



HACETTEPE ÜNİVERSİTESİ EĞİTİM BİLİMLERİ ENSTİTÜSÜ

Eğitim Bilimleri Ana Bilim Dalı
Eğitimde Ölçme ve Değerlendirme Programı

VERİ MADENCİLİĞİ YÖNTEMLERİ İLE ÜLKELERİN PISA BAŞARI
DÜZEYLERİNİ ETKİLEYEN DEĞİŞKENLERİN İNCELENMESİ

Yusuf KASAP

Doktora Tezi

Ankara, 2022

Liderlik, arařtırma, inovasyon, kaliteli eđitim ve deđiřim ile

Daha ileriye ... En İyiyeye ...



HACETTEPE ÜNİVERSİTESİ
EĞİTİM BİLİMLERİ ENSTİTÜSÜ

Eğitim Bilimleri Ana Bilim Dalı
Eğitimde Ölçme ve Değerlendirme Programı

VERİ MADENCİLİĞİ YÖNTEMLERİ İLE ÜLKELERİN PISA BAŞARI
DÜZEYLERİNİ ETKİLEYEN DEĞİŞKENLERİN İNCELENMESİ

INVESTIGATION OF VARIABLES AFFECTING PISA SUCCESS LEVELS OF
COUNTRIES BY DATA MINING METHODS

Yusuf KASAP

Doktora Tezi

Ankara, 2022

Kabul ve Onay

Eđitim Bilimleri Enstitüsü M¼d¼rl¼đ¼ne,

Yusuf KASAP'ın hazırladıđı “Veri Madenciliđi Y¼ntemleri ile Ülkelerin PISA Başarı D¼zeylerini Etkileyen Deđişkenlerin İncelenmesi” başlıklı bu çalıřma j¼rimiz tarafından **Eđitim Bilimleri Ana Bilim Dalı, Eđitimde Ölçme ve Deđerlendirme Bilim Dalında Doktora Tezi** olarak kabul edilmiřtir.

J¼ri Başkanı Prof. Dr. Selahattin GELBAL İmza

J¼ri Üyesi (Danıřman) Prof. Dr. Nuri DOĐAN İmza

J¼ri Üyesi Prof. Dr. H¼lya KELECİOĐLU İmza

J¼ri Üyesi Doç. Dr. Celal Deha DOĐAN İmza

J¼ri Üyesi Doç. Dr. G¼khan AKSU İmza

İkinci Tez Danıřmanı Prof. Dr. Cem KOÇAK

Enstit¼ Y¼netim Kurulunun
.../.../.... Tarihli ve
sayılı kararı.

Bu tez Hacettepe Üniversitesi Lisans¼st¼ Eđitim, Öğretim ve Sınav Y¼netmeliđi'nin ilgili maddeleri uyarınca yukarıdaki j¼ri üyeleri tarafından 26 / 01 / 2022 tarihinde uygun gör¼lm¼ř ve Enstit¼ Y¼netim Kurulunca / / tarihi itibarıyla kabul edilmiřtir.

Prof. Dr. Selahattin GELBAL
Eđitim Bilimleri Enstit¼s¼ M¼d¼r¼

Öz

Bu araştırmanın amacı, 2018 yılında PISA'ya katılan öğrencilere sınavla birlikte verilen öğrenci anketinden elde edilen 34 bağımsız değişkeni kullanarak, farklı başarı düzeyine sahip ülkelerin PISA 2018 okuma alanı başarı puanını yordayan önemli değişkenleri belirlemektir. Bu amaç için PISA'ya giren 79 ülke başarı yüzdelerine göre sıralanmış ve bu sıralamaya göre bu ülkeler alt, orta ve üst grup ülkeler olarak ayrılmıştır. Daha sonra alt grup, orta grup ve üst grup ülkelerin her birinden üçer ülke seçilerek alt, orta ve üst grup ülkeler örnekleme oluşturulmuş ve bu dokuz ülkenin tamamı birleştirilerek çalışma örnekleme belirlenmiştir. Orta gruba seçilen üç ülkeden biri olan Türkiye örnekleme araştırmaya ayrıca bağımsız olarak dâhil edilmiştir. Daha sonra, Türkiye, alt, orta, üst grup ülkeler örnekleme ve çalışma örnekleme üzerinde lojistik regresyon, Sınıflama ve Regresyon Ağacı ve Rastgele Orman yöntemleri ile veri madenciliği analizleri gerçekleştirilmiştir. Yapılan uygulamalarda okuduğunu anlama başarısını yordayan önemli değişkenlerin sayısının 34'ten iki ile sekiz arasında bir sayıya indirgenebildiği görülmüştür. Böylece; az sayıda değişken kullanılarak PISA başarı düzeyini yordayabilen veri madenciliği sınıflama tahmin modelleri elde edilmiştir. Elde edilen modellerin başarıyı iki kategorili (başarısız-başarılı) yordama da yüksek ve üç kategorili (düşük, orta yüksek) yordama da kabul edilebilir düzeyde tahmin performansına sahip oldukları saptanmıştır. Elde edilen sonuçlara göre 34 bağımsız değişkenden öncelikle PISA testinin zorluk algısı, okuma keyfi, baba eğitim düzeyi, okuma zorluk algısı, sosyo-ekonomik düzey indeksi, yaşamın anlamı, Öğretmenin eğitimi yönlendirmesi ve haftalık test dili öğrenme süresi olmak üzere toplamda 27 değişkenin farklı tahmin modellerinde önemli değişkenler olarak yer aldığı görülmüştür.

Anahtar sözcükler: makine öğrenme, veri madenciliği, sınıflama performansı, tahmin performansı, pisa, weka, modeller, karar ağaçları

Abstract

The aim of this research is to determine the important variables that predict the PISA 2018 reading field achievement score of countries with different achievement levels, using 34 independent variables obtained from the student questionnaire given to the students who participated in PISA in 2018. For this purpose, 79 countries that entered PISA were ranked according to their success percentages and according to this ranking, these countries were divided into lower, middle and upper group countries. Then, three countries were selected from each of the lower group, middle group and upper group countries and nine different samples were obtained, all of these nine countries were determined as the study sample. The sample of Turkey, which is one of the three countries selected for the middle group, was also included in the study independently. Then, data mining analyzes were carried out on Turkey, the sample of lower, middle, upper group countries and the study sample using logistic regression, Classification and Regression Tree and Random Forest methods. It has been observed that the number of important variables that predict reading comprehension success can be reduced from 34 to a number between two and eight. Like this; Data mining classification prediction models, which can predict the PISA success level, were obtained by using a small number of variables. It was determined that the models obtained had high predictive performance in the two-category (unsuccessful-successful) prediction of success and acceptable in the three-category (low, medium-high) prediction. According to the results obtained, among the 34 independent variables, first of all, PISA test's perception of difficulty, reading pleasure, father's education level, perception of reading difficulty, socio-economic level index, meaning of life, teacher's direction of education and weekly test language learning time were used in different estimation models of 27 variables were found to be important variables.

Keywords: machine learning, data mining, classification performance, predictive performance, pisa, modeler, weka, decision trees

Teşekkür

Ölçme ve değerlendirme bilim dalında eğitime başladığım ilk günden bu yana bilgisini ve emeğini esirgmeden önerileri ve fikirleriyle beni yönlendiren, tez sürecinin tüm aşamalarında yanımda olan ve tüm sorularıma ayrıntılı olarak yanıt veren, anlayışlı ve yardımsever tavırları için değerli danışmanım Prof. Dr. Nuri DOĞAN'a ve çalışmalarım da her konuda içtenlikle destek olan değerli eş danışmanım Prof. Dr. Cem KOÇAK'a sonsuz teşekkürlerimi sunarım.

Ölçme ve değerlendirme alanında eğitime başladığım ilk günden bu yana bilgi, destek ve emeklerini esirgemeyen, doktora eğitimim boyunca aldığım dersler aracılığıyla bilgisinden ve deneyiminden faydalandığım değerli hocalarım Prof. Dr. Selahattin GELBAL'a ve Prof. Dr. Hülya KELECİOĞLU'na en içten teşekkürlerimi sunarım.

Doktora öğrenimim boyunca her zaman desteklerini hissettiğim ayrıca görüş ve önerileriyle de bu çalışmaya katkıda bulunan Doç. Dr. Celal Deha DOĞAN ve ayrıca tez jürisine katılımından ve katkılarından dolayı Doç. Dr. Gökhan AKSU'ya teşekkürlerimi sunarım.

Tezimi tamamlayabilmem için her zaman yanımda olan arkadaşlarım ve sevgili eşim Duygu KASAP'a teşekkür ederim.

İçindekiler

Öz.....	ii
Tablolar Dizini.....	vii
Şekiller Dizini.....	viii
Simgeler ve Kısaltmalar Dizini.....	ix
Bölüm 1 Giriş.....	1
Problem Durumu.....	5
Araştırmanın Amacı ve Önemi.....	8
Araştırma Problemi.....	10
Sayıtlılar.....	10
Sınırlılıklar.....	10
Tanımlar.....	11
Bölüm 2 Araştırmanın Kuramsal Temeli ve İlgili Araştırmalar.....	12
PISA Uygulamasında Okuryazarlık ve Okuduğunu Anlama.....	12
Veri Madenciliği ve Makine Öğrenme.....	20
Tanımlayıcı Modeller.....	23
Tahmin Edici Modeller.....	23
Veri Madenciliği Yöntemleri Sonuçlarının Değerlendirilmesi.....	53
Performans Kriterleri.....	58
Okuduğunu Anlama ile İlgili Araştırmalar.....	62
Veri Madenciliği ile İlgili Araştırmalar.....	66
Bölüm 3.....	73
Yöntem.....	73
Araştırmanın Türü.....	73
Çalışma Evreni ve Örneklemi.....	74
Verilerin Elde Edilmesi.....	75
Veri Toplama Araçları.....	76

Verilerin Analizi	77
Bölüm 4	80
Bulgular ve Yorumlar	80
Birinci Alt Probleme İlişkin Bulgular	80
İkinci Alt Probleme İlişkin Bulgular	94
Üçüncü Alt Probleme İlişkin Bulgular	108
Bölüm 5	130
Sonuç, Tartışma ve Öneriler.....	130
Sonuç.....	130
Tartışma.....	133
Öneriler	142
Kaynaklar	145
EK-A: İki Kategorili Başarı Durumu İçin Sınıflama ve Regresyon Ağaçları.....	158
EK-B: Üç Kategorili Başarı Durumu İçin Sınıflama ve Regresyon Ağaçları	163
EK-C: Etik Komisyonu Onay Bildirimi	168
EK-Ç: Etik Beyanı.....	169
EK-D: Yüksek Lisans/Doktora Tez Çalışması Orijinallik Raporu	170
EK-E: Thesis/Dissertation Originality Report.....	171
EK-F: Yayımlama ve Fikrî Mülkiyet Hakları Beyanı	172

Tablolar Dizini

Tablo 1 <i>PISA Okuduğunu Anlama Becerileri Testinde Yer Alan Değerlendirme Alanları</i>	15
Tablo 2 <i>PISA 2015 ve 2018 Uygulamalarındaki Bilişsel Süreçler ve Soruların Dağılımı</i>	18
Tablo 3 <i>Hava Durumu için Karar Tablosu</i>	27
Tablo 4 <i>Karışıklık Tablosu</i>	59
Tablo 5 <i>PISA 2018 Okuduğunu Anlama Becerisi Yeterlik Düzeylerinin Kategorileri</i>	76
Tablo 6 <i>Bağımsız Değişkenler, Bağımlı Değişken ve PISA 2018 Kodları</i>	77
Tablo 7 <i>Okuduğunu Anlama Başarısının İki Kategorili Olduğu Durumda LR Modeli ile Seçilen Önemli ve Ortak Değişkenler</i>	83
Tablo 8 <i>Okuduğunu Anlama Başarısının İki Kategorili Olduğu Durumda SRA Modeli ile Seçilen Önemli ve Ortak Değişkenler</i>	87
Tablo 9 <i>Okuduğunu Anlama Başarısının İki Kategorili Olduğu Durumda RO Modeli ile Seçilen Önemli ve Ortak Değişkenler</i>	92
Tablo 10 <i>Okuduğunu Anlama Başarısının Üç Kategorili Olduğu Durumda LR Modeli ile Seçilen Önemli ve Ortak Değişkenler</i>	96
Tablo 11 <i>Okuduğunu Anlama Başarısının Üç Kategorili Olduğu Durumda SRA Modeli ile Seçilen Önemli ve Ortak Değişkenler</i>	101
Tablo 12 <i>Okuduğunu Anlama Başarısının Üç Kategorili Olduğu Durumda RO Modeli ile Seçilen Önemli ve Ortak Değişkenler</i>	105
Tablo 13 <i>İki ve Üç Kategorili Başarı Durumu Kategori Frekansları</i>	109
Tablo 14 <i>İki Kategorili Başarı Durumu için LR Model Performansları</i>	110
Tablo 15 <i>İki Kategorili Başarı Durumu için SRA Model Performansları</i>	113
Tablo 16 <i>İki Kategorili Başarı Durumu için RO Model Performansları</i>	116
Tablo 17 <i>Üç Kategorili Başarı Durumu için LR Model Performansları</i>	120
Tablo 18 <i>Üç Kategorili Başarı Durumu için SRA Model Performansları</i>	123
Tablo 19 <i>Üç Kategorili Başarı Durumu için RO Model Performansları</i>	126

Şekiller Dizini

Şekil 1. Veri madenciliği modellerinin sınıflandırılması	23
Şekil 2. Sınıflama için genel bir karar ağacı örneği.....	25
Şekil 3. Hava durumu verisi için ağaç kütükleri	28
Şekil 4. Rastgele orman algoritması genelleştirilmiş hata oranı işleyiş süreci	40
Şekil 5. LR'de bağımlı ve bağımsız değişken ilişkisi (Hair vd., 2014)	47
Şekil 6. Eğitim ve test verisi ile öğrenme süreci.....	55
Şekil 7. Çapraz geçerlik süreci	55
Şekil 8. Bootstrap yönteminde örnekleme aşamaları	57
Şekil 9. Bagging torbalama yöntemi	58
Şekil 10. Araştırma süreci	73
Şekil 11. Okuduğunu anlama başarısının iki kategorili olduğu durumda LR modeli ile seçilen önemli 10 değişkene ilişkin grafikler	81
Şekil 12. Okuduğunu anlama başarısının iki kategorili olduğu durumda SRA modeli ile seçilen önemli 10 değişkene ilişkin grafikler	86
Şekil 13. Okuduğunu anlama başarısının iki kategorili olduğu durumda RO modeli ile seçilen önemli 10 değişkene ilişkin grafikler	90
Şekil 14. Okuduğunu anlama başarısının üç kategorili olduğu durumda LR modeli ile seçilen önemli 10 değişkene ilişkin grafikler	95
Şekil 15. Okuduğunu anlama başarısının üç kategorili olduğu durumda SRA modeli ile seçilen önemli 10 değişkene ilişkin grafikler.....	99
Şekil 16. Okuduğunu anlama başarısının üç kategorili olduğu durumda RO modeli ile seçilen önemli 10 değişkene ilişkin grafikler	103

Simgeler ve Kısaltmalar Dizini

RO: Rastgele Orman

LR: Lojistik Regresyon

SRA: Sınıflama ve Regresyon Ağacı

WEKA: Waikato Environment for Knowledge Analysis

PISA: Uluslararası Öğrenci Deęerlendirme Programı

TIMMS: Uluslararası Matematik ve Fen Eęilimleri Arařtırması

MEB: Milli Eęitim Bakanlıęı

OECD: The Organization for Economic Cooperation and Development

ÖBBS: Öğrenci Başarısının Belirlenmesi Sınavı

ABİDE: Akademik Becerilerin İzlenmesi ve Deęerlendirilmesi

Bölüm 1

Giriş

Bilişim teknolojilerinin hayatımızın birçok alanında kendine geniş yer bulması ile bireylerden elde edilen veri miktarı katlanarak artmaktadır. Araştırmalardan elde edilen ham veriler tek başına değersizdir. Bilgisayar yazılımlarının gelişmesi sayesinde bu ham verilerin belli bir amaç doğrultusunda işlenmesi ile elde edilen veriler arasındaki örüntüleri ve ilişkileri ortaya çıkarmak, var olan durumu tahmin etmek ve geleceğe yönelik öngöründe bulunmak hem araştırmacılar için hem de karar vericiler için anlamlı sonuçlar ortaya çıkarmaktadır. Elde edilen verilerin artması ve bireylerin farklı nitelikleriyle ilgili çok çeşitli değişkenlerin olması, analiz sürecinde veri madenciliği gibi ileri istatistiksel yöntemlerin kullanılması ihtiyacını doğurmaktadır. Veri madenciliği, büyük miktardaki veride bulunan ilişki, örüntü, bağıntı ve kuralların belirlenmesi sayesinde veride saklı olan önemli bilginin keşfedilmesine ve gelecekle ilgili öngörü yapılmasına imkân sağlayan bir yöntemdir (Kayri, 2008).

Araştırmalardan elde edilen verilerin analizi sürecinde veri madenciliği kapsamındaki tekniklerin kullanılması ile daha ayrıntılı istatistiksel sonuçlar elde edilebilmektedir. Veri madenciliği kullanılarak bireylerden elde edilen büyük miktarda ham veriden bireylerin davranış biçimleri saptanarak gelecekteki davranışları tahmin edilmeye çalışılmaktadır (Sieber, 2008). Veri madenciliği ticaret, tıp, bankacılık, mühendislik, borsa, eğitim gibi birçok disiplinde kullanılmaktadır (Savaş, Topaloğlu ve Yılmaz, 2012).

Geçmişte veri madenciliği algoritmalarının eğitimsel araştırmalarda yoğun olarak kullanılmadığı dikkat çekmektedir (Sinharay, 2016). Son zamanlarda veri madenciliği yöntemleri, sınıflamada, öngöründe bulunmada, bir bağımlı değişkeni etkileyen önemli değişkenleri belirlemede kullanıldığı için daha fazla önem kazanmaktadır. Eğitimde veri madenciliğinin gelişimi, diğer alanlara göre hızlı olmuştur. Eğitim alanında veri madenciliğine dayalı olarak ilk makalelerin yazılmasına ve çalıştayların yapılmasına 2000 yılı sonrası başlanmış, ilk konferans ise (Uluslararası Eğitimsel Veri Madenciliği Konferansı) 2008'de verilmiş ve ilk dergi (Eğitim Veri Madenciliği Dergisi) 2009'da yayınlanmıştır (Baker, 2014).

Eđitimde veri madenciliđi uygulamalarının diđer alanlara gre gecikmesinin nedenlerinden biri kayıtların ođunlukla kâđit formlar halinde tutulması iken diđer bir neden ise, evrimii đrenme uygulamalarının yapıldıđı sistemlerden gelen verilerin kullanımının zor olacak Őekilde kaydedilmesi veya nemli bilgilerin saklanmaması olarak dŐunlmektedir (Baker, 2014). Bu alıŐmada veri madenciliđinde kullanılan đrenme algoritmalarının eđitimde kullanılması ile hem baŐarıyı etkileyen tahmin nemi yksek bađımsız deđiŐkenlerin belirlenmesi hem de kullanılan algoritmaların tahmin performanslarının belirlenmesi sađlanmıŐtır.

Veri madenciliđinin zellikle eđitim alanında kullanılması, eđitim planlamacılarına, eđitim alanında karar alıcılara fikir vererek eđitim politikalarının ve stratejilerinin geliŐtirilmesine imkân sađlamaktadır. Calders ve Pechenizkiy (2012) eđitsel veri madenciliđini, eđitim alanında kullanılan bilgi sistemlerinden elde edilen verileri anlamaya ynelik yntemler geliŐtiren ok disiplinli bir araŐtırma alanı olarak ifade etmektedir. Eđitim verilerinde srekli olarak artıŐ olması nedeniyle eđitsel veri madenciliđi zengin bir uygulama alanı haline gelmiŐtir. Eđitsel veri madenciliđi, đrencilerin đrenme stratejilerinin anlaŐılmasının yanı sıra eđitim uygulamaları ve đrenme materyali geliŐtirmede veri merkezli karar vermeye imkân sađlar.

Diđer bir anlamıyla eđitsel veri madenciliđi, veri madenciliđi yntemlerinin, eđitim alanındaki problemlere yanıt bulmak iin đretim ortamlarından gelen veriler zerinde uygulanmasıdır. Eđitim alanında yapılan araŐtırmalarda tahmin ve ngrlerde bulunmak ve elde edilen sonuları karar verme srelerinde kullanmak iin yaygın olarak kullanılan yntemler sınıflama, tahmin, kmeleme, birliktelik kuralları ve yapay sinir ađları olarak belirtilebilir (Romero ve Ventura, 2010).

Eđitim alanında son yıllarda yapılan alıŐmalarda ok deđiŐkenli veri toplama eđilimi yaygınlaŐmıŐtır. Bu sınavlardan birisi de Uluslararası đrenci Deđerlendirme Programıdır (Programme for International Student Assessment-PISA). PISA 2000 yılından gnmze kadar gittike daha fazla lkenin katılımıyla gerekleŐtirilmektedir. PISA her  yılda bir yapılan, matematik okuryazarlıđı, fen okuryazarlıđı ve okuduđunu anlama testlerini ieren bir uygulamadır. Her bir PISA uygulamasında, bu  testten birine ađırlık verilmektedir. PISA 2018'de ađırlık verilen baŐlıca alan okuduđunu anlamadır. Bu uygulamada; metinleri anlama,

kullanma, değerlendirme, metinler üzerinde düşünme ve metinlerle etkileşim kurma becerilerini ölçmek temel amaçlardandır (OECD, 2019). PISA 2018 uygulaması, 79 ülkenin çoğunda bilgisayar üzerinden dijital olarak gerçekleştirilmiştir. PISA ile ölçülen değişkenler ve veri büyüklüğü dikkate alındığında PISA verilerinin daha iyi yorumlanabilmesi için veri madenciliği uygun bir yöntem olabilir. Dolayısıyla son yıllarda PISA verileri üzerinde veri madenciliği çalışmalarının yoğunlaştığı görülmektedir (Abad, Gamazo ve Rodriguez Conde, 2020; Aksu 2019; Bezek Güre, Kayri ve Erdoğan, 2020).

Alanyazında, akademik başarıyı yordamaya yönelik veri madenciliği yöntemlerinin kullanıldığı ulusal ve uluslararası birçok çalışma mevcuttur (Abad ve Lopez, 2017; Abad ve ark., 2020; Abdous, He ve Yen, 2012; Aksoy, 2014; Aksu, 2019; Bezek Güre ve ark., 2020; Özarslan, 2014; Yu, Kaprolet, Pannel ve Digangi, 2012). Bu çalışmalardan Abad ve ark. (2020), Bezek Güre ve ark. (2020), Yu ve ark. (2012) çalışmaları, PISA başarı düzeyini yordamaya yöneliktir. Bununla birlikte, alanyazında başarıyı yordayan faktörlerin belirlenmesine yönelik çalışmalar iki grupta sınıflanabilir. Birinci gruptaki çalışmalar, t testi, Mann-Whitney U testi, ANOVA, Kruskal-Wallis testi, Faktör analizi ve Çoklu regresyon analizi gibi uygulamalı istatistikteki tekniklerle başarıyı etkileyen değişkenleri belirlemeye yönelik çalışmalardır (Akkurt ve Köse 2019; Berberoğlu, Çalışkan ve Karslı, 2017; Coşkun, 2013; Güzle Kayır, 2012; Önder ve Gelbal, 2016; Özer-Özkan ve Acar-Güvendir, 2014; Uyulgan ve Akkuzu, 2017; Urfalı Dadandı, Dadandı ve Koca, 2018; Yıldırım, 2012;). Sonuç olarak PISA başarı puanını veya herhangi bir başarı puanını etkileyen faktörlerin belirlenmesinde uygulamalı istatistiksel yöntemlerin sıklıkla kullanıldığı ve çıktılarının özellikle p (anlamlılık) olasılıkları incelenerek belirlendiği söylenebilir. İkinci grup çalışmalar ise Aksu (2019) PISA Matematik başarısını yordayan değişkenleri belirlemek için M5P karar ağacı sınıflama algoritmasını, Abad ve Lopez (2017), akademik başarıyı yordayan değişkenleri belirlemek için J48 karar ağacı sınıflama algoritmasını kullanmıştır. Yu ve ark. (2012) ise öğrencilerin PISA fen okuryazarlığı başarısını yordama da lojistik regresyon sınıflama algoritması ve karar ağacı yöntemlerinden partition tree algoritmasını kullanmışlardır. Bu algoritmalar ile elde ettikleri karar ağacının kök düğümünden iç düğümlere oradan da yaprak düğümlere doğru düzeylere göre

değişkenleri en önemli olandan en önemsiz olana doğru önem derecesine göre sıralamışlardır.

Bu iki çalışmada; başarıyı yordayan önemli değişkenlerin belirlenmesinde; SPSS Modeller ve Weka programları kullanılmıştır (Abad ve Lopez, 2017; Yu ve ark., 2012;). Bununla birlikte; Bezek Güre ve ark. (2020) ise, PISA 2015 matematik başarısını yordayabilen önemli değişkenleri belirlemede, SPSS Modeller ve Matlab programlarında bulunan yapay sinir ağları ve rastgele orman algoritmasını kullanarak önemli değişkenleri belirlemede programın hesapladığı tahmin edici önemi (predictor importance) değerlerini kullanmışlardır. Aynı yaklaşıma uygun olacak şekilde, diğer bir çalışmada (Yue, 2021) öğrencilerin İngilizce performansını yordayabilen önemli değişkenleri belirlemede SPSS modeller programında bulunan yapay sinir ağları algoritmasını kullanarak programın hesapladığı tahmin edici önemi değerlerini dikkate almıştır. Alanyazında yapılan çalışmalarda başarıyı etkileyen faktörleri belirlemede, veri madenciliği algoritmalarından elde edilen sonuçlara ve istatistiksel analiz çıktılarına göre karar verildiği görülmekte olup, istatistiksel yaklaşımlar ile veri madenciliği yaklaşımları arasındaki farklılık ortaya konulmaktadır. İstatistiksel yaklaşımda başarıyı etkileyen faktörler, elde edilen istatistiksel modelin çıktılarına göre ilişki temeline dayandırılırken (örneğin p anlamlılık değerlerine göre), veri madenciliği yaklaşımında başarıyı yordama da yordayıcı önemi yüksek olan değişkenler (önemli değişkenler) modelin tahmin performansını en çok artıran yordayıcılar olarak görülmektedir. Bu çalışmada, özellikle Bezek Güre ve ark. (2020)'nin PISA 2015 matematik okuryazarlığı verilerini kullanılarak yaptıkları çalışmanın yaklaşımına benzer olarak, 2018 PISA okuduğunu anlama başarısını yordayabilen önemli değişkenler SPSS Modeller ve Weka programı birlikte kullanılarak belirlenmiştir. Ayrıca, Bezek Güre ve ark. (2020) ve Yue (2021) çalışmalarında, yapay sinir ağı ve rastgele orman veri madenciliği sınıflama algoritmalarının performanslarını belirlerken, bu çalışmada; lojistik regresyon, sınıflama ve regresyon ağacı ve rastgele orman sınıflama algoritmalarının performansları ayrıntılı olarak karşılaştırılmıştır. Bu bağlamda bu çalışmanın, “model performansını en yüksek yapan değişkenler önemli değişkenlerdir” yaklaşımı ve bu yaklaşımın değişken azaltmaya imkân sağlaması ilk kez PISA 2018 okuduğunu anlama verisi üzerinde uygulayan ve bu yeni yaklaşımı literatürde ilk kez lojistik regresyon ve sınıflama ve regresyon ağacı ve

rastgele orman veri madenciliği yöntemlerini kullanarak yapan, yeni ve güncel bir çalışma olduğu söylenebilir. Ayrıca, başarıyı veri madenciliği ile yordama da çok farklı yazılımlardan yararlanıldığı ve farklı algoritmaların kullanıldığı görülmektedir. Aynı çalışmada farklı yazılımlar kullanılarak (Örneğin WEKA ve Modeler vb.) elde edilen sonuçların karşılaştırıldığı çalışmaların yanında bir yazılım kullanılarak farklı değişken örüntülerinde elde edilen sonuçların yorumlanmasını kapsayan çalışmalar söz konusu olabilmektedir. Diğer yandan veri madenciliği kapsamında kullanılan farklı modellerin aynı değişkenler aracılığıyla karşılaştırılmasına da çok sık rastlanmaktadır. İncelenen veri madenciliği çalışmalarında gözlenen en önemli sorunlardan biri başarıyı yordayan değişkenlerin sayısını belirlemek diğeri de başarıyı yordayan değişkenlerin önem sırasına karar vermektir. Sözü edilen iki problemin çözümüne ilişkin farklı alanlardaki çalışmalarda bazı öneriler bulunmakla birlikte eğitsel verilerde bunlara ilişkin çalışmaların yetersizliği bu araştırmayı yapmanın gerekçesini oluşturmaktadır.

Problem Durumu

Günümüzde kişiler hakkında farklı yollarla birçok veri toplama işlemi gerçekleştirilmektedir. Bu veriler yardımıyla kişilerin sağlık, gıda, hizmet, bankacılık, giyim, televizyon gibi alanlardaki davranışları ile ilgili çıkarımlarda bulunmaya ve bu çıkarımlardan strateji geliştirmeye çalışan kurumlar bulunmaktadır. Yapılan çıkarımların doğruluğunun, sistemlerin verimli bir şekilde çalışmasını sürdürmesi için önemli unsurlardan biri olduğu göz önünde bulundurulursa eldeki verilerden performansı en yüksek tahmin modeline ulaşmak çok önemlidir. Bu nedenle çok sayıdaki veri arasından hangi değişkenin ne kadar önemli olduğunun kestirilmesi araştırmacılar için önem arz etmektedir. Geniş ölçekli verilerden belirli amaçlar doğrultusunda istenen sonuçları çıkarmak için önemi her geçen gün artmakta olan veri madenciliği yöntemleri ile bireylerin davranış biçimleri çözümlenerek gelecekteki davranışları hakkında öngörüle bulunmaktadır. Veri madenciliği yöntemleri farklı istatistiksel modellere dayalıdır. Söz konusu modellerin çok sayıda olması nedeniyle, bu modellerden hangilerinin daha iyi öngörüle bulunduğunun belirlenmesi, elde edilen sonuçların doğruluğu bakımından büyük önem teşkil etmektedir. Bu nedenle, yapılan çalışmalarda, farklı veri madenciliği yöntemlerinin performansları karşılaştırılarak karar verilmeye

çalışılmaktadır. Özellikle ölçme faaliyetleri sonrasında geçme-kalma, seçme, yerleştirme vb. kararların veri madenciliği yöntemlerine dayalı olarak verilmesinde kullanılan modelin tahmin performansı ile verilecek kararın doğruluk düzeyi saptanabilmektedir. Ayrıca, eğitim alanında, veri madenciliği ile farklı başarı gruplarında başarıyı belirlemede hangi değişkenlerin ne derece etkili olduğu saptanarak, öğrenme sürecinde etkili olan faktörlerin daha iyi anlaşılmasına katkı sağlanabilir.

Eğitimde de uluslararası ve ulusal düzeyde yapılan ölçme işlemlerinde çok fazla sayıda değişken ile ilgili çok büyük miktarlarda veri toplandığı görülmektedir. PISA, TIMSS gibi uluslararası sınavlarda çok sayıda ülke ve öğrenciye ilişkin çok sayıda değişken içeren veri toplanması buna örnek olarak verilebilir. Ülkemizde de ÖBBS, ABİDE gibi sınavlarla çok sayıda öğrenciden birçok değişken içeren veri toplandığı bilinmektedir. Bu nedenle PISA, TIMMS gibi çok sayıda değişken içeren büyük miktarlarda veri bulunan çalışmalarda, bütün değişkenleri analize dâhil edebilmek ve bunu yaparken anlamlı, geçerli ve güvenilir sonuçlar elde etmek için veri madenciliği tekniklerinin kullanılması yaygınlaşmıştır.

Alanyazında, başarıyı etkileyen önemli değişkenleri belirlemede farklı yaklaşımlar söz konusudur. Örneğin, Aksu (2018) önemli değişkenleri belirlemede lojistik regresyon veri madenciliği ileriye ve geriye doğru adımsal yöntemlerini kullanarak modelde kalan anlamlı değişkenleri önemli değişken olarak kabul etmişlerdir. Aksu (2018) daha sonra elde ettiği önemli değişkenleri kullanarak bazı veri madenciliği sınıflama algoritmalarının performanslarını karşılaştırmıştır. Bu yaklaşım istatistiksel yaklaşım olup başlangıçta önemli değişkenleri bir kez belirledikten sonra bu önemli değişkenleri kullanarak farklı veri madenciliği tahmin modellerini karşılaştırmaya yöneliktir. Bu yaklaşımda her bir sınıflama algoritması için başarıyı yordayan önemli değişkenler lojistik regresyon ile bulunan anlamlı değişkenler olarak kabul edilmiştir. Fakat karşılaştırılan veri madenciliği sınıflama algoritmalarının her biri için başarıyı yordayan önemli değişkenler farklılık gösterebilmektedir. Bu durumda bir sınıflama modeli ile elde edilen önemli değişkenlerle başka bir sınıflama algoritması ile tahminde bulunmak elde edilen sonuçların istatistiksel olarak hatalı olabilmesine neden olacaktır. Bezek Güre ve ark. (2020)'nin çalışmasında bu problem durumunu fark ederek, 2015 PISA matematik okuryazarlığı verileri üzerinde başarıyı yordayabilen (tahmin edebilen)

önemli yordayıcıları (tahmin edicileri) belirlemede SPSS Modeler programındaki tahmin edici önemi işlemine dayanan bir çalışma ortaya koymuşlardır. Yapılan çalışmada önemli değişkenler her bir veri madenciliği sınıflama tahmin modeline dayalı olarak belirlenmiştir. Yue (2021) ise Bezek Güre ve ark. (2020)'nin SPSS Modeler programındaki tahmin edici önemi işlemine dayanan yaklaşımını kolejdaki öğrencilerin başarı performanslarını tahmin edebilen önemli değişkenleri belirlemek için kullanmıştır. Böylece, bu iki çalışmada, başarıyı yordayan önemli değişkenleri belirlemeye yönelik olarak daha gerçekçi bir çözümleme yaklaşımı önerdiklerini iddia etmişlerdir.

SPSS modeler programında temel amaç bağımlı değişkeni yordayan önemli bağımsız değişkenlerin neler olduğunu belirlemek olduğundan, Weka programına göre daha basit istatistiksel çıktılara göre karar verilmektedir. Bezek Güre vd., (2020) ve Yue (2021) çalışmalarında ikili veya üçlü sınıflama düzeyindeki bağımlı değişkeni yordayan önemli değişkenleri belirledikten sonra, tahmin veya öngörmeyi hedefleyen Weka programını kullanarak, daha az sayıda değişken ile performansı yüksek tahminler yapılabileceğini göstermişlerdir.

Alanyazındaki birçok çalışmada, belli bir başarı düzeyine sahip evrenlerden seçilen örneklemeler kullanılarak veri madenciliği uygulamaları yapılmıştır. Örneğin; Abad ve ark. (2020) çalışmalarında PISA İspanya örneklemini, Aksu ve Güzeller (2016) ve Bezek Güre ve ark. (2020), Büyükkıdık ve Mutluer (2017), Kiray, Gok ve Bozkir (2015) ise sadece PISA Türkiye örneklemini kullanmışlardır. Bu çalışmada ise; farklı başarı düzeylerindeki evrenleri temsil edebilecek örneklemeler kullanılarak daha genellenebilir istatistiksel sonuçlar elde edilmesi amaçlanmıştır. Bu tez çalışmasında, Türkiye evreninden bir örneklem, PISA okuduğunu anlama sınavında düşük başarı düzeyine sahip ülkeler evreninden bir örneklem, orta düzey başarıya sahip ülkeler evreninden bir örneklem, yüksek düzey başarıya sahip ülkeler evreninden bir örneklem ve dünya ülkeleri evreninden bir örneklem seçilerek veri madenciliği analizleri ayrıntılı olarak gerçekleştirilmiştir. Böylece, farklı başarı düzeylerindeki ülkeler için; başarıyı yordayan aynı ve farklı değişkenlerin neler olduğu saptanarak, düşük başarı düzeyindeki ülkelerin başarılarını artırmada daha doğru kararlar almaları sağlanabilir. Ayrıca bu çalışmada, farklı başarı düzeyindeki evrenler için, hangi değişkenlerin başarıyı yordama da önemli oldukları saptanmış olup, temsil gücü daha yüksek örneklemeler kullanılarak daha

genellenebilir sonuçlara ulaşılmaya çalışılmıştır. Bu tez çalışmasının, bu bakımdan alanyazına katkı sağlayacağı düşünülmektedir.

Alanyazında, PISA verileri üzerine yapılan çalışmalarda veri madenciliği sınıflama modelleri kullanılırken, başarı değişkeni daha çok iki kategorili (başarısız, başarılı) olarak alınmıştır (Aksu, 2019; Aksu ve Güzeller, 2016; Kiray ve ark., 2015; Yu ve ark., 2012). Ancak Gamazo ve Abad (2020), Bezek Güre ve ark. (2020), Yue (2021)'nin yaptığı çalışmada, veri madenciliği sınıflama algoritmalarını kullanarak PISA başarısını yordama da, başarı değişkeni üç kategorili (düşük, orta, yüksek) olarak alınmıştır.

Araştırmanın Amacı ve Önemi

Öğrenci başarısını uluslararası düzeyde ele alan PISA uygulamasına yönelik birçok araştırma mevcuttur. Yapılan araştırma sonuçları ülkelerin eğitim politikalarının belirlenmesine ve eğitime yapılan yatırımların verimliliğinin değerlendirilmesine olanak sağlamaktadır. Ancak ülkelerin buldukları başarı düzeylerine göre PISA başarısını yordama da önemli olan değişkenlerin tespitine yönelik yeterli sayıda çalışma yoktur. Bu araştırma söz konusu soruna çözüm üretmek amacıyla, üst, orta, alt başarı düzeyinde bulunan ülkelerdeki öğrencilerin PISA başarısını belirlemede önemli olan değişkenlerin saptanması ile uygulamaya katılan ülkeler hakkında daha ayrıntılı bilgilerin elde edilmesine ve elde edilen bilgiler üzerinden daha detaylı yorumların yapılmasına olanak sağlanacağı düşünülmektedir. Bu doğrultuda araştırma sonuçlarında ülkeler bazında başarıyı etkileyen değişkenlerin göstereceği benzerlik ya da farklılıkların ortaya çıkarılması ülkelerin eğitim alanında yapacağı değişikliklerde hangi değişkenlere öncelik vermesi gerektiği konusunda daha ayrıntılı bilgi vermesi beklenmektedir. Araştırmadan elde edilen sonuçların öğretim programlarının güncellenmesi sürecinde ve ihtiyaç analizi planlamasında önemli katkılar sunmasının yanı sıra PISA'ya katılan farklı başarı düzeyine sahip ülkelerin eğitim sistemlerinin geliştirilmesine yönelik atılacak adımlar için temel oluşturması beklenmektedir. Böylece araştırmanın eğitim politikalarına destek olarak yeni eğitim politikalarının geliştirilmesine katkıda bulunacağı düşünülmektedir.

Bununla beraber okuduğunu anlama başarısının yordanması için gerekli değişkenlerin tespit edilmesinde kullanılacak makine öğrenme ve veri madenciliği

algoritmalarının eğitim alanında yapılacak çalışmalara örnek teşkil etmesi beklenmektedir. Araştırmalarda makine öğrenme ve veri madenciliği tekniklerinin kullanılması araştırma süreçlerinde elde edilen çok büyük miktarlardaki verinin daha kapsamlı kullanılabilmesi, daha anlamlı sonuçlar çıkarılabilmesi ve veriye daha geniş bir perspektiften bakılabilmesi için önemli görülmektedir.

Bu araştırmanın temel amacı, PISA öğrenci anketinde bulunan 34 bağımsız değişkene ilişkin puanları kullanarak farklı başarı düzeyine sahip (alt, orta ve üst başarı grubundaki) ülkelerin okuduğunu anlama başarısını etkileyen önemli yordayıcıları belirlemek ve bireylerin PISA başarılarını yordayan değişkenleri tahmin etmek için kullanılan veri madenciliği algoritmalarından hangilerinin daha iyi sınıflama ve tahmin performansına sahip olduklarını ortaya çıkarmaktır. Dolayısıyla bu çalışmayla;

- Öğrencilerin PISA okuduğunu anlama başarı düzeylerini tahmin etmede önemli değişkenlerin (yordayıcıların) belirlenmesi ve bu değişkenler ile performansı yüksek tahmin modelleri oluşturulabileceğinin gösterilmesi ve böylece; veri madenciliğine dayalı olarak değişken sayısını azaltmaya yönelik bir çalışmanın yapılması,
- Öğrencilerin PISA başarılarını tahmin etmek için farklı veri madenciliği sınıflama modellerinden elde edilen önemli değişkenler arasından ortak olanların saptanması ve bu ortak değişkenlerin eğitim bilimleri temelinde tartışılması,
- Öğrencilerin PISA başarılarını tahmin etmek için belirlenen önemli değişkenlerin önem derecelerine göre sıralanması ve önemli değişkenlerin önem derecelerine göre eğitim bilimleri temelinde tartışılması,
- Elde edilen önemli değişkenler kullanılarak modellerin tahmin performanslarının ayrıntılı olarak karşılaştırılması ve böylece, başarıyı yordama da en iyi performansa sahip, veri madenciliği sınıflama yönteminin seçilmesi amaçlanmaktadır.

Araştırma Problemi

PISA'ya katılan farklı başarı düzeyindeki ülkelerin Lojistik Regresyon, Sınıflama ve Regresyon Ağacı ve Rastgele Orman yöntemlerine göre okuduğunu anlama başarılarını tahmin etmede etkili olan öğrenci özellikleri nelerdir?

