



LASSO+LR: Investigation of WISC-R test scores using machine learning methods used in the diagnosis of children with mental retardation

Sinan Altun^{1*}, Hatice Altun²

¹Department of Construction and Technical Affairs, Kahramanmaraş Istiklal University, Kahramanmaraş, 46100, Türkiye

²Department of Child and Adolescent Psychiatry, Faculty of Medicine, Kahramanmaraş Sutcu Imam University, Kahramanmaraş , 46100, Türkiye

Highlights:

- Children with mental retardation
- Semi-Automatic diagnosis of children with mental retardation
- WISC-R test scores

Keywords:

- WISC-R
- Mental retardation in children
- Feature selection
- Machine learning

Article Info:

Research Article

Received: 09.08.2023

Accepted: 07.10.2024

DOI:

10.17341/gazimmfd.1340026

Correspondence:

Author: Sinan Altun

e-mail: s.altun@yaani.com.tr

phone: +90 507 458 4018

Graphical/Tabular Abstract

With appropriate treatment and education, it is possible for children with mental retardation to lead a better quality of life. The diagnosis of mental retardation in children can be made with the WISC-R test. There are 5 sub-questions in these 2 sections, and with these questions, various information about children's intelligence can be obtained. Total Verbal and Total Performance scores are obtained from the questions in the subgroup, and the Total WISC-R score is obtained from these. The WISC-R test is administered by an expert, and the expert's experience is very important for accurate scoring. In this study, the relationship of WISC-R test scores on the diagnosis of mental retardation in children is investigated based on machine learning. Although these methods are called feature selection in the literature, they can be calculated with 3 different algorithms: Lasso, Gini and Permutation calculation. Embedded methods make automatic classification using artificial intelligence-based machine learning methods for diagnosis using selected features as well as feature selection. While Lasso feature selection classifies with Logistic Regression (LR), Gini and Permutation Classifies with Random Forest (RF). When the results of the study are examined in general, while the Total WISC-R score was selected in three feature selection methods, Verbal score types were calculated with low values in Gini and Permutation methods. In the Lasso + LR method, which has 0.97 accuracy calculations, more features are used than the others. Figure A shows the block diagram summarizing the work.

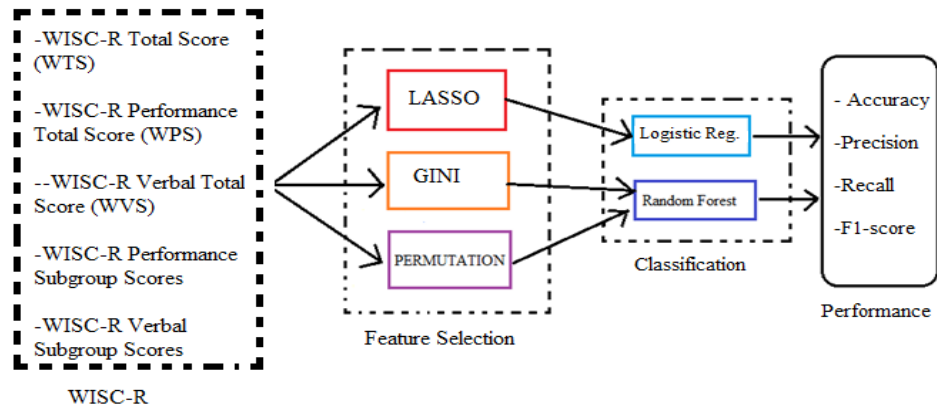


Figure A. Block diagram

Purpose: This study was conducted to investigate the accuracy of WISC-R test scores in detecting mental retardation in children using machine learning methods.

Theory and Methods: It is possible to select features on data sets with Lasso, Gini and Permutation methods. It is possible to classify the features obtained with these 3 algorithms, which have proven themselves in the literature, with machine learning methods. In the proposed model, WISCR test scores were selected with these 3 methods and processed with machine learning methods.

Results: WTS and WPS scores of the WISCR test stand out in all 3 methods in the diagnosis of mental retardation in children. Classifications made by feature selection have achieved high success.

Conclusion: In our study, it has been determined that machine learning methods can be used to diagnose psychological diseases in children and adolescents and to find the effect of tests.



LASSO+LR: Zekâ geriliği olan çocukların tanısında kullanılan WISC-R test puanlarının makine öğrenimi yöntemleri kullanarak incelenmesi

Sinan Altun^{1*}, Hatice Altun²

¹Kahramanmaraş İstiklal Üniversitesi, Yapı İşleri ve Teknik Daire Başkanlığı, 46050, Dulkadiroğlu, Kahramanmaraş, Türkiye

²Kahramanmaraş Sütçü İmam Üniversitesi, Tıp Fakültesi, Çocuk ve Ergen Psikiyatrisi, 46050, Onikişubat, Kahramanmaraş, Türkiye

ÖNEÇIKANLAR

- Zihinsel engelli çocuklar
- Zihinsel engelli çocukların yarı otomatik tanısı
- WISC-R test puanları

Makale Bilgileri

Araştırma Makalesi

Geliş: 09.08.2023

Kabul: 07.10.2024

DOI:

10.17341/gazimmfd.1340026

Anahtar Kelimeler:

WISC-R,
çocuklarda zekâ geriliği,
özellik seçimi,
makine öğrenmesi

ÖZ

WISC-R testi Sözel ve Performans bölümlerinden oluşmaktadır. Bilgisayar yazılımları kullanarak uzman karar destek sistemleri oluşturulması, bilim insanları tarafından yoğun şekilde araştırılmakta ve artık uygulamaya yönelik çalışmalar başlatılmıştır. Bilgisayar destekli yapay zekâ uygulamaları çok sayıda veri ile eğitilmesinden dolayı objektif bir yaklaşım sunmaktadır. Bu çalışmada, WISC-R test puanlarının çocuklardaki zekâ geriliği teşhisi üzerindeki ilişkisi makine öğrenmesi temelli olarak araştırılmaktadır. Bu yöntemler literatürde özellik seçimi olarak adlandırılmakla beraber Lasso, Gini ve Permütasyon hesaplama olmak üzere 3 farklı algoritma ile hesaplanabilmektedir. Yapılan literatür araştırması sonucunda en başarılı özellik seçimi sınıflandırma ikilileri şu şekilde olup çalışmamızda da böyle kullanılmıştır: Lasso özelliği seçimi Lojistik Regresyon (LR) ile sınıflandırma yaparken, Gini ve Permütasyon Rastgele Orman (RF) ile sınıflandırma yapmaktadır. Çalışmanın sonuçları genel olarak incelendiğinde Toplam WISC-R puanı özellik olarak üç özellik seçme yönteminde seçilirken, Sözel puan türleri Gini ve Permütasyon yöntemlerinde düşük değere sahip olarak hesaplanmıştır. Seçilen özellikler ile yapılan sınıflandırma da: Lasso + LR = 0,97, Gini + RF = 0,87, Permutation + RF = 0,91 doğruluk hesaplaması yapılmıştır. 0,97 doğruluk hesabı yapılan Lasso + LR yönteminde, diğerlerine göre daha fazla özellik kullanılmıştır.

