




ULUSLARARASI 3B YAZICI TEKNOLOJİLERİ
VE DİJİTAL ENDÜSTRİ DERGİSİ

INTERNATIONAL JOURNAL OF 3D PRINTING
TECHNOLOGIES AND DIGITAL INDUSTRY

ISSN:2602-3350 [Online]

URL: <https://dergipark.org.tr/ij3dptdi>

ALZHEİMER HASTALIĞININ ERKEN TEŞHİSİNE YÖNELİK UZMAN SİSTEM GELİŞTİRİLMESİ

DEVELOPING A EXPERT SYSTEM FOR EARLY DIAGNOSIS OF ALZHEIMER'S DISEASE

Yazarlar (Authors): Osamah Khaled Musleh SALMAN^{ID*}, Sema ÇAYIR^{ID}, Mustafa Melikşah ÖZMEN^{ID}, Enes AÇIKGÖZOĞLU^{ID}

Bu makaleye şu şekilde atıfta bulunabilirsiniz (To cite to this article): Salman O. K. M., Çayır S., Özmen M. M., Açıkgözoğlu E., "Alzheimer Hastalığının Erken Teşhisine Yönelik Uzman Sistem Geliştirilmesi" *Int. J. of 3D Printing Tech. Dig. Ind.*, 9(1): 21-35, (2025).

DOI: 10.46519/ij3dptdi.1418059

Araştırma Makale/ Research Article

Erişim Linki: (To link to this article): <https://dergipark.org.tr/en/pub/ij3dptdi/archive>

ALZHEİMER HASTALIĞININ ERKEN TEŞHİSİ İÇİN MAKİNE ÖĞRENİMİ TABANLI UZMAN SİSTEM GELİŞTİRİLMESİ

Osamah Khaled Musleh SALMAN^a^{*}, Sema ÇAYIR^a, Mustafa Melikşah ÖZMEN^a, Enes AÇIKGÖZOĞLU^b

^aIsparta Uygulamalı Bilimler Üniversitesi, Teknoloji Fakültesi, Mekatronik Mühendisliği Bölümü, TÜRKİYE
^bIsparta Uygulamalı Bilimler Üniversitesi, Keçiborlu Meslek Yüksekokulu, Bilgisayar Teknolojileri Bölümü, TÜRKİYE

^{*} Sorumlu Yazar: osamahkms1994@gmail.com

(Geliş/Received: 11.01.24; Düzeltilme/Revised: 10.12.24; Kabul/Accepted: 13.01.25)

ÖZ

1990'ların başından bu yana internet kullanımının hızla yaygınlaşması, anlamlı analiz için gelişmiş araçlar gerektiren büyük veri kümelerinin oluşmasına yol açmıştır. Yapay zeka teknolojilerinin, özellikle erken teşhis ve hastalık tespitinde hataların azaltılması için kullanıldıkları sağlık hizmetlerinde bu konuda etkili olduğu kanıtlanmıştır. Bu çalışma, yaşlı bireyler arasında yaygın olan ilerleyici bir nörodejeneratif durum olan Alzheimer Hastalığının (AD) erken teşhisi için yapay zeka tabanlı bir uzman sistem geliştirmeye odaklanmaktadır. Çalışmada 174 örnekle DARWIN veri kümesi (89'u AD'li ve 85'i AD'siz) kullanılarak AdaBoost, Gradient Boost, VotingHard, Stack, Decision Trees, Random Forest, Naive Bayes ve 1D-CNN olmak üzere sekiz makine öğrenimi algoritması ile eğitilmiştir. Çalışmada kullanılan Stack modeli %91,43 doğruluk, %93,75 özgüllük, %94,44 duyarlılık, %89,47 kesinlik, %91,89 F-ölçümü ve %91,43 AUC değeri ile yüksek bir tahmin performansı elde ederek en etkili model olarak ortaya çıkmıştır. Orta düzeyde performans gösteren modeller arasında AdaBoost %88,57 doğruluk, %88,24 özgüllük, %88,89 duyarlılık, %88,89 kesinlik, %88,89 F-ölçümü ve %88,56 AUC değeri elde etmiştir. Buna karşılık, VotingHard modeli %80,00 doğruluk, %77,78 özgüllük, %77,78 duyarlılık, %82,35 hassasiyet, %80,00 F-ölçümü ve %80,00 AUC değeri ile en düşük performansı göstermiştir. Bu bulgular, Stack modelinin güvenilir erken evre AD teşhisi potansiyelini vurgulamakta ve algoritma performansına ilişkin karşılaştırmalı bir bakış açısı sağlamaktadır.

Anahtar Kelimeler: Alzheimer hastalığı erken Teşhisi, Yapay zekâ, Uzman sistem.

DEVELOPING A EXPERT SYSTEM FOR EARLY DIAGNOSIS OF ALZHEIMER'S DISEASE

ABSTRACT

The rapid expansion of Internet use since the early 1990s has led to the generation of massive datasets, necessitating advanced tools for meaningful analysis. Artificial intelligence (AI) technologies have proven instrumental in this regard, particularly in healthcare, where they are employed for early diagnosis and error reduction in disease detection. This study focuses on developing an AI-based expert system for the early diagnosis of Alzheimer's Disease (AD), a progressive neurodegenerative condition prevalent among elderly individuals. Utilizing the DARWIN dataset comprising 174 subjects (89 with AD and 85 without), eight machine learning algorithms were evaluated: AdaBoost, Gradient Boost, VotingHard, Stack, Decision Trees, Random Forest, Naive Bayes, and 1D-CNN. The Stack model emerged as the most effective, achieving a high predictive performance with 91.43% accuracy, 93.75% specificity, 94.44% sensitivity, 89.47% precision, an F-measure of 91.89%, and an AUC value of 91.43%. Among the models with moderate performance, AdaBoost achieved 88.57% accuracy, 88.24% specificity, 88.89% sensitivity, 88.89% precision, an F-measure of 88.89%, and an

AUC value of 88.56%. Conversely, the VotingHard model demonstrated the lowest performance, with 80.00% accuracy, 77.78% specificity, 77.78% sensitivity, 82.35% precision, an F-measure of 80.00%, and an AUC value of 80.00%. These findings highlight the Stack model's potential for reliable early-stage AD diagnosis and provide a comparative perspective on algorithmic performance.

Keywords: Early detection of Alzheimer's disease, Artificial intelligence, Expert system.

1. GİRİŞ

Alzheimer hastalığı (AH), genellikle orta ve ileri yaşlarda ortaya çıkan ve zamanla ilerleyen bir nörodejeneratif (sinir hücrelerindeki yapısal ve işlevsel dejenerasyon) hastalıktır. Hastalık, hafıza kaybı, bilişsel bozukluklar ve kişilik değişiklikleri gibi semptomlarla kendini gösterir. Alzheimer, beyindeki sinir hücrelerinin zamanla hasar görmesi ve ölmesi sonucu ortaya çıkar [1]. Bu nedenle, hastalığın seyri zamanla ilerleyerek bireyin günlük yaşamını etkiler [2]. Hastalığın tedavisinde hem farmakolojik hem de farmakolojik olmayan yöntemler kullanılmakta ve bu tedavilerin etkinlikleri üzerine araştırmalar sürmektedir. Günümüzde, egzersiz uygulamaları farmakolojik olmayan etkili bir tedavi yöntemi olarak ön plana çıkmaktadır [3]. Bu bağlamda, hastalığın erken tanı önlemlerinin zamanında alınması açısından kritik önem taşımaktadır. Alzheimer hastalığının tespiti için bir dizi uzman tarafından klinik değerlendirme ve testler yapılmaktadır [4]. Ancak, Alzheimer hastalığının kesin teşhisi ancak otopsi sonucu ile konulabilmektedir [5]. Bu durum, Alzheimer hastalığının tespiti için çalışmaların artırılması ve tanı sonuçlarının iyileştirilmesi gerekliliğini göstermektedir.