Alt problemler

1. PISA öğrenci anketinde ölçülen öğrenci özelliklerinden yararlanarak iki kategorili okuduğunu anlama başarısını tahmin etmede kullanılan Lojistik Regresyon, Sınıflama ve Regresyon Ağacı ve Rastgele Orman yöntemlerini kullanarak Türkiye, üst, orta, alt başarı düzeyindeki ülkeler örnekleme ve çalışma örneklemindeki ülkelerin başarılarını yordayan önemli değişkenler nelerdir?
2. PISA öğrenci anketinde ölçülen öğrenci özelliklerinden yararlanarak üç kategorili okuduğunu anlama başarısını tahmin etmede kullanılan Lojistik Regresyon, Sınıflama ve Regresyon Ağacı ve Rastgele Orman yöntemlerini kullanarak Türkiye, üst, orta, alt başarı düzeyindeki ülkeler örnekleme ve çalışma örneklemindeki ülkelerin başarılarını yordayan önemli değişkenler nelerdir?
3. PISA öğrenci anketinde ölçülen öğrenci özelliklerinden yararlanarak iki kategorili ve üç kategorili okuduğunu anlama başarısını tahmin etmede kullanılan Lojistik Regresyon, Sınıflama ve Regresyon Ağacı ve Rastgele Orman yöntemleri ile elde edilen sınıflama ve tahmin performansları ne düzeydedir?

Sayıtlılar

Bu araştırmanın temel sayıtlısı; PISA 2018 anketiyle öğrenci özelliklerini ölçmek için öğrencilere yöneltilen maddelere öğrencilerin kendi duygu ve düşünceleri doğrultusunda cevap verdikleridir.

Sınırlılıklar

1. Okuduğunu anlama başarısının çeşitli modellerle tahmin edilmesi sürecinde modele alınan değişkenler PISA anketinde bulunan öğrenci özelliklerine

yönelik sosyo-demografik özellikler, öz yeterlik ve tutum alt ölçekleri ile sınırlıdır.

2. Araştırmada PISA okuduğunu anlama başarısı için başarı ölçütü yeterlik düzeyleri iki ve üç kategori ile sınırlıdır.
3. PISA 2018 okuduğunu anlama yeterlik düzeylerinin kategorileri PISA ön raporundaki eşik değerleri revize edilerek sekizden altıya indirilmesinin uygun olduğu kabul edilmiştir.

Tanımlar

Veri madenciliği: Veriyi birçok yönden analiz ederek anlamlı bilgiye dönüştürmeyi sağlayan analiz yöntemidir.

PISA başarısı: Araştırma kapsamında öğrencilerin PISA 2018 okuduğunu anlama puanları, okuduğunu anlama becerisi yeterlik düzeylerinin kategorileri dikkate alınarak iki ve üç kategorili başarı durumuna dönüştürülmektedir.

Okuryazarlık: Okuryazarlık, okurların temel konulardaki karşılaştıkları problemleri tanıma, yorumlama ve problem çözme, analiz etme, mantıksal çıkarımda bulunma ve etkili iletişimde bulunma yeterlilikleri olarak tanımlanmaktadır (OECD, 2016).

Ham veri: OECD'nin resmi internet sitesinde yer alan 79 ülkeden katılan 32 milyona yakın öğrenciyi örnekleyecek biçimde seçilen yaklaşık 600.000 öğrenciye uygulanan testten elde edilen işlenmemiş veridir.

Test veri seti: Veri madenciliği araştırmalarında modelin performansını belirlemede kullanılan veri setidir.

Eğitim veri seti: Veri madenciliği araştırmalarında model oluşturmak için kullanılan veri setidir.

Veri madenciliğinde değişken kavramı: Analiz yapabilmek için testten elde edilen verilerin dönüşüm yaparak standartlaştırılmış halidir.

Bölüm 2

Araştırmanın Kuramsal Temeli ve İlgili Araştırmalar

Bu bölümde PISA okuduğunu anlama becerisi, PISA okuduğunu anlama becerisinin değerlendirilmesi, okuduğunu anlama becerisini etkileyen faktörleri belirlemede kullanılan veri madenciliği yöntemleri, okuduğunu anlama ve veri madenciliği ile ilgili araştırmalar üzerinde durulmuştur.

PISA Uygulamasında Okuryazarlık ve Okuduğunu Anlama

PISA 2018, okuduğunu anlama becerisini bireyin amaçlarına ulaşmak, bilgi düzeyini ve potansiyelini artırmak ve ticaret, üretim, hizmet sektörü gibi toplumsal kademelerde bulunmak için metinleri iyi derecede anlama, metindeki bilgiyi kullanma, değerlendirme, üzerinde eleştirel düşünme ve analiz etme becerisi olarak ifade etmektedir (OECD, 2019a).

PISA'da okuduğunu anlama; bireyin metinden gerçek ya da mecaz anlamlar çıkarmasıdır. Bu, hem sözcükleri anlama, hem de öyküleme amacıyla yazılmış bir metnin ana fikrini ifade etme de olabilir. PISA'da metindeki bilgiyi kullanma; bir metinden elde edilen bilginin, bir amaç için, bir düşünceyi desteklemek için kullanılmasını ifade eder. Okumaların çoğu bu türdendir. Birey düşüncelerini yansıtırken okuduğu metinle kendi düşünce ve yaşantıları arasında bağlantı kurar. Bu aşamada, kendi yaşantısına farklı bir yaklaşım getirir veya metindeki bilginin doğruluğu ve gerçekliğine yönelik bir karara varır. Böylece birey, metni okuyup metnin amacına uygun olup olmadığını belirlemeye ihtiyaç duyar (MEB, 2010).

Okuryazarlık sadece okuldaki örgün eğitimde değil aynı zamanda etkileşim halinde olunan aile, arkadaşlar, meslektaşlar gibi gruplar içinde de bireyi etkileyip geliştiren önemli bir faktördür. Bugünkü anlamıyla okuryazarlık, sadece eğitimin ilk kademesinde kazanılan bir beceri olarak görülmemekte, bunun yanı sıra yaşam boyunca öğrencinin arkadaş çevresiyle ve çeşitli ortamlarla etkileşim halinde olarak bireysel olarak geliştirdiği bir beceri olarak da görülmektedir (OECD, 2009). PISA'da bahsedilen okuryazarlık kavramı, gerçek hayat durumlarında ihtiyaç duyulan bilgi ve beceri üzerine odaklanarak modern toplumdaki üretim ilişkilerine katılım için temel bilgi ve becerileri kazanmayı sağlayan üst düzey okuryazarlık olarak ifade edilmektedir. Okuryazarlık ile ekonomi ilişkisini belirlemeye yönelik bir

arařtırmada okuryazarlık dzeyi ile ekonomik performans arasında kuvvetli iliřkinin olduėu saptanmıř ve lkelerin ortalama okuryazarlık seviyesinin ekonomik ve eėitimsel ilerlemenin bir gstergesi olduėu belirlenmiřtir (Coulombe, Tremblay ve Marchand, 2004).

PISA uygulamasının deėerlendirme anlayıřı ve kavramsal altyapısı proje iinde yer alan lkelerdeki eėitim uzmanları tarafından belirlenmekte, yapılan grřmelerle katılımcı lkelerin karřılıklı fikir birliėiyle onaylanmaktadır. Bu yaklařımda, "okuryazarlık" kavramına ynelik yeni bir yaklařım ortaya ıkmıřtır. PISA 2009'da okuryazarlık kavramının anlamı; "ėrencilerin bilgilerini gerek hayat durumlarında kullanarak gerek hayat durumlarıyla ilgili problemleri czme kapasitesidir (MEB, 2010).

PISA uygulaması, 2000 yılından 2009 yılına kadar kâėıt-kalem testi kullanılarak uygulanmıřtır. 2012 yılında ilk olarak matematik okuryazarlıėı testi bilgisayar ile uygulanmıřtır. PISA 2015 ve 2018 yılı uygulamalarına Trkiye bilgisayar alt yapısıyla katılmıřtır (MEB, 2015; MEB, 2018).

Son yıllarda dijitalleřme ile birlikte, metin mesajları; arama motorundan aıklamalı sonular gibi kısa metinler ve sekmeli, ok sayfalı internet siteleri; mikro fiřlerden taranan yeni eriřilebilen arřiv materyali gibi uzun metinler ortaya ıkmıřtır. Bunun sonucunda eėitim sistemleri, dijital okuryazarlıėı kendi programlarına almaya bařlamıřlardır.

PISA 2018'de temel alınan test okuduėunu anlama testidir. Katılan 79 lkenin oėunluėunda bilgisayarla iletilen okuduėunu anlama testi dijital iletimle alıřan yeni metin ve test formatlarını iermektedir. Kullanılan test, bir yandan yirmi yıldan bu yana okuma becerisiyle ilgili kapsamı lerken diėer yandan dijital ortamda okuma becerisini lmektedir.

Bireysel geliřim, toplumda var olma, akademik bařarı, retim iliřkilerine katılım gibi birok alanda 20 yıl nce gerek duyulan okuduėunu anlama becerisi ile bugnk gerek duyulan okuduėunu anlama becerisi ierik bakımından farklılařmıřtır. Bugn sadece yazılı dokmanlardan deėil aynı zamanda elektronik dokmanlardan da okuma yapılmaktadır. Bireyler internetin olmadıėı zamanlarda bir sorunun yanıtını bilmedikleri durumda kitap, ansiklopedi ve benzeri kaynaklardan yanıtı bulur ve oėu zaman bulduėu yanıtın doėru olmadıėına iliřkin

şüpheye düşmezlerdi. Fakat bugün arama motorları, yanıtını aradıkları sorularla ilgili bireylere binlerce yanıt vermektedir. Ve bu yanıtların bilimsel anlamda doğruluğuna yönelik güven bireyin kendisine bağlıdır. Bu sorun bireylere önceki zamanlardan daha fazla okuryazarlık ve okuduğunu anlama konusunda sorumluluk vermektedir. Burada bahsedilen okuryazarlık farklı kaynaklardan yararlanılmasını, belirsizlik içinde doğruyu bulabilmeyi, gerçek olan ile algılanan arasındaki farkı fark etmeyi gerektirmektedir. PISA çalışmalarında okuduğunu anlama becerilerini değerlendirmek amacıyla kullanılan yöntemler, okuduğunu anlama becerisinin niteliğinde meydana gelen farklılaşmaya uyum sağlamak için güncellenmiştir. Yapılan güncellemeler aşağıda özetlenmiştir (OECD, 2019b).

Okuma süreci basılı materyalden bilgisayar ortamına ve akıllı telefonlara doğru yöneldikçe metinlerin yapısal özellikleri farklılaşmıştır. Okuma, daha pratik ve zorunlu hale gelmiştir. Çok sayıda kaynaktan elde edilen bilgilerin analizi, sentezlenmesi ve yorumlanması okuduğunu anlama becerisinin günlük gerekleri haline gelmiştir. PISA 2009 ve PISA 2018 uygulamalarında okuma becerileri değerlendirme yaklaşımındaki farklılıklar şunlardır (OECD, 2019b).

- Farklı yazarlar tarafından hazırlanan çok sayıda metnin birlikte sunulduğu çok kaynaklı metinlere daha fazla yer verilmiştir.
- Öğrencilerin metinleri kolay ve etkili biçimde okuyabilmeleri olarak ifade edilen akıcı okuma PISA 2018 çalışmasında değerlendirilmiştir.
- Bilgisayar tabanlı değerlendirme sayesinde bireyselleştirilmiş test uygulaması yapılmıştır.
- Bireyselleştirilmiş test ile çok kaynaklı metinlerin kullanılmasına imkân sağlayan bilgisayara dayalı değerlendirme yaklaşımı uygulanmıştır.

PISA 2018 okuma becerilerini değerlendirme yaklaşımı. Öğrencilerin okuduğunu anlama becerisini etkileyen faktörleri belirlemek için geliştirilen uluslararası projelerden biri PISA'dır. Bu projeyle, öğrencilerin sadece öğrendiklerini ne düzeyde hatırladıklarını değil, bununla birlikte okuduğunu anlamanın önemli göstergeleri olan, öğrencinin öğrendikleri bilgileri okulda ve okul dışı hayatlarında kullanabilme kapasiteleri; karşılaştıkları gerçek hayat problemlerini çözmek, bilmedikleri durumlarda öngöründe bulunmak ve akıl

yürütmek için bilgi birikimlerinden ne düzeyde faydalandığını belirlemek amaçlanmaktadır. Bu amaç, PISA'nın diğer değerlendirme yaklaşımlarından farkını ortaya koymaktadır (MEB, 2019).

Tablo 1

PISA Okuduğunu Anlama Becerileri Testinde Yer Alan Değerlendirme Alanları

Tanımlama ve ayırt edici özellikleri	Bireyin amacına ulaşma, bilgi düzeyini artırma ve toplum içindeki varlığını sürdürmesi için yazılı metinleri anlama, kullanma ve yansıtma kapasitesi ile ilgilidir. Bir metnin analiz edilip anlaşılmasına ek olarak, okuma becerileri, okuma, yorumlama, yansıtma ve bireyin yaşamındaki amaçlara ulaşmada okuma becerilerini kullanma kapasitesini içermektedir. PISA'nın temel mantığı okumayı öğrenmeden çok öğrenmek için okumadır. Bu sebepten dolayı PISA'da öğrencilerin temel okuma becerileri değerlendirilmemektedir.
Bilgi alanı	Okuma materyallerinin yapısı: <ul style="list-style-type: none">• Öyküleme, yorumlama ve tartışma gibi düz yazılarla oluşturulan sürekli metinler• Grafikler, formlar ve listelerle oluşturulan süreksiz metinler
İlgili beceriler ve düşünme süreçleri	Okuma becerileri ile ilgili görev türleri: <ul style="list-style-type: none">• Bilgiye erişim ve bilgiyi hatırlama• Bilgiyi organize etme ve yorumlama• Öğrencinin kendi düşüncelerini ifade etmesi ve bir metni değerlendirmesi
Bağlam ve konular	Metnin oluşturulma amacına yönelik kullanım: <ul style="list-style-type: none">• Kişisel (örneğin: kişisel bir mektup)• Kamusal (örneğin: resmi bir belge)• Mesleki (örneğin: bir rapor)• Eğitimle ilgili (örneğin: okulla ilgili okuma)

(MEB, 2019)

PISA 2018'de okuduğunu anlama becerilerini değerlendirmek için farklı boyutlar tanımlanmıştır (OECD, 2019b). Bu boyutlar:

- Metin türleri
- Öğrencinin metinle etkileşim halinde olduğu bilişsel süreçler
- Farklı güçlük düzeyine sahip sorular

Metin türleri. Okuduğunu anlama becerileri bakımından belirli bir yeterlik düzeyine sahip okuyucunun, okuduğunu anlaması ve verilen bir soruyu çözmesi için kendisine verilen metinlerdeki bilgileri anlayıp ilişkilendirmesi gerekmektedir. Dijital platformların yaygınlaşması ile birlikte birçok yeni metin türü oluşmuştur. Bundan dolayı PISA uygulamalarında okuduğunu anlama becerilerinin değerlendirilmesinde farklı metin türlerinden yararlanılmaktadır (OECD, 2019a). Metin türleri; betimleme, hikâye, açıklama, tartışma, yönerge, etkileşim gibi okuduğunu anlama becerileri değerlendirme yaklaşımının temelini oluşturan ölçütlerdir.

Betimleme. Bir nesnenin sahip olduğu nitelikleri anlatır ve genel olarak “ne” sorusunun yanıtını verir. Günlüklerdeki bazı bölümler, kataloglar, yer bildiren haritalar betimlemeye örnek verilebilir.

Hikâye. Belirli bir zaman periyodundaki nesnelerin niteliklerini anlatır ve genel olarak “ne zaman” sorusuna yanıt verir. Biyografiler, gazetede ki vaka incelemeleri, hikâyeler, kısa hikâyeler, oyunlar, hikâye için örnek verilebilir.

Açıklama. Bilgileri zihinsel yapılar ya da birleşik kavramlar halinde ifade eder. Ve genel olarak “nasıl” sorusuna yanıt verir. Bu metinler, tanımlar, terimler ve isimlerin düşüncelerle arasındaki ilişkiyi açıklar.

Tartışma. Önerme ve kavramlar arasındaki ilişkiyi inceleme ve genel olarak “neden” sorusunun yanıtını verir. İkna ve fikir yazılarında, düşünceye ve bakış açısına odaklanılmaktadır. Yorum yazılarında olaylar, nesnelere ve fikirler ile ilgili kavramlar değerler sistemi ile ilişkilendirilir. Benzer biçimde ele alınan bilimsel tartışma yazıları, elde edilen önermelerin doğru olup olmadığının farklı bakış açısına sahip bireyler tarafından değerlendirilmesini sağlar. Örneğin editöre yazılan mektuplar, e-postalar, tartışma yazılarıdır.

Yönerge. Yönergeler bir görevi yerine getirmek için gerekli davranışları ifade eder. Örneğin Bir bilgisayar yazılımının kılavuzu, yemek tarifleridir.

Etkileşim. Etkileşim metinlerinin diğer metinlerden farkı metinde verilen bilginin okurla etkileşim içerisinde olacak biçimde sunulmasıdır. Mektuplar ve davetiyeler, ikili ilişkilerin kurulmasını sağlar. Örneğin aile ile ilgili bilgilerin yer aldığı kişisel mektuplar, toplantı düzenlemek için yazılan mesajlardır.

PISA 2018 deęerlendirme yaklařımı çerçevesinde okuyucuların bir metni okurken aktif olarak ortaya koyduęu dört farklı biliřsel sreç vardır. PISA 2009 deęerlendirme yaklařımına gre “bilgiye ulařma, “yorumlama” ve “deęerlendirme ve derinlemesine dřnme” olarak ç farklı biliřsel sreç vardır. PISA 2018 okuma becerileri deęerlendirme yaklařımında ifade edilen dięer bir biliřsel sreç ise “akıcı okumadır” ve bu biliřsel sreç, dięer biliřsel sreçlerin alt yapısını oluřturmaktadır. Akıcı okumanın ayrı bir biliřsel sreç olarak deęerlendirmeye alınması PISA 2018 deęerlendirmesinin farklı bir yenilięidir (OECD, 2019b).

Biliřsel sreçler. Okuduęunu anlama becerisini deęerlendirmede kullanılan biliřsel sreçler; akıcı okuma, bilgiye ulařma, anlama, deęerlendirme ve derinlemesine dřnme biçimindedir.

Akıcı okuma. Akıcı okuma, ęrencilerin metinleri rahatlıkla ve doęru bir biçimde okuyabilmeleri olarak ifade edilmektedir. Dięer bir anlamıyla okuma akıcılıęı, verilen bir metnin genel anlamını tam olarak anlamak iin kelimeleri ve metni doęru okuma, etkili çzmleme, ifade etme ve iřleme becerilerini iermektedir (OECD, 2019b).

Bilgiye ulařma. Dijital ortamlarda okuma srecinde bilgiye ulařmak iin gereken beceriler, basılı halde okuma yaparken gerek duyulan becerilerden farklıdır. rneęin ęrencilerin, arama motorunda elde edilen sonular ve internet siteleri gibi yeni metin trlerini kullanmaları gerekir (OECD, 2019b).

Anlama. Bu sreç nceki deęerlendirme yaklařımında “yorumlama” olarak ifade edilmiřtir. Bu ařamada ęrencilerin onlara sunulan bir paragrafta verilen anlamı kavramaları gerekmektedir (OECD, 2019b)

Deęerlendirme ve derinlemesine dřnme. Bireyin kendi tecrbesi ile metnin verdięi bilgiyi karřılařtırıp metnin ierięini inceleyip metni deęerlendirmesidir (Fountas ve Pinnell, 2001). PISA 2018 okuduęunu anlama becerileri deęerlendirme yaklařımına gre tanımlanan en st dzeyde yer alan biliřsel sreç “deęerlendirme ve derinlemesine dřnme”dir. Bu ařamada ęrenciler, metinlerin ierięi ve gvenirlięini deęerlendirebilmeli, metni doęru biçimde anlayıp ıkarım yapmanın da tesine gidebilmelidirler.

Tablo 2

PISA 2015 ve 2018 Uygulamalarındaki Bilişsel Süreçler ve Soruların Dağılımı

PISA 2015 Değerlendirme Çerçevesi		PISA 2018 Değerlendirme Çerçevesi		
Bilişsel Süreçler	Soru Dağılımı	Bilişsel Süreçler	Alt Bilişsel Süreçler	Soru Dağılımı
Bilgiye ulaşma ve bilgiyi hatırlama	%25	Bilgiye Ulaşma	Metindeki bilgileri tarama ve bulma Alakalı metinleri arama ve seçme	%15 %10
Bilgileri bir araya getirme ve yorumlama	%50	Anlama	Gerçek anlamı ifade etme Çıkarımları birleştirme ve çıkarımlar oluşturmak	%15 %30
Kendi düşüncelerini yansıtmaya ve değerlendirme	%25	Değerlendirme ve derinlemesine düşünme	Niteliği ve güvenilirliği değerlendirme Metnin içeriği ve biçimi üzerine derinlemesine düşünme Uyuşmazlıkları belirleme ve uyuşmazlıkların üstesinden gelme	%20 %10

Farklı güçlük düzeyine sahip sorular. PISA'da bulunan sorular, bir veya birkaç metinden oluşan üniteler şeklinde hazırlanmaktadır. Örneğin ünitelerden birinden sorulacak birinci soruda öğrencilerden soruyla en çok ilişkili olan bilgiyi bulmaları, ikinci soruda metinde net bir şekilde ifade edilen bilgileri incelemesi ve üçüncü soruda ise iki farklı metindeki görüşleri inceleyip karşılaştırması istenebilir (OECD, 2019b). Okuduğunu anlama becerileri çerçevesinde iki farklı soru türü kullanılmıştır (OECD, 2019b):

- Öğrencinin sorunun yanıtını seçenekler arasından seçtiği sorular (çoktan seçmeli, doğru/yanlış soruları)
- Öğrencinin yanıtını kendi yapılandığı sorular (kısa veya uzun cevaplı sorular)

PISA 2018 okuduğunu anlama becerileri alanında 245 soru bulunmaktadır. Bu soruların üçte birine yakın kısmı (87 soru) öğrencilerin yanıtını kendi yapılandığı türden sorulardır. Bu sorulardan 82 tanesini alan uzmanları puanlamış, geriye kalan 5 tane soru ise otomatik olarak puanlanmıştır (OECD, 2019b). PISA okuduğunu anlama becerileri testinde yer alan açık uçlu soruların puanlanması sürecinde yazım hatası, dilbilgisi kurallarına uygun yazma gibi yazma becerileri dikkate alınmamaktadır (OECD, 2019b).

Bireyselleştirilmiş test yönteminin kullanımı. PISA'da öğrenci başarısını daha geçerli olarak ölçmek için PISA 2018'de bireyselleştirilmiş test uygulaması yapılmıştır. PISA 2018 okuduğunu anlama becerileri testinin uygulanması sürecinde öğrencinin önceki sorulara verdiği yanıtların doğruluğuna göre sonraki soruların seçilmesi için bir yazılım geliştirilmiştir (OECD, 2019b). Bu amaç için PISA 2018 okuduğunu anlama becerileri testindeki sorular üç kademe yapılandırılmıştır. Temel bölüm, 1. aşama ve 2. aşamada öğrenciler ilk olarak 7-10 sorudan oluşan temel bölümdeki sorulara yanıt vermişlerdir. Bu kısımda bulunan soruların çoğunluğu otomatik puanlanabilen sorulardır. Bu biçimde puanlanan sorulara verilen doğru yanıt sayısına göre öğrencinin başarısı düşük, orta ve yüksek olarak kategorize edilmiştir (OECD, 2019b). Temel bölümde bulunan soru grupları, zorluk bakımından birbiri ile aralarında anlamlı fark olmayacak biçimde hazırlanmıştır. 1. ve 2. aşama için hazırlanan soru grupları kısmen kolay ve kısmen zor olacak şekilde iki farklı güçlük düzeyinde hazırlanmıştır. Temel bölümde orta seviyede başarı gösteren öğrencilere, 1. aşamada kolay veya zor olan gruptaki soruların sorulma ihtimali aynıdır. Temel bölümde düşük başarı sergileyen öğrencilerin, 1. aşamada kolay olan gruptaki sorularla karşılaşma olasılığı %90 iken zor olan gruptaki sorulara karşılaşma olasılığı %10'dur. Temel bölümde yüksek başarı sergileyen öğrencilerin, 1. aşamada zor olan gruptaki sorularla karşılaşma olasılığı %90 iken kolay olan gruptaki sorularla karşılaşma olasılığı %10'dur. Öğrenci gerçek başarısını mümkün olduğunca güvenilir bir biçimde belirleyebilmek için 2. aşamada, hem temel hem de 1. aşamadaki doğru cevap sayısından faydalanılmıştır (OECD, 2019b). PISA 2018'de bireyselleştirilmiş test uygulamasının yapılması ile birlikte öğrencilerin temel ve 1. aşamadaki cevapları genel başarı puanlarının yanı sıra yanıtlayacağı soruları da etkilemektedir. Böylece, ortalamadan önemli ölçüde sapacak biçimde performans gösteren öğrencilerin beceri düzeylerinin daha uygun sorularla test edilmesi mümkün olmaktadır. Bireyselleştirilmiş test ile özellikle ortalamadan önemli ölçüde yüksek veya düşük performans gösteren öğrencilerin beceri düzeylerinin daha düşük hata ile saptanması mümkün olmaktadır (OECD, 2019b).

Okuma becerileri yeterlik düzeyleri. Öğrencilerin PISA uygulamasından aldıkları puanlara göre okuduğunu anlama becerilerine göre sekiz yeterlik düzeyi belirlenmiştir. PISA 2018 okuduğunu anlama becerilerinin değerlendirilmesi için

belirlenen yeterlik düzeyleri 1c,1b,1a,2,3,4,5,6 biçimindedir. Alt puan limitleri 1c düzeyi için 189, 1b düzeyi için 262, 1a düzeyi için 335, 2 düzeyi için 407, 3 düzeyi için 480, 4 düzeyi için 553, 5 düzeyi için 626, 6 düzeyi için 698 biçimindedir (MEB, 2010; OECD, 2019b).

Veri Madenciliği ve Makine Öğrenme

Bilişim teknolojilerinin gelişmesi ve interneti günlük hayatımızın hemen hemen her alanında kullanmamız sonucunda gerek bireysel gerek kurumsal alanda çok büyük miktarlarda veri toplama imkânı oluşmuştur. Bu veri yığından kurumlar için önemli bilgilere kısa zamanda ulaşmanın en etkili tekniği olarak “Veri madenciliği” öne çıkmıştır (Han, Kamber ve Pei, 2012). Veri madenciliği büyük veri tabanlarında yer alan faydalı ve keşfedilmemiş örüntü ve ilişkilerin tespit edilmesi işlemidir (Silahtaroglu, 2016). Burada keşfedilen örüntü ve ilişkilerden elde edilen bilgi daha önce önemsiz görülen potansiyel bilgidir. Bu süreçte karmaşık veri setlerinden elde edilen bilgilerin birleştirilmesi, özetlenmesi sınıflandırılması, ilişkili ve örüntülü bilgilerin keşfedilmesi ve değişimlerin incelenmesi gibi birçok çeşitli yöntemlere başvurulabilir. Veri madenciliği ile verilerin analizi edilmesi süreci bir model oluşturma süreci olarak düşünülebilir. Oluşturulan modeller hem yaşamda olup bitenleri daha iyi anlamaya hem de geleceğe yönelik tahminde bulunmaya imkân sağlar (Williams, 2011).

Veri madenciliği disiplinler arası ilişki kurulmasını gerektiren bir tekniktir. Bu çerçevede veri madenciliği makine öğrenme, istatistik ve veri tabanları alanlarından yararlanarak ortaya çıkmış bir çalışma alanıdır (Holsheimer, Kersten, Mannila ve Toivonen, 1995). İstatistik, genel anlamda verilerin düzenlenmesi, tanımlanması ve yorumlanması amacıyla kullanılan yöntemleri ifade etmektedir (Doğan, 2020). Veri madenciliği ile istatistik arasındaki en önemli fark istatistik örneklem üzerinde çalışırken veri madenciliği ana kitle üzerinde çalışma yapar (Silahtaroglu, 2016). Hipotez testinin istatistik için özel bir anlamı var iken veri madenciliği için özel bir anlamı yoktur. Veri madenciliği tümdengelim, istatistik tümevarım ile ilgilenir. Bu durumda veriler üzerinden yapılan temel istatistiksel çalışmalar veri madenciliği çalışması olarak sayılmaz. Bu nedenle akademik çalışmalarda üzerinde çalışılan araştırma probleminin veri madenciliğine dayalı bir problem olup olmadığını saptamak sonuçların doğruluğu bakımından önemlidir.

Örneğin bir eğitim kurumunun veri tabanındaki öğrenci puanları üzerinde hesaplanan betimsel istatistikler ve verilerin farklı değişkenlere göre analiz edilerek değişkenler arası ilişkinin ve farkın anlamlılığına dayalı uygulamalar veri madenciliği çalışması değildir. Diğer yandan yordayıcı değişkenler ile regresyon modeli oluşturup tahminde bulunma süreci de veri madenciliği çalışması değildir. Ancak veri tabanındaki yüksek yordayıcı değişkenlere ait eğitim verilerinden yararlanarak kurulan modelin eğitilmesi sonucunda test verisi ile tahminde bulunma süreci bir veri madenciliği çalışmasıdır. Veri madenciliği sadece tahminle sınırlı değildir. Veri madenciliğinde tanımlayıcı yöntemlerde vardır. Örneğin çoklu zekâ kuramına göre öğrenciler arasından benzer zekâ alanına sahip olanların kümeleme performansı yüksek olan değişkenlere göre kümelenmesi isteniyorsa bu çalışmada bir veri madenciliği yöntemi kullanılarak veri madenciliği uygulaması yapılmış olur. Ancak veri madenciliği yöntemlerinden birinin kullanılmadığı, sadece eldeki değişkenler kullanılarak kümeleme yapıldığında veri madenciliği uygulaması sayılmayacaktır (Köse, 2018).

Makine öğrenmesinin önemli işlevlerinden birisi de büyük veri yığınlarından önemli olan bilgilerin elde edilmesini kolaylaştırmak ve hızlandırmaktır. Makine öğrenmesi araştırma problemini o problemle ilişkili veriye göre modelleyen bilgisayar algoritmalarına verilen genel addır (Atalay ve Çelik, 2017). Makine öğrenmesi bilgisayarların öğrenme sürecine odaklanmakta ve tıp, ekonomi, eğitim gibi alanlarda bireylerin ilgi ve eğilimlerini belirleyip onlara uygun şartların oluşturulması gibi alanlarda kullanılabilir (Mitchell, 1997). Veri işlemede çok büyük öneme sahip makine öğrenme, küreselleşen dünyada büyük ölçüde bilgi üretme ve depolama amacıyla her geçen gün daha yaygın olarak kullanılmaktadır.

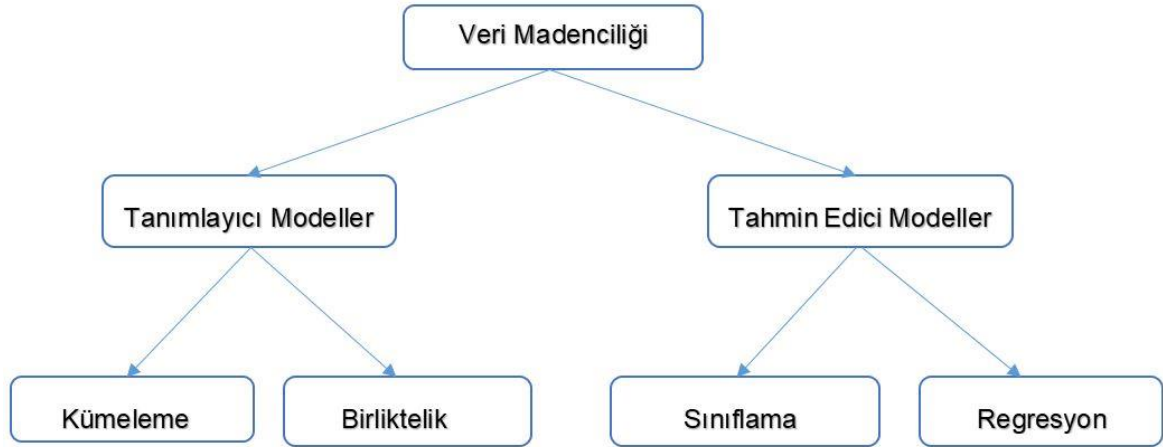
Makine öğrenme üç ayrı öğrenme modeli üzerine inşa edilmiştir. Bunlar aktif öğrenme, yarı gözetimli öğrenme, gözetimsiz öğrenmedir. Aktif öğrenme modelinde kullanıcıdan veriye yönelik etiket vermesi istenebilir. Bu modelde en temel amaç bilgilerin aktif olarak elde edilmesi sağlanarak model kalitesini artırmaktır. Yarı gözetimli öğrenme modelinde, öğrenme sürecinde etiketlenmemiş verinin yanında ön bilgi yardımıyla denetlenen verilerde bulunmaktadır. Gözetimsiz öğrenme kümeleme ile aynı anlamdadır. Öğrenme sürecinin başında sınıf etiketi bulunmadığı için öğrenme süreci hakkında denetleme yapılamaz. Bu öğrenme

modeli büyük ölçekli veri kümelerini etiketlemenin çok masraflı olduğu ya da sınıf etiketinin bulunmaması durumunda kullanılır (Chapelle, Schölkopf ve Zien, 2006).

Bu araştırmada ortaya konulan problemlere dayalı olarak OECD (The Organization for Economic Cooperation and Development) verilerinden gerekli değişkenler tespit edilmiştir. Bu veriler ışığında yapılan çalışma çok değişkenli ve makine öğrenmesine dayalı istatistiksel teknik olarak düşünülür. Çok değişkenli istatistiksel yöntemler geçmişten bu güne geniş ölçekli verilerin analiz edilmesinde kullanıldılar. Bu yöntemler araştırmacıların, karar alıcıların ve diğerlerinin çok sayıda bağımsız ve bağımlı değişkenden oluşan geniş ölçekli verileri analiz edebilmelerine imkân sağlar (Büyüköztürk, 2012).

Veri tabanı sistemleri veri tabanları ve veri ambarları olarak ikiye ayrılır. Veri tabanları ile veri ambarları arasındaki temel fark veri tabanlarında veriler ilişki olarak yığınlar halinde depolanırken veri ambarlarında analize uygun sınırlı bilgiler olarak depolanmasıdır. Veri ambarları çeşitli veri tabanlarından temin edilen verilerin birleştirilip bir bütün getirilmesiyle oluşur (Han ve ark., 2012). Veri ambarları veri madenciliği sürecinde ihtiyaç duyulan veri kaynaklarıdır.

Günümüzde veri, üretim ilişkilerinin en önemli faktörlerinden birisidir. Bu nedenle özel ve devlet işletmelerinin karar vericileri doğru kararlar vermek için verileri depolamaktadır. Veri madenciliği daha önceden bir anlam ifade etmeyen bilgilerin geniş ölçekli veri tabanlarından elde edilip anlamlı hale getirildikten sonra işletme ve kurumların vereceği kararlar doğrultusunda kullanılmasıdır (Silahtaroglu, 2016). Böylece işletmelerin çeşitli bileşenleri arasındaki ilişkiler belirlenerek üretim verimliliği artırılarak daha yüksek kar elde edilebilecektir. Bilginin keşfedilmesi ifadesi önceleri önemsiz görülen verilerden önceleri bilinmeyen faydalı bilginin çıkarılması olarak tanımlanmıştır. Veri madenciliği tanımlayıcı ve tahmin edici modeller olarak ikiye ayrılır.



Şekil 1. Veri madenciliği modellerinin sınıflandırılması

Tanımlayıcı Modeller

Tanımlayıcı veri madenciliği modelleri veri setinde bulunan verilerin genel özelliklerini ve veri setindeki gizli kalmış ilişkilerin, örüntülerin belirlenmesini sağlamaktadır (Agyapong, Hayfron-Acquah ve Asante, 2016). Tahmin edici modeller ise veri madenciliği çalışmalarından elde edilen sonuçların geleceğe yönelik öngöründe bulunmak amacıyla kullanıldığı yöntemlerdir (Swani ve Tyagi, 2017).

Tahmin Edici Modeller

Sınıflama modelleri. Sınıflandırma hayatın her bölümünde çok önemli bir yere sahiptir. Sınıflandırma analizi araştırma kapsamındaki denek veya nesnenin hangi kategoride bulunacağını tahmin eden analiz türüdür. Bu çerçevede sınıflandırmaya yönelik gerçek hayattan çeşitli çok sayıda örnek verilebilir. Bu örneklerden bir kısmı şunlardır (Bramer, 2013).

- Sosyal bir araştırmada katılımcıların sosyo-ekonomik durumlarına göre ayrılımları,
- Bir ürünü satın alan veya almayan müşteriler,
- Bir bölgede ertesi gün yağış beklentisinin düşük, orta ve yüksek olarak tahmin edilmesi,
- Öğrencilerin başarılı veya başarısız olarak sınıflandırılmaları,

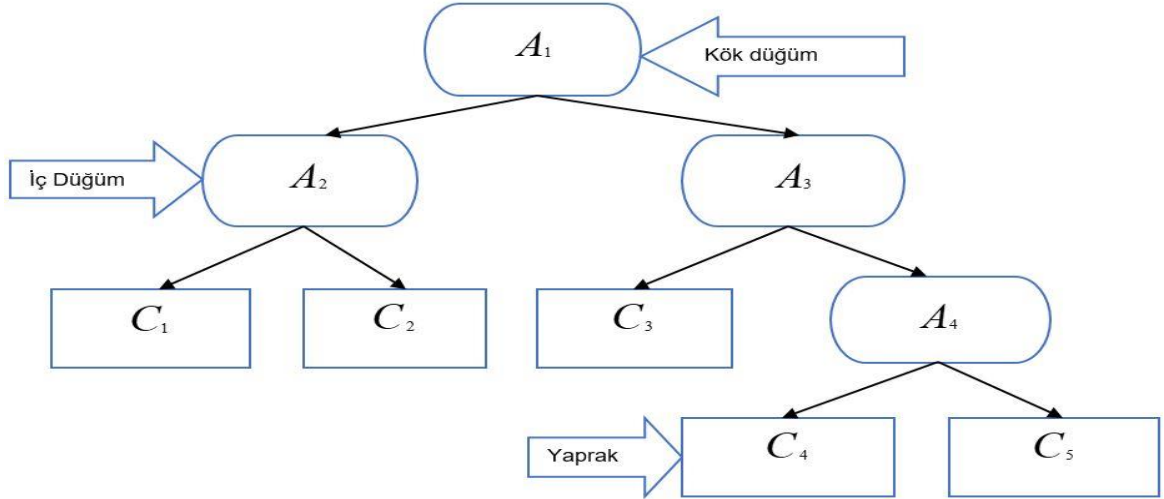
- 12 aylık zaman aralığında trafik kazası geçirme riski düşük, orta, yüksek bireyler,
- Suç işlemiş eşkâli belli birine hiç benzemeyen, az benzeyen veya çok benzeyen şüpheliler,
- 12 aylık zaman aralığında fiyatların artması, aynı kalması veya azalması beklenen gayrimenkuller,
- Bir radar görüntüleme mekanizmasında ağaçlar, insanlar, araçlar ve binalara karşılık gelen işaretler.

Örneklere görüldüğü gibi sınıflama hayatın önemli bir kısmını oluşturmaktadır. Bu bağlamda sınıflandırma analizi sosyal bilim alanında yapılan araştırmalarda çok önemli bir yere sahiptir. Sınıflandırma modellerinde kullanılan temel yöntemlerden biri karar ağaçlarıdır.

Karar ağaçları. Sınıflandırma ve regresyon modellerinde kullanılan temel yöntemlerden biri olan karar ağaçları, ağaca benzeyen yapısı sayesinde kökünden yapraklarına doğru kurallar zinciri içeren akış şemasıdır (Chien, Wang ve Cheng, 2007). Birbirinden bağımsız durumlardan "böl ve yönet" yaklaşımını kullanarak bilgi edinme süreci araştırmacıları "karar ağacı" olarak ifade edilen bilgi sunma tekniğine götürmektedir (Barros, De Carvalho ve Freitas, 2015). Karar ağaçları, hem veri madenciliğinin hem de makine öğrenme algoritmalarının temel taşlarıdır. 1980'li yıllarda ilk kez geliştirilen karar ağaçları; bu güne kadar makine öğrenmeye dayalı veri madenciliği modellemelerinin en önemli öğeleridir. Bu kadar önemli olmalarının asıl nedeni, sonuç modelinin basitliğinden kaynaklanmaktadır. Karar ağaçları, kolay model kurma, analiz sonuçlarının kolay yorumlanması, veri tabanı sistemleriyle bütünleşmesinin kolay olması gibi sebeplerden dolayı veri madenciliğinin sınıflama modelleri arasında en yaygın olanıdır. Diğer yandan anlaşılır kurallar üretmesi, tüm değişken tipleri için uygun olması sınıflandırma ve tahmin için hangi faktörlerin en önemli olduğunu açık şekilde ifade edebilmesi güçlü yönleri olarak düşünülür (Ersöz, 2019).

Bir karar ağacı kök olarak ifade edilen merkez bir nokta ile başlar. Bu merkez noktaya kök düğümü (node) adı verilir (Han ve ark., 2012). Bu kök düğümden başlayan dallarda karar düğümleri bulunur. Karar ağaçlarında sonuç değişkenine yönelik nihai bir karara varılması sürecinde kökten dallarla ayrılan karar düğümleri sonuç değişkenine ulaşana kadar devam eder. En son aşamada

nihai olarak ortaya çıkan sınıflandırmalar hedef değişken ya da hedef değişkenler olarak ifade edilir (Larose, 2005). Karar ağacında en son aşamada bulunan ve sınıf etiketini ortaya koyan düğümlere nihai düğüm veya uç düğüm, bu nihai düğümden önce bulunan düğümlere ise iç düğüm adı verilir (Han ve ark., 2012).



