olduğunda çözeltideki hidronyum iyonlarının sayısının artmasına ve adsorban yüzeyinin hidronyum iyonları ile çevrelenmesine neden olur. Bunun sonucunda Pb⁺² iyonlarının adsorbanın aktif bölgelerine bağlanması engellenir. pH arttığında, aktif bölgelere bağlanan hidronyum iyonları adsorban yüzeyini serbest bırakacaktır. Böylece metal iyonlarının boşaltılan yüzeye bağlanma olasılığı artacaktır [21].

PH 4 ten 6'ya yükseldikçe, adsorban yüzeyindeki negatif yükler artacağından, negatif yüklerin elektrostatik çekimi ile pozitif yüklü Pb(II)'nin adsorpsiyonu da artacaktır. Ayrıca adsorpsiyon aktif bölgeleri için Pb(II) ile rekabet edecek daha az H⁺ iyonu mevcut bulunacak ve sonuçta Pb(II) adsorpsiyonu artacaktır[22].

3.3. Kurşun Adsorpsiyonuna Sıcaklığın Etkisi

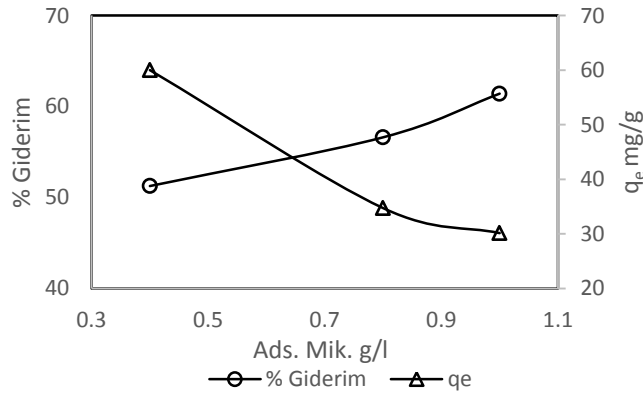
Adsorpsiyon prosesinde sıcaklık, adsorpsiyonun endotermik veya egzotermik olmasına bağlı olarak adsorpsiyon hızını ve adsorplanan madde miktarını etkiler. Proses endotermik ise adsorpsiyon hızı sıcaklığın artması ile, egzotermik ise de sıcaklığın azalması ile artacaktır. Sıcaklığın kurşun giderimine etkisini belirleyebilmek için 26-37-45°C sıcaklıklar parametre olarak seçilmiştir. Diğer parametreler denemelerde sabit tutulmuştur.



Şekil 5. Pb²⁺ adsorpsiyonuna sıcaklığın etkisi (pH5,50 mg/l, 0.4g/l).

Şekil5.'te kurşun adsorpsiyonuna sıcaklığın etkisi görülmektedir. Kurşun giderimi 26°C de % 46.95 iken 37°C de % 51.25, 45°C ise % 53.25 olarak belirlenmiştir. Sıcaklığın artışı ile adsorpsiyon veriminin arttığı söylenebilir. Bunun nedeni sıcaklığın artması ile adsorbatın çözünürlüğünün artması aynı zamanda çözelti viskozitesinin azalması olabilir. Ayrıca sulu çözeltilerde sıcaklığın artışı ile çözünen iyonların kinetik enerjileri ve hızları artar bunun sonucunda adsorbent yüzeyine çarpma olasılıkları artar. Bunların sonucunda kurşun iyonları adsorbent-çözelti film tabakasındaki direnci yenerek adsorbent yüzeyine oradan da tanecik içi difüzyon ile adsorbent gözeneklerine doğru hareket eder [23-24]. Adsorpsiyon olayının endotermik olması, yukarıda açıklanan taşınım olaylarındaki artış ile açıklanabilir

3.4. Kurşun adsorpsiyonuna adsorbent miktarının etkisi



Şekil 6. Pb²⁺ adsorpsiyonuna adsorbent miktarının etkisi (50 mg/l,pH 5, 37°C, t: 90 dakika).