LASSO+LR: Investigation of WISC-R test scores using machine learning methods used in the diagnosis of children with mental retardation

HIGHLIGHTS

- Children with mental retardation
- Semi-Automatic diagnosis of children with mental retardation
- WISC-R test scores

Article Info

Research Article

Received: 09.08.2023

Accepted: 07.10.2024

DOI:

10.17341/gazimmfd.1340026

Keywords:

WISC-R,
mental retardation in
children,
feature selection, machine
learning

ABSTRACT

The WISC-R test consists of Verbal and Performance sections. The creation of expert decision support systems using computer software has been intensively researched by scientists and studies have now been initiated for implementation. Computer-aided artificial intelligence applications offer an objective approach since they are trained with a large number of data. In this study, the relationship between WISC-R test scores on the diagnosis of mental retardation in children is investigated based on machine learning. These methods are called feature selection in the literature and can be calculated with 3 different algorithms: Lasso, Gini and Permutation calculation. As a result of the literature research, the most successful feature selection classification pairs are as follows and used in our study: Lasso feature selection classifies with Logistic Regression (LR), while Gini and Permutation classify with Random Forest (RF). When the results of the study are analyzed in general, Total WISC-R score is selected as a feature in the three feature selection methods, while Verbal score types are calculated to have low values in Gini and Permutation methods. In the classification made with the selected features: Lasso + LR = 0.97, Gini + RF = 0.87, Permutation + RF = 0.91. In the Lasso + LR method with 0.97% accuracy calculation, more features were used than the others.

1. Giriş (Introduction)

Zekâ işlevlerinin belirgin bir biçimde ortalamanın altında olması, uyumsal davranışlarda bozulmalar olması ve bunların gelişim döneminde ortaya çıkması, Zihinsel yetersizlik (ZY) şeklinde tanımlanmaktadır. Bu konuda geliştirilmiş çeşitli ölçekler ve klinik görüşmelerde aileden ya da okuldan elde edilen bilgiler kapsamında ele alınmakta, uyum becerileri/davranışları olarak değerlendirilmektedir. Uyum davranışları değerlendirilirken, sosyal beceriler (ör; kişilerarası ilişkiler, sosyal problem çözme becerisi), kavramsal beceriler (ör; dil, para ve zaman kullanımı) ve pratik beceriler (ör; günlük yaşam etkinlikleri) olmak üzere üç alan göz önünde bulundurulmalıdır [1].

ZY 4 grupta sınıflandırılmıştır. “The Diagnostic and Statistical Manual of Mental Disorders (DSM)” sınıflandırması ZY’i, zekâ bölümü (ZB) aralığına ve uyum davranışlarındaki bozukluklara göre, Hafif Düzeyde ZY (50-69 ZB), Orta Düzeyde ZY (35-49 ZB), Ağır Düzeyde ZY (20-34 ZB) ve İleri Derecede (çok ağır) ZY (0-19 ZB) olmak üzere sınıflandırmıştır [2]. Bunun yanı sıra 70-80 arasında ZB olan bireyler de sınır zekâ olarak belirlenmiştir. ZY tanımlamalarında yer alan zihinsel beceriler değerlendirilirken genellikle zekâ testleri kullanılmaktadır. ZY’nin tanımlanması için, ölçüt olarak sadece zekâ testi puanları ele alındığında, belirli bir düzeyin altında kalan bir ZB puanına sahip olmak yeterli olabilmektedir [3]. ZB düzeyinin bireysel olarak uygulanan, güvenilir bir zekâ testi ile belirlenmesi önemlidir. Wechsler Çocuklar için Zekâ Ölçeği-Yenilenmiş formu (WISC-R) mental kapasitenin belirlenmesinde ve sınıflandırmasında kullanılan önemli bir zekâ testidir. WISC-R zekâ testinin Türk kültürüne uygunluğu 1639 çocuktan oluşan bir örnekleme, 1986 yılında Savaşır ve Şahin tarafından yapılmıştır. Testin güvenilirliği sözel bölüm için 0,97, performans bölüm için 0,93 olarak hesaplanmıştır. Testteki sorular sözel, performans ve toplam zekâ bölümü düzeyini belirlemek için kullanılmaktadır [4]. Bu yönüyle WISC-R ile yapılan değerlendirmelerde Toplam ZB puanının 70’ten düşük olması önemli bir ölçüttür. Bunun yanında uyum becerileri de göz önünde bulundurulurken çocuğun bu alanda özel eğitim ihtiyacı olup olmadığı değerlendirilmektedir.

Çocuk ve ergenlerde zekâ geriliği tespit edilip hızlı tedavi edilirse olumlu dönümler alınabilmektedir. Sınır zekâ olan çocuk ve ergenlerde bu durum daha da önemli hale gelip doğru tedavi sayesinde ileriki yaşamda kendisine ve çevreye zarar verebilecek davranışların önüne

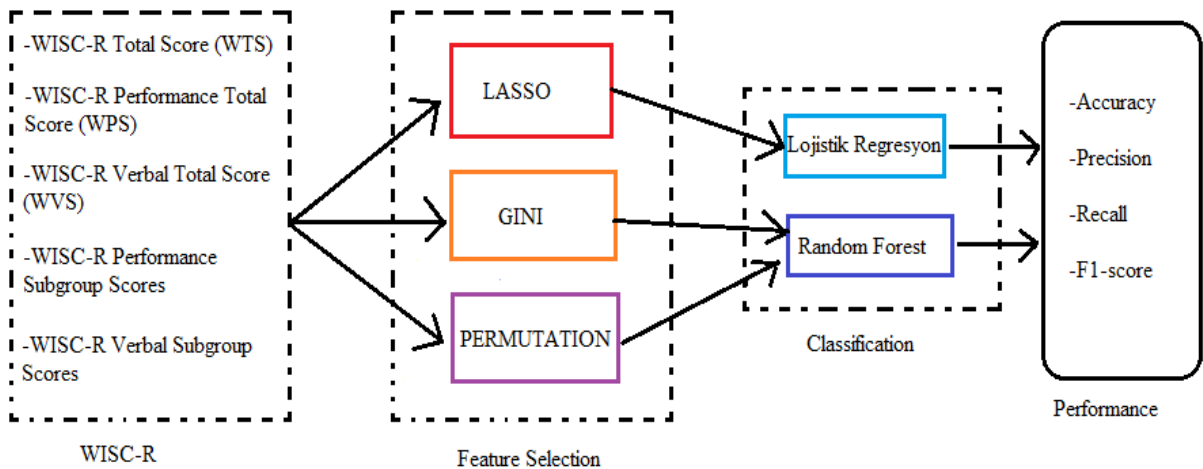
geçilebilmektedir. Zekâ seviyesinin teşhisinde dünya genelinde WISC-R ölçeği kullanılmaktadır. Bilgilerimize göre bu ölçeğin hangisinin teşhis için daha etkili olduğunu ortaya koyan bilgisayar tabanlı bir çalışma yoktur. Bu çalışmada da çocuk ve ergenlerde zekâ seviyesinin teşhisi için kullanılan ölçeklerin teşhiste ne kadar önemli olduğu makine öğrenmesi yöntemleri ile otomatik hesaplanmaya çalışılacaktır.

Şekil 1’de çalışmanın özeti görselleştirilmiştir. Şekil 2’de görüleceği üzere detaylı bir çalışma olup, WISC-R testi skorları ilk önce Feature Selection bilgisayar yazılımı ile teşhise etkileri hesaplanmaktadır. Burada 3 farklı yöntem kullanılarak en doğruya ulaşma hedefi vardır. Feature Selection ile elde edilen sonuçlar, Lojistik Regresyon ve Rastgele Orman makine öğrenmesi yöntemleriyle otomatik sınıflandırılmaktadır. Şekil 1’de görüleceği üzere otomatik sınıflandırmanın başarısı farklı ölçütler kullanılarak ifade edilmiştir. WISC-R testinin Toplam, Sözel Toplam, Performans Toplam, Sözel Alt grup ve Performans Alt grup puanları veri seti olarak oluşturulmuştur. Çalışmamız hem Zihinsel Yetersizliği olan çocukların teşhisinde WISC-R ölçeğinin puan türlerinin etkisini makine öğrenmesi yöntemleri kullanarak araştırmak ve seçilen özellikler ile uzmana yardımcı Bilgisayar Destekli Tanı (BDT) sistemini araştırmak şeklinde 2 bölümden oluştuğu söylenebilir. Özellikle makine öğrenmesi yöntemleri ile WISC-R test puanlarının ZY üzerindeki etkisinin araştırılması literatüre büyük katkı sağlayabileceğini düşünüyoruz.