Günümüzde birçok hastalık tespitine yönelik yeni teknolojik uygulamalar gerçekleştirilmektedir ve çalışmaların sonuçları tartışılmaktadır. Son dönemlerde yapay zekâ ve makine öğrenme algoritmaları ile yapılan çalışmalarda artışlar gözlemlenmektedir [6]. Artışların en önemli sebeplerinden biri, sonuçları açısından değerlendirildiğinde yüksek doğrulukları ile sağlık alanında umut vaat eden bir alan olmaya başlamasıdır. Hoşgör (2022), sağlıkta yapay zekânın kullanımını 125 adet tez çalışması ile ele alarak incelemiştir. Hazırlanan makalede yapay zekâ ve makine öğrenme algoritmalarının kullanımı, hastalık teşhisinde güvenilir ve başarılı sonuçların elde edildiği tespit edilmiştir [7].

Li ve ark. Alzheimer hastaları ile hafif bilişsel bozukluk (MCI) hastalarının teşhisi için yaptıkları çalışmada dayanıklı ya da sağlam olarak ifade edilen Derin Öğrenme tekniğini geliştirmişlerdir. Çalışmanın deneysel sonuçlar, önerilen tekniğin AH tanısında çok etkili olduğunu ve sınıflandırma doğruluğunu klasik derin öğrenme yöntemlerine göre ortalama %5,9 artırdığını göstermiştir [8].

Benzer şekilde, Hu ve çalışma arkadaşları, Alzheimer hastalığını tahmin etmek için yenilikçi bir yöntem geliştirmiştir. İlk aşamada 90 farklı beyin bölgesine ait aktiviteleri bir matrise dönüştürmüşler ve ardından bu bölgeler arasındaki işlevsel bağlantıyı belirlemek için korelasyon hesaplamaları yapmışlardır. Daha sonra, oluşturulan korelasyon matrislerini sınıflandırmak amacıyla Otomatik Kodlayıcı (AE) adı verilen bir sinir ağı modeli kullanmışlardır. Deneysel sonuçlar, bu yöntemin geleneksel yöntemlere kıyasla daha başarılı olduğunu göstermiştir. Özellikle destek vektör makineleri (SVM) ile karşılaştırıldığında, tahmin doğruluğunda yaklaşık %25'lik bir iyileşme sağlanmıştır [9].

Karabay ve Çavaş çalışmalarında, hastalık teşhisi için AlexNet, MobileNetV2 mimarileri ve Evrişimsel Sinir Ağları (ESA) modeli kullanılmıştır. Çalışmada, 6400 adet manyetik rezonans (MR) görüntüsü kullanılmıştır. Her iki mimariden elde edilen özellikler birleştirilmiş ve bu özelliklerin seçiminde Komşuluk Bileşen Analizi (KBA) algoritması kullanılmıştır. Ardından, özelliklerin sınıflandırılması Destek Vektör Makineleri (DVM) ile gerçekleştirilmiş ve modelin %100 doğruluk oranına ulaştığı rapor edilmiştir [10].

Öziç vd., OASIS veri tabanından temin edilen 70 Alzheimer hastası ve 70 sağlıklı bireye ait 3B T1 ağırlıklı manyetik rezonans (MR) görüntülerini kullanmış ve bu görüntüler üzerinde 116 subkortikal bölgenin hacimsel ölçümlerini gerçekleştirebilen atlas tabanlı bir

hacim ölçüm ve sınıflandırma modeli geliştirmiştir. Ölçülen değerler, her bir denekte gri madde, parankim ve toplam beyin hacmi ile ilişkilendirilerek normalizasyon işlemine tabi tutulmuştur. Bu sayede, 140x116 matris boyutuna sahip dört farklı veri kümesi elde edilmiştir. Veri kümeleri, entropi, t-testi, ROC, Bhattacharyya ve Wilcoxon özellik derecelendirme yöntemleri kullanılarak en anlamlı özellikten en anlamsız özelliğe doğru sıralanmıştır. Sıralanan veriler, her bir döngüde birleştirilmiş ve Destek Vektör Makineleri (SVM) kullanılarak lineer ve RBF (Radial Basis Function) çekirdekleri ile 10 kat çapraz doğrulama yöntemiyle sınıflandırma işlemi gerçekleştirilmiştir. Tüm senaryolar ayrıntılı bir şekilde analiz edilerek, en az sayıda özellikle en iyi sonuçları sağlayan özellik derecelendirme ve sınıflandırma yöntemleri belirlenmiştir. Normalizasyon ve özellik derecelendirme yöntemlerinin sınıflandırma sonuçları üzerindeki etkisi detaylı bir şekilde incelenmiştir. Deney sonuçlarına göre, ROC tabanlı özellik derecelendirme yöntemiyle lineer SVM kullanıldığında toplam beyin hacmi normalizasyonu ile %95.71 hassasiyet, %94.29 özgüllük, %95.00 doğruluk ve 0.95 eğri altında kalan alan (AUC) değeri elde edilmiştir [11].

Nalçakan (2018) Alzheimer hastalığı teşhisi için, Alzheimer hastaları ile normal kontrol gruplarına ait manyetik rezonans görüntüleri içeren bir veri kümesi kullanılmış ve bu veri kümesi, üç boyutlu evrişimli sinir ağları (3D CNN) ile eğitim ve test verisi olarak işlenmiştir. Bu çalışma sonucunda geliştirilen yapay zeka modeli, test verileri üzerinde %90.6 doğruluk oranına ulaşarak Alzheimer hastalığının teşhisinde etkili bir performans sergilemiştir. [12].

Wang vd., Alzheimer hastalığının erken teşhisi için yapay sinir ağları kullanarak bir erken uyarı modeli geliştirmiştir. Erken uyarı modelini geliştirmek için Lojistik Regresyon, k-En Yakın Komşu (kNN) ve Destek Vektör Makinesi (SVM) modelleriyle karşılaştırılmıştır. Üç katmanlı geri yayımlı bir yapıya sahip olan modelin performansı, duyarlılık, özgüllük, doğruluk, pozitif ve negatif prognostik değer (PPV ve NPV) ve eğri altındaki alan (AUC) ölçütleriyle değerlendirilmiştir. YSA modeli, %92.13 doğruluk, %87.28 duyarlılık, %94.74 özgüllük

ve 0.897 AUC değeri ile en iyi sonuçları sağlamıştır [13].

Janghel ve Rathore, ADNI veri tabanını kullanarak Alzheimer hastalığının teşhisi için derin öğrenmeye dayalı bir yöntem sunmuştur. Veri setindeki fMRI ve PET görüntüleri, sağlıklı bireylerin verileriyle birlikte analiz edilmiştir. Görüntüler, önce 3D'den 2D'ye dönüştürülmüş ve ardından Konvolüsyonel Sinir Ağları'nın (CNN) VGG-16 mimarisi kullanılarak özellik çıkarımı yapılmıştır. Sınıflandırma işlemi SVM, Doğrusal Ayrım, K-ortalama Kümeleme ve Karar Ağaçları algoritmaları ile gerçekleştirilmiştir. Deney sonuçları, fMRI veri seti için %99.95, PET veri seti için ise %73.46 doğruluk oranı elde edildiğini göstermiştir [14].