Kurşun giderimine adsorbent miktarının etkisinin incelenmesinde 0.4 g/l, 0.8 g/l ve 1 g/l adsorbent miktarları parametre olarak seçilmiştir. Denemeler sırasında 37°C sıcaklık, 50 mg/l ve pH:5 sabit parametrelerdir. Adsorbent miktarının Pb²⁺ giderimine etkisi Şekil 6'da gösterilmiştir. Şekilden görüleceği gibi % kurşun giderimi adsorbent miktarının artışı ile artarken dengede adsorbentin

adsorpladığı kurşun miktarını gösteren qe miktarı azalmaktadır. Kurşun giderim yüzdesi 0.4 g/l de % 51.26 iken 1 g/l'de % 61.41'e artmıştır. Buna karşılık qe değerleri 0.4 g/l de 60 mg/g dan 1 g/l'de 30.1 mg/g'a azalmıştır. Giderim yüzdesinin adsorbent miktarındaki artış ile artması, çözelti içinde bulunan adsorbent yüzey alanının artması ve bununla bağlantılı olarak aktif sitelerin sayısının artması ile açıklanabilir. Aktif yüzey alanının artışı ile metal iyonları tutunacak daha fazla yüzey bulacak ve kolayca katı yüzeyine adsorplanarak giderim yüzdesinin artmasına ve çözeltide bulunan metal iyonu konsantrasyonunun düşmesine neden olacaktır. Adsorpsiyon işlemi gerçekleşirken meydana gelen transfer olayları şu şekilde sıralanabilir: Çözeltide bulunan metal iyonlarının katı-sıvı arayüzeyinde bulunan sınır tabakaya difüzyonu; sınır tabakadan adsorbent dış yüzeyine difüzyonu; dış yüzeyden adsorbent içindeki porlar ve gözeneklere difüzyonu. Tanecik içi difüzyona itici güç olarak çözeltideki metal iyonu konsantrasyonu söylenebilir [23],[24]. Çözeltideki adsorbent miktarının artması metal iyonu konsantrasyonunu düşürür ve itici gücün azalmasına dolayısıyla tanecik içi difüzyonun güçleşmesine neden olur. Sonuçta adsorbent iç bölgelerinde bulunan aktif yüzeyler boş kalır ve qe değeri adsorbent miktarının artışı ile azalır [25],[26],[27],[28].

4. SONUÇLAR

Doğada asalak bir bitki olarak bulunan ve ekonomik değeri olmayan ökseotu bitkisi aktifleştirilerek aktif kömür haline getirilmiştir.

Aktif kömür çeşitli analiz ve görüntüleme metodları ile karakterize edilmiştir.

Elde edilen aktif kömür Pb(II) adsorpsiyonunda kullanılmış ve oldukça yüksek bir adsorpsiyon kapasitesi göstermiştir.

Adsorban heterojen gözenekli boyuta sahip olup, özgül yüzey alanı 2.91 m²/g olarak elde edilmiştir.

Ökseotu üzerindeki Pb(II) adsorpsiyonunun adsorban dozu, başlangıç metal konsantrasyonu, pH ve sıcaklıktan güçlü bir şekilde etkilendiği tespit edilmiştir.

Çözelti pH'ının artmasıyla, adsorpsiyon kapasitesinin arttığı pH 5 ve pH 6 da en iyi giderimin olduğu belirlenmiştir.

Başlangıç kurşun konsantrasyonunun arttırılması, uzaklaştırma yüzdesini azaltmasına rağmen adsorpsiyon kapasitesini arttırmıştır.

Adsorpsiyon işlemi endotermik olarak belirlenmiştir

Sonuç olarak ökseotundan elde edilen aktif kömürün adsorbent olarak kullanılabileceği bu çalışma ile tespit edilmiş olup daha sonraki çalışmalarda diğer kirleticilerin adsorpsiyonunda da kullanılarak etkinliğinin araştırılması önerilmektedir.