Şekil 2. Sınıflama için genel bir karar ağacı örneği

Karar ağacındaki A_1, A_2, \dots, A_n 'dan bir tanesi kök düğüm diğerleri ise düğümü oluşturmaktadır. Her bir düğüm iki dala ayrılmaktadır. Bu ayrılma işlemi A_j düğümü hakkında yanıtı veri tabanında bulunacak bir soru sorulmakta ve verilen yanıtı göre bir dal seçilerek ilerlenmektedir. Karar ağacındaki C_1, \dots, C_n 'lerin her biri bir sınıfı temsil eden yapraktır. Bu karar ağacında düğüm ve yaprakların içerisine genellikle sınıfa ait dağılım bilgisi yazılırken, dallar üzerine dallandırma yapılan özelliğin düzeyi ya da sınıf aralığı yazılır (Altunkaynak, 2019).

Karar ağacı algoritmalarının kullanılmasında gerekli varsayımlar. Karar ağacı oluşturulurken çeşitli algoritmalar kullanılmaktadır. Bu algoritmaların kullanılma sürecinde bazı varsayımların karşılanması gerekmektedir (Larose, 2005).

Bu varsayımlar şunlardır:

- Karar ağacı oluşturmada kullanılan algoritmalar gözetimli öğrenme yöntemlerini ifade etmektedir. Bundan dolayı analize başlamadan önce

bağımlı deęişkenler ve bu bağımlı deęişkenlere yönelik eğitim veri seti olmalıdır.

- Karar ağacında kullanılan eğitim verisi heterojen ve çok deęişkenli olmalıdır. Eğitim verisi kullanılan algoritmaya geleceęe yönelik sınıflamaya dayalı tahmin sürecinde etkili olacak bilgiler sunmalıdır. Kullanılan algoritmalara dayalı öğrenme süreci örneklerle meydana gelmektedir. Örnekler alt kategorilere ayrılacak nitelikte deęilse alt kategorilerin sınıflama ve tahmin performans düzeyi düşecektir.
- Bağımlı deęişkenin her bir kategorisi farklı olmalı ve kesikli nitelikte olmalıdır. Tabii ki bu durum karar ağaçlarının sadece kesikli bağımlı deęişkenler için kullanılacağı anlamına gelmektedir. Bağımlı deęişkenler bir sınıfa ait olup olmama durumuna göre oluşturulmalıdır.

Karar Ağaçlarının Oluşturulması. Karar ağacı oluşturma süreci kendi kendini tekrarlama biçiminde sürmektedir. Karar ağacı ilk başta kökü, sonra dal ve düğümleri olan bir yapıdadır. Kök düğümden sonraki düğümler içsel düğüm ya da test edilen düğüm olarak ifade edilir. Karar ağacında bulunan her bir düğüm, veri setindeki ölçümlerin girdi özellik değerlerinin ayırma fonksiyonuna göre iki ya da daha fazla alt kategoriye bölmektedir. Kategorik girdi özellikler için düğümlerde yapılan testlerde bir kategoriye sahip olup olmama durumuna göre sınıflandırma işlemi yapılırken miktar belirten sayısal bir girdi özellik için özelliğin kesme puanına göre belli değerleri dikkate alınarak sınıflama işlemi yapılır (Maimon ve Rokach, 2005). Her bir ölçüm için kök düğüme seçilecek bir girdi özellik belirlenerek ve her bir ölçüm için bir dal oluşturularak bu işlem dalların her birine erişen ölçümler ile dalların her biri için art arda tekrar edilir. Eğer bir düğümden bulunan ölçümlerin tamamı aynı sınıfa dâhil olurlarsa ağacın o düğümünün bölünmesi durdurulur. Bunun sebebi, ölçümlerin tamamının aynı kategoride karar kılmış olmalarıdır (Tan, Steinbach ve Kumar, 2005). Bu duruma örnek olarak, Tablo 3'te görünüm özelliğinin dört kez "Kapalı" olduğu durumların tamamında aktivitenin evet olması verilebilir. Karar ağacı ile hâlihazırdaki verileri sınıflandırmak için, kök düğümden itibaren bir yaprağa ulaşılan kadar iç düğümler ziyaret edilir. Her bir iç düğümden, düğüme ilişkin testler yapılır bu testler kayıt altına alınır. Bir iç düğümdeki testin sonucu, seçilecek dalı ve ziyaret edilecek sonraki düğümü belirler. Kayıt altına alınan sınıf sadece en son yaprak düğümün sınıfıdır. Böylece, kökten bir yaprağa

kadar uzanan dallar için sağlanan tüm koşulların birleşimi, yaprakla ilişkili olan sınıfın koşullarından birini oluşturur (Rastogi ve Shim, 2000). Karar ağacı oluşturma süreci karar tabloları ile başlar. Karar ağacı oluşturmak için hazırlanan karar tablosu Tablo 3'te verilmiştir.

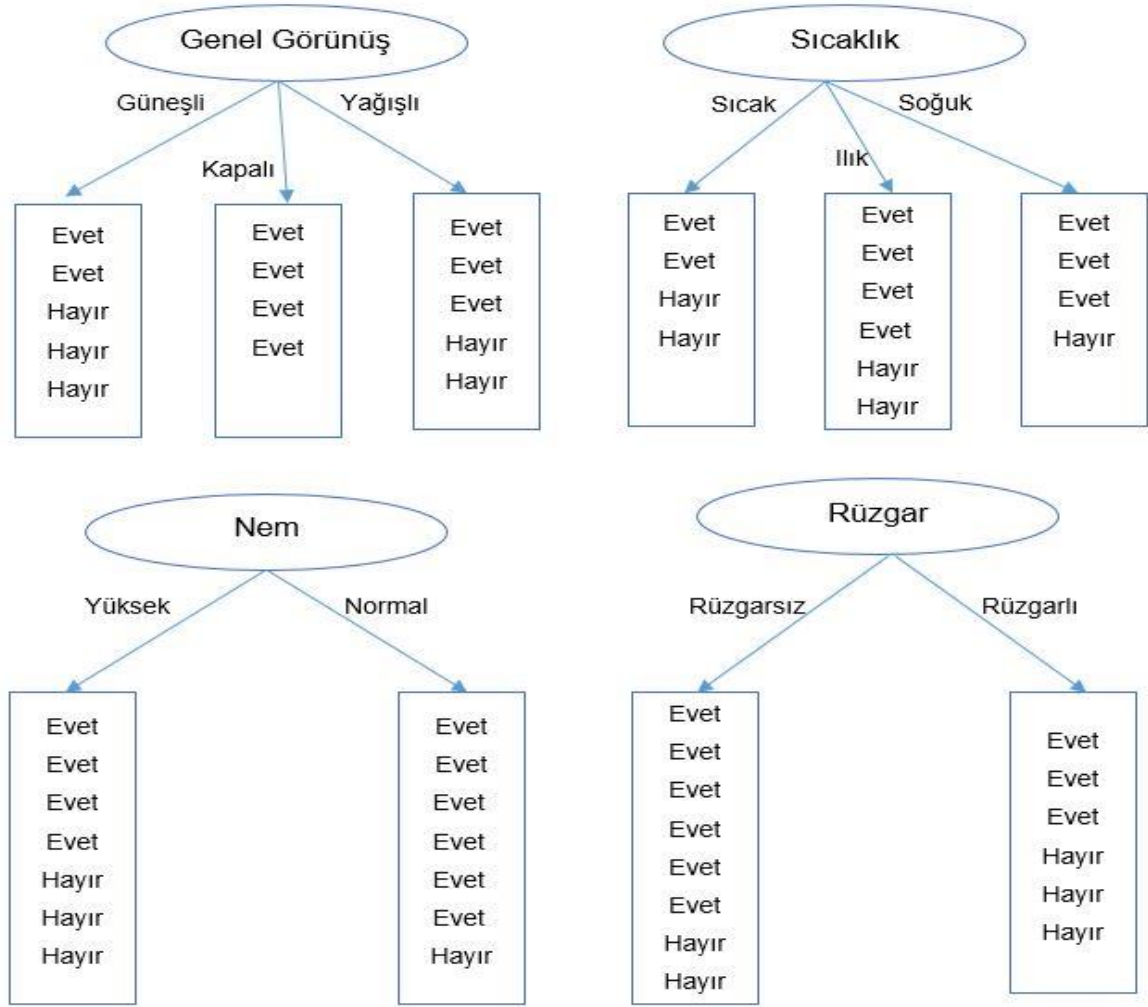
Tablo 3

Hava Durumu için Karar Tablosu

No	Görünüm	Sıcaklık	Nem	Rüzgâr	Aktivite
1	Güneşli	Sıcak	Yüksek	Rüzgârsız	Hayır
2	Güneşli	Sıcak	Yüksek	Rüzgârlı	Hayır
3	Kapalı	Sıcak	Yüksek	Rüzgârsız	Evet
4	Yağışlı	Ilık	Yüksek	Rüzgârsız	Evet
5	Yağışlı	Soğuk	Normal	Rüzgârsız	Evet
6	Yağışlı	Soğuk	Normal	Rüzgârlı	Hayır
7	Kapalı	Soğuk	Normal	Rüzgârlı	Evet
8	Güneşli	Ilık	Yüksek	Rüzgârsız	Hayır
9	Güneşli	Soğuk	Normal	Rüzgârsız	Evet
10	Yağışlı	Ilık	Normal	Rüzgârsız	Evet
11	Güneşli	Ilık	Normal	Rüzgârlı	Evet
12	Kapalı	Ilık	Yüksek	Rüzgârlı	Evet
13	Kapalı	Sıcak	Normal	Rüzgârsız	Evet
14	Yağışlı	Ilık	Yüksek	Rüzgârlı	Hayır

Kaynak: (Quinlan, 1986)

Karar ağacında düğüme bağlı olan yaprakların her biri bir sınıf değerini göstermektedir. Karar vermek için geriye kalan tek şey, bir girdi özelliğinin farklı kategorilerinde bir dizi ölçüm verildiğinde, bölünmenin hangi özelliğe göre ve nasıl yapılacağını belirlemektir. Tablo 3'te verilen farklı hava koşulları ve aktivite yapıp yapmama durumuna ilişkin örnekleri göz önüne aldığımızda, Witten, Frank ve Hall'nın (2016) yaptıkları çalışmadan uyarlanarak her bir bölünme için olası 4 ihtimal bulunmaktadır ve Şekil 3'te gösterildiği gibi en üstte girdi özellik olacak şekilde ölçümler ilgili kategorilere ayrılmıştır.



Şekil 3. Hava durumu verisi için ağaç kütükleri

Şekil 3'te verilen dallanmalara göre hangi girdi özelliğinin seçiminin en iyi olacağına karar vermek için yapraklardaki evet ve hayır sayısına bakmak yeterlidir. Sadece evet ya da hayır şeklinde yaprakta tek bir sınıf olduğunda aşağıya doğru tekrar eden dallanma süreci son bulacaktır. Eğer her bir düğümün saflığı ölçülecekse en saf (purity) çocuk düğümleri üreten özelliklerin seçilmesi gerekmektedir (Tan, Steinbach, Karpatne ve Kumar, 2018). Kullanılan saflık ölçüsü bilgi (information) olarak ifade edilir bu ölçünün birimi ise bittir. Buradaki saflık ölçüsü olan bilgi kavramı ağacın bir düğümü ile ilişkili olarak yeni bir ölçümün evet (aktivite yapılacak) ya da hayır (aktivite yapılmayacak) biçiminde sınıflandırılmasındaki doğruluğu için gerekli olan bilgi miktarını ifade etmektedir. Buradaki sınıflama doğruluğunu sağlayan fonksiyonlar, entropi ve gini safsızlığı ya da bilgi kazancı olarak ifade edilen fonksiyonlardır (Fürnkranz, 1999). Bu durumda

karar ağacı oluşturma sürecinde entropi, gini safsızlığı ve bilgi kazancı kavramları üzerinde durulmalıdır.

Entropi, gini safsızlık indeksi ve bilgi kazancı. Karar ağaçlarında entropi bir belirsizlik ölçüsüdür. Entropi, bir olayda tesadüfi biçimde ortaya çıkan bilgi miktarıdır. Örneğin bir olayın meydana gelme olasılığı kesin ise entropi sıfır olur (Köse, 2018). Entropi verilerin dağınıklığı hakkında bilgi verir. Entropi değerinin yüksek olması tahmin performansının zayıflığı anlamına gelir. Bir özelliğin entropisi o özelliğin sınıf niteliği hakkında sahip olduğu bilgi düzeyi anlamına gelir. Entropi karar ağaçlarında bölünme aşamasında sınıfların saflığını artırır ve yaprak düğümlerinde bulunan sınıfların daha net olmasına imkân sağlar. Entropi, her bir bölünmenin öncesinde ve sonrasında hesaplanır. Entropi değeri azalır, başka bir bölünme denenecek bölünme gerçekleşmezse ağacın dalı duracak ve mevcut ağaç korunacaktır (Fürnkranz, 1999).

Tüm veri kümesi için entropi formülü:

$$E = - \sum_{i=1}^c p_i \cdot \log_2(p_i)$$

Burada, c bir düğümdeki sınıf sayısı iken p_i ise düğümdeki i 'inci sınıfın olasılığıdır. Entropi ID3, C4.5 ve C5.0 karar ağacı oluşturma algoritmaları tarafından kullanılır. Bilgi kazanımı hesaplanırken entropi ve gini safsızlık indeksinden yararlanır. Gini safsızlık (impurity) indeksi ise, sınıflandırma ve regresyon ağacı algoritması tarafından kullanılan belirsizlik ölçüsüdür. Gini safsızlık indeksi entropide olduğu gibi, veri kümesinden rastgele seçilen bir ölçümün alt kümedeki etiketlerin dağılımına göre rastgele etiketlenmesi durumunda ne kadar sıklıkla yanlış etiketleneceğinin ölçüsüdür (Köse, 2018).

Tüm veri kümesi için gini safsızlık formülü:

$$G = 1 - \sum_{i=1}^c p_i^2$$

Burada, c bir düğümdeki sınıf sayısı iken p_i ise düğümdeki i 'inci sınıfın olasılığıdır. Formülden anlaşıldığı gibi gini safsızlık indeks değeri yüksek çıkan girdi özelliklerin rastgelelikleri fazla olacaktır. Bundan dolayı girdi özellik seçilirken gini safsızlık indeksi en küçük olan özellik seçilir.

Bilgi kazancı, bir girdi özelliğın hedef değışkене ait sınıf özelliğı hakkında sağladığı bilgi miktarıdır. Bir veri setinde yer alan girdi özelliğın aldığı değerler ile hedef değışkenin sınıf özelliğı uyumlu ise bu girdi özellik hedef değışkenin sınıf özelliğı hakkında önemli bilgi sağlamış olur. Örneğın, veri setindeki hedef değışkenin sınıf özelliğı golf oynama ve oynamama durumu, girdi özelliklerden biriside cinsiyet olsun eğer erkeklerin tamamı golf oynayıp kadınların tamamı golf oynamıyorsa, cinsiyet girdi özelliğı hedef değışkenin sınıf özelliğı hakkında oldukça belirleyici bilgi sağlamış olur (Köse, 2018). Bilgi kazancı ölçüsü, belirsizliğın ne kadar azaldığı hakkında bilgi verir. Bilgi kazancının hesaplanmasında, hedef değışkenin entropi veya gini safsızlık indeks değerinden bilgi kazanımı belirlenen girdi özelliğın ağırlıklı entropi veya gini safsızlık indeks değerinin çıkarılması ile elde edilir (Quinlan, 1986).

Entropi için bilgi kazancı formülü;

$$\text{Bilgi Kazancı } (T, X_j) = \text{Entropi } (T) - \text{Entropi } (T, X_j)$$

Gini için bilgi kazancı formülü;

$$\text{Gini Kazancı } (T, X_j) = \text{Gini } (T) - \text{Gini } (T, X_j)$$

T: Hedef değışken

X_j: Bölünecek girdi özellik

Entropi (T, X_j): Verilerin X_j girdi özellik üzerinde bölündükten sonra hesaplanan entropi değeridir.

Gini (T, X_j): Verilerin X_j girdi özellik üzerinde bölündükten sonra hesaplanan gini değeridir. Burada bahsedilen girdi özellik tahmin edici anlamına gelmektedir.

Tablo 3'te verilen girdi özelliklere göre oluşturulan Şekil 3'te verilen ağaç kütükleri ile ilk ayırt edici girdi özelliğı belirlemek için öncelikle hedef değışkenin entropisi ve hedef değışken haricindeki diğer girdi özelliklerin entropileri hesaplanmış sonrada bu değerler kullanılarak bilgi kazancı hesaplanmıştır.

$$\text{Entropi } (T) = -\frac{5}{14} \log_2 \left(\frac{5}{14} \right) - \frac{9}{14} \log_2 \left(\frac{9}{14} \right) = 0,940$$

Veri kümesinde hedef değışkене ait beş tane "Hayır", dokuz tane "Evet" ile veri kümesinin belirsizliğı anlamına gelen entropi değeri 0,940 bulunmuştur.

Görünüm özelliğinin Güneşli, Kapalı ve Yağışlı kategorileri için entropiler;

$$\text{Entropi (Görünüm, Güneşli)} = -\frac{2}{5}\log_2\left(\frac{2}{5}\right) - \frac{3}{5}\log_2\left(\frac{3}{5}\right) = 0,971$$

$$\text{Entropi (Görünüm, Kapalı)} = -\frac{0}{4}\log_2\left(\frac{0}{4}\right) - \frac{4}{4}\log_2\left(\frac{4}{4}\right) = 0$$

$$\text{Entropi (Görünüm, Yağışlı)} = -\frac{3}{5}\log_2\left(\frac{3}{5}\right) - \frac{2}{5}\log_2\left(\frac{2}{5}\right) = 0,971$$

Elde edilen değerlere göre "Görünüm" girdi özelliğinin toplam entropisi aşağıdaki gibi hesaplanır.

$$\text{Entropi (Görünüm)} = \frac{5}{14}0,971 + \frac{4}{14}0 + \frac{5}{14}0,971 = 0,694$$

Benzer biçimde hesaplamalar yapıldığında diğer girdi özelliklerin toplam entropileri;

$$\text{Entropi (Sıcaklık)} = 0,911$$

$$\text{Entropi (Nem)} = 0,789$$

$$\text{Entropi (Rüzgar)} = 0,892$$

Tüm özellikler için bilgi kazanımı hesaplanırsa;

$$\text{Bilgi Kazanımı (D, Görünüm)} = 0,940 - 0,694 = 0,246$$

$$\text{Bilgi Kazanımı (D, Sıcaklık)} = 0,940 - 0,911 = 0,029$$

$$\text{Bilgi Kazanımı (D, Nem)} = 0,940 - 0,789 = 0,151$$

$$\text{Bilgi Kazanımı (D, Rüzgar)} = 0,940 - 0,892 = 0,048$$

Elde edilen sonuçlara göre bilgi kazancı en yüksek olan girdi özellik görünümdür. Bu durumda ilk ayırt edici girdi özellik "Görünüm" olduğu için bu özelliğin kök düğüm olarak alınması uygundur (Quinlan, 1986).

Sınıflama ve regresyon ağacı algoritması. Karar ağaçları oluşturulurken en yaygın kullanılan algoritmalarından biridir. Bu algoritma 1984 yılında Breiman, Friedman, Olshen ve Stone tarafından geliştirilmiştir. Sınıflama ve regresyon ağacı (SRA) algoritmasında bir düğümde belirli bir kritere göre bölünme gerçekleşir. Bölünme aşamasında önce tüm özelliklerin bulunduğu değerler dikkate alınır ve tüm eşleşmeler tamamlandıktan sonra evet-hayır biçiminde ikili dallanma ile seçme işlemi gerçekleştirilir (Özkan, 2008).

Sınıflama ve regresyon ağacı algoritması bağımlı değişkenin kategorik ya da sürekli veri olduğu durumlarda kullanılabilir. Bu bakımdan incelendiğinde SRA

algoritması bağımlı deęişkenin sürekli olduęu durumda çoklu regresyon analizini, kategorik olduęu durumda ise lojistik regresyon analizini kapsayan bir algoritma olarak kabul edilebilir (Güner, 2014).

Bu algoritma hangi düęümün kök veya düęüm olmasını belirlenmesi ile birlikte belirlenen düęümün hangi noktasından ikiye bölüneceęini de hesaplamalıdır (Silahtaroęlu, 2016). SRA algoritmasının sürekli bağımlı deęişkenlerde kullanılması sürecinde bölümlene noktasının tespit edilmesinde yakınsama temelli sayısal yöntemlerden yararlanır. Bağımlı deęişkenin kategorik veri olduęu durumda nesnenin bulunduęu sınıf tahmin edilirken sürekli olduęu durumda nesnenin bulunduęu sınıfının sayısal deęeri tahmin edilir (Köse, 2018). SRA algoritmasında dięer algoritmaların aksine başlangıçta büyük bir ağaç oluşturulur sonradan yanlış sınıflandırma tahmin hatasını en aza indirmek için ağaç budanarak küçültülür (Loh, 2011).

İkili ağaç üreten bu algoritmada her bir özelliğın alt seęenekleri iki gruba ayrılmalıdır. Her bir seęeneğın hangi bölüme yönlendirileceęi twoing kriteri veya gini ölçüsü vasıtasıyla belirlenir. Ayrıca, bağımlı deęişkenin kategorik veri olduęu durumda dallandırma kriteri olan twoing kriteri ya da gini ölçüsü kullanılarak oluşturulan yöntem sınıflama ağacı olarak ifade edilirken, sürekli veri ise dallandırma kriteri için hata kareler toplamı kullanılarak oluşturulan yöntem regresyon ağacı olarak ifade edilir (Altunkaynak, 2019).

Twoing Kriteri. Twoing Kriterine baęlı olarak meydana gelen dallanmada bağımsız deęişkenin her birinin olası tüm ikili ayrışmaları ele alınır. Bu kriter ilgili özelliğı sol ve saę olarak ikiye ayırır. Daha sonra her bir dalda bulunan deęerlerden her bir kategori (tekrar eden ayrık deęer) için olasılık deęerleri hesaplanır (Köse, 2018). SRA algoritmasında alt sınıflara ayrılacak kayıtlar olası tüm deęerler dikkate alınarak ařağıdaki formüle göre alt sınıflara ayrılmaktadır (Larose, 2005).

$$\emptyset(D_i) = 2P_L P_R \sum_{j=1}^k |P(Y_j \setminus L) - P(Y_j \setminus R)|$$

$$P_L = \frac{\text{Sol taraftaki verilerdeki ayrık her bir deęerin tekrar sayısı}}{\text{Toplam kayıt sayısı}}$$

$$P_R = \frac{\text{Sağ taraftaki verilerdeki ayrık her bir değerin tekrar sayısı}}{\text{Toplam kayıt sayısı}}$$

$$P(Y_j \setminus L) = \frac{\text{Soldaki kayıtlarda j değerinin tekrar sayısı}}{\text{Soldaki verilerdeki her bir ayrık değerin tekrar sayısı}}$$

$$P(Y_j \setminus R) = \frac{\text{Sağdaki kayıtlarda j değerinin tekrar sayısı}}{\text{Sağdaki verilerdeki her bir ayrık değerin tekrar sayısı}}$$

Burada;

D_i : i. bölünme

$\emptyset(D_i)$: i. bölünmeye ait twoing kriteri

P_L : D_i bölünmesi için bir ölçümün ağacın solunda bulunma olasılığı

P_R : D_i bölünmesi için bir ölçümün ağacın sağında bulunma olasılığı

$P(Y_j \setminus L)$: Ağacın solunda bulunan kategorinin j. düzeyinin olasılığı

$P(Y_j \setminus R)$: Ağacın sağında bulunan kategorinin j. düzeyinin olasılığı

Formülle göre en iyi bölünme, D_i düğümünde $\emptyset(D_i)$ değerini en büyük yapan değişken kategori üzerinde en çok etkiye sahip değişken olarak kabul edilerek dallanma için seçilir (Altunkaynak, 2019).

Gini ölçüsü. Gini ölçüsüne dayalı olarak yapılan dallandırma değişkenler için hesaplanan gini ayırma indeksine göre yapılır (Loh, 2011). Burada gini ayırma indeksi (Gini split) en küçük olan değişken kategori üzerinde en çok belirleyiciliğe sahip olacağından dallandırmada bu değişken seçilir. SRA'da düğümlerin her biri için yalnızca iki dallanma yapıldığı için değişkenlerin her biri iki düzeyli olmalıdır. Eğer değişkenlerin düzey sayısı ikiden fazla ise twoing kriterinde bulunan olası ikili ayırma durumları göz önüne alınır (Altunkaynak, 2019). Gini ölçüsü değişken değerlerinin sol taraf ve sağ taraf olarak iki bölüme ayrılması şeklinde bölünme indeksidir. Gini ölçüsünün uygulama aşamaları şunlardır (Özkan, 2008).

- Her bir değişken değerleri iki kategori olacak biçimde sınıflandırılır. Bu biçimde meydana gelen sol taraf ve sağ taraf bölünmelere göre sınıflama işlemi yapılır.

- Her bir deęişkenle ilgili ağacın soluna ve saęına yönelik bölünmeler için $Gini_{sol}$ ve $Gini_{saę}$ ölçüleri hesaplanır.

$$Gini_{sol} = Gini(L_i) = 1 - \sum_{j=1}^k [P(Y_j \setminus L)]^2$$

$$Gini_{saę} = Gini(R_i) = 1 - \sum_{j=1}^k [P(Y_j \setminus R)]^2$$

Burada;

$P(Y_j \setminus L)$: Ağacın solunda bulunan kategorinin j. düzeyinin olasılığı

$P(Y_j \setminus R)$: Ağacın saęında bulunan kategorinin j. düzeyinin olasılığı

$k = 2$ için gini ayırma indeksinin formülü;

$Gini_{split}(D_i) = P(L_i) Gini(L_i) + P(R_i) Gini(R_i)$, biçimindedir.

Burada;

$P(L_i)$: D_i bölünmesi için bir ölçümün ağacın solunda bulunma olasılığı

$P(R_i)$: D_i bölünmesi için bir ölçümün ağacın saęında bulunma olasılığı

SRA algoritmasının avantajları;

- Sürekli baęımlı deęişkenlerde oldukça başarılıdır.
- Eksik verileri tolere edebilir.
- Aykırı deęerleri kolayca işleyebilir.
- Önemli deęişkenleri belirleyip önemsiz olanları kaldırır.
- Meydana gelen karar ağacı açık ve anlaşılır sınıflama kuralları verir.
- Ağacın büyüklüęü sınır koyularak kontrol edilebilir.
- Dallanmada hata oranını en aza indirmeye odaklanır. Böylelikle büyük ağaçlarda başarı oranı yüksektir.
- İşlem hızı yüksektir (Köse, 2018).

SRA algoritmasının dezavantajları;

- Küçük eğitim veri setleriyle öğrenme sürecinde başarılı deęildir.
- Bazen kararsız davranabilir.
- Oluşturulan ağaçtaki bazı ayrıntılar atlanabilir.
- Veri setinde meydana gelen deęişiklikler ağacı çok fazla etkileyebilir.

- İkili bölümlenme sebebiyle bazen çok büyük ölçüde ağaçlar oluşabilir (Köse, 2018).

Rastgele orman algoritması. Basit yapıda bir sınıflandırma algoritması olan Rastgele Orman (RO) algoritması, doğruluğu ve bağımsızlığı en yüksek olan belirli sayıdaki ağaçların birleşiminden meydana gelen algoritmadır. Karar ağaçlarının her biri veri setindeki değişkenlere göre dallanmaktadır (Breiman, 2001).

Bu algoritmada birbirinden etkilenmeden meydana gelen karar ağaçlarının birbirinden bağımsız olarak birleştirilip karar ormanları oluşturulmasıyla, karar ağaçlarının her biri ile yapılan tahminlerin birleştirilmesi ile etkili bir tahminin yapılması hedeflenir (Atasever, 2011).

Karar Ormanları topluluk öğrenme algoritmaları anlamına gelen karar ormanlarının temel mantığı, her bir algoritmanın aynı tahmini ve sınıflamayı yaptığı, geçerli ve güvenilir tahminler için tek bir algoritmadan elde edilen performanstan daha iyi performans gösteren algoritmalar topluluğundan model oluşturmaktır. Topluluk öğrenme algoritması, kritik öneme sahip bir karar vermeden önce çevresindeki insanlara danışan, farklı görüşleri dikkate alan bir insanın karar vermesi gibidir (Polikar, 2006). Topluluk algoritmalarının oluşturulan modelin tahmin performansını artırmada kullanılabileceği bilinmektedir. Makine öğrenme, veri madenciliği, istatistik ve örüntü tanıma gibi alanlarda araştırmacılar, topluluk algoritmalarından yararlanmaktadır. Alanyazında, “topluluk algoritmaları” aynı sınıflama ve tahmin amacına yönelik küçük farklılıkları olan algoritmaların koleksiyonu veya çoklu sınıflayıcı sistemler olarak ifade edilmektedir (Rokach ve Maimon, 2014).

RO algoritmasının büyük veri setlerinde iyi derecede performans sergilemesi ve değişken silmeye gerek olmadan çok sayıda bağımsız değişkeni işlemesi mümkündür. Bu algoritma bağımlı değişkenin iki veya çok kategorili olması durumunda ve bağımsız değişkenlerin ise kategorik, sıralı ve sürekli olduğu durumlar için kullanılabilir. Bu yöntemde kullanılan veri setindeki değişken sayısının çok fazla olması durumunda, değişkenlerin önem sıraları dikkate alınarak değişken sayısının azaltılması ile daha az sayıda değişken ile daha isabetli tahminler yapılabilir (Akman, 2010).

RO algoritması, analiz için kullanılan verinin tamamından bootstrap yöntemiyle seçilen örneklem ile bağımsız karar ağaçlarının meydana getirildiği torbalama (bagging) ve değişkenlerin tamamından rastgele olarak seçilen az sayıdaki değişkenlerden karar ağacının her bir düğümündeki en iyi bölünmeyi oluşturan değişkenin seçildiği uygulanması kolay bir yöntemdir (Akman, 2010). Rastgele orman algoritmasına dayalı olarak karar ağaçları oluşturma sürecinde bölünme kriteri olarak, gini ölçüsü kullanılır (Pal, 2005).

RO algoritması orman üretimini sürdürürken yansız bir genelleme hatası kestirir. Eksik veri kestirme de etkili bir yöntem olmanın yanı sıra eksik veri miktarının çok fazla olduğu durumlarda bile iyi düzeyde performans gösterir. Sınıfların kesme değerlerine göre örneklem dağılımının çarpık olduğu veri setlerinde hatayı tolere edebilir. Değişken etkileşimlerini belirlemeye imkân sağlar. Torbalamanın ve rastgele değişken seçiminin art arda uygulandığı RO algoritmasında, analize eğitim setinden alınan her yeni eğitim seti için rastgele seçilen değişkenlerin kombinasyonları kullanılarak ormanda bulunan ağaçlarda en fazla derinliğe kadar büyüme olduğu için budamaya gerek yoktur (Breiman, 2001). Bu durum RO algoritmasının karar ağacı algoritmalarına göre en büyük üstünlüğüdür (Pal, 2005). Çünkü Pal ve Mather'a (2003) göre budama tekniklerinin seçimi karar ağaçlarının sınıflama performansını etkilemektedir.

RO algoritmasıyla sınıflama yapılıyorsa eğitilmiş ağaçların mod değerine regresyon işlemi yapılıyorsa eğitilmiş ağaçların aritmetik ortalamasına göre sonuç bulunur ve RO algoritmasının kategorik değişkenlerdeki performansı sürekli değişkenlere göre daha yüksektir. Bu yöntem özünde SRA'ya dayandığı için sınıflandırma ve regresyon işleminde kullanılabilir. Karar ağacının kullanıldığı modellerde temel sorun, verinin yetersiz olması nedeniyle aşırı miktarda uyum (over fitting) meydana gelmesidir (Liao, Ju ve Zou, 2016). RO algoritması, oluşturulmuş belli sayıdaki SRA'yı dikkate alarak, aşırı uyumu engellemek için veri setinin alt kümelerinden öğrenecek biçimde tasarlanmıştır. Bu nedenle aşırı uyuma karşı dirençli bir yöntemdir (Bhalla, 2014).

Diğer sınıflama yöntemlerinin aksine RO algoritmasının kullanılması için sadece ağaç ve değişken sayısı yeterli olmaktadır. Ayrıca bazı algoritmaları kullanmada verileri normalleştirme gereği varken RO algoritmasında böyle bir gereklilik yoktur. RO algoritması ile sınıflandırma sürecinde her bir değişkenin

etkisinin tam olarak açıklanması ve ormandaki ağaçların tamamının yapısının incelenmesinin mümkün olmamasından dolayı bağımsız değişkenler arasındaki ilişkilerin yorumlanması kolay değildir. Bu durum RO algoritmasının önemli bir dezavantajıdır. Ayrıca, RO algoritmasında ağaç sayısı çok fazla olduğundan ağaçların şekilsel olarak görülmesi mümkün değildir (Yan, 2017).

Ormanın oluşturulması sürecinde ağaçların her biri aşağıdaki algoritmaya göre oluşturulur (Breiman, 2001):

- Ağacı yetiştirmede kullanılan veri setinde N tane birey olsun. Bu veri setinden hem rastgele hem de yer değiştirmeli olacak biçimde, N adet birey bootstrap yoluyla örneklem alınır. Bu örneklem ağacı yetiştirmede kullanılan eğitim veri setidir.
- Yordayıcı değişken sayısı p 'dir. Ağacın her bir düğümünde p değerinden küçük sabit bir m değeri vardır. Burada m değeri ağaçtaki her bir düğüm için en iyi bölünmeyi sağlayan yordayıcı değişken sayısıdır. Bu m tane yordayıcı değişken daha önce kullanılmamış yordayıcı değişkenler arasından rastgele seçilerek üzerinde çalışılan düğümde en iyi bölünme sağlanır. Seçilen yordayıcı değişken sayısı m tüm ağaçlar için aynıdır.
- Ormanda bulunan her bir ağaç en iyi biçimde yetiştirilir. Budama yapılmaz.

RO algoritmasının matematiksel gösterimi Breiman (2001) tarafından aşağıdaki gibi gösterilmiştir (Cutler, Cutler ve Stevens, 2012). RO algoritması temel öğrenciler anlamında $h_j(X, Q_j)$ karar ağaçlarını kullanmaktadır.

Eğitim verisi olarak;

$D = \{(x_1, y_1), \dots, (x_N)\}$ kullanılır. Eşitlikteki, $x_i = (x_{i,1}, \dots, x_{i,p})^T$ biçimindedir.

p yordayıcıları, y_i yanıtları ifade eder.

Uyumlu hale getirilmiş karar ağacı $\hat{h}_j(x, \theta_j, D)$ biçiminde gösterilir.

Bu formül Breiman (2004) tarafından ortaya konulmasına rağmen, θ_j rastgele bileşeni doğrudan değil seçkisizliği iki şekilde enjekte etmek üzere dolaylı olarak kullanılır. Birincisi, orijinal veriden bağımsız olarak tekrarlı örnekleme (bootstrap) yöntemi ile ağaçların her biri oluşturulur. Burada tekrarlı örneklemedeki randomizasyon, θ_j 'nin bir kısmını verir. İkincisi ise, bir düğüm bölündüğünde, en iyi bölünme p tane yordayıcının tamamı yerine rastgele seçilen m tane yordayıcının

alt kümesinde yer alır. Yordayıcıları örneklemeyi sağlayan randomizasyon θ_j 'nin kalan kısımlarını verir. Ağaçlar budamasız büyür. Başlangıçta, Breiman'ın (2004) önerisi: uçtaki düğümler kusursuz olana kadar veya uç düğümlerin her birinde önceden tespit edilmiş veri noktası sayısından daha az oluncaya kadar ağaçları büyütmeyi önermiştir. Son zamanlarda, uç noktaların maksimum sayısını kontrol altına almayı tavsiye etmiştir.

Bu durumda RO algoritması;

$D = \{(x_1, y_1), \dots, (x_N)\}$ ve $x_i = (x_{i,1}, \dots, x_{i,p})^T$ eğitim verisini ifade etsin,

$j=1$ 'den J 'ye kadar değer alsın,

1. D 'den bootstrap tekniği ile N genişliğinde D_j örnekleme, alınır.
2. Eğitim seti olarak Bootstrap örnekleme D_j ikili tekrarlı bölünmenin kullanıldığı bir ağaca uyarlanır.
 - a. Tek bir düğümdeki tüm gözlemlerle başlanır.
 - b. Durdurma kriteri devreye girene kadar her bir bölünmemiş düğüm için aşağıdaki adımları tekrar edilir.
 - Mevcut olan p adet yordayıcıdan rastgele m adet yordayıcı seçilir.
 - m yordayıcıdaki ikili bölünmeler arasından en iyisi bulunur.
 - Seçilen en iyi bölünme kullanılarak düğüm iki alt düğüme ayrılır.

Yeni bir x noktasında bir tahminde bulunmak için;

$\hat{f}(x) = \frac{1}{J} \sum_{j=1}^J \hat{h}_j(x)$, regresyon için kullanılır.

$\hat{f}(x) = \operatorname{argmax}_y \sum_{j=1}^J I(\hat{h}_j(x) = y)$, sınıflama için kullanılır.

Burada, $\hat{h}_j(x)$ j . ağaçtaki x yordayıcı değişkeninin yanıtının tahminidir (Cutler ve ark., 2012).

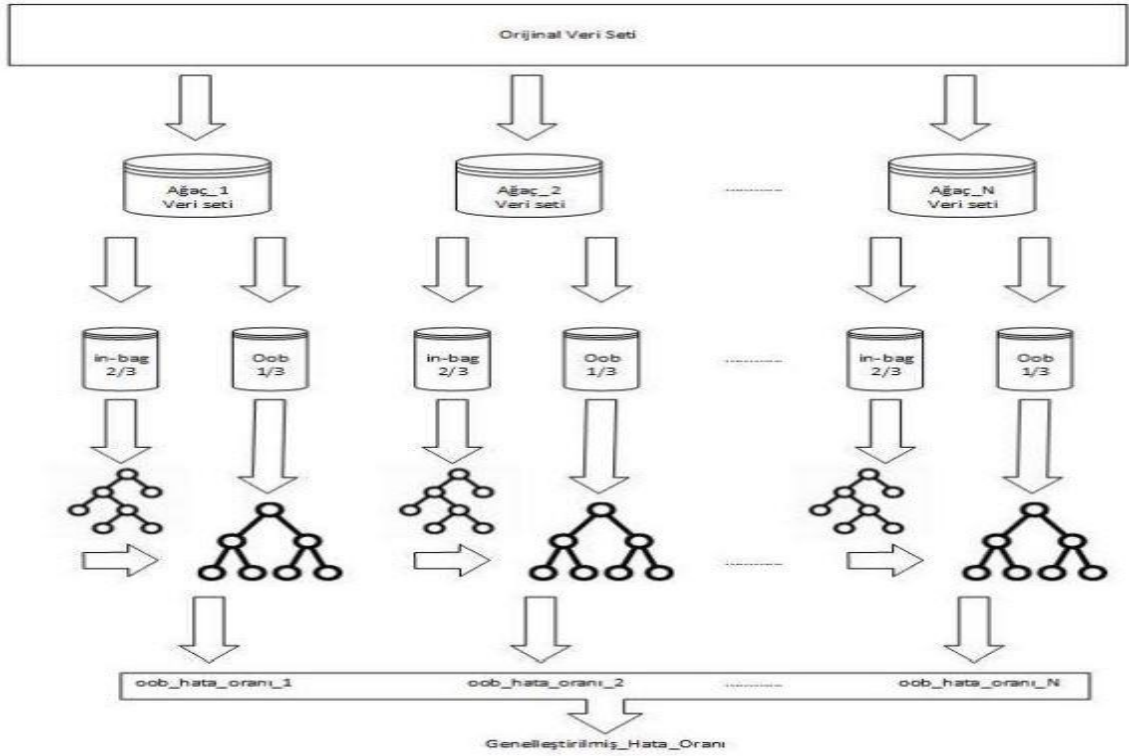
RO algoritmasının işleyiş süreci. Bu algoritmanın işleyiş sürecinde eğitim verisi, üzerinde çalışılan veri setinden tekrarlı örnekleme (bootstrap) yöntemi kullanılarak elde edilir (Breiman, 2004). RO algoritmasına dayalı olarak model oluşturulurken seçilen verinin sonraki adımda tekrar yerine konulması ve rastgele

olarak seçim yapılması koşuluyla veri setinin 2/3'lük kısmı eğitim verisi (inBag), 1/3'lük kısmı ise test verisi (Out-Of-Bag) olarak bölünür (Bhalla, 2014).

Bootstrap yöntemi ile oluşturulması amaçlanan karar ağacı sayısı kadar örneklem alınır ve her bir örneklem için eğitim ve test veri seti bölünür (Akman, 2010). Düğümlerin her birinde rastgele seçilen m tane değişken arasında en iyi bölünmeyi sağlayan değişken vardır. Seçilen değişken sayısı orman oluşturma sürecinde sabit tutulur (Breiman, 2004). Toplam bağımsız değişken sayısının p olduğu ve bağımlı değişkenin kategorik olduğu durumda $m = \sqrt{p}$ olurken regresyon için $m = \frac{p}{3}$ olur (Bhalla, 2014). Bootstrap yöntemiyle oluşturulan örneklemelerin her biri için budanmamış sınıflandırma veya regresyon ağaçlarının meydana gelme sürecinde; düğümlerin her birinde, değişkenlerin tamamı ile en iyi bölünmeyi seçmek yerine rastgele seçilen m hacimli değişken örneklemi ile en iyi bölünme seçilir (Liaw ve Wiener, 2002).