Alzheimer DARWIN veri setini analiz etmek için Rastgele Orman (RF), Lojistik Regresyon (LR), K-en Yakın Komşu (KNN), Doğrusal Diskriminant Analizi (LDA), Gaussian Naive Bayes (GNB) ve SVM algoritmalarını kullanmıştır. Algoritmaların doğruluk oranları %77.14 ile %91.4 arasında değişmiştir [15]. Benzer şekilde, Subha ve arkadaşları (2022), aynı veri setini LR, KNN, SVM, Karar Ağaçları (DT), RF ve AdaBoost algoritmalarıyla eğitmiş ve %86.79 ile %90.57 arasında doğruluk oranları elde etmiştir [16]. Gattulli ve arkadaşları (2022), Alzheimer DARWIN veri seti üzerinde LR, KNN, SVM, DT, RF, LDA, GNB, Çok Katmanlı Perceptron (MLP) ve Öğrenme Vektörü Kantizasyonu (LVQ) algoritmalarını kullanmış, doğruluk oranlarının %71.2 ile %83.5 arasında olduğunu rapor etmiştir [17]. Önder ve arkadaşları (2023) ise XGBoost, AdaBoost, Gradient Boost ve Voting algoritmaları ile %75 ile %85 arasında değişen doğruluk oranlarına ulaşmıştır [18].

Tablo 1. Literatürde DARWIN veri seti üzerinde yapılan çalışmalar

Çalışma	Kullanılan Makine Öğrenmesi Algoritmaları	Doğruluk
Gregorio vd., [15]	RF, LR, KNN, LDA, G-NV, SVM	77,14% - 91,4%
Subha vd., [16]	LR, DT, KNN, RF, AdaBoost, SVM,	86,79%- 90,57%

Gattulli vd., [17]	RF, LR, KNN, LDA, G-NV, SVM, DT, MLP, LVQ	71,2%-83,5%
Önder vd. [18]	XGBoost, AdaBoost, GradientBoost, Voting	75%-85%

1.1 Araştırma soruları/hipotezleri

Hipotez 1: Alzheimer hastalığının erken teşhisine yönelik kullanılan veri setiyle eğitilen makine öğrenimi modelleri, %90'ın üzerinde bir doğruluk oranı sağlayabilir mi?

Hipotez 2: Alzheimer teşhisinde kullanılan makine öğrenimi algoritmaları arasında en yüksek performans hangi algoritma ile elde edilebilir?

Hipotez 3: El yazısı verileri, Alzheimer hastalığının erken belirtilerini belirlemek için uygun maliyetli ve güvenilir biyobelirteçler olarak kullanılabilir mi?

2. MATERYAL VE METOT


2.1. Materyal

Çalışmada kullanılan makine öğrenme algoritmaları bu bölümde detaylı olarak verilmiştir.

2.1.1. AdaBoost

Adaboost (Adaptive Boosting), sınıflandırma ve regresyon gibi görevleri gerçekleştirmek için kullanılan bir makine öğrenme algoritmasıdır. İsmi “adaptive” (uyarlamalı) ve “boosting” (güçlendirme) terimlerinin birleşiminden alan Adaboost, zayıf sınıflandırma algoritmalarının performansını artırarak daha güçlü sınıflandırıcılar oluşturmak amacıyla kullanılmaktadır [19]. Bu algoritma, zayıf sınıflandırıcıların bir arada çalışmasıyla daha güçlü bir sınıflandırma algoritması oluşturmaktadır [20]. Adaboost algoritmasında, ilk olarak tüm verilere ait ağırlık değerleri eşit seçilir ve veriler eğitilir. Daha sonra zayıf olan sınıflandırıcı üzerinde örneklerin ağırlık değerleri artırılmaya başlanır. Sınıflandırıcı, her döngüde ağırlık değerini güncellemektedir. Böylece hatalı olan örneklerin önemi artmaktadır [19,20]. Ağırlıkları artırılmış olan örnekler, bir sonraki sınıflandırıcıda öne çıkarak seçilme olasılığını artırmış olur. Bu şekilde oluşturulan tüm sınıflandırıcıların bir araya getirilmesiyle daha

yüksek doğrulukla bir sınıflandırıcı elde edilmektedir. Algoritmaya ait şema, Şekil 1’de gösterilmektedir [19,20].



Şekil 1. Adaboost Algoritması [20].

2.1.2. Gradient Boost

Gradient Boost algoritması, standart makine öğrenmesinden farklı olarak tahminleri sırayla yapan bir topluluk algoritmasıdır [21]. Algoritmanın temel amacı, düşük doğruluk değerindeki tahminleri yüksek doğrulukla tahminlere çevirmektir. Algoritmada ilk olarak tahminleri üretmek için y_i^p fonksiyonu oluşturulur. Tahminler ve hedef değer arasındaki farkın hesaplanması için ise bir “Loss” fonksiyonu oluşturulmaktadır. İlk iterasyondan sonra y_i^p ve “Loss” fonksiyonları birleştirilerek hedef değerle tahmin edilen değer arasındaki fark yeniden hesaplanır. Bu işlem tekrarlanarak y_i^p fonksiyonuna ait doğruluk değeri artırılmaya ve hedef değere olan uzaklık azaltılmaya çalışılmaktadır [21].

$$\text{Loss} = \text{MSE} = \sum (y_i - y_i^p)^2 \quad (1)$$

Denklemden y_i i. hedef değer, y_i^p ise i. tahmin edilen değeri, “Loss” ise kayıp fonksiyonunu temsil etmektedir. Elde edilen tahminlerin kayıp fonksiyonlarını minimum seviyede tutmak gerekmektedir. Gradyan inişi kullanılarak her iterasyonda öğrenme oranları güncellenir ve kayıp fonksiyonunun minimum değeri bulunur [22].


$$y_i^p = y_i^p - a * \delta \sum \frac{(y_i - y_i^p)^2}{\delta y_i^p} \quad (2)$$

$$y_i^p = y_i^p - a * 2 * \sum (y_i - y_i^p) \quad (3)$$

2.1.3. Voting hard

Voting hard sınıflandırıcısı, tahmin doğruluğunun artırılabilmesi amacıyla birden çok sınıflandırma algoritmasını birleştiren bir yöntemdir [23]. Tek bir modele tahmin yaptırmak yerine, kullanılan tüm modellerin çıktısının oylama prensibine dayanmaktadır. Yani, birden çok modelin verdiği cevaba bakılarak en doğru sonuç hedeflenmektedir

[23,24]. Algoritmaya ait şema, Şekil 2’de gösterilmektedir.




Şekil 2. VotingHard Modeli[24]

2.1.4. Karar ağaçları

Karar ağaçları modeli, kararları veya muhtemel sonuçları göstermek amacıyla kullanılan ağaç benzeri bir modeldir [25]. Bu model, araştırma çalışmalarında gerçekleştirilen analizlerde bir sonuca ulaşabilmek için izlenmesi gereken yolu belirlemekte kullanılmaktadır. Karar ağaçları temel olarak, iç düğümlerden, dallardan ve sonuç düğümünden meydana gelmektedir [25,26]. Algoritmaya ait şema, Şekil 3’te gösterilmektedir.

1. İç Düğüm: İç düğüm belirli bir özelliği değerlendirir ve test eder.
2. Dallar: İç düğümde yapılan değerlendirmelerin sonuçlarını göstermektedir.
3. Sonuç Düğümü: Çıktı olarak alınan kararı göstermektedir.




Şekil 3. Örnek karar ağacı yapısı [26].