2. Literatür Özeti (Review)

Herhangi bir makine öğrenimi modeliyle birleştirilebildikleri ve makine öğrenimi algoritmalarının çalışma süresini büyük ölçüde azaltabildikleri için, özellik seçimi için filtre yöntemleri önemli bir rol oynar. Analizlerin amacı, farklı filtre yöntemlerinin nasıl çalıştığını incelemek, performanslarını hem çalışma süresi hem de tahmin doğruluğu açısından karşılaştırmak ve uygulamalar için rehberlik sağlamaktır. 16 yüksek boyutlu sınıflandırma veri setine dayalı olarak, 22 filtre yöntemi, bir sınıflandırma yöntemiyle birleştirildiğinde çalışma süresi ve doğruluk açısından analiz edilir [5].

Son zamanlarda, akış akışını tahmin etmek için veriye dayalı modellerin kullanılmasına artan bir vurgu yapılmıştır. Bununla birlikte, aylık akış akışını tahmin etmek için kullanılan bu veriye dayalı modellerde, filtre tabanlı özellik seçimi yöntemlerinin



Şekil 1. Blok diyagram (Block diagram)

performansları ayrıntılı olarak incelenmemiştir. Çalışma, Büyük Örneklem Çalışmaları için Havza Nitelikleri ve Meteoroloji veri setlerinden üç vaka üzerinde yürütülmüştür. İlk olarak, enELM veya KNN ile birleşen baskın bir FFS yöntemi yoktur. İkinci olarak, sekiz FFS yöntemi ve üç regresyon modelinin aday kombinasyonlarında nihai bir model seçmek için yeniden örneklem uygulandığında, PCI son model için en uygun FFS yöntemiydi [6].

Bir veri kümesindeki ilgili özellik kümesini belirlemek, veri analitiğinin önemli bir parçasıdır. Önerilen yöntemin değerlendirilmesi, bir olasılık sınıflandırıcı kullanılarak modellenen 27 farklı veri kümesi üzerinde Bilgi Kazanımı ve Ki Kare öznelik seçim yöntemlerine karşı performansı karşılaştırılarak yapılmıştır. Sonuçlar, L2'nin hata oranı, kesinlik ve geri çağırma ölçümleri açısından oldukça rekabetçi olduğunu ve veri setlerinde seçilen değişkenlerin sayısını önemli ölçüde azalttığını ortaya koymaktadır. Çalışmamız, istatistiksel analiz yöntemlerini kullanarak çok sayıda özellik içeren uygulamalarla ilgilenen veri analistleri, akademisyenler ve alan uzmanlarının ilgisini çekecektir [7].

Ev enerji tüketimi tahmin modelini oluşturmak için gömülü özellik seçme algoritmasının uygulanmasına ilişkin mühendislik uygulamasında, yapılandırılmış regresyon öğrencileri genellikle veri seti örnekleme, algoritma başlatma, bilgi işlem platformu kaynak planlaması vb. Aynı özellik kombinasyonu farklı olan çoklu regresyon öğrencilerinin tahmin sonuçları. Bu, enerji tüketimi tahmin modelinin optimizasyon sürecini ciddi şekilde etkilemekte, optimum özellik kombinasyonunun bulunamamasına neden olmakta ve tahmin sonuçlarının doğruluğunu azaltmaktadır. Süreçte ortaya çıkan rastgelelik girişimini çözdüğünü, tahmin modelinin optimizasyon sürecinde özellik kombinasyonunun kararlılığını sağladığını ve doğru tahmin aldığını göstermektedir [8].

Kaba kümelere ve bulanık kaba kümelere dayalı özellik seçimi, çeşitlendirilmiş buluşsal bilgiler sunarak kapsamlı bir şekilde gerçekleştirilir. Arama stratejilerinin sınırlamaları nedeniyle, yerel olarak en uygun özellik alt kümeleri muhtemelen seçilir. Regresyon analizine dayalı gömülü özellik seçimi, yerel olarak en uygun özellik alt kümelerine düşmeyi bir dereceye kadar önleyebilir. Ancak, özellik uzayı ile karar uzayı arasındaki sadece doğrusal ilişkiler söz konusudur. Bu modelde, noktasal bulanık karşılıklı bilgi matrisi, bir veri kümesi için özellik alanı ile karar alanı arasındaki doğrusal olmayan ilişkinin yanı sıra özelliklerin ayırt edilebilirliğini karakterize etmek için bulanık bilgi granüllerine dayalı olarak oluşturulur. Gömülü bir özellik seçim algoritması, optimum IFC'leri uyarlamalı olarak öğrenmek için tasarlanmıştır [9].

Doğru akış tahmini, su kaynaklarının sürdürülebilir kullanımını ve yönetimini garanti etmede önemli bir rol oynar. Akış tahmini için son yıllarda Yapay Zekâ modelleri yaygın olarak kullanılmaktadır. Diğer birçok alanda yaygın olarak kullanılmasına rağmen, akış tahmin yetenekleri şu ana kadar bilinmemektedir. Bu yazıda, geliştirilmiş gri kurt optimize edici ve destek vektör makinesi içeren gömülü bir tahmin modeli, gömülü öznelik seçim yöntemi ilkesine dayalı olarak önerilmiştir ve Kızıl rezervuar istasyonunda aylık akış tahmini ile doğrulanmıştır. Genel araştırma ve analizler, EFS-SVMIGWO modelinin aylık akış tahmininde ikna edici bir performans sergileyebileceğini göstermektedir. Bu nedenle, aylık akış zaman serilerini tahmin etmek için daha etkili modeller geliştirmek için girdi değişkenlerini ve parametrelerini dikkatli bir şekilde seçmek büyük önem taşımaktadır [10].

Ek olarak, güve alevi optimizasyonunda doğrusal alev sayısının azaltılması ve guguk kuşu avında boyutsal varyasyon fikrinden ilham alan bir Elit Levy Saçılımı (ELS) stratejisi önerilmiştir. Burada, ABC'den ilham alan SW stratejisi, küresel keşif yeteneklerini

geliştirmek için kullanılırken, ELS stratejisi, uygun değer çözümlerin kalitesini daha da geliştirmeye adanmıştır. CEC 2017 testlerine dayalı olarak, performansı en son teknoloji ve şampiyon algoritmalarla karşılaştırmak için EDE üzerinde ölçeklenebilirlik testleri gerçekleştirildi. Son olarak, EDE'nin performansını doğrulamak için birkaç meslektaşla dokuz meme kanseri görüntüsü üzerinde bir görüntü bölütleme deneyi yapıldı. Yukarıdaki deneysel sonuçlar, EDE'nin meme kanseri görüntülerinin optimizasyon durumunda ve çok eşikli segmentasyonunda iyi performans gösterdiğini göstermektedir [11].