Ormanda bulunacak karar ağaçlarının her biri SRA algoritması ile oluşturulur. Bunun için gini ölçüsü ile en iyi dallanma kriteri belirlendikten sonra düğüm iki dala ayrılır (Akman, 2010). Regresyona dayalı olarak her bir ağaç indirildiğinde x test vektörü bulunduğu düğümdeki y 'nin ortalama değerine atanır. Sınıflandırma işleminde öngörülen değer ise ormandaki oyların en çoğunu (mod) alan sınıftır (Breiman, 2004). Diğer bir ifadeyle n adet ağacın tahmin değerleri birleştirilerek oluşturulan yeni veri setine göre tahminde bulunulur. Bu birleştirme işleminde regresyon için ortalama, sınıflama için ise en yüksek oy çokluğu (mod) kullanılır (Liaw ve Wiener, 2002).

RO algoritmasının işleyiş süreci Şekil 4'te yer almaktadır (Ercire, 2019).



Şekil 4. Rastgele orman algoritması genelleştirilmiş hata oranı işleyiş süreci

RO yönteminin işleyiş sürecinde kullanıcının belirlediği iki parametre önemlidir. Bunlar birisi ağaç oluşturmada düğümlerin her birinde kullanılan değişken sayısı diğeri ise oluşturulacak ağaçların sayısıdır. Düğümlerin her biri oluşturulurken sadece seçilen değişkenler incelemeye alınır. Bu yöntemde oluşturulacak ağaç sayısını kullanıcı belirlemektedir (Pal, 2005).

RO algoritmasında, tekrarlı örnekleme (bootstrap) tekniği kullanılarak seçilen örneklemin ve her düğümdede değişkenlerin tümü arasından seçilen belirli sayıdaki değişkenlerin algoritmanın sınıflama ve tahmin performansı üzerinde etkisi vardır (Atasever, 2011). Ağacın yetiştirilmesi (training) sürecinde eğitim verisi kullanılırken, genelleştirilmiş hata oranının belirlenmesinde test verisi kullanılır. Ormanda bulunan her bir ağacı oluşturmak için orijinal veri setinden farklı bir veri seti alınıp kullanılır. Her bir ağacın eğitim ve test verisi farklıdır. Orijinal veri setinde test veri seti önceden ayrılmış ise bu veri seti ormanın genel hatasını belirlemede kullanılır. Ağaçların hata oranlarının ortalaması, ormanın genel hata oranıyla yaklaşık aynıdır (Ercire, 2019).

Ormanın hata oranı iki faktöre bağlıdır. Birinci faktör, iki ağaç arasındaki ilişki düzeyidir. İlişki düzeyinin artması ormanın hata oranını artırır. İkinci faktör ise ormanda bulunan ağaçların her birinin gücüdür. Hata oranı düşük olan bir ağaç güçlü bir sınıflandırma yapar. Her bir ağacın gücünün artırılması durumunda ormanın hata oranı düşer. Ağacın her bir düğümünde kararı belirlemede kullanılan yordayıcı değişken sayısının (m) azaltılması ağacın diğer ağaçlarla ilişki düzeyini ve ağacın gücünü azaltır. Yordayıcı değişken sayısının (m) artırılması ise ağacın diğer ağaçlarla ilişki düzeyini ve ağacın gücünü artırır. Uygun bir m değeri için tolerans aralığı oldukça geniştir. Ağaçların eğitim sürecindeki hata değerlerini kullanmak yerine test süreci için ayrılan verinin (out-of-bag) hata değeri kullanılarak bu tolerans aralığında makul bir m değeri çabucak bulunabilir. Bu değer rastgele orman algoritmasının kalibre edilebilen tek parametresidir (Breiman ve Cutler, 2004).

Verilerden bir bootstrap örnekleme alındığında, gözlemlerden bazıları bootstrap örnekleminde bulunmaz. Bunlar genelleme hatası ve değişken önem düzeyini tahmin etmede çok kullanışlı eğitim veri setidir. Eğitim veri seti hata oranını hesaplamada kullanılan öncelikli veri setidir. Eğitim veri seti bootstrap örnekleme sürecinde ağaç oluşturmada kullanılan (inbag) ve ağaç oluşturmada kullanılmayan (out of bag) onun yerine ağacın test edilerek hata tahmininde kullanılan veri seti olmak üzere ikiye ayrılır (Cutler ve ark., 2012).

Her bir ağaçtan elde edilen eğitim verisinin tahminleri birleştirilip ormanın eğitim verisinin hata oranı bulunur (Akman, 2010). Regresyon için test verisi hata kareler ortalamasını kullanılarak genelleştirilmiş hata tahmin edilir.

$$MSE_{oob} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{f}_{oob}(x_i))^2$$

Formüldeki $\hat{f}_{oob}(x_i)$, i.gözlem için test verisi tahminidir.

Sınıflama için test verisi hata oranı kullanılarak genelleştirilmiş hata oranı tahmin edilir.

$$E_{oob} = \frac{1}{N} \sum_{i=1}^N I(y_i \neq \hat{f}_{oob}(x_i)),$$

Her bir ağaç için test verisi hata oranını hesaplayarak test verisi hata oranının meydana getirilmesi ve bu hata oranlarının ortalamasının orman için test verisi hata oranını vermesi yaygın kavram yanılgısıdır. Bunun yerine test verisi

hata oranı tahminleri kullanılır. Bu her bir sınıf için sınıflama hata oranını verir (Cutler ve ark., 2012)

Karar ağacı modellerinde girdi değişkenlerin tahmin edici önemi.

Tahmin edicinin önemi (Predictor importance) modeldeki her bir bağımsız değişkenin bağımlı değişkene yönelik tahmin etmedeki görelî önemiyle ilgilidir. SPSS Modeler veya Matlab gibi programlarda kullanılan veri madenciliği yöntemlerinden elde edilen çıktılardan biri olan tahmin edicinin önem tablosu belirli model için her bir bağımsız değişkenin görelî önemini gösterir. Bağımsız değişkenlerin görelî tahmin edici önem düzeylerinin toplamı 1'dir. Bu durumda bir tahmin edicinin önemi, model doğruluğu ile ilgili değil o tahmin edicinin modelin tahmin performansına görelî katkısıyla ilgilidir. Oluşturulan bir modele ince ayar yapmada tahmin edicinin önemi çok faydalıdır (IBM, 2021).

Karar ağaçları genellikle dengeli olmayan modellerdir. Bu nedenle karar ağaçlarına dayalı olarak oluşturulan modellerde veri setinde meydana gelen küçük değişimler bölünmeyi sağlayan değişkenin seçiminde hataya neden olabilir. SRA ve RO gibi karar ağacı modelleri bölünmeyi sağlayacak değişkenleri belirlerken bu değişkenlerin önemini değerlendirmeye imkân sağlar. Bu yöntemler değişkenleri tahmin edici öneme göre sıralama amacına hizmet eder. Ancak SRA yöntemine dayalı değişken seçme sürecinde son ağaç yapısında seçilmemiş olan bir değişken veri setini açıklamada daha az öneme sahip değişken olarak düşünülebilir. Ancak bunun nedeni değişkenin başka bir değişken tarafından gölgelenmesi olabilir. Örneğin; bir X_1 değişkeni en son ağaçta bulunmamasına rağmen gölgeleyici X_2 değişkeninin kaldırılması durumunda oluşturulan ağaçta önemli bir değişken olabilir. Böyle bir durumda değişken sıralama metodu X_1 değişkeninin önemini belirlemede başarılıdır.

$M(X_m) = \sum_{t \in T} \Delta I(\hat{S}_m, t)$, formülü X_m değişkeninin önemini verir.

$\Delta I(\hat{S}_m, t) = \max \Delta I_{C_i}(S_m, t)$, bu eşitlik;

Ana düğüm (parent node) olan t 'nin \hat{S}_m 'ye bölünmesiyle C_1 ve C_2 çocuk düğümlerine (child node) bölünmesi için düğüm kirliliğindeki maksimum azalışı ifade etmektedir. Bu düğüm kirliliğindeki maksimum azalış önemli değişkenleri belirlemek için optimum T alt ağacının her bir t düğümü için toplanır. Bu süreç yordayıcı değişkenlerin her biri için tekrar edilir. Düğüm kirliliği en az olan

değişkenden en çok olan değişkene doğru ilerlerken değişkenin tahmin edicilik önemi de en fazla olandan en aza doğru gider. Tahmin edicinin önem değerleri yordayıcı değişkenleri yüksekten düşüğe doğru sıralamaya imkân sağlar. Böylece önemli değişkenler belirlenmiş olur. Bu durumda, karar ağaçları değişken seçmeye imkân sağlamış olur (Deconinck, Hancock, Coomans, Massart ve Vander Heyden, 2005).

SRA algoritması ve RO yönteminde tahmin edicinin önemi, o düğüme ulaşma olasılığının ağırlıklandığı düğüm safsızlığındaki azalma olarak hesaplanır. Düğüm olasılığı, düğüme ulaşan ölçüm sayısının toplam ölçüm sayısına oranıyla belirlenir. Bu olasılık değeri ne kadar yüksek olursa, tahmin edicinin önemi o kadar fazla olur (Mathworks, 2021). SRA ile RO yöntemlerinde tahmin edicinin önemini belirlemek için gini safsızlık indeksi kullanılarak düğüm önemi hesaplanır (Ronaghan, 2021). Örneğin i özelliğine (tahmin edici) ait bir ana (parent) j düğümün sol ve sağ iki çocuk (child) düğüme bölündüğü durumda düğüm önemi;

$n_{ij} = w_j \cdot C_j - w_{sol(j)} \cdot C_{sol(j)} - w_{sağ(j)} \cdot C_{sağ(j)}$ formülü ile hesaplanır.

n_{ij} : i özelliğine (tahmin edicisine) ait j ana düğümün önemi

w_j : j ana düğüme ulaşan ölçümlerin sayısının toplam ölçüm sayısına oranıdır.

$w_{sol(j)}$: Sol çocuk düğüme ulaşan ölçümlerin sayısının toplam ölçüm sayısına oranıdır.

$w_{sağ(j)}$: Sağ çocuk düğüme ulaşan ölçümlerin sayısının toplam ölçüm sayısına oranıdır.

C_j : j ana düğümün safsızlık değeri

$C_{sol(j)}$: Soldan bölünen çocuk düğümün safsızlık değeri

$C_{sağ(j)}$: Sağdan bölünen çocuk düğümün safsızlık değeri

Buradaki safsızlık değeri entropi değeri veya gini safsızlık indeksidir.

Bir karar ağacındaki i özelliğinin (tahmin edicinin) önemi (f_i);

$f_i = \frac{\sum_{j:i \text{ özelliğine göre bölünen } j \text{ düğümü}(n_{ij})}{\sum_{k \in \text{ tüm düğümler}}(n_{ik})}$ formülü ile hesaplanır.

Bu formülde paydaki ifade; i girdi özelliğine (tahmin edici) göre bölünen tüm düğümlerin önemleri toplamıdır. Paydadaki ifade ise ağaç yapısındaki tahmin

edicilerin tamamına bölünen tüm düğümlerin önemleri toplamıdır. Daha sonra, elde edilen tahmin edici önem değeri tüm tahmin edicilerin önem değerlerinin toplamına bölünmesi ile 0 ile 1 arasında bir değer alan göreceli tahmin edici değerine normalleştirilebilir (Ronaghan, 2021).

Normalleştirilmiş tahmin edici önemi;

$$\text{norm } f_i = \frac{f_i}{\sum_{j \in \text{tüm tahmin ediciler}}(f_j)} \text{ formülüyle hesaplanır.}$$

RO düzeyindeki son tahmin edici önemi ($\text{RF}f_i$), tüm ağaçlarda yer alan tahmin edicinin değerleri ortalamasıdır. Her ağaçtaki i tahmin edicisinin önem değeri toplanıp ağaç sayısına bölünerek elde edilir (Ronaghan, 2021).

RO düzeyindeki son tahmin edici önemi;

$$\text{RF}f_i = \frac{\sum_{j \in \text{tüm ağaçlar}} \text{norm}(f_{ij})}{T} \text{ formülüyle hesaplanır.}$$

$\text{RF}f_i$: Rastgele Orman modelinde tüm ağaçlardan hesaplanan tahmin edici önemi

$\text{norm}(f_{ij})$: j ağacında i tahmin edicisi için normalleştirilmiş tahmin edici önemi

T: Toplam ağaç sayısı

Regresyon modelleri. Regresyon Analizi, aralarında neden ve sonuç ilişkisi olan değişkenler arasındaki ilişkinin bir matematiksel fonksiyonunu belirleme sürecidir (Büyüköztürk, 2012). Regresyon analizlerinde amaç neden ve sonuç ilişkisi olan değişkenler arasındaki ilişkiyi, en az değişken ile en iyi seviyede tutacak ve değişkenler arasında en iyi uyum sağlayacak bir model kurmaktır. Veri madenciliği, çoğu kurumda geleceğe yönelik tahminde bulunma amacıyla kullanılan bir analiz yöntemidir. Fakat uygulamada tahminde bulunmak kolay değildir. Çünkü kurumların işleyişini etkileyen çok sayıda çeşitli faktörler vardır. Bu nedenle regresyon analizi çok sayıda değişkenin etkilerini dikkate alarak tahminde bulunmaya destek olabilir (Tamilselvi ve Kalaiselvi, 2013). Veri madenciliğinde genellikle lojistik regresyon kullanılmaktadır (Singh, Raw ve Chauhan, 2012).

Lojistik regresyon analizi. Basit ve çoklu doğrusal regresyon modelinde bağımlı değişken eşit oranlı ya da eşit aralıklı ölçek düzeyindedir. Ancak bağımlı (yordanan) değişkenin iki veya daha fazla kategorili olduğu durumda doğrusal regresyon yöntemlerinde parametre kestirimlerinde kullanılan en küçük kareler

yöntemini kullanmak normal dağılıma uymayan hata terimi gibi bazı varsayımların sağlanamamasından dolayı uygun olmamaktadır. Bu durumda lojistik regresyon kullanmak uygun olmaktadır. İki kategorili lojistik regresyonda, Y_i , Bernoulli olasılık dağılımına sahip rastgele değişkenin 1 değerini alma olasılığı π_i ve 0 değerini alma olasılığı ise $(1 - \pi_i)$ olur.

Bağımsız (yordayıcı) değişkenler $X = (X_1, X_2, X_3, \dots, \dots, \dots, X_n)$ biçiminde ifade edildiği durumda, herhangi i'inci gözlemin regresyon modeli $Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i$ biçiminde gösterilen modelde bulunan bağımsız değişkenler için bir kısıtlama yoktur. Bu modelde Y_i bağımlı değişkeni $-\infty$ ile $+\infty$ arasında sonsuz sayıda değer alabilmektedir. Ancak bağımlı değişkenin alacağı 0 ve 1 değerleri için model yapısal olarak değişmektedir. $P(Y_i = 1)$ i'inci gözlemin 1 değerini alma olasılığı olduğundan $E(\varepsilon_i) = 0$ olduğu için Y_i 'nin beklenen değeri; $E(Y_i) = 1 \cdot P(Y_i = 1) + 0 \cdot P(Y_i = 0) = P(Y_i = 1)$ olacaktır. Bağımlı değişken iki kategorili olduğu durumda ($0 \leq E(Y_i) = P(Y_i = 1) \leq 1$) olduğundan en büyük sınırlama bağımlı değişkenin beklenen değeri üzerinde olacaktır. Bunun sonucunda; $E(Y_i) = P(Y_i = 1) = \beta_0 + \beta_1 X_i$ olarak ifade edilebilir. Bu model bağımlı değişkeni 0 ile 1 arasında olasılık değeri alan "Doğrusal olasılık modeli" olarak adlandırılır (Tatlıdil, 1996). Daha sonra bu sınırlamanın önüne geçmek için ilk olarak; $E(Y_i) = P(Y_i = 1) = \beta_0 + \beta_1 X_i$ modelindeki olasılık değerlerinde $\frac{P}{1-P}$ (Odds) dönüşümü yapılarak bağımlı değişkenin sınırları 0 ile $+\infty$ aralığı olarak sonrada $\frac{P}{1-P}$ oranının doğal logaritması alınıp logit dönüşümü yapılarak bağımlı değişkenin sınırları $-\infty$ ile $+\infty$ olarak genişletilir. Dönüşümler sonucunda elde edilen model:

$$\ln\left[\frac{E(Y=1/X_i)}{E(Y=0/X_i)}\right] = \ln\left[\frac{P_i}{1-P_i}\right] = \beta_0 + \beta_1 X_i \text{ olur.}$$

Bu model lojistik model veya logit model olarak adlandırılır Modelden elde edilen olasılık değeri ise:

$$P_i = \frac{\exp(\beta_0 + \beta_1 X_i)}{1 + \exp(\beta_0 + \beta_1 X_i)} \text{ olarak ifade edilir. (Hosmer ve Lemeshow, 2000).}$$

Lojistik regresyon modelinde en çok olabilirlik yöntemi kullanılarak model katsayıları kestirilir. Bu yöntem ile kestirilen katsayıların anlamlılığı Wald testi veya G istatistiği ile elde edilir. Lojistik modelde bulunan "başarılı olmanın", "başarılı olmamaya oranı" $\frac{P}{1-P}$ ile gösterilip bu oran "Odds" olarak bilinir. Bu oran $0 \leq Odds \leq +\infty$ aralığında değer alıp lojistik regresyon modelinde değişkenlere ait katsayıların

yorumunda kullanılır. 0 ile 1 arasında deęer alırsa bařarısızlık olasılıęı bařarılı olma olasılıęından daha fazla, 1 olursa bařarısız olma olasılıęı ile bařarılı olma olasılıęı eřit, 1'den byk olursa bařarılı olma olasılıęı bařarısız olma olasılıęından daha fazladır.

Lojistik regresyon modeli arařtırmadaki deneklerin hangi grubun yesi olduęunu tahmin etmeye yarayan bir modeldir. Bu bakımdan lojistik regresyon analizi (LRA) yapmanın iki amacı vardır; birincisi yordanan deęiřkende grup yeliklerini belirleyen yordayıcı deęiřkenlerin belirlenmesi, ikincisi grup yeliklerini en iyi performansla belirleyen lojistik modelin geliřtirilmesidir (Hair, Black, Babin ve Anderson, 2014).


LRA, bazı istatistiksel analizlerle benzerlikler gstermektedir. Logit modeli olarak ifade edilen LRA, ayırma analizi ile oklu doęrusal regresyon analizinin bileřkesi olarak dřnlebilir. LRA bir veya daha fazla yordayıcı deęiřkenden yordanan tek bir deęiřkenin alacaęı deęerlere ynelik tahminde bulunması bakımından oklu doęrusal regresyon ile benzerlik gstermektedir. İki yntem arasındaki temel fark LRA'da yordanan deęiřkenin ayırma analizinde olduęu gibi eřit aralıklı lek dzeyinde olmamasıdır (Hair ve ark., 2014).

LRA'ya iliřkin farklı bir zellik ise modelin kestirilmesi ve yordayıcı deęiřkenler ile yordanan deęiřken arasındaki iliřkinin belirlenmesinde lojistik iliřkinin dikkate alınmasıdır. Bu analizde baęımlı deęiřkenin dnřm LRA'ya uygun olarak yapılır. Bu dnřm hem kestirim srecini etkiler hem de yordayıcı deęiřkenler iin katsayı deęerlerini etkilemektedir. Bu bakımdan LRA'da model uyumunun belirlenmesi srecinde ayırma analizinde kullanılan istatistiklerden yararlanılır (Hair ve ark., 2014).

LRA'nın sınıflandırılması. Lojistik regresyon analizinde logit dnřmn uygulandıęı baęımlı deęiřkenin nitelięi önemlidir. LRA baęımlı deęiřkenin nitelięine gre e ayrılır. Bu modellerden 'İki kategorili (binary) LRA', kategorik baęımlı deęiřkenin ikili (rn: Bařarı durumu; bařarılı-bařarısız) biiminde olduęu durumda kullanılmaktadır. 'ok kategorili (Multinomial) LRA kategorik baęımlı deęiřkenin ok kategorili (rn: Bařarı durumu; dřk-orta-yksek) biiminde olduęu durumlarda kullanılırken; ok kategorili ve sıralı bir yapı sz konusu ise (rn: Likert

tipi ölçeklerde; hiç katılmıyorum, katılmıyorum, kararsızım, katılıyorum, tamamen katılıyorum) ‘Sıralı (Ordinal) LRA kullanılır (Park, 2013).

LRA’da bağımlı değişkenin dönüştürülmesi. Lojistik regresyon analizinde bağımlı değişkenin 0-1 arasında değer aldığı lojistik bir eğri vardır. Bu eğri ile yordayıcı değişkenlerle yordanan değişken arasındaki ilişki görsel olarak sunulmaktadır. Bu grafikte yatay eksen bağımsız değişkenin düzeyi, dikey eksen ise olayın gerçekleşme ihtimali vardır (Hair ve ark., 2014).



Şekil 5. LR’de bağımlı ve bağımsız değişken ilişkisi (Hair vd., 2014)

Lojistik regresyonda gerçek veriler, S eğrisine yerleştirilir. Eğer gerçek verilerde X bağımsız değişkeninin yüksek değerleri için istenen durumun olasılık değeri 1’e yaklaşıyorsa, düşük değerler için istenen durumun olasılık değeri 0’a yaklaşıyorsa model veri uyumu sağlanmış olur. Aksi durumda model veri uyumu sağlanmaz (Hair ve ark., 2014).

LRA’nın varsayım ve gereklilikleri. LRA’nın avantajlarının yanı sıra gerekli bazı varsayımları da vardır. LRA bağımsız değişkenlerin dağılımına ilişkin herhangi bir varsayımın sağlanmasını zorunlu kılmaz. Ancak LRA uygulaması ile ilgili bazı varsayım ve gereklilikler vardır (Hosmer ve Lemeshow, 2000).

Verilerdeki kayıp ve uç değerler LRA’nın bir varsayımı olmasa da, kayıp ve uç değerlerin sonuçları olumsuz etkilemesinden dolayı analiz öncesinde önlem alınması gerekir. Veri setinde uç değerlerin bulunmaması gereklidir. Çünkü LRA uç değerlere çok duyarlıdır. Uç değerler LRA’da bir deneğin, değişkenin farklı bir sınıfında bulunmasına neden olabilir. Bu durumun tespit edilmesinde standartlaştırılmış artıklar incelenmelidir. Bu standartlaştırılmış artıklar -3 ve +3

aralığında olmasına dikkat edilmelidir (Çokluk, Şekercioğlu ve Büyüköztürk, 2018). Uç değerlerin önlenmesi için veri girişinde uç değerleri almama veya uç değerleri çıkarma gibi işlemler yapılmalıdır. Ayrıca kayıp değerlerin incelenmesinde tüm kategorik değişken çiftleri için tüm hücrelerde beklenen frekans 1'den büyük olmalı ve beklenen frekansın 5'ten küçük olduğu gözenek sayısının %20'yi geçmemesine dikkat edilmelidir (Tabachnick ve Fidell, 2007).

LRA'da katsayı tahmininde en çok olabilirlik yöntemi kullanıldığı için denek sayısının az olmamasına dikkat edilmelidir. Bunun nedeni denek sayısının az olmasının modelin güvenilirliğini düşürmesidir. Bu nedenle modelin güvenilirliğinin artırılmasının denek sayısına bağlı olduğu düşünülebilir (Çokluk ve ark., 2018).

LRA bağımsız değişkenler ile bağımlı değişkenin logit değeri arasında doğrusal ilişki olduğunu varsaymaktadır. Bu varsayım logit dönüşümü ve yordayıcılar arasındaki anlamlı bir ilişkinin olup olmadığı incelenerek test edilebilir.

Hataların bağımsızlığı doğrusal regresyon analizinde olduğu gibi LRA'nın da varsayımlarındandır. Bu durum veriye yönelik örneklerin farklı olmasını gerektirmektedir. Mesela aynı gruptan farklı zamanlarda elde edilen ölçümler LRA'da kullanılamaz. Bu tür verilerin kullanılması durumunda veriler ortalama etrafında aşırı yayılım göstereceğinden hataların bağımlı olmasına neden olacaktır. (Field, 2009).

LRA'da birçok istatistiksel yöntemin gerektirdiği varsayımların zorunluluğu yoktur. Ancak, LRA yordayıcı değişkenler arasındaki yüksek korelasyona oldukça duyarlı olduğundan değişkenler arasında çoklu doğrusal bağlantı sorunu meydana gelmektedir. Çoklu doğrusal bağlantı, değişkenler arasındaki korelasyonların 0,90'dan büyük olması durumunda ortaya çıkmaktadır (Tabachnick ve Fidell, 2007). LRA'da öncelikle değişkenler arası çoklu bağlantı sorununun test edilmesi gerekmektedir. Bu soruna dikkat edilmemesi, yanlış ve sapmalı sonuçlara neden olacaktır (Kayri ve Okut, 2008).

LRA'da model seçimi. Model oluşturma işleminin amacı modelde bulunması gereken önemli değişkenlerin tespit edilmesidir. Yordanan değişkenin varyansını açıklamada önemli artış sağlayan yordayıcı değişkenleri tespit etmek için çeşitli yöntemler vardır. Değişken seçimi üç ya da daha fazla yordayıcı değişken olduğunda dikkate alınmalıdır (Kalaycı, 2009). Yordayıcı değişkenlerden

hangisinin modele alınacağını belirlemek, modelin oluşturulmasında çok büyük öneme sahiptir. Yordayıcı değişken sayısının fazla olduğu durumda oluşturulacak model sayısının da fazla olması beklenmektedir. İdeal olan araştırma, yordayıcı değişkenlerin önceki araştırma sonuçlarına göre modele eklendiği araştırmadır.

LRA'da önce kullanılacak yöntem belirlenmelidir. LRA, enter ve adımsal olmak üzere iki temel yöntemle uygulanmaktadır. Enter yönteminde tüm ortak değişkenler (covariates) bir blok olarak regresyon modelinde bulunur ve her bir blok için parametre kestirimleri hesaplanır. Bazı araştırmacılar 'enter' yönteminin sadece teori test etmede uygun olduğunu düşünmektedirler. Bunun nedeni, adımsal (stepwise) yöntemin verilerdeki tesadüfî değişkenlikten etkilenmesi ve modelin aynı örnekleme tekrar uygulanması durumunda bile, çoğunlukla farklı sonuçlar vermesidir. Eğer bir yordayıcı değişkenin diğerinden daha önemli olduğu düşünülmüyorsa 'enter' yönteminin uygulanmasının uygun olduğu düşünülebilir. Keşfedici araştırma yapıldığında ise en uygun yöntemin adımsal olduğu düşünülebilir (Field, 2009).

Adımsal yöntemler ileriye doğru (forward) ve geriye doğru (backward) olmak üzere ikiye ayrılır. İleriye doğru yöntemlerde analize önce sadece sabit terim dâhil edilerek başlanır. Sonra belirli kritere göre modele değişkenler teker teker seçilir. Burada bahsedilen kriter, puan istatistikleridir. En anlamlı puan istatistiğine sahip olan yordayıcı değişken öncelikle modele alınır. Bu süreç, anlamlı puan istatistiği olan yordayıcı değişken tükenene kadar devam eder. Burada eşik değer olarak $\alpha=0.05$ alınır. Her bir adımda analizden atılması gereken değişken olup olmadığına bakılır. Bu durum üç yöntemle belirlenir (Field, 2009).

İlk yöntem olarak olabilirlik oran (likelihood ratio) istatistiği kullanılır. Bu yöntemle ileriye doğru analizde mevcut model, yordayıcı değişkenin dışarıda bırakıldığı model ile karşılaştırılır. Eğer yordayıcı değişkenin çıkarılması gözlenen verilerin model uyumunda anlamlı farka neden oluyorsa, bu yordayıcı değişken modelde tutulur. Çünkü bu değişken modele alındığında, modelin uyumu iyileşmektedir. Ancak, yordayıcı değişkenin çıkarılması modelde çok küçük farklara neden oluyorsa bu değişken çıkarılır (Field, 2009).

Yordayıcı değişkenlerin modelde bulunup bulunmayacağına karar vermede kullanılan diğer yöntem ise koşul istatistiğidir. Bu yöntemde durum indeksi ile ileriye

doğru analiz de denir. Bu yöntem aritmetik olarak olabilirlik oran istatistiğinin daha az duyarlı olanıdır. Bundan dolayı olabilirlik oran istatistiğine göre kullanımı çok fazla tavsiye edilmez (Field, 2009).

Üçüncü yöntem ise Wald istatistiğidir. Wald istatistiği, LRA'da β_j katsayısının anlamlılık testinde kullanılan test istatistiğidir. Wald istatistiği ile ileriye doğru analiz yöntemi her bir yordayıcı değişken için lojistik regresyon katsayısının anlamlılığını test etmede yaygın olarak kullanılır. Yani bu yöntemle, herhangi bir logit katsayısının sıfıra eşit olduğu şeklindeki null hipotezi test edilir. Araştırmacılar yordayıcı değişkenleri, Wald istatistiği tarafından belirlenen etkilerinin anlamlı olup olmamasına göre modelden çıkartabilirler. Wald istatistiğinde 0.05 anlam düzeyine ulaşamayan hiçbir yordayıcı değişken analize alınmaz.

Eğim parametresinin en yüksek ihtimal tahmincisinin, standart hatasının tahmini değerine oranı Wald istatistiğini verir. Bu oranın test istatistiğinin (W) dağılımı $\beta_j = 0$ hipotezinin testinde standart normal dağılıma uygundur.

$$W = \frac{\hat{\beta}_j}{SE(\hat{\beta}_j)}$$

Wald testi, standardize edilmemiş bir lojistik katsayının, kendi standart hatasına oranının karesini alarak farklı bir yaklaşımla da yapılabilmektedir. Bu durumda normal dağılım gösteren bir rastgele değişkenin karesinin alınmasıyla Wald istatistiği 1 serbestlik dereceli ki-kare dağılımı göstereceğinden Wald istatistiği aşağıdaki gibi ifade edilir.

$$W^2 = \left(\frac{\hat{\beta}_j}{SE(\hat{\beta}_j)} \right)^2 \sim \chi^2$$

Wald istatistiği, örneklem hacminin büyük olması durumunda daha iyi sonuçlar vermektedir. Bu nedenle de bazı araştırmacıların, Wald istatistiğinin kullanımı ile ilgili endişeleri vardır. Agresti (1996), küçük örneklerde Wald istatistiği yerine olabilirlik oran istatistiğinin kullanımının daha uygun olduğunu ifade ederken; Menard (1995), büyük katsayılarda standart hatanın artması Wald istatistiği değerini azalttığını ifade etmiştir. Ayrıca, Field (2009) da söz konusu yöntemler içerisinde olabilirlik oran istatistiğinin en iyi değişken çıkarma kriteri

olduğunu, çünkü Wald istatistiğinin zaman zaman güvenilir olmayan sonuçlar ortaya koyduğunu ifade etmiştir.

İleriye doğru yöntemlerin tersi, geriye doğru yöntemlerdir. Bu yöntemler de aynı değişken eleme ölçütlerini kullanırlar; ancak ileriye doğru yöntemlerde olduğu gibi modele önce sadece sabit terimi alarak başlamak yerine, tüm yordayıcı değişkenleri alarak başlarlar. Sonra modelin gelişmesine ya da iyileşmesine katkılarına göre yordayıcı değişkenlerin modelde tutulmasına ya da çıkarılmasına karar verilir. Modelin iyileşmesine en az katkıda bulunan yordayıcı değişken ilk önce çıkarılır ve işlem bu şekilde devam eder (Field, 2009).

Doğrusal regresyon analizinde olduğu gibi, LRA'da da model seçiminde dikkat edilecek önemli noktalar vardır. Öncelikle model seçiminde yapılan çalışmanın teori test etme amaçlı doğrulayıcı mı, yoksa keşfetme amaçlı açımlayıcı bir çalışma mı olduğudur. Buna ek olarak adımsal yöntemin LRA'da kullanılmasına karar verilirse, geriye doğru aşamalı yöntemin kullanılması gerekmektedir. Bunun ana nedeni baskılama (supressor) etkisidir. Baskılama etkisi, bir yordayıcı değişkenin etkisinin sadece diğer bir yordayıcı değişken sabit tutulduğunda anlamlı olması durumudur. Bu nedenle ileriye doğru aşamalı yöntemin, geriye doğru aşamalı yöntemle kıyasla baskılama etkisi altında olan yordayıcı değişkenleri eleme ihtimalinin daha yüksek olmasıdır. Bundan dolayı ileriye doğru aşamalı yöntemin II. tip hata riski daha fazladır. Aşamalı yöntemlerde kullanılacak test istatistiklerinden en iyi olan yöntem ise olabilirlik oran istatistiğidir. Çünkü Wald istatistiği, bazı durumlarda hatalı sonuçlar verebilmektedir (Field, 2009).

LRA'da girdi değişkenlerin tahmin edici önemi. Araştırmacılar, çoklu doğrusal regresyonda olduğu gibi, lojistik regresyon modelinde de tahmin edicilerin görece önemini belirlemekle ilgilenebilirler. Örneğin, "kalp krizine neden olan tahmin edicilerin hangisi en önemli veya en iyi tahmin edicidir?" gibi bir soruda "en önemli" veya "en iyi" vurgu ifadeleri her bir tahmin edicinin görece önem ölçüsüne dikkat çekmektedir. Lojistik regresyon yönteminde yordayıcı karşılaştırmaları üzerine var olan literatür, genellikle tahmin edici önemi yerine, model seçiminde hangi yordayıcıların modelden çıkarılacağı, hangilerinin modelde tutulacağı ve modele seçilen değişkenlerin sıralanması ile ilgilenir.

Menard (2004a, 2004b), LR için standartlaştırılmış regresyon katsayılarını hesaplamak için çeşitli yöntemleri tartışmıştır, ancak bu yöntemler tahmin edici önemini belirlemek için, doğrusal regresyon literatüründe belirtilen nedenlerle aynı nedenlerden dolayı sorunludur. Çünkü belirli bir standartlaştırılmış regresyon katsayısı β_j , diğer tüm tahmin ediciler sabit tutulması şartıyla bağımsız değişkendeki bir birimlik artışın bağımlı değişkende meydana getirdiği artış veya azalış miktarını gösterir. Bu artış veya azalış bağımlı değişkendeki standartlaştırılmış değişiklik olarak yorumlanabilir. Bu da araştırmacılar tarafından istenen göreceli önemin amaçlanan anlamını her zaman vermez. Tahmin ediciler birbirleriyle ilişkili olduğu durumda, bir tahmin edici değişirken diğer tüm tahmin edicileri sabit tutma uygulaması tamamen sorunludur. Ayrıca, iki tahmin edicinin birbiriyle yüksek düzeyde ilişkili olduğu ancak bir modeldeki diğer tahmin edicilerle yüksek düzeyde ilişkili olmadığı bir durum düşünüldüğünde bu iki tahmin edicinin birbiriyle bağlantılı olması nedeniyle standartlaştırılmış regresyon katsayıları nispeten küçük ve anlamsız olacaktır. Çünkü bu tahmin edicilerden birinin etkisi hesaplandığında diğeri artık sonuç üzerinde herhangi bir etki göstermez. Bu, araştırmacının hatalı bir şekilde bu tahmin edicilerden hiçbirinin önemli olmadığı sonucuna varmasına neden olabilir, ancak bu tahmin edicilerden herhangi biri, tek tek veya modeldeki diğer tahmin edici alt kümeleriyle birlikte düşünüldüğünde sonucu etkilemede önemli olabilir. Bu nedenle, standartlaştırılmış katsayılar, diğer tüm tahmin edicilerin etkilerini hesaba kattıktan sonra belirli bir tahmin edicinin etkisine odaklanırken, tüm alt küme modellerini inceleyen yöntemler, tahmin edicinin etkisinin daha kapsamlı bir resmini sunar. Menard (2004a), standartlaştırılmış katsayılar, tahmin edicilerin göreceli etkisini belirlemek için kullanılabilir de, daha karmaşık prosedürlerin, tahmin edicilerin göreceli önemi belirlemedeki önemini vurgulamıştır. Baskınlık analizinde bu karmaşık prosedürler, tipik olarak, tüm alt küme modellerinin incelenmesini içerir.

Başlangıçta baskınlık analizi sıradan en küçük kareler regresyonları için geliştirildi (Budescu, 1993), ancak şu anda lojistik regresyon modelleri (Azen ve Traxel, 2009) ve hiyerarşik doğrusal modellerle (Luo ve Azen, 2013) kullanılabilir. Bu yöntem, bir regresyon analizinde tahmin edicilerin göreceli önemini belirlemek için kullanılır. Burada bahsedilen önem, yordayıcı çiftleri arasında niteliksel bir karşılaştırma olarak tanımlanır (Budescu, 1993). Bununla

birlikte, bir tahmin edici tüm olası alt küme modellerinde (yani, tüm olası tahmin kombinasyonları) bağımlı değişkenin tahminine daha fazla katkı sağlıyorsa, bu tahmin edici diğerinden daha önemlidir (Azen ve Budescu, 2003). Yine de, önemin analizde ele alınan tahmin edicilere bağlı olduğu vurgulanmaktadır. Baskınlık analizinde, bir tahmin edicinin herhangi bir olası alt küme modeline (hiçbir tahmin ediciyi içermeyen) ek katkısı diğer tahmin ediciden daha büyükse, bu tahmin edicinin diğerine tamamen baskın olduğu söylenir (Azen ve Traxel, 2009). Ancak, baskınlık düzeyi belirlenemezse, tahmin edicinin her bir model boyutundaki ortalama ek katkısı diğer tahmin ediciden daha büyükse, birincinin ikincisine koşullu olarak baskın olduğunu söyleyebiliriz. Sıradan en küçük kareler regresyonları için, tahmin edicilerin belirli bir alt küme modeline ek katkısı, tahmin edici modele eklendiğinde R^2 'deki değişiklik olarak tanımlanır. Lojistik regresyon uygulamalarında, model uyum ölçüleri olarak çoklu regresyon analizindeki R^2 indeksine benzer indeksler vardır. Bunlar uyum (kalite) ölçümleri olan yalancı (Pseudo) R^2 olarak adlandırılır. Bu uyum ölçüleri McFadden (R_m^2), Cox ve Snell (R_{cs}^2), Nagelkerke (R_n^2) ve Estrella (R_e^2) olmak üzere dört tanedir. Bu ölçüler önemi daha fazla olan tahmin ediciyi belirlemek için kullanılır (Azen ve Traxel, 2009).

Veri Madenciliği Yöntemleri Sonuçlarının Değerlendirilmesi

Veri madenciliği araştırmasının başarılı olup olmadığı, kullanılan modelin doğru sınıflama performansı, öngörü performansı ve maliyet uygunluğu bakımından değerlendirilir (Köse, 2018). Veri madenciliği yöntemleri klasik istatistiksel yöntemlerdeki gibi betimleyici veya tahmin edici olmak üzere ikiye ayrılmaktadır. Betimleyici veri madenciliği, büyük veri setlerinde gizli olan örüntüleri keşfetmek ve doğru karar almak için genellikle birliktelik kuralları ve kümeleme yöntemlerini kullanmaktadır. Tahmin edici veri madenciliği, yeni bir veri kümesinin sınıfını tahmin etmede karar ağacı, yapay sinir ağları gibi yöntemleri kullanmaktadır (Mishra, Kumar ve Gupta, 2014). Farklı veri madenciliği yöntemlerinin performansını değerlendirmede farklı kriterler kullanılmaktadır.

Bu araştırmada kullanılan veri madenciliği yöntemlerinin veri seti ile hesaplanan sınıflama performansını tahmin etmede kullanılan en yaygın kriter sınıfı bilinmeyen örnekleri doğru sınıflandırma yüzdesidir. Doğru sınıflandırma yüzdesinin en önemli kriter olduğuna ilişkin yaygın görüş olsa da, sınıflandırıcının

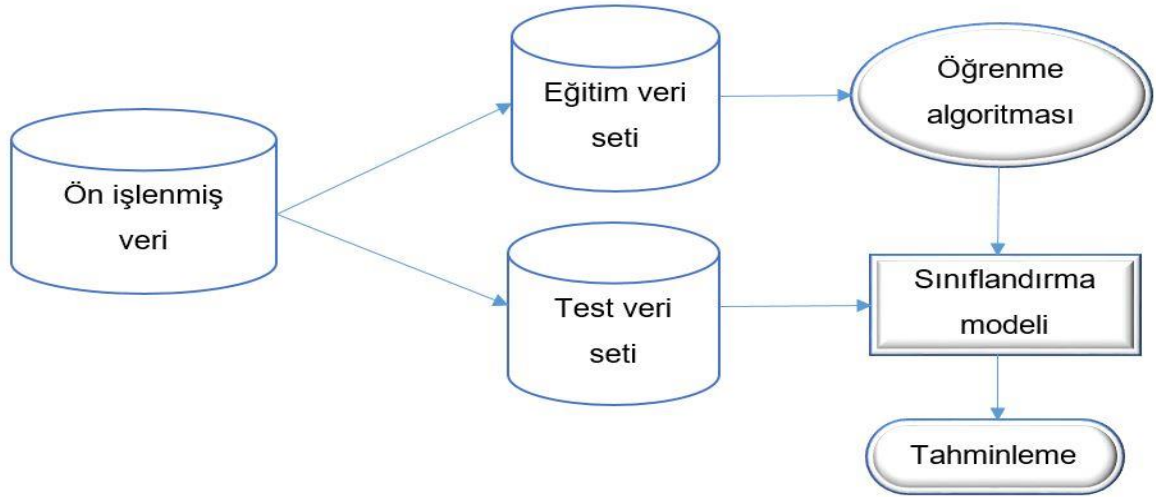
elde ettiđi sonuçları deęerlendirmede başka kriterlerde vardır (Bramer, 2013). Model deęerlendirilmesinde kullanılan yöntemler, Bekletme (hold out), K-katlı çapraz geçirme (k-fold cross validation), tekrarlı örnekleme (Bootstrap) ve Torbalama (Bagging) yöntemleridir.

Eđitim ve test verilerini ayırma. Veri madenciliđi yöntemlerinde kullanılacak veri seti ve nitelik vektörünün belirlenmesi sonrasında verilecek en önemli karar veri setinin ne kadarının eđitim verisi, ne kadarının test verisi olarak belirlenmesidir. Bu kararı vermede dikkat edilecek en önemli nokta, eđitim ve test verisinin problemi en iyi temsil edecek biçimde bilgi içermesidir. Ayrıca eđitim ve test verisi oransal olarak farklı olsalar da içerik olarak benzemeleri gerekmektedir. Bunun mümkün olması için, mevcut veri setini harmanlamanın yanı sıra eđitim ve test verilerini rastgele seçmektir (Köse, 2018).