2.1.5. Rastgele Orman

Rastgele Orman(RO) algoritması temel olarak karar ağaçlarının birleşiminden oluşmaktadır. Karar ağaçlarının genel yapısı kök, düğümler, dallar ve yapraklardan oluşmaktadır. Kök ve düğümler kararların ölçütlerini, yapraklar verilen kararların durumlarını, dallar ise ölçütler ile kararlar arasındaki bağlantıyı temsil etmektedir [27,28]. RO algoritması, her bir düğümde rastgele olarak seçilmiş olan değişkenlerin en iyi olanını belirleyip düğümleri dallara ayırmaktadır. Ana veri setinde yaptığı değişikliklerle alt veri setleri

oluşturulmaktadır. Daha sonrasında rastgele özellikler seçilerek ağaçlar oluşturulur ve ağaçlarda budama yapılmaz. Orijinal eğitim veri setinin yaklaşık olarak %70’i ön yükleme örneklerini, %30’u ise hataları test etmek için kullanılır [27].

Rastgele Orman (RO) algoritması, her düğümde rastgele seçilen en iyi değişkeni belirleyerek dallara ayırır. Orijinal veri setinden küçük veri setleri oluşturulur ve bu veri setleriyle ağaçlar geliştirilir; ağaçlarda budama yapılmaz. Algoritma, her düğümde kullanılan değişken sayısını (m) ve toplam ağaç sayısını (N) ayarlayarak çalışır. Eğitim verisinin %67’si modeli eğitmek, %33’ü ise hataları test etmek için kullanılır. Algoritmanın şeması Şekil 4’te sunulmaktadır [28,29].



Şekil 4. RO Algoritması [29].

2.1.6. Naive bayes

Bayes teoremi, 1701-1761 yılları arasında Thomas Bayes tarafından geliştirilmiş bir teoremdir. Bayes teoremi, bir değişken için koşullu olasılıklar ile marjinal olasılıklar arasındaki bağıntıyı göstermektedir. Herhangi bir olayın meydana gelmesinde birden fazla bağımsız neden varsa, bu nedenlerden birinin olayı meydana getirme olasılığını hesaplamada kolaylık sağlar [30]. Bayes teoremine ait denklem aşağıda verilmiştir. (Denklem 4).

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (4)$$

- $P(A)$; A için olasılık veya marjinal olasılık
- $P(A|B)$; verilen bir B olayında A olayının koşullu olasılığıdır. B olayı var ise A olayının gerçekleşme olasılığıdır.
- $P(B|A)$; A olayı gerçekleşmiş ise B olayının olma olasılığıdır.
- $P(B)$; B olayı için önsel olasılıktır.

Naive Bayes sınıflandırma modeli, Bayes teoreminin basitleştirilmiş bir halidir. Makine öğrenmesi uygulamalarında denetimli öğrenmenin bir alt sınıfıdır. Naive Bayes

modelinde, sınıflandırılması gereken veriler ve bu verilerin hangi kümeye ait olduğu belirlenmiştir. Bu kümelerden yararlanılarak daha sonrasında gelen bir verinin hangi sınıfa ait olduğu belirlenir [30].

2.1.7. Stack

Stack, birçok makine öğrenimi algoritmasının tahminlerini birleştirmek için kullanılan bir topluluk öğrenme tekniğidir [31]. İlk olarak, çeşitli temel algoritmalar veri kümesi üzerinde eğitilir ve tahminler üretir. Ardından, bu temel algoritmaların tahminleri, genellikle başka bir makine öğrenimi modeli olan bir meta-algoritma tarafından birleştirilir. Bu birleştirme süreci, daha iyi tahminler elde etmeyi amaçlar ve farklı modellerin güçlü yanlarını bir araya getirerek modelin genel performansını artırabilir. Stack, karmaşık problemlerde daha iyi sonuçlar elde etmek için yaygın olarak kullanılan bir tekniktir [32,33].

2.1.8. 1D-CNN

Tek boyutlu evrişimli sinir ağları (1D-CNN), derin öğrenme alanında önemli bir yere sahiptir ve çeşitli uygulamalarda etkili sonuçlar elde etmiştir [34,35]. Bu ağlar, özellikle görüntü işleme ve sınıflandırma görevlerinde yaygın olarak kullanılmaktadır. Tek boyutlu CNN'lerin temel avantajlarından biri, öznetelik çıkarımını otomatik olarak gerçekleştirmeleri ve geleneksel yöntemlere göre daha genel çözümler sunmalarıdır [34]. Bu özellikleri, onları birçok farklı görev için uygun hale getirmektedir.


Tek boyutlu evrişimli sinir ağları, genellikle bir dizi ardışık katmandan oluşur. Bu katmanlar, giriş verilerinden özellikleri çıkarmak için filtreler kullanır ve bu filtrelerin ağırlıkları, geri yayılım algoritması ile güncellenir [34,35]. Özellikle, CNN'ler görüntü sınıflandırma, nesne tanıma ve segmentasyon gibi alanlarda yüksek başarı oranları ile dikkat çekmektedir [36,37]. Örneğin, U-Net mimarisi, tıbbi görüntü segmentasyonunda sıkça tercih edilmektedir ve bu alandaki başarıları ile literatürde önemli bir yer edinmiştir [37].

Ayrıca, tek boyutlu CNN'ler, finansal verilerin tahmin edilmesi gibi farklı alanlarda da kullanılmaktadır. Örneğin, bir çalışmada, tek boyutlu CNN'ler kullanılarak finansal piyasa hareketlerinin tahmin edilmesi üzerine başarılı sonuçlar elde edilmiştir [38]. Bu tür

uygulamalar, CNN'lerin çok yönlü kullanım potansiyelini göstermektedir.

Bu ağlar, verinin yerel bağıntılarını öğrenme konusunda makine öğrenme algoritmalarına göre üstünlük sağlar ve bu sayede karmaşık özellikleri tespit edebilmektedirler. Bunun yanında, basit makine öğrenme algoritmaları, genellikle daha az veri gerektiren ve daha hızlı çalışabilen modeller olarak avantaj sağlarlar. Ancak, 1D-CNN'ler karmaşık desenleri ve ilişkileri daha iyi öğrenebilirken, basit makine öğrenme algoritmaları daha az hesaplama gücü gerektiren ve yorumlanabilirliği yüksek çözümler sunar. Bu nedenle, problem türüne ve veri yapısına bağlı olarak her iki yaklaşımın da kendine özgü üstünlükleri vardır.

Sonuç olarak, tek boyutlu evrişimli sinir ağları, derin öğrenme alanında önemli bir yere sahiptir ve görüntü işleme, finansal tahminler gibi birçok alanda etkili bir şekilde kullanılmaktadır. Bu ağların otomatik öznetelik çıkarımı yapabilme yetenekleri ve yüksek başarı oranları, onları günümüzdeki en popüler derin öğrenme yöntemlerinden biri haline getirmiştir [34-38]. 1D-CNN genel yapısı Şekil 5'te gösterilmektedir.



Şekil 5. 1D-CNN Yapısı [39].

2.2. Metot

Alzheimer hastalığının erken teşhisine yönelik geliştirilen makine öğrenme tabanlı uzman sistemi için açık kaynak erişimli DARWIN veri seti kullanılmıştır [40]. Kullanılan veri seti, 85 Alzheimer hastası olmayan ve 89 Alzheimer hastası olan toplam 174 veriden oluşmaktadır. Alınan veri setindeki 450 özellik için her bir kişiye, tıbbi tahliller kullanılarak bazı ölçümler yapılmıştır. Çalışmada kullanılan veri seti, AdaBoost, Gradient Boost, Voting Hard, Stack, Karar Ağaçları, Rastgele Orman, Naive Bayes ve tek boyutlu evrişimli sinir ağları olmak üzere 8 farklı makine öğrenme algoritmasıyla modellenmiştir. Elde

edilen modellerin doğruluk, özgüllük, duyarlılık, kesinlik, F-ölçüsü, AUC ve ROC eğrisi performans değerlendirme ölçütlerine göre değerlendirilmiş ve sonuçlar karşılaştırılmıştır. Çalışmadaki Alzheimer hastalığının erken teşhisine yönelik geliştirilen uzman sistemin pseudo kodu aşağıda verilmiştir.