TEŞEKKÜR

Bu çalışma Doktora tezi kapsamında Atatürk Üniversitesi Bilimsel Araştırma Proje Ofisi Tarafından Desteklenmiştir (BAP, 2013/108)

KAYNAKÇA

- [1] Naushad, Z. A. AL Othman, M. R. Awual, M., Alam, M., Eldesoky, G. E., (2015), Adsorption kinetics, isotherms, and thermodynamic studies for the adsorption of Pb²⁺ and Hg²⁺ metal ions from aqueous medium using Ti(IV) iodovanadate cation exchanger, *Ionics*, 21, 2237–2245.
- [2] Naushad, Z.A. AL Othman, Inamuddin, H. Javadian, (2015), Removal of Pb(II) from aqueous solution using ethylene diamine tetra acetic acid-Zr(IV) iodate composite cation exchanger: Kinetics, isotherms and thermodynamic studies, *Journal of Industrial and Engineering Chemistry* 25 ,35–41.
- [3] Naushad, Z. A., AL Othman, Sharma, G., Inamuddin, H.J., (2015), Kinetics, isotherm and thermodynamic investigations for the adsorption of Co(II) ion onto crystal violet modified amberlite IR-120 resin, *Ionics* ,21:1453–1459.
- [4] Gupta, A. R., (2009), Biosorption of hexavalent chromium by raw and acid-treated green alga *Oedogonium hatei* from aqueous solutions, *Journal of Hazardous Materials*, 163, 396-402.
- [5] Bulut, Z., (2007), Adsorption studies on ground shells of hazelnut and almond, *Journal of Hazardous Materials*, 149, 35-41.
- [6] Kula, M. Ugurlu, H. Karaoglu, A. Celik, A., (2008), Adsorption of Cd(II) ions from aqueous solutions using activated carbon prepared from olive stone by ZnCl₂ activation, *Bioresource technology*, 99, 492-501.
- [7] Kazemipour, M. Ansari, S. Tajrobehkar, Majdzadeh, M., Kermani, H.R., (2008), Removal of lead, cadmium, zinc, and copper from industrial wastewater by carbon developed from walnut, hazelnut, almond, pistachio shell, and apricot stone, *Journal of Hazardous Materials*, 150, 322-327.
- [8] Lalhruaitluanga, K. Jayaram, M.N. Prasad, K., Kumar, K, (2010), Lead(II) adsorption from aqueous solutions by raw and activated charcoals of *Melocanna baccifera* Roxburgh (bamboo)--a comparative study, *Journal of Hazardous Materials*, 175, 311-318.
- [9] Li, W., Zhang, L., Peng, J., Li, N., Zhang, S. and Guo, S., (2008), Tobacco stems as a low cost adsorbent for the removal of Pb(II) from wastewater: Equilibrium and kinetic studies, *Industrial Crops and Products*, 28, 294–302.
- [10] Saadat, A. Karimi-Jashni, M., Doroodmand, M., (2014), Synthesis and characterization of novel single-walled carbon nanotubes- doped walnut shell composite and its adsorption performance for lead in aqueous solutions, *Journal of Environmental Chemical Engineering*, 2 ,2059-2067.
- [11] Kumar, S. Ramalingam, S.D. Kirupha, A. Murugesan, T. Vidhyadevi, G., Sivanesan, S., (2011), Adsorption behavior of nickel(II) onto cashew nut shell: Equilibrium, thermodynamics, kinetics, mechanism and process design, *Chemical Engineering Journal*, 167, 122-131.