Genellikle mevcut verinin 1/3'lük kısmı test, geri kalan 2/3'lük kısmı ise eđitim için kullanılır. Fakat gerekli olduđu durumda eđitim için kullanılan verinin bir kısmı doğrulama verisi olarak kullanılabilir (Ahmed ve Elaraby, 2014). Veri seti eđitim ve test verileri olarak ikiye ayrıldıktan sonra sınıflandırıcı olarak ifade edilen eđitim yöntemini oluşturmak için eđitim veri seti oluşturulur.

Daha sonra sınıflandırıcı test veri setindeki örneklerin sınıfını tahmin etmede kullanılır. Eđer veri setindeki N örneğin C tanesi doğru olarak sınıflanmış ise tahmin edilen doğru sınıflama yüzdesi $p = \frac{C}{N} \cdot 100$ olur. Bu formül sınıfı belli olmayan veriler için işe koşulan sınıflandırıcının performans kriterlerinden biri olan tahmin edilen doğru sınıflama yüzdesini verir. Eđitim ve test verilerini ayırarak yapılan çalışma bekletme (hold out) yöntemi olarak ifade edilir.

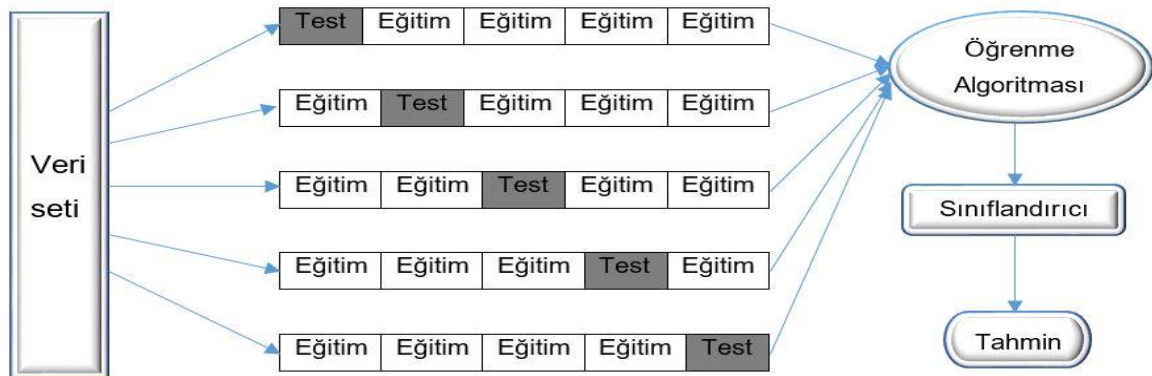
Eđitim ve test sürecinin çalışma biçimi Şekil 6'daki gibidir (Bramer, 2013).



Şekil 6. Eğitim ve test verisi ile öğrenme süreci

Çapraz geçerlik. Veri madenciliğinde kullanılan verinin sınırlı sayıda olduğu durumlarda bekletme (eğitim ve test) yaklaşımına alternatif olarak kullanabilen yaklaşım k-katlı çapraz geçeryleme yaklaşımıdır. Veri seti toplamda N örnekten oluşursa bu örnekler k eşit parçaya bölünür. Burada k adet 5 veya 10 gibi değerler alabilir. (Eğer N değeri k sayısına tam olarak bölünemiyorsa ayrılan en son gruptaki örnek sayısı kalan diğer k-1 grubun her birinde bulunan örnek sayısından az olacaktır). Çapraz geçeryleme süreci k tane analiz in ardışık olarak meydana gelmesi şeklinde olacaktır. Analiz sürecinde art arda k grubun her biri test veri seti, kalan diğer k-1 grup ise eğitim veri seti olarak kullanılır (Bramer, 2013).

Örnek olarak k=5 için 5 katlı çapraz geçeryleme sürecinde izlenen yol Şekil 7’de görsel olarak verilmiştir.




Şekil 7. Çapraz geçerylik süreci

Genellikle 10 katlı çapraz geçerleme yaklaşımını kullanma nedeni çeşitli öğrenme yöntemlerini kullanarak büyük veri setleriyle gerçekleştirilen kapsamlı analizlerde veriyi 10 gruba ayırmanın en iyi hata tahmini vermesinin teorik kanıtlarının olmasıdır. Çünkü 10 katlı çapraz geçerleme yaklaşımında oluşan 10 sınıfta elde edilen 10 farklı hata değerlerinin ortalaması alınıp genel bir hata değeri bulunur (Witten ve Frank, 2005). Elde edilen teorik kanıtlar kesin değil fakat 10 katlı çapraz geçerleme yaklaşımı uygulamada çoğunluk tarafından kullanılan standart bir yaklaşımdır. Yapılan deneysel çalışmalar sonucunda 10 katlı çapraz geçerlemeye ek olarak tabakalı örnekleme yaklaşımının da sonuçları bir miktar iyileştirdiği sonucuna varılmıştır (Vanwinckelen ve Blockeel, 2012).

Diğer yandan güvenilir bir hata kestirimi için 10 katlı ve tabakalı örnekleme dayalı çapraz geçerleme her zaman yeterli sonuçlar vermeyebilir. Aynı öğrenme algoritmasıyla ve aynı verilerle yapılan 10 katmanlı çapraz geçerleme çalışmaları katmanların kendisini seçme safhasındaki tesadüfî değişim etkisi nedeniyle farklı sonuçlar meydana getirebilmektedir. Tabakalı örnekleme yaklaşımı farklılaşmayı azaltır fakat tamamen ortadan kaldırdığı düşünülemez. Doğru bir hata kestirimi yapmak için 10 katlı çapraz geçerleme standart bir süreçtir. Bu 10 tabakalı çapraz geçerleme 10 farklı hatanın ortalamasını bulmayı sağlar (Kohavi, 1995).

Tekrarlı örnekleme (Bootstrap) yöntemi. Kestirim yöntemlerinden Bootstrap yöntemi örneklemin yer değiştirmesi olarak ifade edilen yöntemdir. Bootstrap yönteminde eğitim ya da test veri setinde kullanmak için veri setinden bir örnek alınır ve bu örnekleme alınan örneklerin üzeri çizilir. Yani seçilen örnek bir daha seçilmemektedir (Dekking, Kraaikamp, Lopuhaa ve Meester, 2005). Geleneksel örnekleme yaklaşımının yeni bir yaklaşımı olan Bootstrap yöntemi, performansı yüksek modellerin oluşturulmasına imkân sağlayan tekrarlı örnekleme yöntemidir (Boss, 2003).



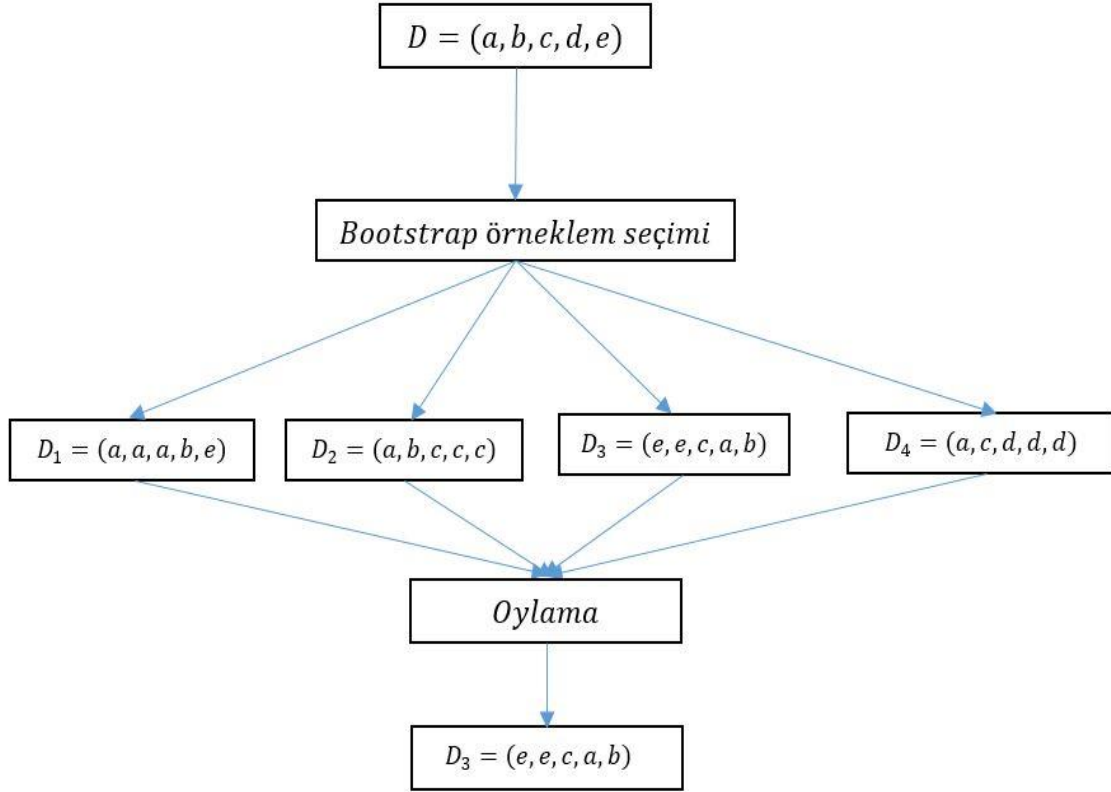
Şekil 8. Bootstrap yönteminde örnekleme aşamaları

Şekil 8'de görüldüğü gibi rastgele seçilen örnekleme bulunan örnekler her adımda yerleri değiştirilerek örnekleme tekrar alınmaktadır. Bootstrap yöntemi 4 aşamada uygulanmaktadır. İlk aşamada tüm veri setinde bulunan örneklerin yerleri değiştirilip rastgele bir örneklem seçilir. İkinci aşamada seçilen örneklem birimlerinden bazı istatistikler hesaplanır. Örneğin, örneklem ortalaması hesaplanır. Üçüncü aşamada ilk iki adımdaki uygulamalar Bootstrap dağılımını elde etmek için N kez tekrar edilir. Son aşamada ise elde edilen Bootstrap dağılımını ile standart hata ve güven aralığı gibi istatistikler hesaplanır (Galdi ve Tagliaferri, 2017).

Torbalama (Bagging) yöntemi. Bootstrap toplaması (bootstrap aggregating) ya da Torbalama (bagging) olarak ifade edilen yöntem Breiman tarafından 1996 yılında geliştirilmiştir. Bu yöntem istatistiksel öğrenme modelinin hata varyansını azaltmaktadır. Torbalama dayalı tahmin, bir tahmincinin birden fazla kombinasyonunu meydana getirerek toplu bir tahmin yapmada kullanan yöntemdir. Torbalama, sayısal bir değeri tahmin etmede tahminlerin ortalamasını alırken, bir sınıfı tahmin etmede oylamaya dayalı olarak tahmin yapar (Breiman, 1996). Torbalama yöntemi, öğrenme sürecini tamamlamış sınıflandırıcıların tahminlerini birleştirerek tek bir tahmine dönüştürerek tahminin doğruluğunu arttırmaktadır. Yeni bir örnekleme sınıflandırmak için, sınıflandırıcıların her biri sınıf tahminini oluşturur. Burada, torbalamadaki amaç, orijinal veriden oluşturulan tek bir model yerine performansı daha yüksek birleşik bir model oluşturmaktır.

Breiman tarafından 1996 yılında yayınlanan makalede, özellikle kararsız sınıflandırıcıların bulunduğu modellerde torbalamanın uygun bir yöntem olduğu ifade edilmektedir. Bunun nedeni torbalamanın sınıflandırıcıdaki kararsızlığı giderebilmesidir. Torbalama algoritmasını açık bir ifade etmek gerekirse; Bootstrap örnekleme ile eğitim veri setinden iadeli seçimle eşit oranda n tane denek içeren

örneklem oluşturulur. K adet bootstrap örnekleme D_1, D_2, \dots, D_K olarak oluşturulur. Daha sonra bootstrap örnekleme D_i için bir E_i sınıflandırıcısı üretilir. E_1, E_2, \dots, E_K sınıflandırıcılarının oy çokluğuna göre tahmin ettiği sınıf dikkate alındığında son sınıflandırıcı E^* olur (Bauer ve Kohavi, 1999).



Şekil 9. Bagging torbalama yöntemi

Performans Kriterleri

Doğru sınıflandırma yüzdesi. Model performansının değerlendirilmesinde en yaygın kullanılan yöntem, modelin doğru sınıflandırma yüzdesidir. Doğru sınıflandırma yüzdesi, bir sınıflayıcının yapmış olduğu sınıflamanın gerçekte olması gereken sınıflama ile karşılaştırılmasını sağlayan bir kriterdir (Köse, 2018).

Sınıflayıcının yaptığı sınıflama ile gerçekte bu sınıflama ile aynı sınıfta olan örnek sayısının, sınıflanan örneklerin tamamının sayısına oranının 100 ile çarpılması ile elde edilir. Yapılan sınıflama işlemindeki hata oranı ise 100'den doğru sınıflandırma yüzdesinin çıkarılması ile elde edilir.

Tablo 4

Karışıklık Tablosu

		Gerçek değer		
		Pozitif	Negatif	Toplam
Test Sonucu	Pozitif	DP	YP	DP+YP
	Negatif	YN	DN	YN+DN
	Toplam	DP+YN	YP+DN	DP+YP+YN+DN

Tabloda DP doğru pozitif, DN doğru negatif, YP yanlış pozitif, YN yanlış negatif durumların sayısını göstermektedir.

Doğru sınıflama yüzdesi (DSY) formülü;

$$DSY = \left(\frac{DP+DN}{DP+DN+YP+YN} \right) \cdot 100$$

Duyarlık. Doğru sınıflandırılmış pozitif örneklerin (DP) sayısının, toplam pozitif örneklerin sayısına (DP+YN) oranıdır. Testin gerçekte pozitif olan durumları pozitif olarak etiketleme performansdır. Yani kullanılan yöntemin gerçekte pozitif olan durumlar içinden pozitif durumları ayırma kapasitesidir.

$$\text{Duyarlık (Sensitivity)} = \frac{DP}{DP+YN}$$

Seçicilik. Testin gerçekte negatif olan durumları negatif olarak etiketleme performansdır. Yani kullanılan yöntemin gerçekte negatif olan durumlar içinden negatif durumları ayırma kapasitesidir.

$$\text{Seçicilik (Specifity)} = \frac{DN}{DN+YP}$$

Kappa istatistiği. Beklenen ve gözlenen değerlerin karşılaştırılmasıyla hesaplanan bir istatistiktir. Sınıflama sürecinde tesadüfi şans faktörünü dikkate aldığı için yanlılılık düzeyi düşük bir istatistiktir. Kappa istatistiği beklenen ve gözlenen değer dikkate alınarak karışıklık matrisi ile hesaplanmaktadır. Sınıflama sürecinde meydana gelecek hataları tolere edecek niteliktedir. Cohen'in Kappa katsayısına bağlı olan Kappa istatistiği, sınıflama algoritmalarının yapmış olduğu sınıflamaların doğru olup olmadığını saptamak için geliştirilmiştir (Ben-David, 2008). Kappa istatistiği 0-1 aralığında yorumlanmaktadır. Beklenen ve gözlenen değer arasındaki uyum 1'e doğru artarken, 0'a doğru düşmektedir. Kappa istatistiğinin aldığı değerlere göre yorumlanmasında kesin standart olmamakla

birlikte genellikle 0.00-0.20 arası düşük, 0.20-0.40 arası kayda değer, 0.40-0.60 arası orta düzey; 0.60-0.80 arası yüksek ve 0.80-1.00 arası çok yüksek olarak yorumlanmaktadır (Landis ve Koch, 1977). Kısacası, Kappa istatistiği veri setinde bulunan örneklerin beklenen ve gözlenen sınıflara ayrılma sürecinde şansla meydana gelen doğru sınıflama oranını düzeltmeye imkân sağlar.

$$\text{Kappa}(\kappa) = \frac{\text{Gözlenen doğruluk} - \text{Beklenen doğruluk}}{1 - \text{Beklenen doğruluk}}$$

Sayısal Tahmin için Performans Kriterleri

Hata kareler ortalamasının karekökü (HKOK). Bir veri madenciliği modelinde, tahmin edilen değerler ile gerçek değerler arasındaki uzaklığın bulunmasında kullanılan, meydana gelen hatanın miktarını belirleyen kriterdir. HKOK tahmin hatalarının kareli ortalaması olduğu için tahmin hatalarının standart sapmasıdır. Yani, HKOK artıkların regresyon hattı etrafında yayılma düzeyini veren ölçüdür. Başka bir deyişle, veriler için en uygun olan çizgi etrafında verilerin yoğunlaşma düzeyi hakkında bilgi verir.

Doğrusal regresyon gibi birçok veri madenciliği modelinde yaygın olarak kullanılan hatadır. Çünkü matematiksel anlamda müdahale edilmesi kolay olan bir performans kriteridir. HKOK değeri 0 ile ∞ aralığında değer almaktadır. HKOK değeri 0'a yakın olan modeller daha iyi performans gösterir. HKOK değeri 0'a ne kadar yakın ise modelin büyük hatalara yönelik toleranssız olma avantajı vardır.

$$HKOK = \sqrt{\frac{\sum_{i=1}^N (P_i - O_i)^2}{N}}$$

P_i tahmin edilen değerleri, O_i gözlenen değerleri göstermektedir.

Ortalama mutlak hata (OMH). Ortalama mutlak hata (OMH) gözlenen değer ile tahmin edilen değer arasındaki ortalama uzaklıktır. OMH kriterinin yorumlanması kolay olduğu için genellikle regresyonda ve zaman serisinde kullanılmaktadır. OMH değeri 0 ile ∞ aralığında değer almaktadır. OMH değeri 0'a yaklaştıkça kullanılan modelin performansı artar. OMH hesaplanırken hataların mutlak değeri alındığı için sadece hataların pozitif değerlerinin ortalaması alınmaktadır. HKOK uç değerlerden çok fazla etkilenirken OMH için bu durum geçerli değildir.

$$OMH = \frac{\sum_{i=1}^N |P_i - O_i|}{N}$$

P_i tahmin edilen değerleri, O_i gözlenen değerleri göstermektedir

HKOK ve OMH sifira yakın olması model performansının yüksek olması için istenen durumdur.

Görelî hata karelerinin karekökü (GHKK). Bağlı hatalar mutlak hatalara göre az da olsa farklı anlam taşımaktadır. GHKK, basit bir tahminleyicinin dikkate alınması ile göreceli olarak değişimi hesaplanmaktadır. Buradaki tahminleyici eğitim veri setinde bulunan gözlenen değerlerin ortalamasıdır. Böylece toplam kareli hata tahminleyicisi üretilen toplam kareli hataya bölünerek toplam kareli hata değeri normalleştirilip karekök alınarak GHKK değeri elde edilir.

$$GHKK = \sqrt{\frac{\sum_{j=1}^n (P_{ij} - O_j)^2}{\sum_{j=1}^n (O_j - \bar{O})^2}}$$

P_j ve P_{ij} tahmin edilen değerleri, O_j gözlenen değerleri \bar{O} ise gözlenen değerler ortalamasını göstermektedir.

Görelî mutlak hata (GMH). Görelî (Bağlı) mutlak hata GHKK'nın hesaplanması gibi normalleştirme yapılarak elde edilen mutlak hataların toplamıdır. Hem görelî hata karelerinin karekökü hem de görelî mutlak hata kriterinde hatalar, ortalama değerleri kestiren basit bir tahminleyici ile normalleştirilmektedir (Witten ve ark., 2016).

$$GMH = \frac{\sum_{j=1}^n |P_j - O_j|}{\sum_{j=1}^n |O_j - \bar{O}|}$$

P_i tahmin edilen değerleri, O_i gözlenen değerleri, \bar{O} ise gözlenen değerler ortalamasını göstermektedir.

Mutlak hatalar ile bağlı hatalar karşılaştırıldığında; bazen bağlı hata, mutlak hatadan daha anlamlı olmaktadır. Örneğin % 5'lik hata düzeyi, 1000 tahminden 50 tanesinin hatalı olması ile aynı anlamı taşımaktadır ve 4 tahminde %1'lik bir hata meydana gelirse mutlak hataların ortalaması bir anlam taşımayacak ve bağlı hataların dikkate alınması daha uygun olacaktır (Aksu, 2018).

Okuduğunu Anlama ile İlgili Araştırmalar

Lietz ve Kotte (2004) çalışmasında PISA 2000 verilerine göre okuduğunu anlama başarıları alanında birinci sırada olan Finlandiya ile OECD ortalamasının altında kalan Almanya'nın okuduğunu anlama başarısını etkileyen değişkenleri karşılaştırmışlardır. Araştırma kapsamında öğrenci ve okul düzeyindeki değişkenler kullanılarak Almanya'nın okuduğunu anlama başarısını artırmada yordayıcı değişkenlerin hangileri olduğu belirlenmeye çalışılmıştır. Araştırma bulgularına göre Almanya'daki okuduğunu anlama başarı puanlarından hesaplanan varyansın %46'sı öğrencilerden kaynaklı olduğu belirlenmiştir. Diğer bir bulgu ise Almanya'da savunulan tam gün okul saatlerinin akademik başarıyı arttırdığına yönelik görüşün desteklenmemesidir. Ayrıca okulların öğrenci başarısına yönelik beklentileri artıkça öğrencilerin okuduğunu anlama başarısının artacağı belirtilmiştir.

Kotte, Liez ve Lopez (2005) çalışmalarında PISA 2000 verilerini kullanarak, Almanya ve İspanya'daki öğrencilerin okuduğunu anlama başarılarını artıran ve azaltan değişkenleri araştırmışlardır. Özellikle bu ülkelerin okuduğunu anlama, matematik ve fen okuryazarlığı başarılarının OECD ortalamasının altında kalması nedeniyle bu iki ülke arasındaki benzerlik ve farklılıklar belirlenmeye çalışılmıştır. Verilerin analizinde yol analizi ve iki düzeyli aşamalı doğrusal modelleme yöntemi kullanılmıştır. Araştırma bulgularına göre Almanya'dan katılan öğrencilerin okuduğunu anlama başarılarını artıran öğrenci düzeyindeki değişkenler; sınıfın büyük olması, üst sınıf düzeyinde bulunma, okumaya ilgi duyma, ailenin sosyo-ekonomik düzeyinin yüksek olması, okula düzenli gelme, okul düzeyindeki değişkenler ise; akademik yönlendirme, yarı zamanlı çalışan Öğretmen sayısındaki artış ve kitap ve dergilere kolay erişim sağlama olarak saptanmıştır. İspanya için elde edilen bulgulara göre öğrencilerin okuduğunu anlama başarısını artıran değişkenler öğrenci düzeyinde; üst sınıf düzeyinde olma, ailenin sosyo-ekonomik düzeyinin yüksek olması, okumaya ilgili duyma olarak saptanmıştır. Okul düzeyinde ise; özel okula gitme, büyük okullarda öğrenim görme, okulun başarıya önem vermesi olarak belirlenmiştir. Ayrıca bu iki ülkenin okuduğunu anlama başarıları arasındaki farklılığa Almanya da okullar arası, İspanya da ise okul içi öğrenciler arası farklılık neden olmaktadır.

Nonoyama (2006) çalışmasında öğrencilerin okuduğunu anlama başarıları üzerinde okul kaynakları ve aile ile ilgili değişkenlerin etkilerini araştırmıştır. Araştırma kapsamında PISA 2000 ve PISA 2003 verileri kullanılarak, çok boyutlu analizlerle bağımsız değişkenlerin öğrencilerin okuduğunu anlama başarısına etkisi incelenmiştir. Araştırmadan elde edilen sonuçlara göre ailenin eğitim düzeyi, iş statüsü ve evdeki eğitimsel kaynakların öğrencinin okuduğunu anlama başarısını yordama da etkili olduğu saptanmıştır.

Maslowski, Scheerens ve Luyten (2007), PISA 2000 uygulamasına katılan OECD ülkelerinin öğrenci ve okul düzeyindeki verileri kullanarak, okul özerkliğinin öğrencinin okuduğunu anlama başarısı üzerindeki etkisini araştırmışlardır. Araştırma kapsamında birinci düzeyde öğrenciye ait özellikler, ikinci düzeyde okul özellikleri dikkate alınarak iki düzeyli aşamalı modelleme yöntemi kullanılmıştır. Araştırma bulgularına göre öğrencinin cinsiyetinin erkek olması, göçmen bir aileden gelmesi, anne ve babasının mesleki statülerinin düşük olması öğrencilerin okuduğunu anlama başarısını düşüren değişkenler oldukları saptanmıştır. Bunlara ek olarak; personel yönetimi konusunda özerk olan okulların, özerkliğe sahip olmayan okullara göre okuduğunu anlama başarı düzeyleri daha yüksek bulunmuştur. Ekonomik kaynaklar, öğrenci politikaları ve öğretim programı üzerinde özerkliği olan okullar ile bu özerkliği olmayan okullar arasında öğrenci başarıları açısından anlamlı fark bulunmamıştır.

Cromley (2009), PISA 2000, PISA 2003 ve PISA 2006 uygulamalarına katılan ülkelerin tamamındaki öğrencilerin okuduğunu anlama başarıları ile fen okuryazarlığı başarıları arasındaki ilişkiyi incelemiştir. PISA 2000 uygulama sonucuna göre Rusya, Sırbistan ve Yeni Zelanda'nın okuduğunu anlama ve fen okuryazarlığı başarıları arasındaki ilişki düzeyi en yüksek iken İspanya, Kore ve Danimarka'nın okuduğunu anlama ve fen okuryazarlığı başarıları arasındaki ilişki düzeyi en düşük bulunmuştur. PISA 2003 uygulama sonucuna göre Avusturya, Çek Cumhuriyeti ve Avustralya'nın okuduğunu anlama ve fen okuryazarlığı başarıları arasındaki ilişki düzeyi en yüksek iken İspanya, Rusya ve Litvanya'nın okuduğunu anlama ve fen okuryazarlığı başarıları arasındaki ilişki düzeyi orta olarak bulunmuştur. PISA 2006 uygulama sonucuna göre Lihtenştayn, Hollanda ve İsviçre'nin okuduğunu anlama ve fen okuryazarlığı başarıları arasındaki ilişki düzeyi en yüksek iken Kırgızistan, Azerbaycan, Meksika'nın okuduğunu anlama ve

fen okuryazarlığı başarısı arasındaki ilişki düzeyi Lihtenştayn, Hollanda ve İsviçre'nin ilişki düzeyine göre düşük olsa da yüksek düzeyde bulunmuştur.

Bradshaw, Ager, Burge ve Wheeler (2010), PISA 2009 İngiltere verileri üzerindeki çalışmalarında; okuduğunu anlama başarısı bakımından kız öğrencilerin erkek öğrencilerden daha başarılı olduğunu saptamışlardır. Sosyo-ekonomik düzeyi yüksek öğrencilerin okuduğunu anlama başarısının da yüksek olduğunu ve başarı düzeyi yüksek öğrencilerin sınıf iklimi bakımından memnunken Öğretmenleriyle iletişim kurma konusunda yetersiz oldukları belirlenmiştir.

Gürsakar (2012), PISA 2009 Türkiye verileri üzerinden okuduğunu anlama başarısı, fen ve matematik okuryazarlığı başarılarını etkileyen değişkenleri belirlemeyi amaçlayan bir çalışma yapmıştır. Çalışma çerçevesinde öğrencilerin fen ve matematik okuryazarlıkları ile okuduğunu anlama başarılarını etkileyen değişkenler belirlenmeye çalışılmıştır. Çalışma sonunda; cinsiyet değişkenine göre okuduğunu anlama ve fen okuryazarlığı başarısı bakımından kızların, matematikte ise erkeklerin başarılı olduğu sonucuna varılmıştır. PISA 2009 sınavına katılan öğrencilerin okula başlama yaşı arttıkça okuduğunu anlama başarıları azalmıştır. Buna ek olarak; öğrencilerin evde ve okulda bilgisayar kullanma süresi değişkenine göre bilgisayar kullanım süresi arttıkça okuduğunu anlama başarısının azaldığı sonucuna varılmıştır.

Yıldırım (2012) Hollanda, Kore ve Türkiye'den PISA 2009 uygulamasına katılan öğrencilerin okul ve öğrenci düzeyinde okuduğunu anlama başarılarını etkileyen değişkenleri belirledikten sonra, ülkeler arasındaki ortak olan değişkenleri saptamıştır. Çalışmada iki düzeyli aşamalı doğrusal modellemeden yararlanarak analiz yapılmıştır. Araştırmadan elde edilen bulgulara göre Hollanda, Kore ve Türkiye'den katılan öğrencilerin okuduğunu anlama başarı puanları bakımından okullar arası farklılık olduğu belirlenmiştir. Hollanda ve Türkiye arasındaki farkın çoğunluğu okullar arası, Hollanda ve Kore arasındaki fark ise öğrencilerden kaynaklandığı saptanmıştır. Hollanda, Kore ve Türkiye'de okuduğunu anlama başarısını öğrenci düzeyinde etkileyen değişkenler; okumaktan zevk alma, okuduğunu anlama ve hatırlama, özetleme stratejilerini kullanma frekansı, sosyo-ekonomik durum, ailesinin sosyal ve kültürel durumu olduğu belirlenmiştir. Hollanda, Kore ve Türkiye'de okul düzeyinde etkili olan değişkenler ise okulun sosyo-ekonomik ve kültürel durumu olarak belirlenmiştir.

Saatçiođlu (2014) PISA 2009 verileri üzerinde yaptıđı alıřmada đrencilerin, okuma becerileri alt testinde bulunan madde tr, metnin řekli ve metnin ltđ zihinsel sre dzeyi boyutları bakımından ele alınan maddelere ynelik performansları profil analizi tekniđi ile saptanarak, lkelerin madde trleri bakımından gl ve zayıf yanları belirlenmiřtir. Arařtırma kapsamında, Trkiye'den katılan đrencilerin aık ulu maddelerdeki performanslarının anlamlı dzeyde yksek, oktan semeli maddelerde ise anlamlı dzeyde dřk olduđu bulunmuřtur. Trkiye'den katılan đrencilerin okuduđunu anlama becerileri alt testindeki genel performansları dřk olmasına karřın madde trleri bakımından yapılan profil analizine gre Trkiye'nin aık ulu madde trnde lkeler arasındaki performans sırası 11'dir. Bununla birlikte, Trkiye'den katılan đrencilerin karma metin kategorisindeki okuduđunu anlama performansları beklenenden dřk olmasına karřın, gzlenen ve beklenen performans dzeyleri arasında anlamlı fark bulunmamıřtır. Ayrıca, Trkiye'den katılan đrencilerin okuduđunu anlama becerileri alt testindeki genel performanslarının dřk olmasına karřın madde trleri kapsamında yapılan profil analizine gre dřncelerini yansıtmaya ve deđerlendirme kategorisinde lkeler arasında performans sırası beřtir.

Urfalı Dadandı ve ark.,(2018) yaptıkları alıřmada PISA 2015 Trkiye verilerine gre sosyo-ekonomik faktrleri temsil eden deđerřkenler ile okuduđunu anlama bařarısı arasındaki iliřkiyi incelemiřlerdir. Arařtırma kapsamına PISA 2015 Trkiye rnekleminde yer alan 2501'i kız, 2462'si erkek olmak zere toplam 4963 đrenci alınmıřtır. Arařtırmanın bulgularına gre ebeveynlerinin mesleki stats, ailenin kltrel kaynakları ve evlerindeki BİT kaynakları PISA 2015 okuduđunu anlama bařarısını anlamlı dzeyde yordamaktadır. Diđer yandan ailenin mal varlıđı ve evdeki eđitimsel kaynaklar PISA 2015 okuduđunu anlama bařarısını yordama da anlamlı deđerildir. Bunlara ek olarak PISA 2015 okuduđunu anlama bařarısı anne ve baba eđitim dzeyi ile evlerindeki kitap sayılarına gre anlamlı dzeyde farklılařmaktadır.

Okuduđunu anlama ile ilgili olarak yapılan PISA arařtırmalarında korelasyon analizi, oklu regresyon analizi, lojistik regresyon analizi, profil analizi, yol analizi, iki dzeyli ařamalı dođrusal modelleme ve ok boyutlu analizler yapılmıřtır. Kullanılan yntemler veri madenciliđine dayanan yntemler deđer

istatistiksel yöntemlerdir. Bu arařtırmalarda ÷lkelerin okuduđunu anlama başarısını etkileyen deđiřkenlerin belirlenmesi ve karřılařtırılması amaçlanmıřtır.

PISA arařtırmalarından elde edilen bulgulara g÷re ÷đrencilerin okuduđunu anlama başarısını yordama da etkili olan deđiřkenlerin; cinsiyet, ÷đrencinin okumaya ilgisi ve tutumu, ailenin sosyo-ekonomik d÷zeyi, okulun imkânları, yerleřim yeri, okul y÷netim sistemi gibi deđiřkenler olduđu belirlenmiřtir.

Veri Madenciliđi ile İlgili Arařtırmalar

Abdous ve ark., (2012) yaptıkları çalıřmada veri madenciliđi yöntemleri ile ÷đrencilerin interaktif eđitim durumları ve final başarıları arasındaki iliřkiler incelenmeye çalıřılmıřtır. Çalıřmada ÷đrencilerin çevrimiçi ÷đrenme davranıřlarını ve derslerindeki başarı d÷zeylerini incelemek amacıyla regresyon ve veri madenciliđi yöntemlerini ieren karma bir yaklařım kullanılmıřtır. Bađımsız deđiřkenler olarak ÷đrencilerin dersle ilgili tartıřmalara katılma sıklıđı, oturum ama sıklıkları, ÷đretmenlerine sordukları soru sayısı, ÷đretmenlerine g÷nderdikleri mesaj sayısı dikkate alınırken bađımlı deđiřken olarak ÷đrencilerin final notları alınıp analiz edilmiřtir. SPSS Modeler programının kullanıldıđı çalıřmada ÷đretmene g÷nderilen mesaj sayısı ve ÷đrencilerin dersle ilgili tartıřmalara katılma sıklıđının final başarıları üzerinde önemli etkiye sahip olduđu belirlenmiřtir.

Kurt ve Erdem (2012) yaptıkları çalıřmada ÷đrencilerin başarılı ve başarısız olmasına neden olan fakt÷rlerin belirlenmesine y÷nelik profil analizi yapılarak başarısız ÷đrenciler iin ne gibi önlemler alınacađı belirlenmeye çalıřılmıřtır. ÷đrencilerin akademik başarılarını yordayan deđiřkenleri belirlemek iin sosyal, ekonomik, kiřisel ve barınmayla ilgili demografik özelliklerini ölçmek iin 38 maddelik Likert tipi ölek hazırlanmıřtır. ÷đrencilerin başarılarına yordayan deđiřkenleri belirlemek amacıyla SRA, CHAID, Neural Network, Apriori, K-Means algoritmaları uygulanarak kullanılan yöntemlerin performansları incelenmiřtir. Çalıřma sonunda veri madenciliđi yöntemlerinin performanslarının daha yüksek olduđu sonucuna varılmıřtır.

Yu ve ark.,(2012) yaptıkları arařtırmada, PISA 2006 uygulamasına katılan Amerikalı ve Kanadalı 10. sınıf ÷đrencileri arasından PISA fen okuryazarlıđı puanını yordamak iin fen dersine y÷nelik ÷đrenci g÷rüşleri, kaynaklara eriřim ve

kaynakları kullanma gibi bağımsız değişkenlerin belirlenmesi amaçlanmıştır. Araştırma, kapsamında veri madenciliği yaklaşımlarından karar ağacı ve lojistik regresyon yöntemi kullanılmıştır. Burada araştırmacıların çalışmalarını Amerika ve Kanada verileri üzerinde yapmalarının bir nedeni; Amerika'dan katılan öğrencilerin PISA başarısının OECD ülkelerinden katılan öğrencilerin başarısından önemli ölçüde düşük çıkması ve Kanada'dan katılan öğrencilerin PISA başarısının ilk sıralarda yer alması gösterilmiştir. Ayrıca diğer bir neden ise Amerika ve Kanada'nın eğitim sistemlerinin ve kültürlerinin benzer olması gösterilmiştir. Bu nedenlerden dolayı araştırma kapsamında Amerika ve Kanada'nın performans haritası incelenmiştir. Bu çalışmada yapılan incelemeden elde edilen bulgular ise fen dersinden keyif alma, eğitim kaynaklarını sıklıkla kullanma Kanadalı öğrencilerin PISA başarılarında önemli rol oynamıştır.

Yung, Hsu ve Rice (2012) yaptıkları çalışmada öğrencilerin öğrenme süreciyle ilgili kayıtları, demografik özellikleri ve dönem sonunda yapılan anketlerle 7539 öğrenciden elde edilen verilere dayanarak K-12 programının değerlendirilmesi amaçlanmıştır. Programın değerlendirilmesi veri madenciliği sınıflama ve tahmin algoritmaları ile yapılmıştır. Çalışmada öğrencilerin benzer özelliklerini saptamak için kümeleme analizi yapılmış ve öğrenci başarısı ile dersi veren öğretim elemanına yönelik memnuniyet düzeylerini yordamak için karar ağacı algoritması kullanılmıştır. Araştırma sonucunda programın değerlendirilmesi için veri madenciliğinin nasıl kullanılacağı gösterilmiştir. Buna ek olarak öğrenci başarısını yordamak için oluşturulan karar ağacına göre sırasıyla okul türü, cinsiyet ve yaş değişkenlerinin en iyi yordayıcılar olduğu saptanmıştır.

Akçapınar (2014) yaptığı çalışmada çevrimiçi öğrenme sürecindeki etkileşim verileri ile öğrencilerin akademik başarılarını veri madenciliği algoritmaları ile modellenmesi amaçlanmıştır. Öğrencilerden dersi bırakma eğilimi olanları ve dönem sonundaki olası başarısızlıkların önceden tahmin edilmesi bakımından önem teşkil eden çalışma 76 öğrencilik bir grup ile 14 haftalık bir zaman diliminde tamamlanmıştır. Araştırmaya göre etkileşim verileri ile akademik başarının iyi düzeyde yordanacağı saptanmıştır. CN2 kuralları ve kNN algoritmalarını kullanarak derste başarılı olan ve olmayan öğrencilerin %86'sı doğru olarak sınıflanmıştır. Öğrencilerin dönem sonu akademik başarılarının üçüncü haftada %74 oranında doğru olarak yordanabileceği belirlenmiştir.

Aksoy (2014) yaptığı arařtırmada, veri madencilięi algoritmalarını kullanarak öğrenme stili, sahip olunan zekâ alanı, kiřilik tipi, cinsiyet ve sınıf düzeyi deęiřkenleri ile öğrencilerin matematik alanında üstün yetenekli olup olmadıklarının yordamayı amaçlamıřtır. Üstün yetenekli öğrencileri tespit etmek için veri madencilięi tekniklerinden C5.0 karar ağaçları ve kümeleme algoritmaları kullanılmıřtır. Elde edilen sonuca göre matematik alanında üstün yetenekli olanlar ve olmayanlar arasında öğrenme stilleri bakımından anlamlı fark bulunmadığı saptanmıřtır. Buna ek olarak; Üstün yetenekli olan ve olmayanlar arasında zekâ alanları ve kiřilik tipi açısından anlamlı fark olduęu saptanmıřtır.

Bilen, Hotaman, Ařkın ve Büyüklü (2014) yaptıkları çalışmada İstanbul'dan 2011 yılı LYS sınavına katılan 42 lise türü, başarılarına göre kümelenmiř ve kümelere ayrışmada etkili olan test türlerini belirlemek amacıyla veri madencilięi yöntemlerinden karar ağacı ve kümeleme algoritmaları kullanılmıřtır. Çalışma grubunda bulunan okulların puan türlerinin her biri için başarı seviyelerini göre toplamda 5 kümeye ayrıldığı saptanmıřtır. Fen lisesi, Özel fen liseleri, Anadolu Öğretmen liseleri ve Anadolu liseleri tüm test türleri için en başarılı kümede bulunduęu saptanmıřtır. Ayrıca CHAID algoritmasına dayalı olarak oluřturulan karar ağacı modellerinde okulların kümelenmesinde hangi testlerin daha etkili olduęu saptanmıřtır.

Özarıslan (2014) yaptığı arařtırmada Temel Bilgi Teknolojileri dersi akademik başarılarını yordayan deęiřkenleri belirlemek için veri madencilięi sınıflama yöntemleri ve karar ağaçlarını kullanmıřtır. Çalışmada baęımlı deęiřken olarak Kırıkkale Üniversitesindeki birinci sınıf öğrencilerinin ENF-101 kodlu Temel Bilgi Teknolojileri Kullanımı dersinin yılsonu başarıları puanları kullanılmıřtır. Elde edilen sonuçlara göre %82,2'lik doęru sınıflama yüzdesi ile C4.5 algoritmasının, dięer algoritmalara göre daha başarılı olduęu belirlenmiřtir. Öğrenci başarısını yordayan deęiřkenlerin ise; eğitim türü, fakülte ya da yüksekokul öğrencisi olma durumu ve öğrenci yaşı olarak kaydedilmiřtir.

Kiray ve ark., (2015) yaptıkları arařtırmada, TIMSS 1999, PISA 2003, PISA 2006 uygulamalarına katılan Türk öğrencilerin matematik ve fen başarısını yordayan deęiřkenlerin önem sırasını belirlemiřlerdir. Arařtırmaya yordayıcı deęiřkenler olarak okuma ve problem çözme becerileri, biliřsel ve duyuřsal özellikler alınmıřtır. Analiz sürecinde karar ağaçları ve kümeleme algoritması

kullanılmıştır. Araştırma bulgularına göre öğrencilerin okuma ve problem çözme becerilerinin matematik ve fen başarısını etkileyen çok önemli değişkenler olduğu saptanmıştır. Ayrıca matematik başarısı fen başarısını, fen başarısı ise matematik başarısını etkilemektedir. Diğer yandan matematik ve fen başarısını etkileyen değişkenlerin eşit düzeyde öneme sahip oldukları saptanmıştır.