Davranışa dayalı fide yazılımı tespitinin zorluğu, bir analiz çıktısı olarak yüzbinlerce sistem çağrısı almaktır, bu da fide yazılımına özgü özellikleri manuel olarak aramayı ve seçmeyi imkânsız hale getirir. Ancak, otomatik özellik seçimi, kötü amaçlı yazılım tespitinde iyi çalışmamıştır. Bu yazıda, davranışsal fide yazılımı tespiti ve sınıflandırması için parçacık sürüsü optimizasyonunu kullanan otomatikleştirilmiş bir özellik seçme yöntemi öneriyoruz. Önerilen yöntem, fide yazılımı tespiti ve sınıflandırmasında farklı veri özellik gruplarının önemini dikkate alır ve grup önemine göre özellik seçimi gerçekleştirir. Makale ayrıca, fide yazılımı algılama ve sınıflandırmada önerilen yöntemlerle seçilen farklı özellik kümelerinin ve özelliklerin önemini ayrıntılı bir analizini sağlar [12].

Sarmalayıcı tabanlı özellik (altküme) seçimi, özellikle sınıflandırma problemleriyle uğraşırken veri kümelerinin boyutsallığını azaltmak için yaygın olarak kullanılan bir yaklaşımdır. Bu, bu tür özellik alt kümelerinin diğer sınıflandırıcı türleri için ne kadar uygun olduğu sorusunu gündeme getirir. Başka bir deyişle, diğer özellikler için de geçerli olan özelliklerin alt kümelerini bulmak için bir sınıflandırıcı kullanılabilir mi? Bu konuyla ilgili araştırma, bir sınıflandırıcı tarafından bulunan alt kümelerin diğer sınıflandırıcılara kıyasla yararlılığının test edilmesi ve analiz edilmesiyle yürütülmüştür [13].

Ankara'daki iki Bilim ve Sanat Merkezi'nde 2010-2012 eğitim öğretim yılları arasında değerlendirme kriterlerini karşılayarak üstün yetenekliliği belirlenen 503 öğrenci araştırmanın çalışma grubunu oluşturan bir çalışma yapılmıştır. Çalışmadan elde edilen sonuçlarla, üstün yetenekliliği belirlenen öğrencilerin dilsel-sözel alanda, görsel-motor alana göre daha yüksek düzeyde performans gösterdiklerini ortaya koyduğu anlatılmaktadır. Görsel uzamsal akıl yürütme (Küplerle Desen), kavramsal ve mantıksal yargılama yeteneğine (Benzerlikler) ilişkin performanslarının diğerlerine göre daha yüksek olduğu; yeni bir görevi öğrenme, dikkatini toplama (Şifre) ve soyut sayı kavramlarını kullanarak akıl yürütme, problem çözme, dikkati toplama ve sürdürme (Aritmetik) performanslarının ise düşük olduğu belirlenmiştir. Çoğunlukla görsel uzamsal akıl yürütme (Küplerle Desen) ve kavramsal-mantıksal yargılamada (Benzerlikler) güçlü özellikler sergiledikleri, buna karşın, yeni bir görevi öğrenme ve dikkatini toplamada (Şifre) zayıf özellikler sergiledikleri belirlenmiştir [14].

Çalışmada, Wechsler Çocuklar İçin Zekâ Ölçeği-Geliştirilmiş Formu (WÇZÖ-R) ve Türkiye standardizasyonu yeni yapılmış olan Wechsler Çocuklar İçin Zekâ Ölçeği-IV (WÇZÖ-IV) ile Dikkat Eksikliği ve Hiperaktivite Bozukluğu (DEHB) tanısı konulan çocukların, bilişsel profilleri incelenmiştir. Çocuklara WÇZÖ-R, WÇZÖ-IV ve Sesli Okuma Becerisi ve Okuduğunu Anlama Testi (SOBAT) uygulanmıştır. WÇZÖ-R Zekâ Bölümü (ZB) puanları ile WÇZÖ-IV dönüştürülmüş puanları kendi aralarında istatistiksel olarak anlamlı bir farklılık göstermediği anlatılmaktadır [15].

Çalışmanın amacı bir üniversite hastanesinin çocuk ergen ruh sağlığı polikliniğinde değerlendirilerek sağlık kuruluna yönlendirilen çocuk ve ergen hastaların sosyodemografik ve klinik özelliklerini belirleyerek çocuk ruh sağlığı alanındaki engellilik ve engelli hakları

konusunda yapılan önceki çalışmalara katkı sağlamaktır. 2016-2017 tarihleri arasında Düzce Üniversitesi Tıp Fakültesi Hastanesi Çocuk Ergen Ruh Sağlığı Hastalıkları Polikliniği'nde değerlendirilen ve Özürlü Sağlık Kurulu'na yönlendirilen 352 çocuk ve ergen alınmıştır. Sosyodemografik ve klinik verileri dosya bilgileri üzerinden geriye dönük olarak değerlendirilmiştir. Çocukluk çağında zihinsel engellilik, otizm, öğrenme güçlüğü gibi durumların çok erken tespit edilebilmesi ve yapılacak erken eğitimsel müdahaleler çocuklardaki engellilik oranını azaltabileceği gibi gerek akademik gerekse sosyal alanda yaşanabilecek işlev kayıplarını büyük oranda telafi edilebileceği çalışmada anlatılmaktadır [16].

3. Materyal (Material)

Çalışmanın veri seti, 6-15 yaş grubundan 132 hastanın verileri ile oluşturulmuş retrospektif bir çalışmadır. Bu veriler Kahramanmaraş Sütçü İmam Üniversitesi Tıp Fakültesi Çocuk ve Ergen Ruh Sağlığı ve Hastalıkları Ana Bilim Dalı'na başvuran hastalardan, sınır zekâ, hafif ve orta düzeyde ZY tanısı saptanan hastalardan oluşan veri seti için gerekli etik kurul izni alınmıştır (Etik kurul tarih 20.02.2019, karar no: 20). Sınıflandırma başarısı elde edebilmek için hastaların WISC-R test sonuçlarıyla birlikte dosyaları tek tek incelenerek, teşhis doğruluğu teyit edilmiştir. Çocuk ve Ergen Ruh Sağlığı ve Hastalıkları uzmanı tarafından dosya incelemeleri yapılmıştır. Hastaların tanıları WISC-R testi ve DSM-V'e göre yapılan klinik psikiyatrik muayene sonucuna göre belirlenmiştir.

Çalışmada kullanılan veri setinde 61 hafif düzeyde ZY, 21 orta düzeyde ZY ve 47 ağır düzeyde (sınır zekâ), 3 tane ileri düzeyde (sınır zekâ) bulunmaktadır. 132 hastanın bütün bilgileri sayısal değere sahiptir. Sınıf oluşturulurken sayısal değer kullanmak için ağır düzeyde (sınır zekâ) ZY 'Sınıf 1', ileri düzeyde (sınır zekâ) ZY 'Sınıf 2', hafif düzeyde ZY ise 'Sınıf 3', orta düzeyde ZY 'Sınıf 4' olarak belirlenmiştir.

Bu çalışmada BDT sisteminin temeli, sınıflandırma konusunda oldukça başarılı olan karar ağaçları algoritması, Puanların sonuca etkisinin daha anlaşılır şekilde yorumlanabilmesi için tercih edilmiştir. Çalışmada karar ağaçları algoritmasının dallanma yapısını kullanarak sınır zekâ ile WISC-R testi ve ZY teşhisinde kullanılan puan türlerinin ağırlıkları incelenmek istenmiştir. WISC-R testi sonucunda oluşturulan raporda, sözel ve performans zekâ bölümü puanları toplam zekâ bölümü puanı ile sözel ve performans zekâ bölümlerinin alt ölçek puanları yer almaktadır. Tablo 1'de sözel, toplam ve performans zekâ puanlarını içeren veri seti öznelikleri ve kısaltmaları, sözel ve performans zekâ bölümlerinin alt puanlarını içeren öznelikleri ve kısaltmaları, toplam ölçek puanları bulunmaktadır.