DARWIN veri seti, 450 özelliğe sahip 174 örnekten oluşmakta olup, yüksek boyutlu verilerle çalışabilen ve karmaşık desenleri algılayabilen sağlam modellerin kullanımını gerektirmektedir. Bu bağlamda, stack modeli, üstün tahmin performansı sunma kapasitesi, yüksek hassasiyete ulaşma yeteneği ve yanlış negatifleri en aza indirerek erken teşhis sürecini destekleme potansiyeli nedeniyle tercih edilmiştir. Gradient Boost ve AdaBoost gibi yöntemlerin yanı sıra RO ve VotingHard gibi topluluk yaklaşımları, doğruluğu ve genelleştirilebilirliği artırmak amacıyla yanlış sınıflandırılmış örnekler odaklanma yetkinlikleri ve gürültüye karşı dirençleri ile dengesiz veri setlerinde sağlamlık sağlamaları nedeniyle seçilmiştir. Ayrıca, Karar Ağaçları ve Naive Bayes algoritmaları, veri setindeki farklı özellik türlerini işleyebilme kapasiteleri sayesinde yorumlanabilirlik ve kararlılık sunarken, aynı zamanda güvenilir tahminler yapabilmektedir. Tüm bu algoritmalar, doğruluğu optimize ederek, erken teşhis süreçlerinde yüksek hassasiyet sağlayarak ve Alzheimer hastalığının teşhisine yönelik makine öğrenimi yaklaşımlarının kapsamlı bir şekilde değerlendirilmesine katkıda bulunarak araştırma hedeflerini desteklemektedir.

Algoritma: Uzman sistemin Pseudo Kodu

Veri seti	Alzheimer hastalığına dair veri seti toplama ve ön işleme: veri setinin standartlaştırılması, normalleştirilmesi, eksik değerlerin işlenmesi ve kategorik değişkenlerin kodlaması.
Seçme	Makine Öğrenme Algoritmaları (Sınıflandırma): AdaBoost, Gradient Boost, VotingHard, Stack, Karar Ağaçları, RO, Naive Bayes ve tek boyutlu evrişimli sinir ağıları.
Tanımla	En iyi modeli, kombinasyonu ve performansı saklamak için değişkenler tanımlanır

Ayırma	Eğitim Veri Kümesini rastgele olarak eğitime ve teste ayırma
Döngü	Tüm makine öğrenme algoritmaları için: (1)Model tanımlama (2)Eğitim veri seti ile modeli eğitime (3)Eğitilen modelin test edilmesi (4)Modeli değerlendirme (5)Değerlendirme sonuçlarını saklama
Sonuç	En iyi modeli seçme

3. ARAŞTIRMA BULGULARI


Çalışmada, Alzheimer hastalığının erken teşhisine yönelik makine öğrenme tabanlı bir uzman sistem geliştirilmiştir. Uzman sistemin geliştirilmesinde AdaBoost, Gradient Boost, VotingHard, Stack, Karar Ağaçları, Rastgele Orman, Naive Bayes ve 1D-CNN olmak üzere farklı makine öğrenme algoritması kullanılmıştır. Eğitilen modeller, test veri seti ile test edilerek doğruluk, özgüllük, duyarlılık, kesinlik, F-ölçüsü, AUC ve ROC eğrisi performans değerlendirme ölçütlerine göre değerlendirilmiştir.

Şekil 7’de 8 makine öğrenme modeli için karmaşıklık matrisleri verilmiştir. Matrislerdeki Gerçek Pozitifler (TP) doğru bir şekilde tanımlanmış Alzheimer vakalarını temsil ederken, Gerçek Negatifler (TN), doğru bir şekilde tanımlanmış Alzheimer olmayan vakalardır. Yanlış Pozitifler (FP) Alzheimer olmayan vakaların yanlış bir şekilde Alzheimer olarak sınıflandırılması durumunda meydana gelir ve Yanlış Negatifler (FN) yanlış bir şekilde Alzheimer olmayan olarak tanımlanmış Alzheimer vakalarıdır. Şekil 7 incelediğinde, modellerin 35 adet veri ile test edildiği ve 32 tanesinin doğru bir şekilde sınıflandırdığı görülmektedir; (d) Stack algoritması en başarılı modeldir. Ayrıca çalışmada eğitilen tüm modellerin ROC eğrisi Şekil 8’de verilmiştir. ROC eğrileri, her model için duyarlılık (Gerçek Pozitif Oranı) ve özgüllük (1 - Yanlış Pozitif Oranı) arasındaki dengeyi gösterir. Eğri altındaki alan (AUC), modellerin genel performansını niceliksel olarak belirler ve 1’e yakın değerler üstün sınıflandırma yeteneğini gösterir. Bu ölçüm, modelin duyarlılığı ve özgüllüğü etkili bir şekilde dengeleme yeteneğini vurgular. Tablo 2’de ve Şekil 6’da eğitilen tüm modellerin performans değerlendirme ölçütlerinin sonuçları

verilmiştir. Tablo 2 incelendiğinde, Stack modeli en başarılı modeldir.

Tablo 2. Makine öğrenme modellerin performans değerlendirme ölçütlerinin sonuçları.

Model	Doğruluk	Özgüllük	Duyarlılık	Kesinlik	F-ölçüsü	AUC
Stack	91,43	93,75	94,44	89,47	91,89	91,43
Karar Ağaçları	88,57	93,33	94,44	85,00	89,47	89,47
Gradient Boost	88,57	93,33	94,44	85,00	89,47	88,40
Rastgele Orman	88,57	93,33	94,44	85,00	89,47	88,40
AdaBoost	88,57	88,24	88,89	88,89	88,89	88,56
1D-CNN	88,57	88,24	88,89	88,89	88,89	88,56
Naive Bayes	80,00	77,78	77,78	82,35	80,00	80,07
VotingHard	80,00	77,78	77,78	82,35	80,00	80,00



Şekil 6. Makine öğrenme modellerin performans değerlendirme ölçütlerinin sonuçları

4. TARTIŞMA

Literatür incelendiğinde, birçok çalışma, el yazısının kinematik, basınç ve zamansal özelliklerinin bilişsel gerilemeyi tespit etmek için potansiyel biyobelirteçler olarak hizmet edebileceğini göstermiştir. Garré-Olmo vd., (2017) hafif bilişsel bozukluğu (MCI), Alzheimer hastalığı ve sağlıklı kontrolleri olan hastalarda el yazısı kinematığı ve basıncının derinlemesine bir analizini yapmışlardır. Araştırmaları, üç grup arasında el yazısı desenlerinde önemli farklılıklar olduğunu göstermiş ve bu özelliklerin potansiyel olarak Alzheimer hastalığı için erken belirteçler olarak hizmet edebileceğini vurgulamışlardır. Bu durum, el yazısı analizinin klinik ortamlarda uygulanabilecek non-invaziv bir tanı aracı olarak faydasını vurgulamaktadır[41]. Ayrıca, Alzheimer hastalığı teşhisi için el yazısı analizindeki son gelişmeler, yeni veri kümeleri ve makine öğrenimi modelleri aracılığıyla elde edilmiştir. Cilia vd., (2022), özellikle Alzheimer hastalığının teşhisine yönelik çevrimiçi el yazısı analizi için yeni bir veri kümesi sunmuştur [42]. Öcal (2024) üçlü bir topluluk öğrenme modeli üzerine yaptığı araştırma, Alzheimer hastalarında ince motor becerilere