Jiang, Javaad ve Golab (2015) yaptıkları çalışmada mühendislik fakültesine yönelik hazırlık kurslarının 10 yıllık süre zarfında öğretime dâhil ettiği yaklaşık 250.000 öğrenciden oluşturulan veri seti ile kurs kalitesi etkileyen faktörler saptanmıştır. Veri madenciliği yöntemleri ile kurs kalitesini saptamak için beş farklı bileşene yönelik lojistik modeller oluşturulmuştur. Çalışmada en iyi yordayıcılardan biri sorulara verilen yanıt iken diğer yordayıcı ise kurs düzeyi olarak belirlenmiştir. Sonuç olarak kurslardaki eğitimin niteliğini artırmak için öğretmenlerin sorulara açık biçimde cevap vermeleri, öğrencileri değerlendirmede farklı değerlendirme yaklaşımlarını kullanmaları, tutumlarını ve görsel sunumlarını artırmaları gerekli görülmüştür.

Aksu ve Güzeller (2016) yaptıkları çalışmada öz yeterlik algısı, kaygı, çalışma disiplini, kursa karşı tutum, motivasyon değişkenlerinin matematik okuryazarlığı bakımından başarılı olanlar ile başarısız olanları sınıflama ve bu sınıflamada etkili olan değişkenlerin belirlenmesi amaçlanmıştır. Araştırma PISA 2012 uygulamasına Türkiye'den katılan 1391 öğrencinin verisi SPSS ve WEKA programları yardımıyla CHAID analizi ve J.48 karar ağacı algoritması kullanılmıştır. Elde edilen sonuçlara göre Türkiye örneklemini için öz yeterlik algısı, kursa karşı tutum ve çalışma disiplini değişkenleri başarılı öğrencilerle başarısız öğrencileri sınıflamada en etkili değişkenler olarak bulunmuştur. Ayrıca J.48 karar ağacı algoritması ile CHAID analiz yönteminden elde edilen sınıflama yüzleri çok yakın çıktığı için CHAID analizi veri madenciliğinde kullanılan karar ağacı algoritmalarına alternatif olarak düşünülebileceği sonucuna varılmıştır.

Abad ve Lopez (2017) yaptıkları çalışmada akademik başarıyla ilişkili değişkenleri belirlemek için yaşı 11-15 aralığında olan 18.935 öğrenciden toplanan veriler veri madenciliği algoritmaları ile analiz edilmiştir. Sınıflama yöntemlerinden J48 karar ağacı algoritmasının kullanıldığı çalışmada Meksika eyaletindeki okullardaki başarıyı yordayan değişkenler en önemli olandan başlamak üzere

önem sırası uyuşturucu kullanımı, okuma alışkanlığı, öz saygı ve evdeki eğitimsel kaynaklar olarak saptanmıştır.

Aksu (2019) yaptığı çalışmada; PISA 2015 sınav verilerini kullanarak veri madenciliği tahmin modelleri ile öğrencilerin matematik okuryazarlık başarılarını yordama da etkili olan değişkenlerin farklılık gösterip göstermediğini belirlemeyi amaçlamıştır. Bu amaç için farklı başarı düzeyine sahip altı ülke için öğrencilerin matematik okuryazarlık başarılarını yordayan önemli değişkenleri belirleyip incelenmiştir. Çalışma örneklemini Singapur, Japonya, Norveç, Amerika, Türkiye ve Dominik Cumhuriyetinden PISA 2015 sınavına katılan 34.565 öğrenci oluşturmaktadır. Analiz sürecinde WEKA ve MATLAB programı ile M5P algoritmasından ve yapay sinir ağlarından yararlanılmıştır. İnceleme sonucunda farklı başarı düzeyine sahip ülkelerin matematik okuryazarlığı başarısını yordama da önemli olan değişkenlerin farklılık gösterdiği saptanmıştır.

Abad ve ark., (2020) yaptıkları çalışmada ortaöğretimde okulun etkisi ile ilgili faktörleri belirlemeye çalışmışlardır. PISA 2015 İspanyol örnekleminde ikincil veri ile çok düzeyli (iki düzeyli) model ile yüksek ve düşük etkiye sahip okullar seçilmiştir. Daha sonra düşük ve yüksek etkiye sahip okulları seçmede yordama gücü yüksek değişkenleri belirlemek için karar ağaçları kullanılmıştır. Hiyerarşik lineer modeller okullar arası varyans puanlarını %10'dan büyük elde ederken karar ağaçları % 90'ın üzerinde tahmin performansı elde etmişlerdir.

Bezek Güre ve ark., (2020) yaptıkları araştırmada, Çok Katmanlı Algılayıcı Yapay Sinir Ağları ve Rastgele Orman veri madenciliği yöntemleri ile PISA 2015 uygulamasına Türkiye'den katılan öğrencilerin matematik okuryazarlık başarılarını yordayan değişkenleri belirlemiştir. Yapılan çalışmada sınıflama performansı en yüksek olan yöntemin bulguları matematik okuryazarlık başarısını yordayan değişkenleri belirlemek için dikkate alınmıştır. Analiz sürecine bağımlı değişken ve bu bağımlı değişken ile ilişkili olduğu düşünülen 25 bağımsız değişken için Türkiye'den 2257 kız ve 2165 erkek öğrencinin verileri alınmıştır. Analiz sonuçlarına göre performans kriterleri bakımından en küçük tahmin hatası Rastgele Orman yönteminden elde edilmiştir. Rastgele Orman yönteminden elde edilen yordayıcı değişkenlerin en önemli olandan en önemsiz doğru sırası; Kaygı, anne eğitim düzeyi, motivasyon düzeyi, epistemolojik inançlar, Öğretmenin ilgi düzeyi ve sınıfın disiplin iklimi biçimindedir.

Gamazo ve Abad (2020) yaptıkları arařtırmada, akademik performansla ilgili faktörleri belirlemek için veri madencilięi yöntemlerini kullanmışlardır. PISA 2018 uygulamasına katılan tüm ülkelerden 21903 adet okulun öğrenci ve Öğretmenlerine ait sosyo-ekonomik düzey, süreç ve dış deęişkenlerle ilgili veriler alınıp analizde kullanılmıştır. Öncelikle C4.5 karar ağacı ile öğrencilerin matematik, fen ve okuduęunu anlama başarılarını yordama da önemli olan deęişkenler belirlenmiştir. Daha sonra elde edilen önemli deęişkenlerle k-means kümeleme analizi yapılmıştır. Elde edilen bulgulara göre akademik başarıyı yordama da yüksek sosyo-ekonomik düzeye sahip ülkelerde bilişsel stratejiler ve başarı motivasyonu deęişkenleri etkili iken düşük sosyo-ekonomik düzeye sahip ülkelerde gayri safi yurtiçi hâsıla ve bireysel eğitim göstergeleri etkili olduęu belirlenmiştir.

Yue (2021), sonuca dayalı eğitime (OBE) tabi olan 3353 kolej öğrencisinin verileri üzerinde bir arařtırma yapmıştır. Öğrencilerin kolej İngilizce performansını tahmin etmek için veri madencilięi yöntemi kullanmıştır. Arařtırma kapsamında SPSS Modeler programında bulunan yapay sinir ağları algoritmasını kullanmıştır. Kullanılan algoritma ile elde edilen arařtırma bulgularına göre öğrencilerin İngilizce performansını yordayan deęişkenlerin önem sırası en yüksek olandan en düşük olana doğru cinsiyet, final sınav puanı, İngilizce sınıf ortalaması, ödevlerin ortalaması, derse katılım oranı şeklindedir.

Veri madencilięi ile ilgili arařtırmalarda yapay sinir ağları algoritması, çok katmanlı algılayıcı yapay sinir ağları, hiyerarşik lineer modeller, sınıflama ve regresyon ağacı yöntemi, rastgele orman yöntemi, C5.0, C4.5, J.48 gibi karar ağacı algoritmaları, CHAID algoritması, k-means kümeleme algoritması, CN2 kuralları ve kNN gibi veri madencilięi yöntemleri kullanılmıştır. Bu çalışmalarda WEKA, SPSS Modeler ve MATLAB yazılımları kullanılmıştır. Arařtırmalarda kullanılan veriler öğrencilerin PISA matematik, fen, okuduęunu anlama testinden elde edilen puanlar, demografik özellikler anketinden elde edilen ölçümler, interaktif eğitim verileri, LYS matematik, fen, Türkçe testinden elde edilen puanlar, akademik başarı puanları biçimindedir.

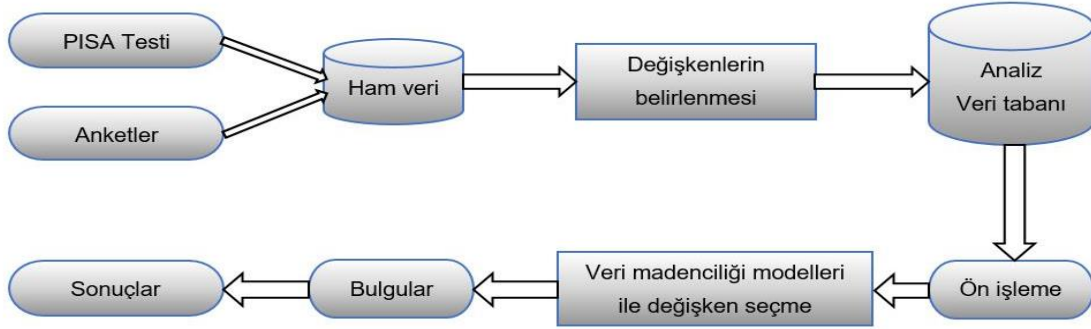
Yapılan arařtırmalar PISA verilerini kullanılarak veri madencilięi yöntemleri ile PISA başarısını yordayan önemli yordayıcıları belirlemeye yöneliktir. Ancak kullanılan veri madencilięi tahmin modelinin performansının ne olduęu dikkate alınmamaktadır. Böylece; performansı yeterince yüksek olmayan modeller

kullanılarak önemli deęişkenler belirlenebilmektedir. Yapılan alıřmalar başarı veya performansı yordayan deęişkenler üzerinde yoğunlaşmakta ancak bu alıřmalar birbirine benzer şekilde fen, matematik veya okuma puanını baęımlı deęişken kabul ederek sözü edilen üç alandaki başarıyı etkileyen faktörlerin açığa çıkarılmasına yöneliktir. Ancak bu alıřmalarda okuduęunu anlamamanın farklı başarı düzeyleri dikkate alınmamıştır. Oysaki okuduęunu anlama başarısını belirlemede farklı alt başarı gruplarında farklı deęişkenlerin etkili olabileceęinden dolayı bu iddiayı farklı başarı gruplarında alışılarak doęrulamak mümkündür. Başarıyı yordayan deęişkenleri saptamak için veri madencilięi kapsamında birçok yöntem kullanılabilir ancak kullanılan modelin performans düzeyi deęiřtięinde ve alışılan örnekleminin başarı düzeyi deęiřtięinde nasıl bir sonuçla karşılařıldığını görmek için belirli bir veri madencilięi kestirim teknięi ile elde edilen sonuçların karşılařtırılması yeterli olabilir. Bu alıřmada Lojistik Regresyon, Sınıflama ve Regresyon Aęacı ve Rastgele Orman yöntemlerini kullanarak hem belirlenen az sayıda daha önemli baęımsız deęişkenleri kullanarak performansı yüksek sınıflama modellerinin elde edilip edilmeyeceęinin gösterilmesi hem de farklı yöntemlerin farklı başarı düzeyinde seçtięi önemli deęişkenlerin belirlenip karşılařtırılması amaçlanmıştır.

Bölüm 3

Yöntem

Bu bölümde araştırma süreci, çalışma evreni ve örnekleme, araştırma türü, verilerin elde edilmesi ve verilerin analizine yer verilmiştir. Bu çalışmada izlenen sürece ilişkin aşamalar; görsel olarak şekil 10'da verilmiştir.



Şekil 10. Araştırma süreci

Araştırma kapsamındaki dokuz ülkenin 15 yaş grubundaki öğrencilerinin PISA uygulama anketindeki alt ölçeklere verdikleri yanıtlar ile PISA okuduğunu anlama başarı düzeylerini yordama da önemli değişkenlerin belirlenmesi ve kullanılan veri madenciliği yöntemlerinin sınıflama ve tahmin performanslarının ne düzeyde olduğunun belirlenmesi için Şekil 10'daki süreç izlenmiştir. Bu sürece göre öncelikle PISA öğrenci anketinden ve PISA okuduğunu anlama testinden ham veriler elde edildikten sonra bağımlı ve bağımsız değişkenler belirlenmiştir. Daha sonra analiz edilecek veriler ön işleme tabi tutulduktan sonra veri madenciliği yöntemleri ile analiz yapılmıştır. Analiz bulgularından elde edilen sonuçlara göre önerilerde bulunulmuştur.

Araştırmanın Türü

Araştırmada öğrencilerin duyuşsal özelliklerini ölçen ölçekler ve sosyo-demografik özelliklerini ölçen anketler kullanılarak; alt, orta, üst başarı grubundan seçilen ülke örneklemi, seçilen ülkelerin birleştirilmesiyle oluşturulan PISA çalışma örnekleme ve ayrıca Türkiye örnekleme için PISA okuduğunu anlama başarı düzeyini iki kategorili (başarısız-başarılı) ve üç kategorili (düşük başarı-orta başarı-yüksek başarı) olarak tahmin edebilen önemli değişkenlerin belirlenmesi doğrultusunda araştırmanın türleri nicel araştırma tasarımlarından tanımlayıcı

tasarım, karşılaştırmalı tanımlayıcı tasarım, ilişkiel tasarım olarak sıralanabilir (Büyüköztürk, Kılıç-Çakmak, Akgün, Karadeniz ve Demirel, 2018).

Çalışma Evreni ve Örneklemi

Çalışmanın amacı için ülkeler; PISA okuma puanı sıraları dikkate alınarak alt (zayıf), orta, üst (yüksek) başarı grubuna göre belirlendiği için amaçlı örnekleme yöntemi kullanılmıştır. Çünkü amaçlı örnekleme derinlemesine araştırma yapabilmek amacıyla çalışmanın amacı bağlamında bilgi açısından zengin durumların seçilmesidir (Büyüköztürk ve ark., 2018). Ayrıca, çalışma örneklemine ülkeler seçilirken kayıp veri oranının düşük olmasına ve farklı yüzdelerle dilimlere dağılacak şekilde örüntü oluşturmasına dikkat edilmiştir. Böylece çalışma grubunun sağlayacağı bilgilerin zenginleşmesi sağlanmıştır.

PISA 2018 uygulaması, 37'si OECD üyesi olmak üzere 79 ülkeden 612004 öğrencinin katılımıyla gerçekleştirilmiştir. PISA'ya katılacak okul ve öğrencilerin seçim işlemi, OECD tarafından iki aşamalı tabakalı tesadüfî yöntemle belirlenmektedir (MEB, 2019). Çalışma evrenini 2018 PISA'ya katılan ülkelerdeki 15 yaş grubu öğrencilerin tamamı oluşturmaktadır. Bu araştırmanın hedeflerine göre PISA 2018 sınavına katılan ülkelerin tamamından dokuz ülke çalışma örneklemi olarak seçilmiş ve seçilen bu çalışma örnekleminin 79 ülkeyi temsil edebilmesi hedeflenmiştir. Bu hedef doğrultusunda, dokuz ülke; 79 ülkenin başarı puanlarına göre yüzdelerle sıralamaları dikkate alınarak belirlenmiştir. Son üçte birlik %68 ile %100'lük başarı diliminden seçilen ülkelerin yüzdelerle sırası Endonezya için 91, Suudi Arabistan için 82 ve Kolombiya için 73'tür. Böylece; Endonezya, Suudi Arabistan ve Kolombiya ülkelerinden oluşan örneklem, son % 33'lük dilimdeki en başarısız ülkeleri temsil edecek şekilde alt başarı grubundaki ülkeler örneklemi olarak adlandırılmıştır. % 33 ile % 67'lik başarı diliminden seçilen ülkelerin yüzdelerle sırası ise; Sırbistan için 57, Türkiye için 50 ve Macaristan için 41'dir. Böylece; Sırbistan, Türkiye ve Macaristan'dan oluşan örneklem, % 33 ile % 67'lik dilim aralığındaki orta düzeyde başarılı ülkeleri temsil edecek şekilde orta başarı grubundaki ülkeler olarak adlandırılmıştır. Son olarak; ilk üçte birlik başarı sırasındaki dilimden seçilen ülkelerin yüzdelerle sırası ile Slovenya için 27, ABD için 16 ve Finlandiya için dokuzdur. Böylece; Slovenya, ABD ve Finlandiya örneklemi, ilk % 33'lük dilimdeki en başarılı ülkeleri temsil edecek şekilde üst başarı grubu

lkeler rneklemi olarak adlandırılmıřtır. Bu dokuz lkenin tamamı ise; PISA'nın uygulandıđı 79 lkeyi temsil edecek řekilde PISA alıřma rneklemi olarak adlandırılmıřtır. Bu durumda, alt bařarı grubu lkeler iin rneklem byklđ 25378, orta bařarı grubu lkeler iin rneklem byklđ 18523, st bařarı grubu lkeler iin rneklem byklđ 16567 olarak ortaya ıkmıřtır. Alt, orta ve st bařarı grubu olmak zere her bir grupta  lkenin bulunduđu dokuz lkenin birleřtirilmesi ile oluřturulan alıřma rneklemine sayı ise 60468'dir. Yzdelik dilimler belirlenirken Trkiye % 50. dilimde olduđu iin arařtırmada orta grupta yer almıřtır. Diđer yandan Trkiye'nin orta gruba seilen lkelerden biri olması nedeniyle arařtırma kapsamında bađımsız olarak incelenmesi uygun grlerek orta grup ve diđer gruplarla karřılařtırılması yapılmamıřtır. Trkiye iin aynı analizler 6859 kiři zerinden yrtlmřtr.

Verilerin Elde Edilmesi

Arařtırma srecinde kullanılan veriler 2020 yılında paylařıma aılan veri tabanından <http://www.oecd.org/pisa/data/2018database/> adresi kullanılarak elde edilmiřtir. Arařtırma kapsamına 2018 PISA verilerine ait toplamda 34 bađımsız ve okuduđunu anlama bařarı dzeyine karřılık gelen 10 makul deđerin ortalaması olan bir bađımlı deđerken alınmıřtır. Veriler incelendiđinde bađımlı deđerkene iliřkin kayıp veriye rastlanmamıřtır. Ancak, 34 bađımsız deđerkene iliřkin yanıt vermeyen bireyler analizden ıkarıldıktan sonra saptanan az sayıda u deđerler verilerden ıkarılmıřtır. Ayrıca tm bađımsız deđerkenlerin her birinde kayıp veriye rastlanmıřtır. Bu kayıp veriler tesadfi dađıldıđı iin oklu atama yntemi kullanılarak atama yapılmıřtır. oklu atama ynteminin temel mantıđı kayıp veriye iki veya ikiden ok kez atama yapma biimindedir. Kayıp verinin bulunduđu deđerkenin deđerlerinin dađılımına uygun bir model belirlenir ve bu modelin dađılımından rastgele deđerler seilerek atama iřlemi yapılır. Atama sayısı kadar sayıda tamamlanmıř veri setlerinden elde edilen sonuların ortalaması alınarak bir tahmin elde edilir. Atama srecinde kullanılan paket programlar birbirinden farklı modelleri kullanmaktadır. Ancak, gerek yařamdan elde edilen verileri kullanılan modele uyarlamak her zaman kolay deđerildir. Kullanılan atama modeli deđerkenlerin birbiriyle olan iliřki dzeyini yansıtacak nitelikte olmalıdır. oklu atama'nın birok uygulamasında, isabetli atamalar yapılmaktadır (He, 2006). Bu

çalışmada çoklu atama işlemi sürekli değişkenler için doğrusal regresyon modeline dayalı olarak beş kez atama yapılarak gerçekleştirilmiştir.

Veri Toplama Araçları

Araştırmada veriler 2018 yılında uygulanan PISA okuduğunu anlama sınavındaki test ve öğrenci anketinden elde edilmiştir. Kullanacağımız bağımlı değişkeni elde etmek için öncelikle okuduğunu anlama başarı puanı sürekli nicel değişken olarak elde edilmiş ve PVREAD olarak adlandırılmıştır. Burada PVREAD makul okuduğunu anlama başarı puanını ifade eder. PVREAD değişkeni PISA 2018 okuduğunu anlama başarı testinden her bir öğrencinin aldığı ve öğrencilerin sahip olabileceği yetenekler yelpazesini ifade eden (Wu ve Adams, 2002), 10 makul puan değerinin (PV1,PV2,...,PV10) ortalamasıdır. Daha sonra, PVREAD puanının sınıflandırılması sürecinde PISA 2018 Türkiye ön raporundaki, okuma becerileri yeterlilik düzeyi tablosundan yararlanılmıştır (MEB, 2019). MEB (2019)'un ön raporundaki bu tablodaki eşik değerler revize edilerek, PISA 2018 okuma becerileri yeterlilik düzey sayısı 8'den 6'ya indirgenecek şekilde, PISA 2018 okuduğunu anlama becerisi yeterlik düzeylerinin eşikleri ve kategori bilgileri elde edilmiştir (Tablo 5). Bu indirgeme PISA 2018 raporunda belirtilen 1. düzeydeki 1a, 1b, 1c düzeylerinin birleştirilip tek düzey olarak alınması ve düzey sayısının 6 olarak belirlenmesi işlemleriyle gerçekleştirilmiştir.

Tablo 5

PISA 2018 Okuduğunu Anlama Becerisi Yeterlik Düzeylerinin Kategorileri

Yeterlilik seviyeleri	Puan(x)
Düzen 1	$0 < X < 407$
Düzen 2	$407 < X < 480$
Düzen 3	$480 < X < 553$
Düzen 4	$553 < X < 626$
Düzen 5	$626 < X < 698$
Düzen 6	$698 < X < 1000$

Tablo 5'e göre iki kategorili başarı değişkeni; PVREAD değeri 0-552,999 arası başarısız ve 553-1000 arası başarılı olacak şekilde sınıflanarak elde edilmiştir. (0=Başarısız, 1=Başarılı). Benzer olarak; üç kategorili başarı değişkeni; PVREAD değeri 0-479,999 arası düşük başarı, 480-625,999 arası orta düzey

başarı ve 626-1000 arası yüksek başarı olacak şekilde sınıflanarak elde edilmiştir (1=Düşük, 2=Orta, 3=Yüksek).

Bu tez çalışmasında kullanılan 10 makul değerlerin ortalaması alınarak elde edilen bir bağımlı değişken ve PISA 2018 teknik raporundan elde edilen 34 bağımsız değişken Tablo 6'da verildiği gibi düzenlenmiştir.

Tablo 6

Bağımsız Değişkenler, Bağımlı Değişken ve PISA 2018 Kodları

Değişken Adı	Kodu	Değişken Adı	Kodu
İleri düzey görevlere motivasyon	WORKMAST	BİT kaynakları	ICTRES
Olumlu duygular	SWBP	Öğrenciden beklenen mesleki statü	BSMJ
Öz yeterlik	RESILIENCE	Ebeveynlerin duygusal desteği	EMOSUPS
Yaşamın anlamı	EUDMO	Test dili öğrenme süresi	LMINS
Öğretmenin okumaya teşviki	STIMREAD	Okula ait hissetme	BELONG
Öğrenci işbirliği	PERCOOP	Evdeki eğitim kaynakları	HEDRES
Okulun değeri	ATTLNACT	Öğretim adaptasyonu	ADAPTIVITY
Öğretmen Coşkusu	TEACHINT	Rekabete karşı tutumlar	COMPETE
Okuma keyfi	JOYREAD	Zorbaliğa maruz kalma	BEINGBULLIED
Anne eğitim düzeyi	MISCED	Başarısızlık korkusu	GFOFAİL
Baba eğitim düzeyi	FISCED	Öğrenme amaçları	MASTGOAL
Disiplin İklimi	DISCLIMA	Ailenin mal varlığı	WEALTH
Öğretmen desteği	TEACHSUP	Okuma yetkinlik algısı	SCREADCOMP
Evdeki eğitimsel eşyalar	HOMEPOS	Okuma zorluk algısı	SCREADDIFF
Öğretimin yönlendirilmesi	DIRINS	PISA testinin zorluk algısı	PISADIFFF
Sosyo-ekonomik durum indeksi	ESCS	Öğretmen geri bildirim	PERFEED
Öğrenci rekabeti	PERCOMP	Okuduğunu anlama başarısı	PVREAD
Ebeveynlerin en yüksek mesleki statüsü	HISEI		

Verilerin Analizi

Veriler analiz edilirken önce bağımsız olarak Türkiye verileri, sonra alt, orta ve üst başarı grubundaki ülkelerin verileri ve ardından da çalışma örnekleminin verileri analiz edilmiştir. Verilerin analizinde temel olarak ve sistematik bir biçimde sırası ile SPSS Modeller ve WEKA programları kullanılmıştır. Excel ve SPSS programları ise; SPSS Modeller ve WEKA programına veri aktarımı yapılırken ve bazı istatistikler hesaplanırken yardımcı programlar olarak kullanılmıştır. SPSS programında ayrıca, eksik verileri doldurmak için çoklu atama yöntemi

gerçekleştirilmiştir. Araştırma kapsamında Tablo 6'da verilen 34 değişken, bağımsız değişken olarak alınmış ve bağımlı değişkenler iki kategorili ve üç kategorili alınarak farklı uygulamalar gerçekleştirilmiştir.

Bağımlı değişkenin iki kategorili ve üç kategorili olduğu uygulamaların her birinde, başarıyı yordayan önemli değişkenlerin belirlenmesi için Lojistik Regresyon, Sınıflama ve Regresyon Ağacı ve Rastgele Orman veri madenciliği yöntemlerinin uygulaması SPSS Modeller programı aracılığı ile yapılmış ve elde edilen istatistiksel sonuçlar ayrıntılı bir şekilde karşılaştırılmıştır.

SPSS Modeller programında önemli değişkenler belirlenirken PISA verilerinin yapısı gereği ağırlık değişkeni kullanılması gerekmesi nedeniyle (Arıkan ve ark., 2020) veri setinde her bir öğrencinin ağırlığını gösteren W_FSTUWT (Final Trimmed Nonresponse Adjusted Student) ağırlık (Weight) değişkeni analize dâhil edilmiştir.

SPSS Modeller analizleri ile her bir veri madenciliği yöntemi için önemli değişkenler, ilgili veri madenciliği yönteminden elde edilen tahmin modelinin performansını en yüksek yapan değişkenler olarak adlandırılmıştır. Bu yaklaşım; bağımlı değişkeni etkileyen değişkenlerin t testi ve F testi gibi uygulamalı istatistik yöntemlerle belirlenmesinden farklı bir yaklaşım olup, bu tez çalışması kapsamında daha gerçekçi bir yöntem olduğu iddia edilmektedir. Burada dikkat edilmesi gereken husus, etkileyen değişken kavramıyla önemli değişken kavramının birbirinden farklı kavramlar olduğudur. Bağımlı değişkeni etkileyen bağımsız değişkenlerin belirlenmesi işi bir uygulamalı istatistik işi iken önemli değişkenlerin belirlenmesi işlemi bir veri madenciliği işidir. Veri madenciliği istatistik biliminin kendisi olmayıp, bilgisayar ve istatistik biliminin bir birleşimidir. Böylece, veri madenciliği istatistiksel yöntemleri makine öğrenmesi yaklaşımıyla kullanan algoritmalar olarak ortaya çıkmaktadır. Bundan dolayı, veri madenciliği yöntemlerinde önemli değişkenlerin belirlenmesi anlamlılık seviyesine (significant level) bakılarak değil, elde edilen tahmin modelinin performansına dayalı tahmin edici önemi (predictor importance) oranına dayanır. Bu çalışmada verilerin analizi sürecinde yordayıcılık önemi yüksek bağımsız değişkenlerin belirlenmesinde tahmin edici önemi (predictor importance) değerleri dikkate alınmıştır.

LR, SRA ve RO yöntemleri ile verilerin analiz edilmesi sürecinde, SPSS Modeler programını kullanarak her bir yöntem ile bu tez çalışmasının ana amacına uygun bir şekilde, 34 bağımsız değişken ve bağımlı değişken olarak iki ve üç kategorili başarı durumu değişkeni kullanılmıştır. Yapılan analizlerde her bir yöntemin hesapladığı tahmin edici önem (predictor importance) değerleri dikkate alınarak başarıyı en iyi yordayan ilk 10 değişken saptanmıştır. Daha sonra, iki ve üç kategorili başarı durumu için elde edilen önemli bağımsız değişkenler kullanılarak Weka programında; tüm veri, 10 katlı çapraz geçerlik verisi ve test verisi ile performans kriterleri hesaplanmıştır. Bu hesaplanan performans kriterlerinin 34 bağımsız değişken kullanıldığında hesaplanan performans kriterlerinden önemli düzeyde bir farklılığa sahip olmadığı belirlenmiş ve böylece başarıyı tahmin etmede, daha az sayıda değişken ile yüksek performansla sahip modeller kurulabildiği gösterilmiştir. Bu analizler, Türkiye, alt, orta, üst başarı grubu ülkeler ve çalışma örnekleme için iki düzeyli ve üç düzeyli bağımlı değişken kullanılarak yapılmış ve elde edilen sonuçlar ayrıntılı bir karşılaştırma yapılarak yorumlanmıştır. Analizler yapılırken, SPSS Modeler ve Weka programlarının amaçlarının birbirinden farklı programlar olduğu görülmüştür. SPSS Modeler programı, elde edilen basit bir tahmin modelinin performansını en yüksek yapan tahmin edicileri saptamaya yöneliktir. Weka programı ise; SPSS Modeler'in saptadığı bu tahmin edicileri (değişkenleri) kullanarak daha karmaşık yapıdaki en iyi tahmin modelini bulmayı ve böylece modelin başarı oranını artırmayı amaçlamaktadır. Son olarak sonuçları karşılaştırmada mutlak performans kriterleri; Doğru Sınıflama Yüzdesi (DSY), Hata Kareler Ortalamasının Karekökü (HKOK) ve Ortalama Mutlak Hata (OMH) ve bağımlı performans kriterleri ise; Kappa (κ) katsayısı, Göreli Hata Karelerinin Karekökü (GHKK) ve Göreli Mutlak Hata (GMH) (Tabachnick ve Fidel, 2007; Field, 2009) her bir veri madenciliği yöntemi için ayrı ayrı hesaplanmış ve yöntemlerin sonuçları birbirleri ile karşılaştırılmıştır.

Bölüm 4

Bulgular ve Yorumlar


Bu bölümde araştırma problemlerini çözümlmek için yapılan analizlerden elde edilen bulgular yer almaktadır. Bulgular alt problemler dikkate alınarak yorumlanmıştır.

Birinci Alt Probleme İlişkin Bulgular


PISA öğrenci anketinde ölçülen öğrenci özelliklerinden yararlanarak iki kategorili okuduğunu anlama başarısını tahmin etmede kullanılan Lojistik Regresyon (LR), Sınıflama ve Regresyon Ağacı (SRA), Rastgele Orman (RO) yöntemlerine göre Türkiye, üst, orta, alt başarı düzeyindeki ülkeler örnekleme ve çalışma örneklemindeki ülkelerin başarılarını etkileyen önemli değişkenler nelerdir?

Lojistik Regresyon Yöntemine İlişkin Bulgular


İki kategorili başarı durumu için LR uygulamasından, elde edilen önemli ilk 10 değişkene ilişkin tahmin edici önem yüzdeleri grafikleri Şekil 11’de verilmiştir.




1a. Türkiye




1b. Alt grup



1c. Orta grup



1d. Üst grup



1e. Çalışma örneklemi

Şekil 11. Okuduğunu anlama başarısının iki kategorili olduğu durumda LR modeli ile seçilen önemli 10 değişkene ilişkin grafikler

Şekil 11 incelendiğinde, alt grup ülkeler için başarıyı yordayan önemli değişkenlerin HISEI (ebeveynlerin en yüksek mesleki statüsü) ve ICTRES (bilgi iletişim teknolojileri kaynakları) olduğu görülmektedir. Bununla birlikte; orta grup ülkeler için PISADIFF (PISA testinin zorluk algısı) ve HISEI, üst grup ülkeler için PISADIFF ve JOYREAD (okuma keyfi) ve çalışma örnekleme için ise, HOMEPOS (evdeki eğitimsel eşyalar) ve PISADIFF değişkenleri ilk sıradaki en önemli başarı tahmin edicileri olarak ortaya çıkmaktadırlar. Şekil 11'deki grafiklere göre başarıyı yordayan birinci sıradaki önemli değişkenler; alt grup ülkeler örnekleme için HISEI, orta grup ülkeler ve üst grup ülkeler örneklemleri için PISADIFF ve çalışma örnekleme için HOMEPOS olarak elde edilmiştir. Burada, PISADIFF değişkeninin tüm örneklem grupları için önemli değişkenlerden biri olduğu dikkat çekmektedir.

Şekil 11'de LR yöntemi ile her bir grup örnekleme için seçilen PISA okuduğunu anlama başarısını yordayan önemli 10 bağımsız değişkenden “başarıyı % 5 ya da daha büyük oranda yordama” kriteri (predictor importance) dikkate alınarak 10'dan daha az sayıda “PISA okuduğunu anlama başarısını en iyi yordayan” olarak adlandırılan bağımsız değişkenler belirlenerek Tablo 7'de sunulmuştur. Tablo 7 incelendiğinde, her bir örneklem grubu için, önem sırası, LR katsayısının işareti tablo içinde belirtilmiş ve önemli ortak değişkenler aynı sırada yazılmıştır.

Tablo 7

Okuduğunu Anlama Başarısının İki Kategorili Olduğu Durumda LR Modeli ile Seçilen Önemli ve Ortak Değişkenler

Türkiye Örnekleme	Alt Grup Ülkeler Örnekleme	Orta Grup Ülkeler Örnekleme	Üst Grup Ülkeler Örnekleme	Çalışma Örnekleme
3.(-)PISADIFF	3.(-)PISADIFF	1.(-)PISADIFF	1.(-)PISADIFF	2.(-)PISADIFF
4.(+)HISEI	1.(+)HISEI	2.(+)HISEI	6.(+)HISEI	3.(+)HISEI
5.(+)HOMEPOS	6.(+)HOMEPOS	5.(+)HOMEPOS	3.(+)HOMEPOS	1.(+)HOMEPOS
1.(+)JOYREAD	8.(+)JOYREAD	3.(+)JOYREAD	2.(+)JOYREAD	-
2.(+)BSMJ	-	4.(+)BSMJ	4.(+)BSMJ	-
-	2.(+)ICTRES	6.(+)ICTRES	-	-
-	5.(+)MISCED	-	-	4.(+)MISCED
-	-	-	5.(+)SCREADCOMP	5.(+)SCREADCOMP
-	4.(+)FISCED	-	-	-
-	7.(-)SCREADIFF	-	-	-

-,+:Lojistik regresyon modelindeki beta katsayısının işareti, 1.2.3, önemli değişkenlerin önem sırası

Tablo 7 incelendiğinde, beta katsayılarının işaretine göre PISADIFF (PISA testinin zorluk algısı) ve SCREADIFF (öz okuma zorluk algısı) değişkenlerinin iki kategorili PISA okuduğunu anlama başarı durumunu yordama da negatif, diğer değişkenlerin ise pozitif etkiye sahip oldukları görülmektedir. Bu sonuçlar eğitim açısından doğal bir sonuçtur. Örneğin, zorluk algısı arttıkça başarının azalacağı söylenebilir. PISADIFF ve SCREADIFF değişkenleri dışındaki değişkenler, başarıyı artırabilecek değişkenler olduğundan, Lojistik Regresyon beta katsayıları pozitif değerler olarak elde edilmiştir. PISADIFF, HISEI (ebeveynlerin en yüksek mesleki statüsü), HOMEPOS (evdeki eğitimsel eşyalar) değişkenleri tüm örneklem gruplarının her biri için, iki kategorili PISA okuduğunu anlama başarısını yordama da önemli olan ortak değişkenler olarak saptanmıştır. Burada, PISADIFF değişkeni tüm örneklem grupları için, birinci, ikinci veya üçüncü sırada öneme sahip değişkendir ve genel olarak çalışma örneklemindeki ülkeler için PISA testinin zorluk algısının, PISA okuduğunu anlama başarı-başarısızlık durumunu yordama da önemli tahmin edicilerden biri olduğu söylenebilir. Bununla birlikte bu ortak üç değişkenden, HISEI değişkeninin alt grup ülkeler ve orta grup ülkeler örneklemlerinde birinci, ikinci sırada öneme sahip olduğu görülmektedir. Bu bulgu, orta düzey veya daha düşük düzeydeki ülkelerde, ebeveynlerin mesleki statüsü

değişkeninin PISA okuduğunu anlama başarı-başarısızlık durumunu yordayan önemli tahmin edici olduğunu ifade etmektedir. Bununla birlikte, başarıyı yordama bakımından HOMEPOS değişkeni ise çalışma örnekleminde ilk sırada öneme sahip olup; çalışma örnekleminde bulunan ülkeler için evdeki eğitimsel eşyalar değişkeninin, PISA okuduğunu anlama başarı durumunu artırıcı en etkili tahmin edici olduğu söylenebilir.

JOYREAD (okuma keyfi) çalışma örneklemini için, PISA okuduğunu anlama başarı-başarısızlık durumunu yordayan önemli değişkenlerden biri değildir. Bununla birlikte JOYREAD; alt, orta, üst grup ülkeler örneklemlerinin her biri için, PISA okuduğunu anlama başarı-başarısızlık durumunu yordayan önemli ortak tahmin edici olarak ortaya çıkmaktadır. Böylece; JOYREAD değişkeni alt grup ülkeler örnekleminde sekizinci sırada, orta grup ülkelerde üçüncü sırada, üst grup ülkelerde ise ikinci sırada öneme sahip tahmin edicidir.

BSMJ (öğrenciden beklenen mesleki statü) değişkeni başarıyı yordama da orta ve üst grup ülkeler örneklemlerinde önemli değişkenlerden biri olup, alt grup ve çalışma örneklemindeki ülkelerde önemli değişkenlerden biri değildir. BSMJ değişkeninin orta ve üst grup ülkeler örnekleminde dördüncü sırada başarıyı yordayabilen önemli tahmin edici olduğu görülmektedir. Bu bulgu, öğrenciden beklenen mesleki statünün alt grup ve çalışma örneklemini için önemli olmadığı ancak orta ve üst grup ülkeler örnekleminde önemli tahmin edici olduğunu göstermektedir.

ICTRES (bilgi iletişim teknolojileri kaynakları) değişkeni alt ve orta grup ülkeler örneklemlerinde başarıyı yordama da önemli değişkenlerden biridir. Bu değişken alt grup ülkeler örnekleminde ikinci sırada bir öneme sahip iken orta grup ülkeler örnekleminde altıncı sırada öneme sahiptir. Bu bulgu, alt grup ülkelerde BİT kaynaklarının diğer gruplara göre başarıyı belirlemede daha önemli bir tahmin edici olarak ortaya çıktığını göstermektedir.

MISCED (anne eğitim düzeyi) değişkeni alt grup ülkeler ve çalışma örnekleminde başarıyı yordama da önemli ortak değişkenlerden biriyken orta ve üst grup ülkelerde önemli tahmin edicilerden biri değildir.

SCREADCOMP (öz okuma yetkinlik algısı) değişkeni üst grup ülkeler örnekleminde ve çalışma örnekleminde okuduğunu anlama başarısını yordama da


önemli deęişkenlerden biridir. Bu deęişken alt grup ve orta grup ülkeler için, iki kategorili PISA başarı durumunu belirleyen önemli deęişkenlerden biri deęildir.

FISCED (baba eğitim düzeyi) ve SCREADIFF (öz okuma zorluk algısı) deęişkeninin sadece alt grup ülkelerde iki kategorili PISA başarı-başarısızlık durumunu yordama da önemli deęişkenlerden biri olduęu görülmektedir. Böylece; başarıyı yordama da, orta ve daha ileri düzeydeki ülkelerde, babanın eğitim düzeyinin ne olduęu ve öz okuma zorluk algısı önemli deęişkenlerden biri deęil iken bu deęişkenlerin alt grup ülkelerde önemli deęişkenler olarak yer alması dikkat çekmektedir. Örneęin; babanın eğitim düzeyi çocuęun okuduęunu anlama başarısını belirlemede üst grup ülkelerde önemli deęişkenlerden biri deęilken, alt grup ülkelerde babanın eğitimi olmasının çocuęunun okuduęunu anlamasında önemli bir yere sahip olduęu şeklinde yorumlanabilir.


LR yöntemi ile Türkiye örnekleminde iki kategorili PISA başarı-başarısızlık durumunu yordama da önemli deęişkenlerin önem derecesinin en yüksekten en düşüğe doğru sıralaması; okuma keyfi, öğrenciden beklenen mesleki statü, PISA testinin zorluk algısı, ebeveynlerin en yüksek mesleki statüsü ve evdeki eğitimsel eşyalar biçimindedir.

Sınıflama ve Regresyon Ağacı Yöntemine İlişkin Bulgular


İki kategorili başarı durumu için SRA uygulamasından, elde edilen önemli ilk 10 deęişkene ilişkin tahmin edici önem yüzdeleri grafikleri Şekil 12’de verilmiştir.