- [12] Zhou, R. Zhang, X. Gu, J. Lu, M., (2015), Adsorption of Divalent Heavy Metal Ions from Aqueous Solution by Citric Acid Modified Pine Sawdust, Separation Science and Technology, 50, 245-252.
- [13] Zou, Y. Tang, C. Jiang, J. Zhang, M., (2015), Efficient adsorption of Cr(VI) on sunflower seed hull derived porous carbon, Journal of Environmental Chemical Engineering, 3, 898-905.
- [14] Shoaib, H., Al-Swaidan, M., (2015), Optimization and characterization of sliced activated carbon prepared from date palm tree fronds by physical activation, Biomass and Bioenergy, 73, 124-134.
- [15] Pearlin K., P. Senthil, K., Sangita G., Shahul Hameed, S., Sindhuja, M., Prabhakaran, C., (2014), Study of adsorption kinetic, mechanism, isotherm, thermodynamic, and design models for Cu(II) ions on sulfuric acid-modified Eucalyptus seeds: temperature effect, Desalination and Water Treatment, 7, 1-18.
- [16] Gupta A., Balomajumder, C., (2015), Simultaneous adsorption of Cr(VI) and phenol onto tea waste biomass from binary mixture: Multicomponent adsorption, thermodynamic and kinetic study, Journal of Environmental Chemical Engineering, 3, 785-796.
- [17] Khoramzadeh, E., Nasernejad, B., Halladj, R., (2013), Mercury biosorption from aqueous solutions by sugarcane bagasse. Journal of the Taiwan Institute of Chemical Engineers, 44, 266–269.
- [18] Esfandiari, N., Nasernejad, B., Taghi Ebadi, T., (2014), Removal of Mn(II) from groundwater by sugarcane bagasse and activated carbon (a comparative study): Application of response surface methodology (RSM), Journal of Industrial and Engineering Chemistry, 20, 3726–3736.
- [19] Asadullah, M., Asaduzzaman, M., Kabir, M. S., Mostofa, M.G., Miyazawa, T., (2010), Chemical and structural evaluation of activated carbon prepared from jute sticks for brilliant green dye removal from aqueous solution, Journal of Hazardous Materials 174, 437–443.
- [20] Anirudhan, T. S. and Sreekumari, S. S., (2011), Adsorptive removal of heavy metal ions from industrial effluents using activated carbon derived from waste coconut buttons, Journal of Environmental Sciences, 23(12), 1989–1998.
- [21] Youssef A.M., Ahmed, A.I., Amin, M.I., El-Banna, U.A., (2014), Adsorption of lead by activated carbon developed from rice husk, Desalination and Water Treatment, 5, 1-14.
- [22] Chakravarty S., A. Mohanty, T.N. Sudha, A.K. Upadhyay, J. Konar, J.K. Sircar, A. Madhukar, K.K. Gupta, (2010), Removal of Pb(II) ions from aqueous solution by adsorption using bael leaves (Aegle marmelos), Journal of Hazardous Materials, 173, 502-509.
- [23] Gündoğdu, A., (2010), Fabrika çay atıklarından aktif karbon üretimi, karakterizasyonu ve adsorpsiyon özelliklerinin incelenmesi, Doktora Tezi, Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü, Trabzon.

- [24] Kalavathy, M. H. and Miranda, L. R., (2010),. A solid phase extractant for the removal of copper, nickel and zinc from aqueous solutions, Chemical Engineering Journal, 158, 188–199.
- [25] Sharma, D.C. and Forster, C.F., (1993), Removal of hexavalent chromium using sphagnum moss peat, Water Research, 27, 1201–1208.
- [26] Shukla, A., Zhang, Y.H., Dubey, P., Margrave J.L. ve Shukla, S.S., (2002), The role of sawdust in the removal of unwanted materials from water, Journal of Hazardous Materials, 95, 137–152.
- [27] Calvete, T., Lima, E. C., Cardoso, N. F., Dias, S. L. P. and Pavan, F. A., (2009), Application of carbon adsorbents prepared from the brazilian pine-fruit-shell for the removal of Procion Red MX 3B from aqueous solution kinetic, equilibrium, and thermodynamic studies, Chemical Engineering Journal, 155, 627–636.
- [28] Köse, B.(2015), Akut Zehirlenmelerin Etkisinin Azaltılmasında Farklı Adsorbentlerin Etkinliğinin İncelenmesi, Doktora Tezi, Atatürk Üniversitesi Fen Bilimleri Enstitüsü, Erzurum.