Tablo 1. Puan türleri ve kısaltmalar (Score types and abbreviations)

Feature name:	Abbreviation:
Age	Age
Sex	Sex
Verbal score	WVS
Performance score	WPS
Total score	WTS
	General information
	Similarity
Verbal Scores	Arithmetic
	Judgment
	Number sequence
	Picture completion
	Pattern with cubes
Performance Scores	Joining parts
	Code
	Image editing

3.1. WISC-R testinde uygulanan sözel zekâ bölümü alt ölçekleri (Verbal intelligence subscales applied in the WISC-R test):

Kişinin yaşadığı kültürde öğrenebileceği, kolaydan zora doğru sıralanmış, 30 soruluk bir alt testtir. Sorular kolaydan zora doğru sırayla okunur ve her soruya cevap vermesi beklenir. Bu testin dili kullanma ve konuşma becerisini öğrenme yoluyla kazanılan genel kültür dağarcığı ile ölçtüğü kabul edilir [17].

İki kavramın ne yönden benzediğini soran, somuttan soyut kavramlara doğru giden ve açık uçlu 17 sorudan oluşur. Sorular sorulduktan sonra çocuğun her bir soruda iki kavramın ne yönden benzediğini cevaplaması beklenir. Bu alt test çocukta mantıksal ve kavramsal ilişki kurma becerisini ölçer.

Basit aritmetik işlem gerektiren, kolaydan zora doğru ilerleyen ve akıldan çözmesi istenen 18 sorudan oluşur. Çocuktan her bir problemi sınırlı bir süre içinde kâğıt kalem kullanmadan, cevaplaması beklenir.

17 sorudan oluşan bu test, kişinin bazı sosyal durumlarda ne yapması gerektiğini sorgulayan bir alt testtir. Her bir soru çocuğa yavaş yavaş okunur ve çocuktan soruyu düşünüp cevaplaması istenir. Bu alt test, sosyal muhakeme, pratik bilgi, soyut düşünme ve bilgilerini organize etme becerilerini ölçmek için kullanılır.

Uzunluğu gittikçe artan sayı dizilerinden oluşan iki aşamalı bir testtir. Sayıların kısa süreli bellekte tutulmasını gerektirir. Test uygulanan çocuğa ikili ve dokuzlu sayı dizileri arasında artan maddeler söylenir. İlk başta düzden, sonra tersten tekrarlaması istenir. Bu test kısa süreli belleği ve dikkati çevirme becerisini ortaya çıkardığı varsayılır.

3.3. WISC-R testinde uygulanan performans bölümünün alt ölçekleri (Subscales of the performance section applied in the WISC-R test):

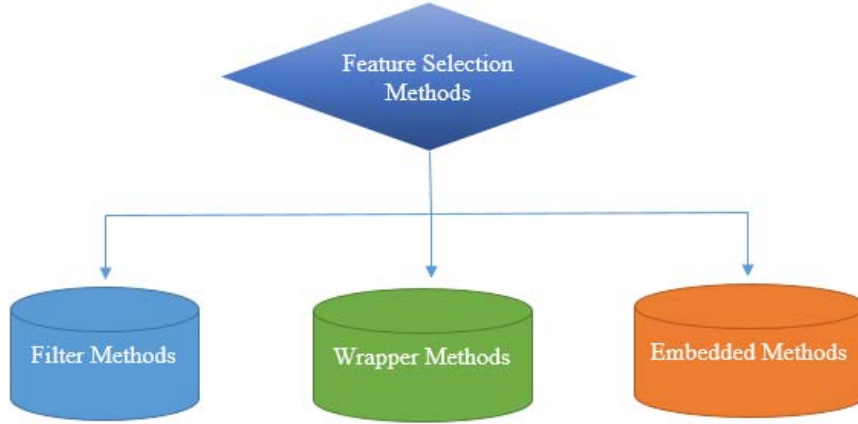
26 resimden oluşan Resim tamamlama, eksik parçalara sahip resimlerden meydana gelir. Çocuktan bu eksik kısımları tamamlamaya çalışır. Test çevreye ve ayrıntılara dikkati ölçtüğü kabul edilmektedir.

Küplerle desen, 11 maddeden oluşan yüzeyleri beyaz, kırmızı ve kırmızı-beyaz boyanmış küplerden oluşan bir alt testtir. Testte çocuktan, küplerle, kendisine verilen desenin aynısını, belirli sürede yapması istenir. Alt testin performans hızını, görsel algı-motor koordinasyon yeteneğini, sözel olmayan muhakeme becerisini, analitik düşünme yeteneğini, üç boyutlu düşünme gibi yetenekleri ölçtüğü kabul varsayılmaktadır.

Parça Birleştirmede, çocuktan parçalara ayrılmış şekillerin bulunduğu dört gereken sürede birleştirmesi istenir. Alt testin parçadan bütüne gitme yeteneğini, algı hızını, deneme-yanılmayı kullanma becerisini, üç boyutlu düşünme yeteneğini ölçtüğü kabul edilmektedir.

Code, bir örnekle çocuğa sayı ve şekillerin altında yer alan işaretler gösterilir. Sonrasında, bu sayı veya şekilleri altında işaretlerin olduğu bölüm boş bırakılarak verilir ve çocuğun boş yerleri uygun işaretler kullanarak yerleştirmesi istenir. Bu test, yeni bir görevi öğrenebilme kapasitesini, görsel algı-motor koordinasyon yeteneğini ölçtüğü kabul edilmektedir.

12 maddeden oluşan Resim düzenleme, her maddede karışık düzende resimler gösterilir ve çocuktan resimleri, bir öykü halinde düzenlemesi istenir. Bu alt test ile neden-sonuç ilişkilerini kavrayabilme ve sentez yapma yeteneği, sosyal süreçleri tahmin, planlama gücü ve espri yeteneğini ölçmek amacı vardır.



Şekil 2. Özellik seçim yöntemleri (Feature Selection methods)

4. Metot (Method)

Makine öğrenmesinin temel bileşenlerinden biri olan özellik seçimi, makine öğrenimi algoritmalarını beslemek için temel özellikleri seçme sürecidir. Özellik seçme teknikleri, gereksiz veya ilgisiz özellikleri ortadan kaldırarak ve özellik setini makine öğrenimi modeliyle en alakalı olanlara daraltarak girdi değişkenlerinin sayısını azaltmak için kullanılır [18]. Şekil 2' de özellik seçim yöntemleri yer almaktadır.

Özellik seçim algoritmaları denetimli olarak sınıflandırılır ve etiketlenmiş veriler üzerinde kullanılabilir. Denetimsiz yöntemler, filtreleme yöntemleri, sarma yöntemleri, gömme yöntemleri veya hibrit yöntemler olarak sınıflandırılır.

4.2. Filtre Yöntemi (Filter Method):

Filtre yöntemi, özellik seçiminin çapraz doğrulama performansı yerine istatistiklere dayalı olarak özellikleri seçer. Alakasız nitelikleri belirlemek ve özyinelemeli özellik seçimi gerçekleştirmek için seçilen metrikleri uygulayın. Burada, özellik alt kümelerinin son seçimini bildirmek için sıralı bir özellik sıralaması listesi oluşturulur. Çok değişkenli analiz, işlevsel alaka düzeyini bir bütün olarak değerlendirir ve gereksiz ve ilgisiz özellikleri tanımlar [19, 20].