ve bunların bozulmasına odaklanarak literatüre daha fazla katkıda bulunmaktadır. Bu çalışma, el yazısı analizinde tanısal doğruluğu artırmak için çeşitli makine öğrenimi algoritmalarını birleştirmenin önemini vurgulamaktadır. Birden fazla modelin tahminlerini bir araya getiren topluluk yöntemlerinin, yığın modelinin en yüksek doğruluk ve hassasiyeti sağladığı bu çalışmada görüldüğü gibi, gelişmiş performans sunduğu gösterilmiştir[43]. Bu çalışmalar ışığında, el yazısı analizinin erken AD teşhisi için invazif olmayan, uygun maliyetli ve erişilebilir bir yöntem olarak önemli bir potansiyel sunduğu açıktır. Makine öğrenimi modellerinin bu verilere uygulanması, tanısal doğruluğu daha da artırabilir ve bu da onu gelecekteki araştırmalar için önemli bir alan haline getirir. Mevcut çalışmanın da gösterdiği gibi, Stack modeli diğer algoritmalarından daha iyi performans göstererek Alzheimer hastalığını tespit etmede yüksek düzeyde doğruluk elde etmiştir.

Makine öğrenimi tabanlı uzman sistemler, Alzheimer hastalığının erken teşhisinde sağlık hizmetlerine önemli katkılar sunabilir. Yüksek doğruluk ve hassasiyet oranlarıyla bu sistemler, erken tanı süreçlerini optimize ederek hastalık ilerlemesini yavaşlatacak müdahalelere olanak tanır. Özellikle Stack modeli gibi performansı yüksek algoritmalar, yanlış negatifleri en aza indirerek tedavi planlamasını daha etkin hale getirir. Bu yaklaşım, bireysel yaşam kalitesini artırmanın yanı sıra sağlık sistemlerinin verimliliğini ve mali sürdürülebilirliğini destekler.

Çalışmada, DARWIN veri seti kullanılarak Alzheimer hastalığının erken teşhisi için makine öğrenimi algoritmaları ile

modellenmiştir. Kullanılan algoritmaların performans ölçütleri bakımından avantajlar ve sınırlamalar sunmuştur.

Gerçekleştirilen deneylerde Stack modeli, %91,43 AUC değeri ile en yüksek performansı sergileyerek diğer tüm algoritmaları geride bırakmıştır. Bu üstün başarısı, topluluk öğrenmesi yaklaşımı sayesinde birden fazla modelin güçlü yönlerini bir araya getirmesine bağlanabilir. Modelin yüksek doğruluk, özgüllük ve duyarlılık değerleri, erken evre Alzheimer teşhisinde güvenilir bir araç olabileceğini göstermektedir. Ancak, modelin karmaşık yapısı ve yüksek hesaplama maliyeti, aşırı uyum riskini artırarak eğitim ve ayarlama süreçlerini zorlaştırmaktadır.

Karar Ağaçları modeli de, özellikle özgüllük ve duyarlılık metriklerinde yüksek değerler elde ederek dikkat çekmiştir. Modelin yorumlanabilir yapısı, tıbbi teşhislerde açıklanabilirliğin büyük önem taşıdığı düşünüldüğünde önemli bir avantaj sunmaktadır. Ancak, karar ağaçları karmaşık veri yapılarında aşırı uyum eğilimi gösterebilmekte ve tıbbi verilerde sıklıkla görülen doğrusal olmayan ilişkileri tam olarak yakalayamamaktadır.

Gradient Boosting ve AdaBoost gibi artırma algoritmaları, zayıf öğrencileri birleştirerek güçlü bir tahminci oluşturma prensibine dayanmaktadır. Bu algoritmalar, Alzheimer hastalığı gibi sınıflandırma problemlerinde başarılı sonuçlar vermektedir. Gradient Boosting, her adımda önceki adımdaki hataları minimize etmeye çalışarak daha iyi bir model oluşturur. AdaBoost ise hatalı sınıflandırılan örneklerin ağırlıklarını artırarak modelin bu örnekleri daha iyi öğrenmesini sağlar. Her iki algoritma da Alzheimer veri kümesinde %88.57 doğruluk oranına ulaşarak güçlü bir teşhis yeteneği sergilemiştir. Özellikle Gradient Boosting, yüksek özgüllük ve duyarlılık değerleriyle dengesiz veri kümelerinde etkili bir sınıflandırıcı olduğunu kanıtlamıştır. Ancak, aşırı uyum ve yüksek hesaplama maliyeti gibi dezavantajları da bulunmaktadır.

Rastgele Orman algoritması, birden fazla karar ağacının tahminlerinin ortalamasını alarak karar veren bir topluluk öğrenme yöntemidir. Bu sayede aşırı uyum riskini azaltır ve daha

genelleyici bir model oluşturur. Alzheimer veri kümesinde %88.57 doğruluk oranıyla Gradient Boosting ile benzer bir performans göstermiştir. Ancak, tek bir karar ağacı kadar yorumlanabilir değildir ve büyük veri kümeleri için hesaplama maliyeti yüksek olabilir.

1D-CNN, sıralı verilerden otomatik olarak özellik çıkarma yeteneği sayesinde Alzheimer hastalığının teşhisinde başarılı sonuçlar elde etmiştir. Bu model, Alzheimer hastalığına özgü karmaşık örüntüleri etkili bir şekilde öğrenerek AdaBoost ile benzer bir performans göstermiştir. Ancak, derin öğrenme modelleri genellikle büyük miktarda veri ve hesaplama kaynağı gerektirmektedir. Özellikle küçük veri kümelerinde aşırı uyum riski bulunmaktadır.

Naive Bayes, hesaplama açısından verimli ve basit yapısıyla bilinir. Bu çalışmada, Alzheimer hastalığının teşhisinde %80,00 doğruluk ve %82,35 kesinlik oranlarına ulaşılmıştır. Ancak, modelin tüm özniteliklerin birbirinden bağımsız olduğu varsayımı, gerçek dünyadaki verilerin karmaşık ilişkilerini tam olarak yakalamada yetersiz kalmıştır.

VotingHard, tüm algoritmalar arasında en düşük performansı sergileyerek %80,00 doğruluk oranına ulaşmıştır. Gelişmiş bir optimizasyon stratejisi kullanılmadan farklı modellerin tahminlerinin birleştirilmesi, modelin genel performansını sınırlamıştır.

Alzheimer hastalığının teşhisi için makine öğrenmesi algoritmalarının kullanımı, hastalığın erken teşhisinde önemli bir adım olarak değerlendirilmektedir. Ancak, her bir algoritmanın kendine özgü avantajları ve dezavantajları bulunmaktadır. Bu nedenle, farklı algoritmaların performanslarının karşılaştırılması ve veri setinin özelliklerine göre en uygun modelin seçilmesi önemlidir.