1a. Türkiye örnekleme




1b. Alt grup örnekleme



1c. Orta grup örnekleme



1d. Üst grup örnekleme



1e. Çalışma örnekleme

Şekil 12. Okuduğunu anlama başarısının iki kategorili olduğu durumda SRA modeli ile seçilen önemli 10 değişkene ilişkin grafikler

Şekil 12 incelendiğinde, alt grup ülkeler için HOMEPOS (evdeki eğitimsel eşyalar) ve PISADIFF (PISA testinin zorluk algısı), orta grup ülkeler için ESCS (sosyo-ekonomik durum indeksi) ve PISADIFF, üst grup ülkeler için PISADIFF ve JOYREAD (okuma keyfi), çalışma örneklemindeki ülkeler için ise, PISADIFF ve ESCS değişkenleri önemli tahmin ediciler olarak ortaya çıkmaktadırlar. Burada, PISADIFF değişkeninin alt grup, orta grup, üst grup ülkeler örneklemleri ve çalışma örneklemleri için önemli değişkenlerden biri olduğu dikkat çekmektedir. Şekil 12'deki grafiklere göre başarıyı yordayan birinci sıradaki önemli değişkenler; alt grup ülkeler örneklemleri için HOMEPOS, orta grup ülkeler örneklemleri için ESCS, üst grup ve çalışma örneklemindeki ülkeler için PISADIFF olarak elde edilmiştir.

SPSS Modeller programıyla SRA uygulamasından elde edilen regresyon ağacından yararlanarak 10'dan daha az sayıda "PISA okuduğunu anlama başarısını en iyi yordayan" bağımsız değişkenler belirlenerek Tablo 8'de sunulmuştur.

Tablo 8

Okuduğunu Anlama Başarısının İki Kategorili Olduğu Durumda SRA Modeli ile Seçilen Önemli ve Ortak Değişkenler

Türkiye Örneklemleri	Alt Grup Ülkeler Örneklemleri	Orta Grup Ülkeler Örneklemleri	Üst Grup Ülkeler Örneklemleri	Çalışma Örneklemleri
-	2.PISADIFF	2.PISADIFF	1.PISADIFF	1.PISADIFF
1.JOYREAD	-	3.JOYREAD	2.JOYREAD	4.JOYREAD
3.ESCS	-	1.ESCS	-	2.ESCS
-	4.EUDMO	-	-	3.EUDMO
-	-	5.GFOFAIL	-	5.GFOFAIL
2.BSMJ	-	-	-	-
-	-	4. HISEI	-	-
-	1.HOMEPOS	-	-	-
-	3.WORKMAST	-	-	-
-	5.ATTLNACT	-	-	-

1.2.3, önemli değişkenlerin önem sırası

Tablo 8 incelendiğinde, PISADIFF (PISA testinin zorluk algısı) alt, orta, üst grup ülkeler örneklemleri ve çalışma örnekleminde, JOYREAD (okuma keyfi) orta ve üst grup ülkeler örneklemleri ve çalışma örnekleminde, iki kategorili PISA okuduğunu

anlama başarısını yordama da önemli olan değişkenler olarak saptanmıştır. PISADIFF değişkeni alt, orta, üst grup ülkeler örneklemini ve çalışma örnekleminde birinci veya ikinci sırada önemli değişkendir. Bununla birlikte JOYREAD değişkeni orta ve üst grup ülkeler örneklemini ve çalışma örnekleminde ikinci, üçüncü veya dördüncü sırada önemli değişkendir.

ESCS (sosyo-ekonomik durum indeksi) değişkeni başarıyı yordama da orta grup ülkeler örnekleminde ve çalışma örnekleminde önemli değişkenlerden biri olup, alt grup ve üst grup ülkeler örnekleminde önemli değişkenlerden biri değildir. ESCS orta grupta birinci sırada, çalışma örneklemindeki ülkelerde ise ikinci sırada öneme sahip değişkendir. Bu bulguya dayanarak, orta grup ve çalışma örneklemindeki öğrencilerin sosyo-ekonomik düzeylerinin PISA okuma başarısı için önemli tahmin edicilerden biri olduğu söylenebilir.

EUDMO (yaşamın anlamı) değişkeni alt grup ve çalışma örnekleminde yer alan ülkelerde başarıyı yordama da önemli değişkenlerden biridir. Bu değişken alt grup ülkeler örnekleminde dördüncü sırada bir öneme sahip iken çalışma örnekleminde üçüncü sırada öneme sahiptir. Bu bulguya dayalı olarak, alt grup ülkeler örneklemindeki öğrencilerin orta grup ve üst grup ülkeler örneklemindeki öğrencilere göre yaşamın anlamını daha fazla sorguladıkları söylenebilir.

GFOFAIL (başarısızlık korkusu) değişkeni orta grup ve çalışma örneklemindeki ülkelerde başarıyı yordama da önemli ortak değişkenlerden biri iken alt ve üst grup ülkelerde önemli tahmin edicilerden biri olmadığı görülmektedir.


HISEI (ebeveynlerin en yüksek mesleki statüsü) değişkeni sadece orta grup ülkeler örnekleminde PISA okuduğunu anlama başarısını yordama da önemli değişkenlerden biridir.

HOMEPOS (evdeki eğitimsel eşyalar), WORKMAST (ileri düzey görevlere motivasyon), ATTLNACT (okulun değeri) değişkenleri sadece alt grup ülkeler örnekleminde PISA okuduğunu anlama başarısını yordama da önemli değişkenlerdir. Diğer yandan orta grup, üst grup ve çalışma örneklemindeki ülkelerde evdeki eğitimsel eşyalar, ileri düzey görevlere motivasyon ve okulun değeri öğrencilerin PISA okuduğunu anlama başarı-başarısızlık durumunu yordama da önemli değişkenler değildir.


SRA yöntemi ile Türkiye örnekleminde iki kategorili PISA başarı-başarısızlık durumunu yordama da önemli değişkenlerin önem derecesinin en yüksekten en düşüğe doğru sıralaması; okuma keyfi, öğrenciden beklenen mesleki statü ve sosyo-ekonomik durum indeksi biçimindedir.

Rastgele Orman Yöntemine İlişkin Bulgular


İki kategorili başarı durumu için RO uygulamasından, elde edilen 10 değişkene ilişkin tahmin edici önem yüzdelerinin grafikleri Şekil 13'te verilmiştir.




1a. Türkiye örnekleme




1b. Alt grup örnekleme



1c. Orta grup örnekleme



1d. Üst grup örnekleme



1e. Çalışma örnekleme

Şekil 13. Okuduğunu anlama başarısının iki kategorili olduğu durumda RO modeli ile seçilen önemli 10 değişkene ilişkin grafikler

Şekil 13 incelendiğinde, alt grup ülkeler için JOYREAD (okuma keyfi) ve PISADIFF (PISA testinin zorluk algısı), orta grup ülkeler için PERFEED (Öğretmen geri bildirim) ve DISCILIMA (disiplin iklimi), üst grup ülkeler için PERCOMP (öğrenci rekabeti) ve WEALTH (ailenin mal varlığı), çalışma örnekleme için ise, JOYREAD ve LMINS (haftalık test dili öğrenme süresi) değişkenleri ilk sırada önemli başarı tahmin edicileri olarak ortaya çıkmaktadırlar. Şekil 13'teki grafiklere göre başarıyı yordayan birinci sıradaki önemli değişkenler; alt grup ülkeler örnekleme için JOYREAD, orta grup ülkeler örnekleme için PERFEED, üst grup ülkeler örnekleme için PERCOMP ve çalışma örneklemindeki ülkeler için JOYREAD olarak elde edilmiştir.

Şekil 13'te RO yöntemi ile her bir grup örnekleme için seçilen PISA okuduğunu anlama başarı durumu değişkenini yordayan değişkenlerden ilk sıradaki 10 yordayıcı bağımsız değişkenden yordayıcılığı en düşük olan değişkenler çıkartılarak azaltılmış model ile WEKA programında sınıflama performansının 10 değişkenle elde edilen performansa yakın olacak şekilde değişken azaltarak ayarlama yapıldıktan sonra 10'dan daha az sayıda "PISA okuduğunu anlama başarısını en iyi yordayan" olarak adlandırılan bağımsız değişkenler Tablo 9'da sunulmuştur.

Tablo 9

Okuduğunu Anlama Başarısının İki Kategorili Olduğu Durumda RO Modeli ile Seçilen Önemli ve Ortak Değişkenler

Türkiye Örnekleme	Alt Grup Örnekleme	Orta Grup Örnekleme	Üst Grup Örnekleme	Çalışma Örnekleme
6. PERCOMP	-	5. PERCOMP	1. PERCOMP	3. PERCOMP
5. JOYREAD	1. JOYREAD	-	-	1. JOYREAD
-	5. DIRINS	3. DIRINS	-	5. DIRINS
1. WORKMAST	-	-	4. WORKMAST	-
3. EUDMO	-	-	5. EUDMO	-
-	-	-	3. LMINS	2. LMINS
2. GFOFAIL	-	-	-	-
4. SCREADCOMP	-	-	-	-
-	2. PISADIFF	-	-	-
-	3. MASTGOAL	-	-	-
-	4. COMPETE	-	-	-
-	-	1. PERFEED	-	-
-	-	2. DISCLIMA	-	-
-	-	4. ADAPTIVITY	-	-
-	-	-	2. WEALTH	-
-	-	-	6. FISCED	-
-	-	-	7. ESCS	-
-	-	-	-	4. RESILENCE

1.2.3, önemli değişkenlerin önem sırası

Tablo 9 incelendiğinde, PERCOMP (öğrenci rekabeti) orta, üst grup ülkeler örnekleme ve çalışma örnekleminde, JOYREAD (okuma keyfi) alt grup ülkeler örnekleme ve çalışma örnekleminde, iki kategorili PISA okuduğunu anlama başarısını yordama da önemli değişkenler olarak saptanmıştır. Burada, PERCOMP değişkeni orta, üst grup ülkeler örnekleme ve çalışma örnekleminde, birinci, üçüncü, beşinci sırada önemli değişkendir. Bununla birlikte JOYREAD değişkeni alt grup ülkeler örnekleme ve çalışma örnekleminde, birinci sırada öneme sahiptir.

DIRINS (öğretmenin eğitimi yönlendirmesi) değişkeni başarıyı yordama da alt grup, orta grup ülkeler örnekleme ve çalışma örnekleminde önemli değişkenlerden biridir. DIRINS üst grup ülkeler örnekleminde önemli değişkenlerden biri değildir. DIRINS alt grup ülkeler örnekleminde beşinci sırada, orta grupta üçüncü sırada, çalışma örnekleminde ise beşinci sırada öneme sahiptir.

EUDMO (yaşamın anlamı) değişkeni üst grup ülkeler örnekleminde başarıyı yordama da önemli değişkenlerden biridir. Bu değişken üst grup ülkeler örnekleminde beşinci sırada öneme sahiptir.

LMINS (haftalık test dili öğrenme süresi) değişkeni üst grup ülkeler örnekleme ve çalışma örnekleminde başarıyı yordama da önemli değişkenlerden biridir. Bu değişken üst grup ülkeler örnekleminde üçüncü sırada bir öneme sahip iken çalışma örnekleminde ikinci sırada öneme sahiptir.

PISADIFF (PISA testinin zorluk algısı), MASTGOAL (öğrenme amaçları), COMPETE (rekabete karşı tutum) değişkenleri sadece alt grup ülkeler örnekleminde PISA okuduğunu anlama başarısını yordama da önemli değişkenlerdir. Bu değişkenler orta grup, üst grup ülkeler örnekleme ve çalışma örneklemindeki ülkeler için, iki kategorili PISA okuduğunu anlama başarı durumunu etkileyen önemli değişkenlerden değildir.

PERFEED (Öğretmen geri bildirim), DISCLIMA (disiplin iklimi), ADAPTIVITY (öğretim adaptasyonu) değişkenleri sadece orta grup ülkeler örnekleminde PISA okuduğunu anlama başarısını yordama da önemli değişkenlerdir. Bu değişkenlerin alt grup, üst grup ülkeler örnekleme ve çalışma örneklemindeki ülkeler için PISA okuduğunu anlama başarı durumunu etkileyen önemli değişkenlerden olmadığı görülmektedir.

WEALTH (ailenin mal varlığı), FISCED (baba eğitim düzeyi), ESCS (sosyo-ekonomik durum indeksi) değişkenleri sadece üst grup ülkeler örnekleminde PISA okuduğunu anlama başarısını yordama da önemli değişkenlerdir. Bu değişkenler alt grup, orta grup ve çalışma örneklemindeki ülkeler için, PISA okuduğunu anlama başarı durumunu etkileyen önemli değişkenlerden değildir.

RESILIENCE (öz yeterlik), değişkeni sadece çalışma örnekleminde PISA okuduğunu anlama başarısını yordama da önemli bir değişkendir. Bu değişken alt

grup, orta grup ve üst grup ülkeler örnekleme için PISA okuduğunu anlama başarı durumunu etkileyen önemli bir değişken değildir.


RO yöntemi ile Türkiye örnekleminde iki kategorili PISA başarı-başarısızlık durumunu yordama da önemli değişkenlerin önem derecesinin en yüksekten en düşüğe doğru sıralaması; ileri görevlere motivasyon, başarısızlık korkusu, yaşamın anlamı, öz okuma yetkinlik algısı, okuma keyfi, öğrenci rekabeti biçimindedir.

İkinci Alt Probleme İlişkin Bulgular


PISA öğrenci anketinde ölçülen öğrenci özelliklerinden yararlanarak üç kategorili okuduğunu anlama başarısını tahmin etmede kullanılan Lojistik Regresyon (LR), Sınıflama ve Regresyon Ağacı (SRA), Rastgele Orman (RO) yöntemlerini kullanarak Türkiye, üst, orta, alt başarı düzeyindeki ülkeler örnekleme ve çalışma örneklemindeki ülkelerin başarılarını etkileyen önemli değişkenler nelerdir?

Lojistik Regresyon Yöntemine İlişkin Bulgular


Üç kategorili başarı durumu için LR uygulamasından, elde edilen önemli ilk 10 değişkene ilişkin tahmin edici önem yüzdeleri grafikleri Şekil 14'te verilmiştir.




1a. Türkiye örnekleme




1b. Alt grup örnekleme



1c. Orta grup örnekleme



1d. Üst grup örnekleme



1e. Çalışma örnekleme

Şekil 14. Okuduğunu anlama başarısının üç kategorili olduğu durumda LR modeli ile seçilen önemli 10 değişkene ilişkin grafikler

Başarıyı en iyi yordayan değişkenler bakımından Şekil 14 incelendiğinde, alt grup ülkeler örnekleminde HOMEPOS (evdeki eğitimsel eşyalar) ve ICTRES (bilgi iletişim teknolojileri kaynakları), orta grup ülkeler örneklemini için HOMEPOS, PISADIFF (PISA testinin zorluk algısı) ve HISEI (ebeveynlerin en yüksek mesleki statüsü), üst grup ülkeler örneklemini için PISADIFF ve JOYREAD (okuma keyfi), HOMEPOS ve çalışma örneklemini için ise, HOMEPOS ve PISADIFF değişkenleri ilk sıralarda önemli başarı tahmin edicileri olarak ortaya çıkmaktadırlar. Şekil 14'teki grafiklere göre başarıyı yordayan birinci sıradaki önemli değişkenler; alt grup, orta grup ülkeler örneklemini ve çalışma örneklemini için HOMEPOS, üst grupta ise PISADIFF olarak elde edilmiştir. Burada, HOMEPOS değişkeninin çoğu örneklem grupları için birinci sırada önemli değişken olduğu dikkat çekmektedir.

Şekil 14'te LR yöntemi ile her bir grup örneklemini için seçilen PISA okuduğunu anlama başarısını yordayan önemli 10 bağımsız değişkenden tahmin önem düzeyi (predictor importance) % 5 ve üzerinde olan "PISA okuduğunu anlama başarısını en iyi yordayan" bağımsız değişkenler belirlenerek Tablo 10'da sunulmuştur. Tablo 10 incelendiğinde, her bir örneklem grubu için önem sırasının ve LR katsayısının işaretinin belirtildiği; önemli ortak değişkenlerin aynı sırada yazıldığı görülmektedir.

Tablo 10

Okuduğunu Anlama Başarısının Üç Kategorili Olduğu Durumda LR Modeli ile Seçilen Önemli ve Ortak Değişkenler

Türkiye Örneklemini	Alt Grup Ülkeler Örneklemini	Orta Grup Ülkeler Örneklemini	Üst Grup Ülkeler Örneklemini	Çalışma Örneklemini
1.(+)HOMEPOS	1.(+)HOMEPOS	1.(+)HOMEPOS	3.(+)HOMEPOS	1.(+)HOMEPOS
2.(-)PISADIFF	4.(-)PISADIFF	2.(-)PISADIFF	1.(-)PISADIFF	2.(-)PISADIFF
3.(+)HISEI	-	3.(+)HISEI	6.(+)HISEI	3.(+)HISEI
4.(+)ICTRES	2.(+)ICTRES	6.(+)ICTRES	-	4.(+)ICTRES
5.(+)BSMJ	-	4.(+)BSMJ	4.(+)BSMJ	5.(+)BSMJ
-	-	5.(+)JOYREAD	2.(+)JOYREAD	-
-	3.(-)SCREADDIFF	-	-	-
-	-	-	5.(+)SCREADCOMP	-

-,+:Lojistik regresyon modelindeki beta katsayısının işareti, 1.2.3, önemli değişkenlerin önem sırası

Tablo 10 incelendiğinde, beta katsayılarının işaretine göre PISADIFF (PISA testinin zorluk algısı) ve SCREADIFF (öz okuma zorluk algısı) değişkenlerinin üç kategorili PISA okuduğunu anlama başarı durumunu yordama da olumsuz, diğer değişkenlerin ise olumlu etkiye sahip oldukları görülmektedir. PISADIFF ve SCREADIFF değişkenleri dışındaki değişkenler, başarıyı artırabilecek değişkenler olarak ortaya çıkmaktadır. HOMEPOS (evdeki eğitimsel eşyalar) ve PISADIFF değişkenleri tüm örneklem gruplarının her biri için, üç kategorili PISA okuduğunu anlama başarısını yordama da önemli olan değişkenler olarak saptanmıştır. Burada, Başarıyı yordama bakımından HOMEPOS değişkeni alt grup, orta grup ve çalışma örnekleminde ilk sırada öneme sahip olup; bu ülkeler için evdeki eğitimsel eşyalar değişkeninin, PISA okuduğunu anlama başarı durumunu artırıcı en etkili tahmin edici olduğu söylenebilir. PISADIFF değişkeni ise tüm örneklem gruplarının her biri için, birinci, ikinci veya dördüncü sırada öneme sahip önemli değişken olup; üst grup ülkeler için PISA testinin zorluk algısının, PISA okuduğunu anlama başarı durumunu yordama da en önemli tahmin edici olduğu söylenebilir.

HISEI (ebeveynlerin en yüksek mesleki statüsü), alt grup ülkeler örneklemini için, PISA okuduğunu anlama başarı durumunu yordayan önemli değişkenlerden biri değildir. Bununla birlikte HISEI; orta grup, üst grup ülkeler örneklemini ve çalışma örneklemindeki ülkelerin her biri için, PISA okuduğunu anlama başarı durumunu yordayan önemli ortak tahmin edici olarak ortaya çıkmaktadır.

ICTRES (bilgi iletişim teknolojileri kaynakları) değişkeni alt grup, orta grup ve çalışma örnekleminde başarıyı yordama da önemli değişkenlerden biridir. Bu değişken çalışma örnekleminde dördüncü, alt grup ülkeler örnekleminde ikinci sırada öneme sahip iken orta grup ülkeler örnekleminde altıncı sırada öneme sahiptir. Bu bulgu, alt grup ülkelerde bilgi iletişim teknolojilerinin gelişmiş ülkelere göre daha az gelişmesi nedeniyle, bilgi iletişim teknolojileri kaynaklarının alt grup ülkelerde diğer gruplara göre başarıyı belirlemede daha önemli bir tahmin edici olduğu şeklinde yorumlanabilir.

BSMJ (öğrenciden beklenen mesleki statü) değişkeni başarıyı yordama da orta grup, üst grup ülkeler örneklemini ve çalışma örnekleminde önemli değişkenlerden biri olup, alt grup ülkeler örnekleminde önemli değişkenlerden biri değildir. BSMJ çalışma örnekleminde beşinci sırada öneme sahip iken orta ve üst grup ülkeler örnekleminde bu önem dördüncü sırada yer almaktadır. Bu bulgu,

BSMJ deęişkeninin alt grup ülkelerde önemli olmadığı ancak orta grup, üst grup ülkeler örnekleme ve çalışma örnekleminde önemli olduğunu göstermektedir.

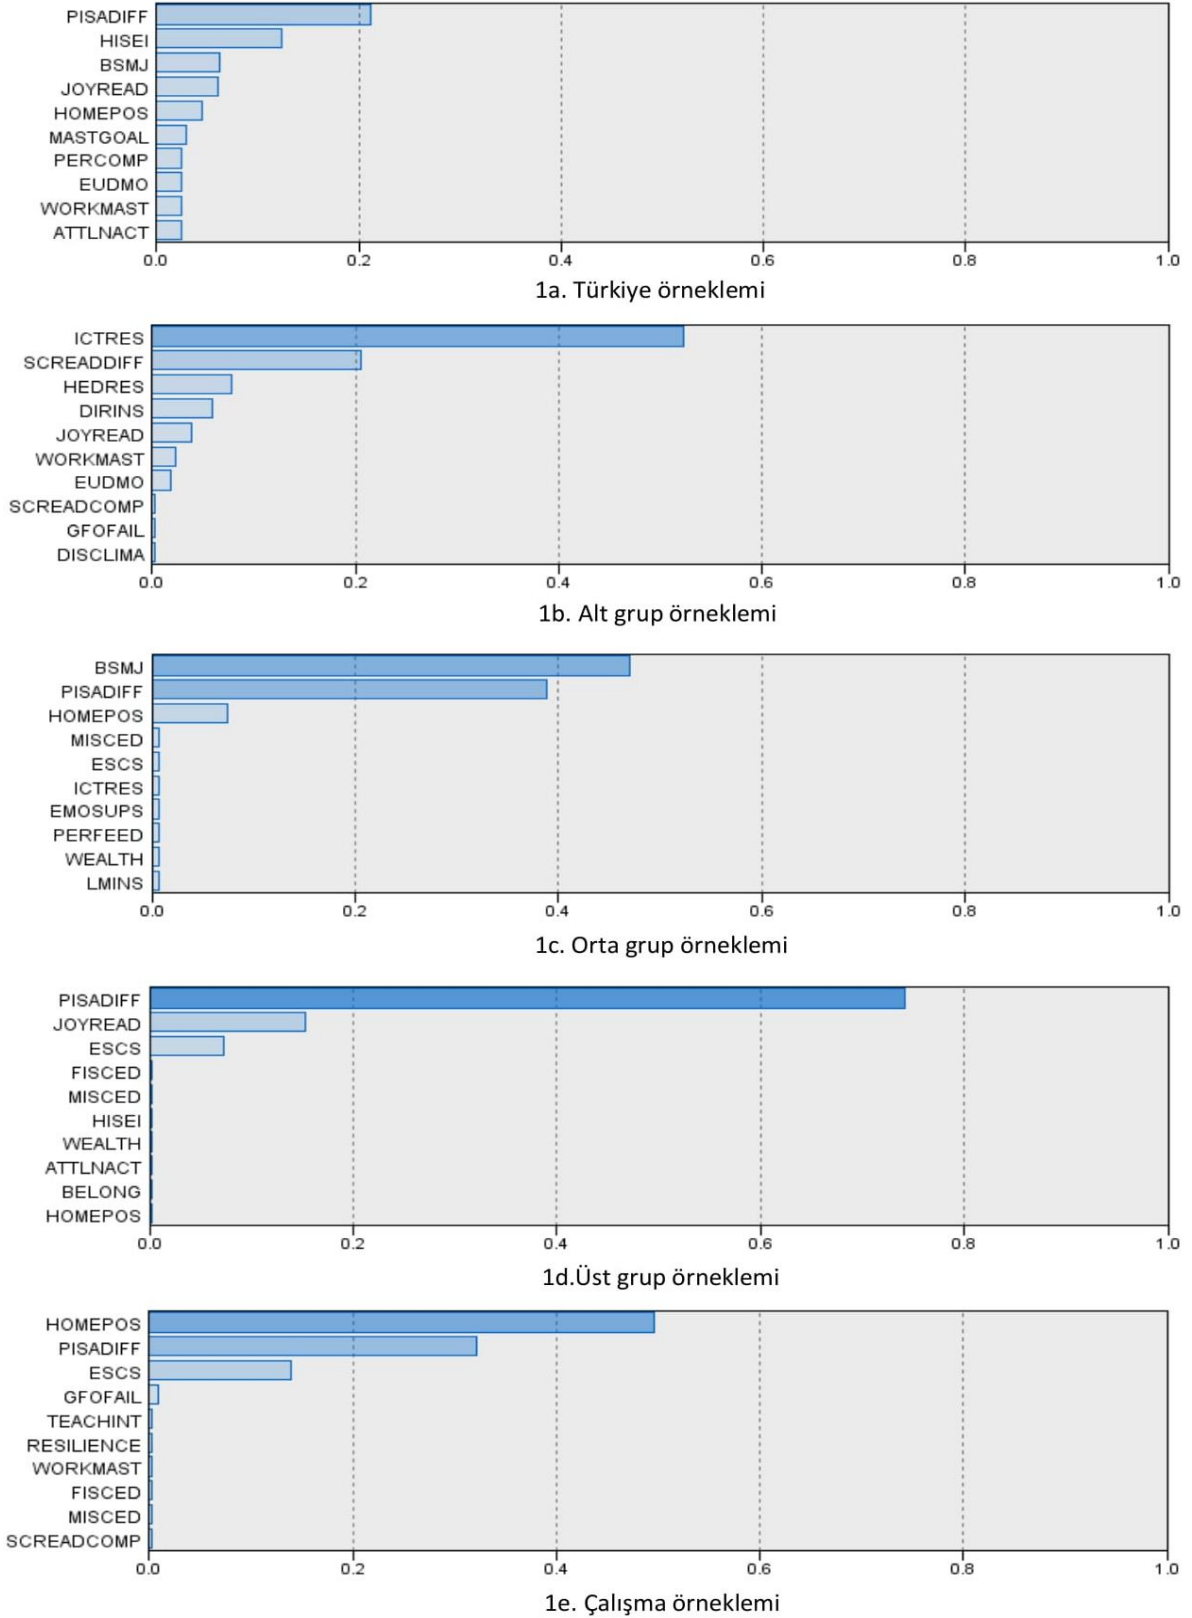
JOYREAD (okuma keyfi) deęişkeni orta grup ve üst grup ülkeler örnekleminde başarıyı yordama da önemli ortak deęişkenlerden biri iken alt grup ve çalışma örneklemindeki ülkeler için başarıyı yordama da önemli deęişkenlerden biri değildir.

SCREADCOMP (öz okuma yetkinlik algısı) deęişkeni sadece üst grup ülkeler örnekleminde, SCREADIFF (öz okuma zorluk algısı) deęişkeninin ise sadece alt grup ülkeler örnekleminde üç kategorili PISA okuduğunu anlama başarı durumunu yordama da önemli deęişkenlerden biri olduğu saptanmıştır.

LR yöntemi ile Türkiye örnekleminde üç kategorili PISA başarı durumunu yordama da önemli deęişkenlerin önem derecesinin en yüksekten en düşüğe doğru sıralaması; evdeki eğitimsel eşyalar, PISA testinin zorluk algısı, ebeveynlerin en yüksek mesleki statüsü, bilgi iletişim teknolojileri kaynakları ve öğrenciden beklenen mesleki statü biçimindedir.

Sınıflama ve Regresyon Ağacı Yöntemine İlişkin Bulgular

Üç kategorili SRA uygulamasından, elde edilen önemli ilk 10 deęişkene ilişkin tahmin edici önem yüzdeleri grafikleri şekil 15'te verilmiştir.



Şekil 15. Okuduğunu anlama başarısının üç kategorili olduğu durumda SRA modeli ile seçilen önemli 10 değişkene ilişkin grafikler

Başarıyı yordayan önemli değişkenler bakımından şekil 15 incelendiğinde, alt grup ülkeler örnekleminde, ICTRES (bilgi iletişim teknolojileri kaynakları) ve SCREADDIFF (öz okuma yetkinlik algısı), orta grup ülkeler örneklemini için BSMJ (öğrenciden beklenen mesleki statü) ve PISADIFF (PISA testinin zorluk algısı), üst grup ülkeler örneklemini için PISADIFF ile JOYREAD (okuma keyfi) ve çalışma örneklemini için ise, HOMEPOS (evdeki eğitimsel eşyalar) ve PISADIFF değişkenleri ilk sıralarda önemli başarı tahmin edicileri olarak ortaya çıkmaktadırlar. Şekil 15'teki grafiklere göre; başarıyı yordayan birinci sıradaki önemli değişkenler; alt grup ülkeler örnekleminde ICTRES, orta grup ülkeler örnekleminde BSMJ, üst grup ülkeler örneklemini için PISADIFF, çalışma örnekleminde ise HOMEPOS olarak elde edilmiştir.

Şekil 15'te SRA yöntemi ile her bir grup örneklemini için seçilen PISA okuduğunu anlama başarı durumu değişkenini yordayan değişkenlerden ilk sıradaki 10 yordayıcı bağımsız değişkenden Modeler programında yapılan analiz sonucunda ortaya çıkan regresyon ağacından elde edilen 10'dan daha az sayıda "PISA okuduğunu anlama başarısını en iyi yordayan" olarak adlandırılan bağımsız değişkenler belirlenerek Tablo 11'da sunulmuştur. Tablo 11 incelendiğinde, her bir örneklem grubu için, önem sırası, tablo içinde belirtilmiş ve önemli ortak değişkenler aynı sırada yazılmıştır.

Tablo 11

Okuduğunu Anlama Başarısının Üç Kategorili Olduğu Durumda SRA Modeli ile Seçilen Önemli ve Ortak Değişkenler

Türkiye Örnekleme	Alt Grup Ülkeler Örnekleme	Orta Grup Ülkeler Örnekleme	Üst Grup Ülkeler Örnekleme	Çalışma Örnekleme
1. PISADIFF	-	2. PISADIFF	1. PISADIFF	2. PISADIFF
5. HOMEPOS	-	3. HOMEPOS	-	1. HOMEPOS
4. JOYREAD	5. JOYREAD	-	2. JOYREAD	-
-	-	-	3. ESCS	3. ESCS
3. BSMJ	-	1. BSMJ	-	-
-	-	-	-	4. GFOFAIL
2. HISEI	-	-	-	-
-	1. ICTRES	-	-	-
-	2. SCREADDIFF	-	-	-
-	3. HEDRES	-	-	-
-	4. DIRINS	-	-	-
-	6. WORKMAST	-	-	-
-	7. EUDMO	-	-	-

1.2.3, önemli değişkenlerin önem sırası

Tablo 11 incelendiğinde, PISADIFF (PISA testinin zorluk algısı) değişkeni alt grup hariç diğer örneklem gruplarının her biri için, üç kategorili PISA okuduğunu anlama başarısını yordama da önemli ortak değişken olarak saptanmıştır. Burada, başarıyı yordama bakımından PISADIFF değişkeni üst grup ülkeler örnekleminde ilk sırada, çalışma örnekleme ve orta grup ülkeler örnekleminde ikinci sırada öneme sahip olup; bu ülkeler için PISA testinin zorluk algısı değişkeninin, PISA okuduğunu anlama başarı durumunu etkileyen önemli tahmin edici olduğu söylenebilir.

HOMEPOS (evdeki eğitimsel eşyalar), orta grup ülkeler örnekleme ve çalışma örneklemindeki ülkeler için, PISA okuduğunu anlama başarı durumunu yordayan önemli ortak değişken olarak belirlenmiştir. Bu değişken başarıyı yordama bakımından orta grup ülkeler örnekleminde üçüncü sırada, çalışma örneklemindeki ülkelerde ise birinci sırada öneme sahip olup; bu ülkeler için evdeki

eğitimsel eşyalar değişkeninin, PISA okuduğunu anlama başarı durumunu yordayan etkili tahmin edici olduğu söylenebilir.

JOYREAD (okuma keyfi), alt grup ve üst grup ülkeler örnekleme için, PISA okuduğunu anlama başarı durumunu yordayan önemli ortak değişken olarak belirlenmiştir. Bu değişken başarıyı yordama bakımından alt grup ülkeler örnekleminde beşinci sırada ve üst grup ülkeler örnekleminde ise ikinci sırada öneme sahip olup; bu ülkeler için okuma keyfi değişkeninin, PISA okuduğunu anlama başarı durumunu yordayan etkili tahmin edici olduğu söylenebilir.

BSMJ (öğrenciden beklenen mesleki statü), orta grup ülkeler örnekleminde PISA okuduğunu anlama başarı durumunu yordayan önemli değişken olarak belirlenmiştir. Bu değişken başarıyı yordama bakımından orta grup ülkeler örnekleminde birinci sırada öneme sahip olup; bu ülkeler için öğrenciden beklenen mesleki statü değişkeninin, PISA okuduğunu anlama başarı durumunu yordayan etkili tahmin edici olduğu söylenebilir.


ESCS (sosyo-ekonomik durum indeksi), üst grup ülkeler örnekleme ve çalışma örnekleminde PISA okuduğunu anlama başarı durumunu yordayan önemli ortak değişken olarak belirlenmiştir. Bu değişken başarıyı yordama bakımından üst grup ve çalışma örnekleminde üçüncü sırada öneme sahip olup bu ülkeler için sosyo-ekonomik durum indeksi değişkeninin PISA okuduğunu anlama başarı durumunu yordayan etkili tahmin edici olduğu söylenebilir.

Diğer yandan, PISA okuduğunu anlama başarısını yordama da; çalışma örnekleminde GFOFAIL (başarısızlık korkusu) değişkeni dördüncü sırada öneme sahip değişkendir. Alt grup ülkeler örnekleminde ICTRES (bilgi iletişim teknolojileri kaynakları) birinci, SCREADDIFF (öz okuma zorluk algısı) ikinci, HEDRES (evdeki eğitim kaynakları) üçüncü, DIRINS (Öğretmenin eğitimi yönlendirmesi) dördüncü, WORKMAST (ileri düzey görevlere yönelik motivasyon) altıncı, EUDMO (yaşamın anlamı) yedinci sırada öneme sahip değişkenlerdir.


SRA yöntemi ile Türkiye örnekleminde üç kategorili PISA başarı durumunu yordama da önemli değişkenlerin önem derecesinin en yüksekten en düşüğe doğru sıralaması; PISA testinin zorluk algısı, ebeveynlerin en yüksek mesleki statüsü, öğrenciden beklenen mesleki statü, okuma keyfi ve evdeki eğitimsel eşyalar biçimindedir.

Rastgele Orman Yöntemine İlişkin Bulgular


Üç kategorili Rastgele Orman uygulamasından, elde edilen önemli ilk 10 değişkene ilişkin tahmin edici önem yüzdeleri grafikleri Şekil 16'da verilmiştir.




1a. Türkiye örnekleme




1b. Alt grup örnekleme



1c. Orta grup örnekleme



1d. Üst grup örnekleme



1e. Çalışma örnekleme

Şekil 16. Okuduğunu anlama başarısının üç kategorili olduğu durumda RO modeli ile seçilen önemli 10 değişkene ilişkin grafikler

Başarıyı yordayan önemli değişkenler bakımından Şekil 16 incelendiğinde, alt grup ülkeler örnekleminde LMINS (haftalık test dili öğrenme süresi) ve JOYREAD (okuma keyfi), orta grup ülkeler örneklemini için DISCLIMA (disiplin iklimi) ve LMINS, üst grup ülkeler örneklemini için ESCS (sosyo-ekonomik durum indeksi) ve HOMEPOS (evdeki eğitimsel eşyalar) ve çalışma örneklemini için ise, DIRINS (Öğrenmenin eğitimi yönlendirmesi) ve LMINS değişkenleri ilk sıralarda öneme sahip başarı tahmin edicileri olarak ortaya çıkmaktadırlar. Şekil 16'daki grafiklere göre başarıyı yordayan birinci sıradaki önemli değişkenler; alt grup ülkeler örnekleminde LMINS, orta grup ülkeler örnekleminde DISCLIMA, üst grup ülkeler örnekleminde ESCS, çalışma örnekleminde ise DIRINS olarak elde edilmiştir.

Şekil 16'da RO yöntemi ile her bir grup örneklemini için seçilen PISA okuduğunu anlama başarı durumu değişkenini yordayan değişkenlerden ilk sıradaki 10 yordayıcı bağımsız değişkenden yordayıcılığı en düşük olan değişkenler çıkartılarak azaltılmış model ile WEKA programında sınıflama performansının 10 değişkenle elde edilen performansa yakın olacak şekilde değişken azaltarak ayarlama yapıldıktan sonra 10'dan daha az sayıda "PISA okuduğunu anlama başarısını en iyi yordayan" olarak adlandırılan bağımsız değişkenler belirlenerek Tablo 12'de sunulmuştur. Tablo 12 incelendiğinde, her bir örneklem grubu için, önem sırası, tablo içinde belirtilmiş ve önemli ortak değişkenler aynı sırada yazılmıştır.

Tablo 12

Okuduğunu Anlama Başarısının Üç Kategorili Olduğu Durumda RO Modeli ile Seçilen Önemli ve Ortak Değişkenler

Türkiye Örnekleme	Alt Grup Örnekleme	Orta Grup Örnekleme	Üst Grup Örnekleme	Çalışma Örnekleme
-	1. LMINS	2. LMINS	7. LMINS	2. LMINS
1. JOYREAD	2. JOYREAD	7. JOYREAD	-	4. JOYREAD
7. PISADIFF	3. PISADIFF	-	-	6. PISADIFF
2. PERFEED	-	3. PERFEED	-	-
5. TEACHSUP	-	5. TEACHSUP	-	-
3. STİMREAD	-	6. STİMREAD	-	-
4. EUDMO	-	-	5. EUDMO	-
-	4.COMPETE	-	8.COMPETE	-
-	-	1. DISCLIMA	-	3. DISCLIMA
-	-	8.DIRINS	-	1. DIRINS
6. PERCOMP	-	-	-	-
8. GFOFAIL	-	-	-	-
-	5. MASTGOAL	-	-	-
-	6. WORKMAST	-	-	-
-	-	4. ADAPTIVITY	-	-
-	-	-	1. ESCS	-
-	-	-	2. HOMEPOS	-
-	-	-	3. FISCED	-
-	-	-	4.SCREADCOMP	-
-	-	-	6. ICTRES	-
-	-	-	-	5.SCREADDIFF

1.2.3, önemli değişkenlerin önem sırası

Tablo 12 incelendiğinde, LMINS (haftalık test dili öğrenme süresi) değişkeni alt grup, orta grup, üst grup ülkeler örnekleme ve çalışma örnekleminde üç kategorili PISA okuduğunu anlama başarısını yordama da önemli ortak değişken olarak saptanmıştır. Burada, başarıyı yordama bakımından LMINS değişkeni alt grupta birinci sırada, orta grupta ikinci sırada, üst grupta yedinci sırada ve çalışma örnekleminde ise ikinci sırada öneme sahip olup; bu ülkeler için haftalık test dili

öğrenme süresi değişkeninin, PISA okuduğunu anlama başarı durumunu etkileyen önemli tahmin edici olduğu söylenebilir.

JOYREAD (okuma keyfi), alt grup, orta grup ve çalışma örnekleme için, PISA okuduğunu anlama başarı durumunu yordayan önemli ortak değişken olarak belirlenmiştir. Bu değişken başarıyı yordama bakımından alt grup ülkeler örnekleminde ikinci sırada, orta grup ülkeler örnekleminde yedinci sırada, çalışma örnekleminde ise dördüncü sırada öneme sahip olup; bu ülkeler için okuma keyfi değişkeninin, PISA okuduğunu anlama başarı durumunu yordayan etkili tahmin edici olduğu söylenebilir. Bu değişken üst grup ülkeler örnekleminde önemli tahmin edici olarak çıkmamıştır.

PISADIFF (PISA testinin zorluk algısı) alt grup ülkeler örnekleme ve çalışma örnekleme için, PISA okuduğunu anlama başarı durumunu yordayan önemli ortak değişken olarak belirlenmiştir. Bu değişken başarıyı yordama bakımından alt grup ülkeler örnekleminde üçüncü sırada, çalışma örnekleminde ise altıncı sırada öneme sahip olup; bu ülkeler için PISA testinin zorluk algısı değişkeninin, PISA okuduğunu anlama başarı durumunu yordayan etkili tahmin edici olduğu söylenebilir. Bu değişken en çok da alt grup ülkeler örnekleminde başarıyı yordama da etkilidir.

PERFEED (Öğretmenin geri bildirim), orta grup ülkeler örnekleminde PISA okuduğunu anlama başarı durumunu yordayan önemli değişken olarak belirlenmiştir. Bu değişken başarıyı yordama bakımından orta grup ülkeler örnekleminde üçüncü sırada öneme sahip olup; bu ülkeler için Öğretmenin geri bildiriminin, PISA okuduğunu anlama başarı durumunu yordayan etkili bir tahmin edici olduğu söylenebilir.

TEACHSUP (Öğretmen desteği), orta grup ülkeler örnekleminde PISA okuduğunu anlama başarı durumunu yordayan önemli değişken olarak belirlenmiştir. Bu değişken başarıyı yordama bakımından orta grup ülkeler örnekleminde beşinci sırada öneme sahip olup; bu ülkeler için Öğretmen desteğinin, PISA okuduğunu anlama başarı durumunu yordayan etkili tahmin edici olduğu söylenebilir.

STIMREAD (Öğretmenin okumaya teşviki), orta grup ülkeler örnekleminde PISA okuduğunu anlama başarı durumunu yordayan önemli değişken olarak

belirlenmiştir. Bu değişken başarıyı yordama bakımından orta grup ülkeler örnekleminde altıncı sırada öneme sahip olup; bu ülkeler için Öğretmen geri bildiriminin, PISA okuduğunu anlama başarı durumunu yordayan etkili tahmin edici olduğu söylenebilir.

EUDMO (yaşamın anlamı), üst grup ülkeler örnekleminde PISA okuduğunu anlama başarı durumunu yordayan önemli değişken olarak belirlenmiştir. Bu değişken başarıyı yordama bakımından üst grup ülkeler örnekleminde beşinci sırada öneme sahip olup; bu ülkeler için yaşamın anlamı değişkeninin, PISA okuduğunu anlama başarı durumunu yordayan etkili tahmin edici olduğu söylenebilir.