4.3. Wrapper Yöntemleri (Wrapper Method):

Seçim için kullanılan kümeleme algoritmasının sonuçlarının kalitesini artıran bir özellik alt kümesine odaklanır [21].

4.4. Embedded Yöntemleri (Embedded Method):

Gömme özelliği seçme yöntemleri, sınıflandırma ve özellik seçiminin aynı anda gerçekleştirildiği bir öğrenme algoritmasının parçası olarak özellik seçimi için makine öğrenimi algoritmalarını entegre eder [22]. Lasso, Gini ve Permütasyon Embedded yöntemlerinin kullandığı özellik seçme algoritmalarıdır. Embedded yöntemler özellik seçimini yapmak ile işlemi sonlandırmazlar. Özellik seçildikten sonra sınıflandırma yapılır. Sınıflandırma işlemi tekrarlanarak ideal özelliklerin seçilme amacı vardır. Lasso özellik seçim algoritması Lojistik Regresyon (LR) sınıflandırma metotunu, Gini ve Permütasyon özellik seçimi ise Random Forest (RF) sınıflandırma yöntemini kullanır [23]. Embedded yöntemler Filtre ve Wrapper yöntemin kombinasyonu olarak çalıştığından bu çalışmada Embedded yöntemler kullanılacaktır.

4.5. Değerlendirme Ölçütleri (Evaluation Criteria):

F1-score, bir modelin doğruluğunu ölçen bir makine öğrenimi değerlendirme metriğidir. Bir modelin kesinlik ve geri çağırma puanlarını birleştirir. F1-score Eş. 1'e göre hesaplanır:

$$F1 - score = \frac{TP}{TP + \frac{1}{2}(YP + YN)} \quad (1)$$

Burada; TP: Toplam pozitif sayısını, YP: yanlış pozitif sayısını, YN: yanlış negatif sayısını ifade etmektedir.

Precision, model tarafından yapılan "olumlu" tahminlerin kaç tanesinin doğru olduğunu ölçer. Eş. 2'ye göre hesaplama gerçekleştirir:

$$Precision = \frac{TP}{TP + YP} \quad (2)$$

Burada; TP: Toplam pozitif sayısını, YP: yanlış pozitif sayısını ifade eder.

Recall, veri kümesinde bulunan pozitif sınıf örneklerinin kaç tanesinin model tarafından doğru bir şekilde tanımlandığını ölçer. Eş. 3'e göre hesaplanır:

$$Recall = \frac{TP}{TP + YN} \quad (3)$$

Burada; TP: Toplam pozitif sayısını, YN: yanlış negatif sayısını ifade eder.

5. Deneysel Çalışmalar (Experimental Studies)

Zekâ geriliği olan çocukların doğru eğitim ve tedavi almaları oldukça önemlidir. Elbette bunların temelini hızlı ve doğru teşhis oluşturmaktadır. Çocuklarda zekâ geriliği teşhisi çeşitli araştırmalar ile doğruluğu denenmiş WISC-R ölçeği ile yapılmaktadır. Bizim bilgilerimize göre bu test skorlarını makine öğrenmesi yöntemleri kullanarak araştıran bir çalışma literatürde bulunmamaktadır. Çalışmada 3 farklı Embedded yöntem (Lasso, Gini ve Permütasyon) kullanılarak zekâ geriliğinde WISC-R test skorlarının sonuca etkisi araştırılacaktır. Embedded yöntemler doğru sonuca ulaşmak için Lojistik Regresyon ve Random Forest sınıflandırma yöntemlerini kullanarak otomatik sınıflandırma gerçekleştirir. Çalışmamızın ikinci bölümünde seçilen özellikler ile 4 adet sınıfta otomatik sınıflandırma yapılacaktır.

Tablo 2. Lasso özellik seçimi (Lasso feature Selection)

Feature Selection
Age
WPS
WTS
WV1
WV2
WV3
WV4
WP2
WP3
WP4
WP5

Tablo 2’de Lasso yönteminin seçtiği 11 adet özellik yer almaktadır. Veri setinde toplam 15 adet özellik olup Lasso yöntemi bu özellikleri %74 oranında seçmiştir. Tablo 2’ye göre seçilmeyen özellikler Toplam Sözel Puan, Sözel Puan 5, Performans Puanı 1 ve cinsiyet bilgisidir. Sözel skorlardan 2 tanesinin, özelliklerde toplam sözle puanın seçilmemesi dikkat çekicidir.

Tablo 3. Lasso lojistik regresyon sınıflandırması (Lasso logistic regression classification)

class	precision	recall	f1-score	support
1	0,98	0,98	0,99	47
2	0,98	0,96	0,98	3
3	0,96	0,94	0,97	61
4	0,96	0,96	0,98	21
accuracy			0,97	132
macro avg	0,97	0,96	0,98	132
weighted avg	0,97	0,96	0,98	132

Lasso yöntemi, Lojistik Regresyon ile otomatik sınıflandırma gerçekleştirmektedir. Tablo 3’ ten toplam sınıflandırma başarısına bakıldığında 0,97 ile oldukça yüksek bir sınıflandırma başarısı elde edilmiştir. Sınıflarda bulunan verilerin sayısı Sınıf 2 haricinde nispeten orantılıdır. Sınıflarda bulunan veri sayısına bakılmadan (macro avg) hesaplanan (precision, recall ve f1-score) skorları ile sınıf sayıları dikkate alınarak (weighted avg) yapılan skor hesaplamaları (precision, recall ve f1-score) benzerdir. Sınıf bazında hesaplanan değerlere baktığımızda da birbirlerine yakın sonuçlar elde edilmiştir.

Tablo 4. Gini özellik seçimi (Gini feature selection)

Feature name:	Gini:
Age	0,054531
Sex	0,014751
WVS	0,400446
WPS	0,463749
WTS	0,862698
WV1	0,105078
WV2	0,18302
WV3	0,154378
WV4	0,183434
WV5	0,313876
WP1	0,16081
WP2	0,294208
WP3	0,31191
WP4	0,181712
WP5	0,315397

Tablo 4’te Gini yönteminin özellikler için hesapladığı değerler yer almaktadır. Özelliklerin Gini ortalaması 0,27’dir. Sınıflandırmada da 0,27 ve üzeri değere sahip 7 adet özellik kullanılmıştır. 0,86 ile ilişkili

özellik Toplam Puan türü belirlenmiştir. İkinci sırada gelen özellik için Gini değeri 0,46’ya kadar düşmektedir. Cinsiyet burada da en ilgisiz özellik olarak belirlenmiştir.

Gini yöntemi kullanılarak seçilen özellikler, Random Forest makine öğrenmesi ile sınıflandırılmaktadır. Tablo 5’te, 0,27 ve üzeri Gini değerine sahip 7 adet özellik kullanılarak yapılan sınıflandırma sonuçları yer almaktadır. Sınıflandırma başarısı 0,87’ de kalmıştır. Sınıflardaki veri sayısına bakılmaksızın (macro avg) ile sınıf sayılarına bakılarak (weighted avg) yapılan sınıflandırmada performans sayıları arasında farklar Tablo 5’te görülmektedir. Ayrıca ileri düzeyde zekâ geriliği olan 3 hastanın tamamı yanlış sınıflandırılmıştır.