5. SONUÇLAR

Alzheimer hastalığının erken teşhisine yönelik uzman sistemlerin geliştirilmesi önemli bir sağlık hedefidir. Bu tür bir uzman sistem, bireylerin risk faktörlerini, semptomlarını ve genetik yatkınlıklarını dikkate alarak erken teşhis ve müdahale için daha iyi bir yol sunabilir. Yapay zekâ ve derin öğrenme teknolojilerinin gelişimi, büyük miktarda veri analizi ve nörolojik göstergelerin daha iyi anlaşılmasıyla bu hedefe ulaşmada önemli bir

rol oynamaktadır. Bu çalışmada Alzheimer hastalığının erken teşhisi için makine öğrenme tabanlı bir uzman sistemi geliştirilmiştir. Çalışmada kullanılan açık erişimli veri seti, AdaBoost, Gradient Boost, VotingHard, Stack, Karar Ağaçları, Rastgele Orman, Naive Bayes ve 1D-CNN olmak üzere 8 farklı makine öğrenme algoritmasıyla modellenmiştir. Elde edilen modellerin doğruluk, özgüllük, duyarlılık, kesinlik, F-ölçüsü, ROC eğrisi ve ROC eğrisinin altındaki alan (Ardea Under Curve ve AUC) performans değerlendirme ölçütlerine göre değerlendirilmiş ve sonuçlar karşılaştırılmıştır. Elde edilen sonuçlar aşağıda maddeler halinde verilmiştir.

- Tüm değerlendirme kriterlerine göre en başarılı model Stack olmuştur. Stack'in değerlendirme sonucunda %91.43 doğruluk, %93.75 özgüllük, %94.44 duyarlılık, %89.47 kesinlik, %91.89 F-ölçüsü ve %91.43 AUC değeri ile başarılı tahmin gerçekleştirdiği belirlenmiştir.
- Tüm değerlendirme kriterlerine göre en başarısız model VotingHard olmuştur. VotingHard'ın değerlendirme sonucunda %80.00 doğruluk, %77.78 özgüllük, %77.78 duyarlılık, %82.35 kesinlik, %80.00 F-ölçüsü ve %80.00 AUC değeri ile başarılı tahmin gerçekleştirdiği belirlenmiştir.


Ayrıca araştırma soruları için öngörülen sonuçlar şu şekilde ifade edilebilir.

Hipotez 1 Sonucu: Çalışmadaki veri seti ve algoritmalar, Alzheimer hastalığının erken teşhisinde %90'ın üzerinde doğruluk sağlamış; Stack modeli %91.43 doğrulukla en yüksek başarıyı göstermiştir.


Hipotez 2 Sonucu: Stack modeli, diğer algoritmalarından daha yüksek doğruluk, özgüllük ve duyarlılık ile Alzheimer teşhisinde en başarılı yöntem olmuştur

Hipotez 3 Sonucu: El yazısı verileri, Alzheimer hastalığının erken belirtilerini tespit etmek için düşük maliyetli, güvenilir bir biyobelirteç olarak umut vaat etmektedir; bu veriler, hastalığın non-invaziv teşhisinde potansiyel sunmaktadır.

Sonuç olarak yapay zekâ ile Alzheimer hastalığı tespitinde en iyi modelin Stack olduğu belirlenmiştir. İleride yapılacak çalışmalarda daha büyük veri setleri ve farklı yapay zekâ yöntemleri kullanılarak doğruluk oranının artırılmasının mümkün olacağı düşünülmektedir.



Şekil 7. Karmaşıklık Matrisleri: (a) AdaBoost (b) Gradient Boost (c) VotingHard (d) Stack (e) Karar Ağaçları (f) Rastgele Orman (g) Naive Bayes (h) 1D-CNN



Şekil 8. Karmaşıklık Matrisleri: (a) AdaBoost (b) Gradient Boost (c) VotingHard (d) Stack (e) Karar Ağaçları (f) Rastgele Orman (g) Naive Bayes (h) 1D-CNN

TEŞEKKÜR

Çalışma 5. Uluslararası Mühendislikte Yapay Zekâ ve Uygulamalı Matematik Konferansı'nda özet metin olarak sunulmuştur. Ayrıca çalışmada DARWIN veri setini açık kaynak erişime açan kişi/kişilere teşekkürlerimizi sunarız

KAYNAKLAR

1. Demir, Z., and Türkan, F. "Asetilkolinesteraz ve Bütirikolinesteraz Enzimlerinin Alzheimer Hastalığı ile İlişkisi". *Journal of the Institute of Science and Technology*, Vol. 12, Issue 4, Pages 2386-2395, 2020.
2. Kara, G. and Kılınç, G.E. "Alzheimer hastalığında ketojenik diyet tedavisi". *İstanbul Gelişim Üniversitesi Sağlık Bilimleri Dergisi*, Vol. 15, Pages 630-638, 2021.
3. Keleş, E., and Özalevli, S. "Alzheimer hastalığı ve tedavi yaklaşımları". *İzmir Kâtip Çelebi Üniversitesi Sağlık Bilimleri Fakültesi Dergisi*, Vol. 3, Issue 2, Pages 39-42, 2018.
4. Tekin, S., "Alzheimer Hastalığı Klinik Göstergeleri", In Keskin A, O., UYSAL, A., Özge, A., Yener, G., Kırbaş, D., *Sağlık Kurulunda Demans*, Pages 28-36, Türk Nöroloji Derneği. Ankara, 2022.
5. Mutluer, M., "Devinime ilişkin kortikal potansiyellerin hafif bilişsel bozukluk ve orta evre alzheimer hastalığını değerlendirmede nöropsikolojik testler ile korelasyonu", *Tıpta Uzmanlık Tezi*, Necmettin Erbakan Üniversitesi, Konya, 2009.
6. Saphioğlu, K., and Uzundurukan, S. "Bilimsel çalışmalarda kullanılan bazı yapay zeka uygulamalarının ve trendlerinin incelenmesi". *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, Vol. 10, Issue 1, Pages 249-262, 2019
7. Hoşgör, H., and Güngördü, H. "Sağlıkta Yapay Zekanın Kullanım Alanları Üzerine Nitel Bir Araştırma". *Avrupa Bilim ve Teknoloji Dergisi*, Vol. 35, Pages 395-407, 2022
8. Li, F., Tran, L., Thung, K.H., Ji, S., Shen, D., Li, J. "A robust deep model for improved classification of ad/mci patients", *IEEE J. Biomed. Health Inform.* Vol. 19, Issue 5, 1610–1616, 2015
9. Hu, C., Ju, R., Shen, Y., Zhou, P., Li, Q. "Clinical decision support for alzheimer's disease based on deep learning and brain network", *2016 IEEE International Conference on Communications (ICC)*, Kuala Lumpur, Pages 1-6, 2016
10. Karabay, G. S. and Çavaş, M. "Derin Öğrenme Yöntemiyle Alzheimer Hastalığının Tespiti". *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, Vol. 34, Issue 2, Pages 879-887, 2022.
11. Öziç, M. Ü. , Ekmekci, H. , Özşen, S. , Barstuğan, M. & Yıldıoğan, A. "3B T1 Ağırlıklı MR Görüntülerinde Atlas Tabanlı Hacim Ölçüm Yöntemini Kullanarak Alzheimer Hastalığının Teşhisi". *Politeknik Dergisi* , Vol. 25, Issue 1 , Pages 47-58, 2022
12. Nalçakan, Y., "Derin Öğrenme ile Alzheimer Hastalığının Teşhisi", *Yüksek Lisans Tezi*, İstanbul Üniversitesi-Cerrahpaşa Lisansüstü Eğitim Enstitüsü, İstanbul, 2018.
13. Wang, N., Chen, J., Xiao, H. et al., "Yapay sinir ağı modelinin Alzheimer hastalığının tanısında uygulanması". *BMC Neurol*, Vol. 19 , Issue 154, 2019.
14. Janghel, R. R., & Rathore, Y. K. "Deep convolution neural network based system for early diagnosis of Alzheimer's disease". *Irbm*, Vol. 42, Issue4, Pages 258-267, 2021.
15. De Gregorio, G., Desiato, D., Marcelli, A., & Polese, G. "A multi classifier approach for supporting Alzheimer's diagnosis based on handwriting analysis. In *Pattern Recognition*", *ICPR International Workshops and Challenges: Virtual Event*, January 10–15, 2021, *Proceedings*, Part I , pages 559-574, Springer International Publishing.
16. Subha, R., Nayana, B. R., & Selvadass, M. "Hybrid Machine Learning Model Using Particle Swarm Optimization for Effectual Diagnosis of Alzheimer's Disease from Handwriting", In *2022 4th International Conference on Circuits, Control, Communication and Computing (I4C)*, 2022, December, Pages 491-495, IEEE.
17. Gattulli, V., Impedovo, D., Pirlo, G., & Semeraro, G. "Handwriting Task-Selection based on the Analysis of Patterns in Classification Results on Alzheimer Dataset", In *DSTNDS*, pages 18-29, 2023
18. Önder, M., Şentürk, Ü., Polat, K., & Paulraj, D. "Diagnosis of Alzheimer's Disease Using Boosting Classification Algorithms", In *2023 International Conference on Research Methodologies in Knowledge Management, Artificial Intelligence and Telecommunication Engineering (RMKMATE)*, 2023, Pages 1-5, IEEE.