Tablo 5. Gini özellik seçimi ve rastgele orman sınıflandırması (Gini feature selection and random forest classification)

class	precision	recall	f1-score	support
1	0,89	0,73	0,80	47
2	0,00	0,00	0,00	3
3	0,80	0,92	0,86	61
4	0,89	1,00	0,94	21
accuracy			0,87	132
macro avg	0,645	0,67	0,65	132
weighted avg	0,83	0,85	0,83	132

Tablo 6’da permütasyon yönteminin özellikler için hesapladığı ağırlıklar yer almaktadır. 4 adet özellik için permütasyon hesabı yapılmış olup diğerleri 0 olarak hesaplanmıştır. En ilişkili özellik 0,7455 ± 0,0594 ile Toplam Puan skorunda hesaplanmıştır. Gini özellik seçimi de en yüksek hesaplamayı Toplam WISC-R puanı için gerçekleştirmiştir. İkinci sırada yer alan Performans 5’in puanı ise 0,1212 ± 0,0542 olarak hesaplanmıştır. Tablo 6’ya bakıldığında, üçüncü sıradaki Toplam Performans Skoru da 0,1212 olarak hesaplanmıştır. Sözel puan türlerinin herhangi biri için hesaplama yapılmamış olması dikkat çekicidir.

Tablo 6. Permütasyon özellik seçimi (Permutation feature selection)

Weight	Feature
0,7455 ± 0,0594	WTS
0,1212 ± 0,0542	WP5
0,1212 ± 0,0000	WPS
0,0728 ± 0,0297	WP3
0 ± 0,0000	WP4
0 ± 0,0000	WP2
0 ± 0,0000	WP1
0 ± 0,0000	WV5
0 ± 0,0000	WV4
0 ± 0,0000	WV3
0 ± 0,0000	WV2
0 ± 0,0000	WV1
0 ± 0,0000	WVS
0 ± 0,0000	Sex
0 ± 0,0000	Age

Permütasyon yöntemi ile seçilen 4 adet özellik (WTS, WP5, WPS ve WP3) Random Forest yönteminde otomatik sınıflandırılmıştır. Tablo 7’de görüleceği üzere ortalama 0,91 doğruluk hesaplanmıştır. Sınıflarda yer alan veri sayısı dikkate alınarak yapılan sınıflandırma (weighted avg) performans skorları (precision, recall, f1-score) dikkate alınmadan elde edilen skorlara göre daha yüksek hesaplanmıştır. Gini yönteminde olduğu gibi burada da İleri Düzey ZY sınıfının tamamı yanlış sınıflandırılmıştır. Her bir hastalık için yapılan sınıflandırmaya bakıldığında 47 elemana sahip Sınıf 1 ve 21 elemana sahip Sınıf 4 için benzer skorlar hesaplanmıştır. 61 veriye

sahip Sınıf 3' te recall ve f1-score değerleri diğer sınıftakilerle benzer olmuş ancak precision değeri çok az düşük hesaplanmıştır.

Tablo 7. Permütasyon özellik seçimi ve rastgele orman sınıflandırması
(Permutation feature selection and random forest classification)

class	precision	recall	f1-score	support
1	0,91	0,95	0,88	47
2	0,00	0,00	0,00	3
3	0,88	0,95	0,91	61
4	0,91	0,95	0,93	21
accuracy			0,91	132
macro avg	0,68	0,71	0,68	132
weighted avg	0,88	0,93	0,88	132

6. Sonuçlar ve Tartışmalar (Results and Discussions)

Zekâ geriliği olan çocukların doğru bir eğitim almaları gerekmektedir. Doğru eğitim ile yönlendirilmeyen çocuklar kendi öz bakım becerilerini yapamayıp birilerine bağımlı halde yaşamak zorunda kalabilirler. Hatta doğru yönlendirilme yapılmayan bu çocuklar ileriki yaşamlarında hırcım, kendine ve çevresine zarar veren, istismarda bulunan veya istismara maruz kalabilecek hale gelebilirler. Doğru eğitimin yanı sıra zekâ problemi yaşayan çocukların gerekirse ilaç tedavisi de alması gerekebilir. Bu yöntemlerin tamamının uygulanabilmesi için öncelikle hızlı ve doğru teşhis konması gereklidir. WISC-R teşhis koymada kullanılan ve çeşitli çalışmalarla ispatlanmış bir ölçektir. Bu ölçek gerek sözel gerek uygulamalar ile çocuğun zekâ düzeyi hakkında bilgiler sunmaktadır. Unutmamak gerekir ki bu test bir uzman tarafından uygulandığından, uzmanın değerlendirmesi oldukça önemlidir. Yetkin bir uzman tarafından gerçekleştirilmeyen WISC-R testi doğru sonuç vermeyebilir.

Makine öğrenmesi yöntemleri, çeşitli verileri kullanarak sınıflandırma gerçekleştirmektedir. Kan değerleri, derecelendirilmiş ölçekler ile yapılan testler gibi verileri kullanarak hastalık teşhisine yönelik sınıflandırmalarda tıp alanında yapılmaktadır. Yapılan bu çalışmalar ile elde edilen yüksek sınıflandırma başarıları artık bilim insanlarını uygulamaya geçmeye yönlendirmektedir. Makine öğrenmesi yöntemleri algoritmalar ve bilgisayar yazılımı kullanarak çalıştığından objektif bir yaklaşım sunmaktadır ve bu çok önemli bir özelliktir. Tıp alanında yapılacak otomatik sınıflandırmalarda objektif yaklaşım insan hatalarını da sıfırlayabilir. Makine öğrenmesi yöntemleri sınıflandırmanın yanı sıra çeşitli algoritmalar ile özellik seçimi de yapmaktadır. Literatür incelendiğinde özellik seçimi ile yapılan sınıflandırmalar daha başarılı olabilmektedir. Veri setinde yer alan özellikler ile yapılan sınıflandırmanın daha başarılı olması, özellik seçimi yöntemlerinin hastalık teşhisinde hangi verilerin daha etkili olduğu hakkında bilgi verebilir. WISC-R gibi derecelendirilmiş ölçeklerin doğruluğu da farklı çalışmalarda denenmiş ve ispatlanmış olsa da bizim bilgilerimize göre literatürde WISC-R testinin sorularını makine öğrenmesi yöntemleri ile araştıran bir çalışma yoktur.

Çalışmamızda Embedded Özellik Seçimi yöntemleri kullanılarak WISC-R testinin; hafif düzey ZY, orta düzey ZY, ağır düzey ZY, ileri düzey ZY hastalar için etkisi Embedded yöntemler ile araştırılmak istenmiştir. Embedded yöntemler; 3 farklı yöntem ile hesaplama gerçekleştirmektedir (Lasso, Gini, Permütasyon). Embedded yöntemler, Filtreleme ve Wrapper yöntemlerini içerisinde barındıran detaylı hesaplama yapan yöntemlerdir. Yöntemin ikinci kısmında Lojistik Regresyon ve Random Forest makine öğrenmesi yöntemleri kullanılarak en yüksek sınıflandırma başarıları yakalama amacı vardır. Elde edilen sınıflandırma sonuçları geri besleme ile özellik seçimi

tarafından değerlendirilip ideal özellikler seçilene kadar devam eder. Lasso yöntemi Lojistik Regresyon ile sınıflandırma yaparken, Gini ve Permütasyon özellik seçiciler Random Forest makine öğrenmesi yöntemini kullanırlar.

3 özellik seçici sonuçları da incelendiğinde Toplam WISC-R Skorunun (WTS) yüksek ilişkili olarak seçildiği görülmektedir. Yöntemler detaylıca incelendiğinde ikinci sırada Toplam Performans Skorunun (WPS) geldiği görülmektedir. Sözel Toplam Skoru (WVS) Lasso ve Permütasyon yöntemlerinde hesaplanmamıştır. Gini yöntemi ise WVS'yi 0,4 ile üçüncü sırada belirlemiştir. Lasso ve Gini Sözel ve Performans alt puan türlerini eşit olarak belirlemiş görünse de Performans alt puan türlerini göreceli olarak daha etkili olduğu söylenebilir. Permütasyon yöntemi Sözel alt puan türlerinin tamamını 0 olarak hesaplamış olup, 3. ve 5. Performans alt puan türünde hesaplama gerçekleştirmiştir. Hatta 3. puan türü için hesapladığı değer 0,1212 ile WPS'ye eşittir. Yöntemlerde farklı sonuçlar elde edilmiş olsa da Toplam Skoru (WTS)'nin ZY hastalık teşhisinde yüksek ilişkili olduğu söylenebilir. Ayrıca performans puan türlerinin sözel puan türlerine göre daha ilişkili olduğu da söylenebilir. 3 farklı yöntem ile hesaplanan özellikler sınıflandırıldığında yüksek sınıflandırma başarıları elde edilmiştir (Lasso + LR = 0,97, Gini + RF = 0,87, Permutation + RF = 0,91). Lasso ve Lojistik Regresyon ile yapılan sınıflandırmanın diğer iki yöntemle göre daha başarılı olması burada seçilen özellik sayısının diğerlerinden fazla olmasından kaynaklandığı söylenebilir.

Çalışmamız Kahramanmaraş İlinde bulunan hasta bilgilerini içerdiği için sınırlı bir lokasyonu içermektedir. Farklı coğrafyalardan hastaların verilerini kullanmak elbette çalışmanın yaygın etkisini arttıracaktır. Bu açıdan kullandığımız veri seti çalışmamızın sınırlanmasına etki etmiş gibi görünse de el edilen yüksek sınıflandırma başarıları, ileride yapılacak daha kapsamlı çalışmalar için bizi teşvik etmektedir.

Kaynaklar (Reference)

1. Tassé, M. J., Luckasson, R., & Nygren, M. A., AAIDD Proposed Recommendations for ICD-11 and the Condition Previously Known as Mental Retardation. Intellectual and Developmental Disabilities. 2013.
2. Ewer, Diagnostic and Statistical Manual of Mental Disorders, 5th Edition. In American Psychiatric Publishing, Inc. eBooks. American Psychiatric Publishing, Inc., 2013.
3. Whitaker, S., WISC-IV and low IQ: review and comparison with the WAIS-III. Educational Psychology in Practice, 24 (2), 129-137, 2008.
4. Savaşır, I. ve Şahin, N., Wechsler Çocuklar İçin Zekâ Ölçeği uygulama kitapçığı. Ankara: Türk Psikologlar Derneği, 1995.
5. Bulut C., Ballı T., Yetkin E.F., Comparative classification performances of filter model feature selection algorithms in EEG based brain computer interface system, Journal of the Faculty of Engineering and Architecture of Gazi University, 38 (4), 2397-2408, 2023.
6. Ren, K., Fang, W., Qu, J., Zhang, X., Shi, X., Comparison of eight filter-based feature selection methods for monthly streamflow forecasting – three case studies on camels data sets. Journal of Hydrology, 586, 124897, 2020.
7. Thabtah, F., Kamalov, F., Hammoud, S., Shahamiri, S. R., Least loss: A simplified filter method for feature selection. Information Sciences, 534, 1-15, 2020.
8. Zhao, L., Li, Y., Li, S., Ke, H., A frequency item mining based embedded feature selection algorithm and its application in energy consumption prediction of electric bus. Energy, 271, 126999, 2023.
9. Deng, T., Huang, Y., Yang, G., Wang, C., Pointwise mutual information sparsely embedded feature selection. International Journal of Approximate Reasoning, 151, 251-270, 2022.
10. Wang, Q., Yue, C., Li, X., Liao, P., Li, X., Enhancing robustness of monthly streamflow forecasting model using embedded-feature selection algorithm based on improved Gray Wolf optimizer. Journal of Hydrology, 617, 128995, 2023.
11. Xing, J., Zhou, X., Zhao, H., Chen, H., Heidari, A. A., Elite levy spreading differential evolution via ABC shrink-wrap for multi-

- threshold segmentation of breast cancer images. *Biomedical Signal Processing and Control*, 82, 104592, 2023.
12. Abbasi, M. S., Al-Sahaf, H., Mansoori, M., Welch, I., Behavior-based ransomware classification: A particle swarm optimization wrapper-based approach for feature selection. *Applied Soft Computing*, 121, 108744, 2022.
 13. Bajer, D., Dudjak, M., Zoric, B., Wrapper-based feature selection: How important is the wrapped classifier? *2020 International Conference on Smart Systems and Technologies (SST)*, 2020.
 14. Taşdedir, M.Ö ve Ergül, C., WISC-R Temelinde Üstün Yeteneklilik Profil Analizi: Ankara İli Örneği* Ankara Üniversitesi Eğitim Bilimleri Fakültesi, 16 (3), 271-289. 10.1501/Ozlegt_0000000232, 2015.
 15. Çelik, C., Erden, G., Özmen S., Hesapçıoğlu Tural, S., Dikkat Eksikliği Hiperaktivite Bozukluğu'nda Wechsler Çocuklar İçin Zekâ Ölçeği'nin İki Sürümünün Karşılaştırılması ve Okuma Becerilerinin Değerlendirilmesi. *Türk Psikiyatri Dergisi*, 28 (2), 104-16, 2017.
 16. Yektaş, Ç. ve Kaplan, E.S., Bir Üniversite Hastanesi Çocuk Ergen Ruh Sağlığı ve Hastalıkları Birimi'ne Başvuran Hastaların Sağlık Kurulu Raporlarının Değerlendirilmesi. *Konuralp Tıp Dergisi*, 9 (3), 228-232, 2017.
 17. Altun, S., Alkan, A., Altun, H., The investigation of WISC-R profiles in children with border intelligence and intellectual disability with machine learning algorithms, *Gazi University Journal of Science*, 27 (5), 589-596, 2021.
 18. Hu, J., Pan, K., Song, Y., Wei, G., Shen, C., An improved feature selection method for classification on incomplete data: Non-negative latent factor-incorporated duplicate mic. *Expert Systems with Applications*, 212, 118654, 2023.
 19. Zhou, L., Si, Y.-W., Fujita, H., Predicting the listing statuses of Chinese-listed companies using decision trees combined with an improved filter feature selection method. *Knowledge-Based Systems*, 128, 93–101, 2017.
 20. Salati M., Askerzade İ., Bostancı G.E., Convolutional neural network models using metaheuristic based feature selection method for intrusion detection, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 40 (1), 179-188, 2025.
 21. Guo, H., Ma, J., Wang, R., Zhou, Y., Feature library-assisted surrogate model for evolutionary wrapper-based feature selection and classification. *Applied Soft Computing*, 110241, 2023.
 22. Fu, Y., Liu, X., Sarkar, S., Wu, T., Gaussian mixture model with feature selection: An embedded approach. *Computers Industrial Engineering*, 152, 107000, 2021.
 23. Şafak E., Barişçı N., Real-time fire and smoke detection for mobile devices using deep learning, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 38 (4), 2179–2190, 2023.