19. Schapire, R.E. “explain Adaboost”. In: Schölkopf, B., Luo, Z., Vovk, V. (eds) Empirical Inference, Pages 37-52, Heidelberg: Springer Berlin Heidelberg, Berlin, 2013.
20. “Alma Better”, <https://www.almabetter.com/bytes/tutorials/data-science/adaboost-algorithm>, Ocak 05, 2024.
21. Keleş, M. B., Keleş, A., & Keleş, A. “Makine Öğrenmesi Yöntemleri İle Uçuş Fiyatlarının Tahmini”. Euroasia Journal of Mathematics, Engineering, Natural & Medical Sciences, Vol. 7, Issue 11, Pages 72-78, 2020.
22. Gültekin, M., “Makine öğrenmesi tabanlı yazılım maliyet tahmini yöntemlerinin karşılaştırmalı analizi”, Doktora Tezi, Yıldız Teknik Üniversitesi, İstanbul, 2019.
23. Delgado, R. “A semi-hard voting combiner scheme to ensemble multi-class probabilistic classifiers”. Applied Intelligence, Vol. 52, Issue 4, Pages 3653-3677, 2022.
24. Koptur, M., “Makine Öğrenimi”, <https://makineogrenimi.wordpress.com/2017/06/14/modellerin-birlestirilmesi-ensemble-learning/>, Ocak 05, 2024.
25. Uysal, M., and Güyer, T. “İstatistiksel veri analizine ilişkin genişleyebilir bir karar ağacı tasarımı”. Bilişim Teknolojileri Dergisi, Vol. 7, Issue 3, Pages 33-43, 2014.
26. Kuzey, C., “Veri madenciliğinde destek vektör makinaları ve karar ağaçları yöntemlerini kullanarak bilgi çalışanlarının kurum performansı üzerine etkisinin ölçülmesi ve bir uygulama”, Yayımlanmamış Doktora Tezi, İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul, 2012.
27. Aytuğ, O. “Şirket iflaslarının tahminlenmesinde karar ağacı algoritmalarının karşılaştırmalı başarımlı analizi”. Bilişim Teknolojileri Dergisi, Vol. 8, Issue 1, Pages 9-19, 2015.
28. Özlem, A. & Güngör, O. “Rastgele orman algoritması kullanılarak çok bantlı görüntülerin sınıflandırılması”. Jeodezi ve Jeoinformasyon Dergisi, Issue 106, Pages 139-146, 2012.
29. Emhan Ö., & Mehmet, A. “Filtreleme tabanlı öznelik seçme yöntemlerinin anomali tabanlı ağ saldırısı tespit sistemlerine etkisi”. Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi, Vol. 10, Issue 2, Pages 549-559, 2019.
30. Gülcü, Ş. “Bilgisayar ağ güvenliğinde naive bayes algoritmasının kullanımı”. Kilis 7 Aralık Üniversitesi Fen ve Mühendislik Dergisi, Vol. 3, Issue 1, , 2019.
31. Farzaliyev, E., Saihood, Q., and Sonuç, E. “Çocuklarda Anemi Hastalığının Teşhisinde Topluluk Öğrenme Yöntemlerinin Kullanılması”. In International Conference on Recent Academic Studies Vol. 1, Pages. 129-135, 2023.
32. Sikora, R. “A modified stacking ensemble machine learning algorithm using genetic algorithms”. In Handbook of research on organizational transformations through big data analytics, Pages 43-53, IGI Global, 2015.
33. Dou, J., Yunus, A. P., Bui, D. T., Merghadi, A., Sahana, M., Zhu, Z., ... and Pham, B. T. “Improved landslide assessment using support vector machine with bagging, boosting, and stacking ensemble machine learning framework in a mountainous watershed”, Japan. Landslides, Vol. 17, Pages 641-658, 2020.
34. Doğan, G. and Ergen, B. “İmobilenet cnn yaklaşımları ve özellik seçme yöntemleri kullanarak araç türlerini sınıflandırma”. Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi, Vol. 25, Issue 3, Pages 618-628, 2021.
35. Elmas, B. “Türkiye'deki kelebek türlerinin basamaklı evrişimli sinir ağları ile sınıflandırılması”. Konya Journal of Engineering Sciences, Vol. 9, Issue 3, 568-587, 2021.
36. Uçar, M. “Glokom hastalığının evrişimli sinir ağı mimarileri ile tespiti”. Deu Mühendislik Fakültesi Fen Ve Mühendislik, Vol. 23, Issue 68, Pages 521-529, 2021.
37. Gökçe, E., Demiral, M. F., Işık, A. H., & Bilen, M. “Evrişimli sinir ağlarında beyin tümörü segmentasyonu”. El-Cezeri Fen Ve Mühendislik Dergisi. Vol. 9, Issue 4, Pages 1518-1528, 2022.
38. Kantar, O. and Kilimci, Z. H. “Derin öğrenme temelli hibrid altın endeksi (xau/usd) yön tahmin modeli”. Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, Vol. 38, Issue 2, Pages 1117-1128, 2022.
39. Özen, G., Sultanov, R., Özen, Y., & Güneş, Z. Y. “A Convolutional Neural Network Based on Raw Single Channel EEG for Automatic Sleep Staging”. Sakarya University Journal of Computer and Information Sciences, Vol. 3, Issue 3, pages 149-158, 2020.

40. Cilia, N. D., De Gregorio, G., De Stefano, C., Fontanella, F., Marcelli, A., and Parziale, A. "Diagnosing Alzheimer's disease from on-line handwriting: a novel dataset and performance benchmarking". *Engineering Applications of Artificial Intelligence*, Vol. 111, 104822, 2022.

41. Garré-Olmo, J., Faundez-Zanuy, M., Ipiña, K. L. d., Calvó-Perxas, L., & Turró-Garriga, O. "Kinematic and pressure features of handwriting and drawing: preliminary results between patients with mild cognitive impairment, alzheimer disease and healthy controls". *Current Alzheimer Research*, Vol. 14, Issue 9, Pages 960-968, 2017.

42. Cilia, N. D., Stefano, C. D., Fontanella, F., Marcelli, A., & Parziale, A. "Diagnosing alzheimer's disease from on-line handwriting: a novel dataset and performance benchmarking". *Engineering Applications of Artificial Intelligence*, Vo. 111, 104822, 2022.

43. Öcal, H. "A novel approach to detection of alzheimer's disease from handwriting: triple ensemble learning model". *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım Ve Teknoloji*, Vol. 12, Issu 1, Pages 214-223, 2024.