COMPETE (rekabete karşı tutum), alt grup ve üst grup ülkeler örnekleminde PISA okuduğunu anlama başarı durumunu yordayan önemli ortak değişken olarak belirlenmiştir. Bu değişken başarıyı yordama bakımından alt grup örnekleminde dördüncü sırada, üst grup ülkeler örnekleminde ise sekizinci sırada öneme sahip olup; bu ülkeler için rekabete karşı tutum değişkeninin, PISA okuduğunu anlama başarı durumunu yordayan etkili tahmin edici olduğu söylenebilir. Bu sonuca dayalı olarak alt grup ve üst grup ülkelerdeki öğrencilerin rekabete karşı tutumlarının başarı durumlarını etkilediği ancak orta grup ülkeler ve çalışma örneklemindeki ülkelerin öğrencilerinin başarı durumlarını etkilemediği söylenebilir.

DISCLIMA (disiplin iklimi), orta grup ülkeler örneklemini ve çalışma örnekleminde PISA okuduğunu anlama başarı durumunu yordayan önemli ortak değişken olarak belirlenmiştir. Bu değişken başarıyı yordama bakımından orta grup ülkeler örnekleminde birinci sırada, çalışma örnekleminde ise üçüncü sırada öneme sahip olup; bu ülkeler için disiplin iklimi değişkeninin, PISA okuduğunu anlama başarı durumunu yordayan etkili tahmin edici olduğu söylenebilir. Bu sonuca dayalı olarak disiplin ikliminin orta grup ülkeler örnekleminde çalışma örneklemine göre başarıyı etkilemede daha önemli olduğu söylenebilir.

DIRINS (Öğretmenin eğitimi yönlendirmesi), orta grup ülkeler örneklemini ve çalışma örnekleminde PISA okuduğunu anlama başarı durumunu yordayan önemli ortak değişken olarak belirlenmiştir. Bu değişken başarıyı yordama bakımından orta grup ülkeler örnekleminde sekizinci sırada, çalışma örnekleminde ise birinci

sırada öneme sahip olup; bu ülkeler için Öğretmenin eğitimi yönlendirmesinin, PISA okuduğunu anlama başarı durumunu yordayan etkili tahmin edici olduğu söylenebilir.

Diğer yandan, PISA okuduğunu anlama başarısını yordama da; alt grup ülkeler örneğinde MASTGOAL (öğrenme amaçları) beşinci sırada, WORKMAST (ileri görevlere motivasyon) altıncı sırada öneme sahip tahmin edicilerdir. Orta grup ülkeler örneğinde ADAPTIVITY (öğretim adaptasyonu) dördüncü sırada öneme sahip tahmin edicidir. Üst grup ülkeler örneğinde ESCS (sosyo-ekonomik durum indeksi) birinci sırada, HOMEPOS (evdeki eğitimsel eşyalar) ikinci sırada, FISCED (baba eğitim düzeyi) üçüncü sırada, SCREADCOMP (öz okuma yetkinlik algısı) dördüncü sırada, ICTRES (bilgi iletişim teknolojileri kaynakları) altıncı sırada öneme sahip tahmin edicilerdir. Son olarak da çalışma örneğinde SCREADDIFF (öz okuma zorluk algısı) beşinci sırada öneme sahip tahmin edicidir.

RO yöntemi ile Türkiye örneğinde üç kategorili PISA başarı durumunu yordama da önemli değişkenlerin önem derecesinin en yüksekten en düşüğe doğru sıralaması; okuma keyfi, Öğretmen geri bildirim, Öğretmenin okumaya teşviki, yaşamın anlamı, Öğretmen desteği, öğrenci rekabeti, PISA testinin zorluk algısı ve başarısızlık korkusu biçimindedir.

Üçüncü Alt Probleme İlişkin Bulgular

PISA öğrenci anketinde ölçülen öğrenci özelliklerinden yararlanarak Türkiye örneği, alt grup, orta grup, üst grup ülkeler örneği ve çalışma örneğinden elde edilen verilerle iki kategorili ve üç kategorili okuduğunu anlama başarısını tahmin etmede kullanılan Lojistik Regresyon (LR), Sınıflama ve Regresyon Ağacı (SRA) ve Rastgele Orman (RO) veri madenciliği yöntemleri yardımıyla elde edilen ölçümlerin tüm veri, geçerlik verisi ve test verisi için elde edilen sınıflama ve tahmin performansları ne düzeydedir?

Bağımlı değişkenin iki ve üç kategorili olduğu duruma Türkiye, alt grup, orta grup, üst grup ülkeler örneği ve çalışma örneğindeki öğrencilerin başarı kategorine dağılımlarının frekansları Tablo 13'te verilmiştir.

Tablo 13

İki ve Üç Kategorili Başarı Durumu Kategori Frekansları

Kategori	Türkiye Örnekleme	Alt grup Örnekleme	Orta grup Örnekleme	Üst grup Örnekleme	Çalışma Örnekleme
Başarısız	5779	24382	15353	11296	51031
Başarılı	1080	996	3170	5271	9437
Düşük	3887	20720	10626	6734	38080
Orta	2814	4579	7326	8192	20097
Yüksek	158	79	571	1641	2291

Birinci ve ikinci alt problem kapsamında, Türkiye, alt grup, orta grup, üst grup ülkeler örnekleme ve çalışma örnekleme verileriyle SPSS Modeller programında bulunan LR, SRA ve RO yöntemleriyle tüm veri, geçerlik verisi ve test verisini kullanarak öncelikle, 34 bağımsız değişken arasından her bir modelin seçtiği yordama düzeyi yüksek 10 değişken belirlenmiştir. Daha sonra bu 10 değişken arasından yordama düzeyi en yüksek önemli değişkenler seçilmiştir. Bu işlemin ardından, 34 değişken, 10 değişken ve yordama düzeyi en yüksek önemli değişkenlere ilişkin model performansları hesaplanmıştır. Bu işlemin amacı, değişken sayısı azalırken her bir model için hesaplanan model performanslarının çok az miktarda değişmesi durumunda, başarıyı tahmin etmede, az sayıdaki önemli değişkenlerin kullanılmasının yeterli olduğunu göstermektir.

İki Kategorili Başarı Durumu için Lojistik Regresyon Model Performansları

LR veri madenciliği yöntemi ile iki kategorili PISA başarı durumu değişkenini yordamak amacıyla tüm değişkenleri, seçilen 10 önemli değişkeni ve mümkün olan en az sayıda önemli değişkenleri kapsayan modeller için performans hesaplamaları yapılmış ve sonuçlar Tablo 14'te verilmiştir. Model performans hesaplamaları tüm veri, çapraz geçerlik verisi ve test verisi için WEKA yazılımı aracılığı ile gerçekleştirilmiştir.

Tablo 14

İki Kategorili Başarı Durumu için LR Model Performansları

		Mutlak Performanslar				Görelî Performanslar		
	Değişken	Veri	DSY	OMH	HKOK	Kappa	GMH	GHKK
Türkiye Örneklemleri	Tüm Değişkenler (34)	Tüm veri	86,324	0,196	0,314	0,353	74,126	86,307
		Geçerlik verisi	86,149	0,198	0,316	0,342	74,614	86,942
		Test verisi	85,377	0,200	0,322	0,328	74,738	87,113
	Seçilen değişkenler (10)	Tüm veri	85,741	0,211	0,325	0,271	79,805	89,428
		Geçerlik verisi	85,741	0,212	0,326	0,273	79,968	89,626
		Test verisi	85,248	0,214	0,332	0,262	80,225	89,913
	Önemli değişkenler (5)	Tüm veri	85,034	0,215	0,333	0,255	80,480	90,185
		Geçerlik verisi	85,551	0,213	0,327	0,263	80,317	89,806
		Test verisi	85,034	0,215	0,333	0,255	80,480	90,185
Alt Grup Örneklemleri	Tüm Değişkenler (34)	Tüm veri	96,189	0,061	0,176	0,181	81,490	90,737
		Geçerlik Verisi	96,146	0,061	0,177	0,174	81,898	91,182
		Test verisi	96,117	0,061	0,177	0,170	81,222	90,579
	Seçilen değişkenler (10)	Tüm veri	96,083	0,065	0,181	0,081	86,937	93,655
		Geçerlik verisi	96,095	0,065	0,182	0,088	87,232	93,841
		Test verisi	96,013	0,065	0,182	0,055	86,297	92,885
	Önemli değişkenler (8)	Tüm veri	96,087	0,066	0,183	0,074	88,419	94,403
		Geçerlik verisi	96,083	0,066	0,183	0,070	88,494	94,476
		Test verisi	95,990	0,066	0,183	0,040	87,777	93,836
Orta Grup Örneklemleri	Tüm Değişkenler (34)	Tüm veri	85,796	0,204	0,320	0,390	71,399	84,989
		Geçerlik verisi	85,693	0,204	0,320	0,386	72,103	85,191
		Test verisi	85,423	0,205	0,323	0,372	72,130	85,246
	Seçilen değişkenler (10)	Tüm veri	84,754	0,219	0,331	0,314	77,379	88,090
		Geçerlik verisi	84,721	0,219	0,332	0,312	77,426	88,149
		Test verisi	84,391	0,220	0,335	0,296	77,392	88,377
	Önemli değişkenler (6)	Tüm veri	84,759	0,220	0,332	0,312	77,611	88,195
		Geçerlik verisi	84,775	0,220	0,332	0,312	77,639	88,227
		Test verisi	84,454	0,220	0,335	0,298	77,515	88,317
Üst Grup Örneklemleri	Tüm Değişkenler (34)	Tüm veri	78,384	0,294	0,384	0,472	67,845	82,528
		Geçerlik verisi	78,324	0,295	0,385	0,471	68,017	82,745
		Test verisi	78,412	0,296	0,385	0,474	68,268	82,885
	Seçilen değişkenler (10)	Tüm veri	76,984	0,313	0,395	0,432	72,149	84,996
		Geçerlik verisi	76,996	0,313	0,396	0,432	72,209	85,070
		Test verisi	77,010	0,314	0,397	0,435	72,492	85,358
	Önemli değişkenler (6)	Tüm veri	76,694	0,316	0,397	0,424	72,864	85,420
		Geçerlik verisi	76,694	0,316	0,398	0,424	72,899	85,465
		Test verisi	76,602	0,317	0,399	0,425	76,602	85,824
Çalışma Örneklemleri	Tüm Değişkenler (34)	Tüm veri	87,333	0,180	0,301	0,419	68,530	83,150
		Geçerlik verisi	87,320	0,180	0,302	0,418	68,588	83,228
		Test verisi	87,173	0,181	0,302	0,415	68,826	83,325
	Seçilen değişkenler (10)	Tüm veri	86,449	0,192	0,311	0,359	73,105	85,834
		Geçerlik verisi	86,457	0,192	0,311	0,359	73,121	85,854
		Test verisi	86,312	0,193	0,312	0,355	73,371	86,000
	Önemli değişkenler (5)	Tüm veri	85,726	0,203	0,320	0,299	77,308	88,223
		Geçerlik verisi	85,739	0,203	0,320	0,299	77,316	88,233
		Test verisi	85,587	0,204	0,320	0,290	77,474	88,315

DSY: Doğru sınıflama yüzdesi, OMH: Ortalama mutlak hata, HKOK: Hata kareler ortalamasının karekökü, GMH: Görelî mutlak hata, GHKK: Görelî hata karelerinin karekökü

Tablo 14 incelendiğinde Türkiye, alt, orta, üst grup ve çalışma örneklemini için tüm veri, çapraz geçerlik verisi ve test verisi için yapılan model performans analizlerinde örneklem gruplarının kendi içinde doğru sınıflama yüzdesinin (DSY) önemli düzeyde değişmediği görülmektedir. Örneğin Türkiye örnekleminde 34 tane değişken için başarı yüzdesi 86,324 iken 10 tane değişken için başarı yüzdesi 85,741, 5 tane değişken için 85,034 bulunmuştur. Sonuç olarak, değişken sayısının azalması DSY üzerinde önemli bir değişikliğe neden olmamaktadır. Dolayısıyla; Türkiye için 34 değişkenden elde edilen doğru sınıflama yüzdesine 5 değişkenle ulaşılmaktadır ve istatistiksel ekonomiklik ilkesine bağlı olarak değişken sayısı az olan model tercih edilmelidir. Benzer sonuçların alt, orta, üst grup ülkeler örneklemini ve çalışma örneklemini için de elde edildiği görülmektedir. Bununla birlikte DSY bakımından önemli değişkenler için kurulan LR modellerinin en başarılı olandan en başarısız olana sırası alt grup ülkeler örneklemini, çalışma örneklemini, Türkiye örneklemini, orta grup ülkeler örneklemini ve üst grup ülkeler örneklemini olarak sıralanmaktadır.

Buna ek olarak alt grup ülkelerde Kappa katsayısı 0,20'in altında olduğu için düşük, GMH (görelî mutlak hata) ve GHKK (görelî hata karelerinin karekökü) değerleri ise yüksek çıkmıştır. Bunun nedeni Tablo 13'te görüldüğü gibi alt gruptaki bireylerin çok büyük bir kısmının (%96) kesme puanı olan 553'ün altında puan almış olmalarındandır. Diğer yandan Türkiye ve orta grup ülkeler örnekleminde Kappa katsayısının kayda değer, üst grup ülkeler ve çalışma örnekleminde ise orta düzey olduğu görülmektedir. Tablo 14'teki bulgulara göre üst grup ülkeler örneklemini için Kappa katsayısı diğer gruplardan daha yüksektir. Bu sonuca dayanarak üst grup için oluşturulan model hesaplarına karışan tesadüfî hataların az olduğu söylenebilir. Bunun nedeninin Tablo 13'te görüldüğü gibi üst grupta başarılı ve başarısız bireylerin oranının diğer örneklem gruplara göre daha yakın olmasından kaynaklı olduğu söylenebilir. Bu durumda, LR yöntemiyle en iyi doğru sınıflama performansı alt grup ülkeler örnekleminde elde edilirken iken Kappa katsayısı, GMH ve GHKK ölçüleri bakımından oluşturulan en iyi modelin üst grup ülkeler örnekleminiyle elde edildiği söylenebilir. Çünkü üst grup ülkeler örnekleminde değişken sayısının azalmasına rağmen Kappa katsayısının azalmadığı görülmektedir. Diğer gruplarda ise değişken sayısı azalırken Kappa katsayısı bir miktar azalmaktadır.

İki Kategorili Başarı Durumu için Sınıflama ve Regresyon Ağacı Model Performansları

SRA veri madenciliği yöntemi ile iki kategorili PISA başarı durumu değişkenini yordamak amacıyla kurulan tüm değişkenleri, seçilen 10 önemli değişkeni ve mümkün olan en az sayıda önemli değişkenleri kapsayan modeller için performans hesaplamaları yapılmış ve sonuçlar Tablo 15'te verilmiştir. Model performans hesaplamaları tüm veri, çapraz geçerlik verisi ve test verisi için WEKA yazılımı aracılığı ile gerçekleştirilmiştir.

Tablo 15

İki Kategorili Başarı Durumu için SRA Model Performansları

			Mutlak Performanslar			Görelî Performanslar		
	Değişken	Veri	DSY	OMH	HKOK	Kappa	GMH	GHKK
Türkiye Örneklemleri	Tüm Değişkenler (34)	Tüm veri	85,901	0,230	0,339	0,280	86,791	93,173
		Geçerlik verisi	85,231	0,233	0,345	0,241	88,120	94,747
		Test verisi	84,691	0,237	0,351	0,211	88,711	94,977
	Seçilen değişkenler (10)	Tüm veri	85,581	0,233	0,341	0,230	87,774	93,700
		Geçerlik verisi	85,420	0,230	0,344	0,262	86,780	94,531
		Test verisi	84,862	0,235	0,350	0,244	87,992	94,599
	Önemli değişkenler (3)	Tüm veri	85,828	0,230	0,339	0,219	86,934	93,250
		Geçerlik verisi	85,362	0,233	0,343	0,214	88,089	94,314
		Test verisi	84,691	0,237	0,351	0,211	88,908	94,973
Alt Grup Örneklemleri	Tüm Değişkenler (34)	Tüm veri	96,075	0,075	0,194	0,000	99,955	100
		Geçerlik Verisi	96,087	0,072	0,190	0,044	95,371	98,181
		Test verisi	96,001	0,075	0,195	0,000	95,195	100
	Seçilen değişkenler (10)	Tüm veri	96,075	0,075	0,194	0,000	99,955	100
		Geçerlik verisi	96,075	0,075	0,194	0,000	99,950	100
		Test verisi	96,001	0,075	0,195	0,000	99,933	100
	Önemli değişkenler (5)	Tüm veri	96,075	0,075	0,194	0,000	99,955	100
		Geçerlik verisi	96,063	0,075	0,194	0,000	99,558	100
		Test verisi	96,001	0,075	0,195	0,000	99,933	100
Orta Grup Örneklemleri	Tüm Değişkenler (34)	Tüm veri	86,249	0,223	0,334	0,402	78,746	88,743
		Geçerlik verisi	84,565	0,230	0,344	0,318	81,380	91,383
		Test verisi	84,010	0,235	0,350	0,256	82,767	92,260
	Seçilen değişkenler (10)	Tüm veri	85,509	0,228	0,337	0,359	80,502	89,727
		Geçerlik verisi	84,225	0,239	0,349	0,276	84,363	92,808
		Test verisi	83,534	0,235	0,351	0,293	84,648	92,521
	Önemli değişkenler (5)	Tüm veri	84,932	0,235	0,343	0,321	82,958	91,085
		Geçerlik verisi	84,392	0,237	0,346	0,280	83,647	91,930
		Test verisi	84,153	0,252	0,359	0,212	88,674	94,482
Üst Grup Örneklemleri	Tüm Değişkenler (34)	Tüm veri	78,167	0,328	0,405	0,453	75,659	86,983
		Geçerlik verisi	76,260	0,334	0,413	0,413	77,142	88,687
		Test verisi	76,105	0,335	0,415	0,403	77,439	89,191
	Seçilen değişkenler (10)	Tüm veri	77,268	0,335	0,409	0,437	77,396	87,976
		Geçerlik verisi	76,181	0,339	0,414	0,408	78,292	88,952
		Test verisi	76,087	0,338	0,416	0,399	78,129	89,465
	Önemli değişkenler (2)	Tüm veri	75,638	0,344	0,415	0,396	79,431	89,125
		Geçerlik verisi	74,950	0,345	0,417	0,377	79,692	89,662
		Test verisi	75,182	0,348	0,418	0,378	80,358	89,927
Çalışma Örneklemleri	Tüm Değişkenler (34)	Tüm veri	87,490	0,198	0,314	0,405	75,195	86,716
		Geçerlik verisi	86,480	0,202	0,321	0,360	76,929	88,520
		Test verisi	86,293	0,204	0,323	0,359	77,423	88,935
	Seçilen değişkenler (10)	Tüm veri	87,054	0,201	0,317	0,389	76,569	87,505
		Geçerlik verisi	86,320	0,204	0,322	0,352	77,756	88,772
		Test verisi	86,385	0,202	0,322	0,362	76,957	88,623
	Önemli değişkenler (5)	Tüm veri	87,108	0,201	0,317	0,391	76,489	87,459
		Geçerlik verisi	86,419	0,204	0,321	0,360	77,560	88,636
		Test verisi	86,477	0,204	0,320	0,338	77,422	88,311

DSY: Doğru sınıflama yüzdesi, OMH: Ortalama mutlak hata, HKOK: Hata kareler ortalamasının karekökü, GMH: Görelî mutlak hata, GHKK: Görelî hata karelerinin karekökü

Tablo 15 incelendiğinde Türkiye, alt grup, orta grup, üst grup ülkeler örnekleme ve çalışma örnekleme için tüm veri, çapraz geçerlik verisi ve test verisi için yapılan model performans analizlerinde DSY'nin önemli düzeyde değişmediği görülmektedir. Örneğin Türkiye örnekleminde 34 tane değişken için başarı yüzdesi 85,901 iken 10 tane değişken için başarı yüzdesi 85,581, 3 tane değişken için 85,828'dir. Sonuç olarak, değişken sayısının azalması DSY üzerinde önemli bir değişikliğe neden olmamaktadır. Dolayısıyla; Türkiye için 34 değişkenden elde edilen doğru sınıflama yüzdesine 3 tane değişkenle ulaşılmaktadır ve istatistiksel ekonomiklik ilkesine bağlı olarak değişken sayısı az olan model tercih edilmelidir. Benzer sonuçların alt grup, orta grup, üst grup ülkeler örnekleme ve çalışma örnekleme için de elde edildiği görülmektedir. Bununla birlikte DSY bakımından önemli değişkenler için kurulan SRA modellerinin en başarılı olandan en başarısız olana sırası alt grup ülkeler örnekleme, çalışma örnekleme, Türkiye örnekleme, orta grup ülkeler örnekleme ve üst grup ülkeler örnekleme olarak sıralanmaktadır.

Buna ek olarak alt grup ülkelerde Kappa katsayısı 0,20'in altında ve sıfıra yakın olduğu için çok düşük, GMH (görelî mutlak hata) ve GHKK (görelî hata karelerinin karekökü) değerleri ise çok yüksek çıkmıştır. Bunun nedeni Tablo 13'te görüldüğü gibi alt gruptaki bireylerin çok büyük bir kısmının (%96) kesme puanı olan 553'ün altında puan almış olmalarındandır. Diğer yandan Türkiye, orta grup, üst grup ve çalışma örnekleminde Kappa katsayısının kayda değer olduğu görülmektedir. Tablo 15'teki bulgulara göre üst grup ülkeler örnekleme ve çalışma örnekleme için Kappa katsayısı diğer gruplardan daha yüksektir. Bu sonuca dayanarak üst grup ülkeler örnekleme ve çalışma örnekleme için oluşturulan model hesaplarına karışan tesadüfî hataların az olduğu söylenebilir. Bunun nedeninin üst grup ülkeler örnekleme ve çalışma örnekleminde başarılı ve başarısız bireylerin oranının yakın olmasından kaynaklı olduğu düşünülebilir. Bu durumda SRA modeliyle yapılan analizde en iyi doğru sınıflama performansına sahip alt grup ülkeler örnekleme iken Kappa katsayısı, GMH ve GHKK ölçüleri bakımından en iyi modelin üst grup ülkeler örnekleme ve çalışma örnekleme olduğu söylenebilir. Çünkü üst grup ülkeler örnekleme ve çalışma örnekleminde değişken sayısının azalmasına rağmen Kappa katsayısının belirgin miktarda azalmadığı görülmektedir. Diğer gruplarda ise değişken sayısı azalırken Kappa katsayısı bir miktar azalmaktadır.

İki Kategorili Başarı Durumu için Rastgele Orman Model Performansları

RO veri madenciliği yöntemi ile iki kategorili PISA başarı durumu değişkenini yordamak amacıyla tüm değişkenleri, seçilen 10 önemli değişkeni ve mümkün olan en az sayıda önemli değişkenleri kapsayan modeller için performans hesaplamaları yapılmış ve sonuçlar Tablo 16'da verilmiştir. Model performans hesaplamaları tüm veri, çapraz geçerlik verisi ve test verisi için WEKA yazılımı aracılığı ile gerçekleştirilmiştir.

Tablo 16

İki Kategorili Başarı Durumu için RO Model Performansları

		Mutlak Performanslar			Görelî Performanslar			
Değişken	Veri	DSY	OMH	HKOK	Kappa	GMH	GHKK	
Türkiye Örneklemleri	Tüm Değişkenler (34)	Tüm veri	100	0,078	0,118	1,000	29,489	32,553
		Geçerlik verisi	86,120	0,211	0,316	0,276	79,826	86,863
		Test verisi	85,806	0,215	0,324	0,275	80,690	87,641
	Seçilen değişkenler (10)	Tüm veri	99,985	0,086	0,128	0,999	32,396	35,237
		Geçerlik verisi	84,268	0,233	0,340	0,143	87,774	93,475
		Test verisi	83,576	0,238	0,350	0,135	89,149	94,625
	Önemli değişkenler (6)	Tüm veri	99,854	0,091	0,136	0,994	34,591	37,384
		Geçerlik verisi	83,816	0,246	0,355	0,102	92,703	97,649
		Test verisi	83,319	0,245	0,362	0,077	91,824	97,895
Alt Grup Örneklemleri	Tüm Değişkenler (34)	Tüm veri	100	0,025	0,066	1,000	33,089	34,380
		Geçerlik Verisi	96,118	0,068	0,177	0,043	90,073	91,636
		Test verisi	96,013	0,068	0,178	0,016	89,893	91,198
	Seçilen değişkenler (10)	Tüm veri	100	0,026	0,070	1,000	35,686	36,206
		Geçerlik verisi	96,075	0,073	0,187	0,021	97,193	96,407
		Test verisi	95,990	0,073	0,188	0,015	96,779	96,119
	Önemli değişkenler (5)	Tüm veri	99,929	0,027	0,074	0,990	36,500	38,525
		Geçerlik verisi	95,823	0,074	0,195	0,015	98,673	100,686
		Test verisi	95,781	0,074	0,196	0,005	97,974	100,446
Orta Grup Örneklemleri	Tüm Değişkenler (34)	Tüm veri	99,994	0,080	0,120	0,999	28,324	31,964
		Geçerlik verisi	85,623	0,219	0,321	0,332	77,222	85,413
		Test verisi	85,439	0,220	0,325	0,326	77,419	85,745
	Seçilen değişkenler (10)	Tüm veri	99,938	0,087	0,129	0,999	30,976	34,337
		Geçerlik verisi	83,517	0,238	0,344	0,221	84,061	91,464
		Test verisi	82,915	0,240	0,347	0,201	84,245	91,500
	Önemli değişkenler (5)	Tüm veri	99,600	0,103	0,149	0,985	36,322	39,633
		Geçerlik verisi	81,585	0,273	0,380	0,040	96,209	101,094
		Test verisi	81,406	0,272	0,382	0,033	95,727	100,519
Üst Grup Örneklemleri	Tüm Değişkenler (34)	Tüm veri	99,994	0,115	0,144	0,999	26,573	30,952
		Geçerlik verisi	78,324	0,314	0,385	0,460	72,459	82,821
		Test verisi	78,253	0,316	0,386	0,462	72,844	82,967
	Seçilen değişkenler (10)	Tüm veri	100	0,135	0,161	1,000	31,196	34,560
		Geçerlik verisi	72,016	0,367	0,429	0,277	84,776	92,302
		Test verisi	72,146	0,369	0,430	0,279	85,176	92,408
	Önemli değişkenler (7)	Tüm veri	99,994	0,138	0,165	0,999	31,875	35,525
		Geçerlik verisi	70,688	0,375	0,442	0,247	86,525	95,020
		Test verisi	70,282	0,379	0,444	0,236	87,568	95,487
Çalışma Örneklemleri	Tüm Değişkenler (34)	Tüm veri	99,998	0,070	0,112	0,999	26,620	30,889
		Geçerlik verisi	87,570	0,190	0,299	0,396	72,420	82,436
		Test verisi	87,324	0,192	0,300	0,387	72,989	82,636
	Seçilen değişkenler (10)	Tüm veri	99,995	0,077	0,120	0,998	29,333	33,202
		Geçerlik verisi	85,828	0,209	0,321	0,288	79,665	88,634
		Test verisi	85,621	0,212	0,322	0,285	80,416	88,814
	Önemli değişkenler (5)	Tüm veri	99,773	0,087	0,134	0,991	33,031	36,914
		Geçerlik verisi	84,011	0,234	0,349	0,159	88,827	96,345
		Test verisi	83,909	0,235	0,350	0,143	89,480	96,550

DSY: Doğru sınıflama yüzdesi, OMH: Ortalama mutlak hata, HKOK: Hata kareler ortalamasının karekökü, GMH: Görelî mutlak hata, GHKK: Görelî hata karelerinin karekökü

Tablo 16 incelendiğinde Türkiye, alt grup, orta grup, üst grup ülkeler örnekleme ve çalışma örnekleme için tüm veri, çapraz geçerlik verisi ve test verisi için yapılan model performans analizlerinde DSY'nin tüm veri için hemen hemen değişmediği, çapraz geçerlik ve test verisi için ise çok az miktarda değiştiği görülmektedir. Örneğin Türkiye örnekleminde 34 tane değişken için başarı yüzdesi 100 iken 10 tane değişken için başarı yüzdesi 99,985, 6 tane değişken için 99,854'tür. Bu durumda, 34 tane değişkenden 6 tane değişkene düştüğünde tüm veri için DSY neredeyse hiç, çapraz geçerlik verisi ve test verisi için DSY'nin çok az miktarda azaldığı görülmektedir. Sonuç olarak, değişken sayısının azalması DSY için önemli bir değişikliğe neden olmamaktadır. Dolayısıyla Türkiye için 34 değişkenden elde edilen DSY'ye 6 değişkenle ulaşılmakta ve istatistiksel ekonomiklik ilkesine bağlı olarak değişken sayısı az olan model tercih edilmelidir. Benzer sonuçların alt grup, orta grup, üst grup ülkeler örnekleme ve çalışma örnekleme için de elde edildiği görülmektedir. Bununla birlikte DSY bakımından önemli değişkenler için kurulan RO modellerinin en başarılı olandan en başarısız olana sırası alt grup ülkeler örnekleme, çalışma örnekleme, Türkiye örnekleme, orta grup ülkeler örnekleme ve üst grup ülkeler örnekleme olarak sıralanmaktadır.

Buna ek olarak Kappa katsayısı, Türkiye, alt grup, orta grup, üst grup ülkeler örnekleme ve çalışma örneklemindeki ülkelerde 34 tane değişken ve tüm veri için mükemmel düzeydedir. Ancak 34 tane değişken için çapraz geçerlik ve test verisi için Türkiye örnekleme, orta grup ülkeler örnekleme ve çalışma örnekleminde makul, alt grup ülkeler örnekleminde Kappa katsayısı 0,20'in altında ve sıfıra yakın olduğu için çok düşük, GMH (görelî mutlak hata) ve GHKK (görelî hata karelerinin karekökü) değerleri ise çok yüksek çıkmıştır. Bunun nedeni Tablo 13'te görüldüğü gibi alt gruptaki bireylerin çok büyük bir kısmının (%96) kesme puanı olan 553'ün altında puan almış olmalarındandır. Değişken sayısı 10 tane olduğu durumda, Türkiye örnekleme ve alt grup ülkeler örnekleminde çapraz geçerlik ve test verisi üzerinden hesaplanan Kappa katsayısı düşük iken orta grup, üst grup ülkeler örnekleme ve çalışma örnekleminde Kappa katsayısı makul düzeyde bulunmuştur. Azaltılmış model (orta grupta beş adet, üst grupta yedi adet, çalışma örnekleminde beş adet değişken) için hesaplanan Kappa katsayısı orta grup ülkeler örnekleme ve çalışma örnekleminde yetersiz iken üst grup ülkeler örnekleminde makul düzeydedir. Gerek tüm veri, çapraz geçerlik ve test verisi

bakımından gerekse değişken sayısı azaltılarak oluşturulan model bakımından Kappa katsayısının en yüksek çıktığı grup üst grup ülkeler örneklemdir. Bunun nedeninin üst grup örnekleminde başarılı ve başarısız bireylerin oranının yakın olmasından kaynaklı olduğu düşünülebilir. Bu durumda tüm gruplarda RO yöntemiyle kurulan modelde değişken sayısı 34 iken tüm veri üzerinden hesaplanan Kappa katsayısı mükemmel düzeyde iken çapraz geçerlik ve test verisi üzerinden hesaplanan Kappa katsayısı tüm veriye göre düşük çıkmıştır. Ayrıca değişken sayısı azalırken gruplarda tüm veri için Kappa katsayısı hemen hemen hiç değişmez iken çapraz geçerlik ve test verisi için düşmüştür.

İki kategorili PISA okuduğunu anlama başarısını yordama da önemli değişkenleri belirlemede kullanılan yöntemlerin tahmin performansı ve Kappa istatistiği gruplara göre incelendiğinde; Türkiye örnekleminde en iyi performans gösteren LR yöntemi iken SRA yöntemi de iyi düzeyde performans göstermiştir. Ancak RO yöntemi Türkiye örneklemini için gerçeğe uygun sonuç vermemiştir. Alt grup ülkeler örneklemini için üç modelin hiçbiri gerçeğe uygun sonuç vermemiştir. Orta grup ülkeler örneklemini için en iyi performans gösteren LR yöntemi iken SRA yöntemi de iyi düzeyde performans göstermiştir. Ancak RO yöntemi gerçeğe uygun sonuç vermemiştir. Üst grup ülkeler örnekleminde en iyi performans gösteren LR yöntemi iken SRA yöntemi iyi düzeyde, RO yöntemi ise kabul edilebilir düzeyde performans göstermiştir. Çalışma örneklemini için en iyi performans gösteren SRA yöntemi iken LR yöntemi iyi düzeyde performans göstermiştir. Ancak RO yöntemi iyi düzeyde performans göstermemiştir. Bu durumda grupların genelinde en iyi derecede performans gösteren LR yöntemi, daha sonra ise SRA yöntemidir.

Üç Kategorili Başarı Durumu için Lojistik Regresyon Model Performansları

LR veri madenciliği yöntemi ile üç kategorili PISA başarı durumu değişkenini yordayabilen ilk önemli 10 değişken Şekil 14'te ve bu 10 değişkenden "başarıyı % 5 ya da daha büyük oranda yordama" kriterine (predictor importance) göre Türkiye'de beş, alt grupta dört, orta grupta altı, üst grupta altı, çalışma örnekleminde beş tane seçilen 10'dan az sayıdaki önemli değişkenler elde edilip Tablo 10'da gösterilmişti. Burada ise, önce 34 bağımsız değişken kullanılarak, bağımlı değişken olan PISA okuduğunu anlama başarısı üç kategorili alınarak; tüm veri, çapraz geçerlik ve test verisi için farklı denemeler gerçekleştirilerek model

performansları Weka programı kullanılarak hesaplanmıştır. Daha sonra, aynı hesaplamalar, üç kategorili PISA okuduğunu anlama başarı durumunu yordayan ilk önemli 10 bağımsız değişken ve bu 10 bağımsız değişkenden seçilen 10'dan az sayıdaki önemli değişkenler kullanılarak, performans hesaplamaları tekrar yapılmıştır. Elde edilen sonuçlar Tablo 17'de gösterilmiştir.

Tablo 17

Üç Kategorili Başarı Durumu için LR Model Performansları

			Mutlak Performanslar			Görelî Performanslar		
	Değişken	Veri	DSY	OMH	HKOK	Kappa	GMH	GHKK
Türkiye Örnekleme	Tüm Değişkenler (34)	Tüm veri	70,710	0,260	0,360	0,408	76,583	87,442
		Geçerlik verisi	70,476	0,262	0,363	0,403	77,116	88,100
		Test verisi	69,854	0,264	0,364	0,392	77,424	88,372
	Seçilen değişkenler (10)	Tüm veri	67,415	0,278	0,373	0,336	81,999	90,568
		Geçerlik verisi	67,385	0,279	0,374	0,335	82,161	90,760
		Test verisi	66,895	0,281	0,376	0,324	82,743	91,211
	Önemli değişkenler (5)	Tüm veri	66,307	0,287	0,379	0,311	84,440	91,935
		Geçerlik verisi	66,205	0,287	0,379	0,309	84,530	92,047
		Test verisi	65,866	0,289	0,381	0,303	84,997	92,425
Alt Grup Örnekleme	Tüm Değişkenler (34)	Tüm veri	84,009	0,150	0,275	0,342	74,921	86,865
		Geçerlik Verisi	83,934	0,150	0,275	0,340	75,104	87,097
		Test verisi	83,937	0,150	0,275	0,336	74,825	86,813
	Seçilen değişkenler (10)	Tüm veri	82,914	0,160	0,284	0,259	80,226	89,918
		Geçerlik verisi	82,926	0,161	0,285	0,259	80,285	89,989
		Test verisi	82,477	0,161	0,285	0,241	80,265	90,033
	Önemli değişkenler (4)	Tüm veri	81,696	0,174	0,296	0,133	87,014	93,593
		Geçerlik verisi	81,677	0,174	0,296	0,132	87,037	93,621
		Test verisi	81,527	0,175	0,297	0,128	87,319	93,696
Orta Grup Örnekleme	Tüm Değişkenler (34)	Tüm veri	71,478	0,254	0,354	0,424	74,306	86,222
		Geçerlik verisi	71,381	0,255	0,357	0,422	74,531	86,500
		Test verisi	70,895	0,254	0,358	0,413	74,370	86,608
	Seçilen değişkenler (10)	Tüm veri	68,854	0,272	0,369	0,366	79,463	89,193
		Geçerlik verisi	68,838	0,272	0,369	0,366	79,522	89,263
		Test verisi	69,063	0,271	0,368	0,371	79,254	89,124
	Önemli değişkenler (6)	Tüm veri	68,504	0,275	0,371	0,359	80,409	89,715
		Geçerlik verisi	68,428	0,275	0,371	0,357	80,443	89,757
		Test verisi	68,736	0,274	0,370	0,363	80,181	89,503
Üst Grup Örnekleme	Tüm Değişkenler (34)	Tüm veri	65,902	0,299	0,387	0,386	77,320	88,025
		Geçerlik verisi	65,654	0,300	0,388	0,382	77,548	88,396
		Test verisi	65,932	0,299	0,387	0,385	77,355	88,076
	Seçilen değişkenler (10)	Tüm veri	63,505	0,314	0,397	0,340	81,383	90,258
		Geçerlik verisi	63,463	0,315	0,397	0,339	81,461	90,348
		Test verisi	63,767	0,314	0,396	0,342	81,368	90,167
	Önemli değişkenler (6)	Tüm veri	63,083	0,319	0,400	0,330	82,667	90,964
		Geçerlik verisi	63,107	0,320	0,400	0,330	82,708	91,013
		Test verisi	63,376	0,319	0,398	0,333	82,571	90,774
Çalışma Örnekleme	Tüm Değişkenler (34)	Tüm veri	73,690	0,234	0,342	0,433	71,549	84,687
		Geçerlik verisi	73,685	0,234	0,343	0,433	71,614	84,765
		Test verisi	73,612	0,235	0,343	0,431	71,735	86,678
	Seçilen değişkenler (10)	Tüm veri	71,661	0,250	0,354	0,382	76,316	87,462
		Geçerlik verisi	71,614	0,250	0,354	0,381	76,338	87,489
		Test verisi	71,579	0,250	0,354	0,382	76,439	87,443
	Önemli değişkenler (5)	Tüm veri	70,582	0,259	0,360	0,353	79,117	89,019
		Geçerlik verisi	70,562	0,259	0,360	0,353	79,128	89,032
		Test verisi	70,441	0,259	0,360	0,352	79,181	88,939

DSY: Doğru sınıflama yüzdesi, OMH: Ortalama mutlak hata, HKOK: Hata kareler ortalamasının karekökü, GMH: Görelî mutlak hata, GHKK: Görelî hata karelerinin karekökü

Tablo 17 incelendiğinde Türkiye, alt grup, orta grup, üst grup ülkeler örnekleme ve çalışma örnekleme için tüm veri, çapraz geçerlik ve test verileri için yapılan analizlerde önemli 10 değişken ve önemli 10'dan az sayıda değişkenler kullanıldığında DSY'nin çok fazla değişmediği görülmektedir. Örneğin alt grup ülkeler örnekleminde 34 tane değişken için başarı yüzdesi 84,009 iken 10 tane değişken için başarı yüzdesi 82,914, 4 tane değişken için 81,696'dır. Buna göre değişken sayısının azalması DSY için büyük ölçüde bir değişikliğe neden olmamaktadır. Buradan çıkarılacak sonuç örneğin alt grup ülkeler örnekleme için 34 değişkenden elde edilen DSY'ye 4 değişkenle yaklaşılabilmektedir. Benzer sonuçların Türkiye, orta grup, üst grup ülkeler örnekleme ve çalışma örnekleme için de aynı olduğu görülmektedir.

Bununla birlikte önemli değişkenlerle yapılan LR analiziyle kurulan azaltılmış modelin DSY bakımından en başarılı olandan en başarısız olana sırası alt grup, çalışma örnekleme, orta grup, Türkiye, üst grup olarak sıralanmaktadır. Buna ek olarak alt grup ülkeler örnekleminde Kappa katsayısı değişken sayısının 34 ve 10 tane olduğu durumda 0,20-0,40 aralığında olduğu için kayda değer ancak değişken sayısının 4 tane olduğu durumda 0,20'in altında olduğu için düşük, GMH (görelî mutlak hata) ve GHKK (görelî hata karelerinin karekökü) değerleri ise yüksek çıkmıştır. Bunun nedeni olarak hem değişken sayısının azalmasının modeli zayıflattığı düşünülebilir hem de Tablo 13'te görüldüğü gibi düşük, orta, yüksek başarı kategorilerindeki öğrenci sayılarının dengeli dağılmaması gösterilebilir. Diğer yandan Kappa katsayısının Türkiye, orta grup, üst grup ülkeler örnekleme ve çalışma örnekleminde kayda değer olduğu görülmektedir. Tablodaki bulgulara göre değişken sayısının artması Kappa katsayısını bir miktar yükseltmiştir. Bu anlamda değişken sayısının fazla olduğu durumda model ile sınıflama sürecinde karışan tesadüfî hataların az olduğu söylenebilir. Bu sonuca göre değişken sayısının artmasının modeli bir miktar güçlendirdiği düşünülebilir. Bu durumda LR analiziyle en iyi doğru sınıflama performansının elde edildiği alt grup ülkeler örnekleme iken Kappa katsayısı, GMH ve GHKK ölçüleri bakımından en iyi modelin çalışma örnekleme olduğu söylenebilir. Bunun nedeninin çalışma örneklemindeki bireylerin puanlarının üç kategoriye göre ayrılmış puanlara göre dengeli dağılması düşünülebilir.

Üç Kategorili Başarı Durumu için Sınıflama ve Regresyon Ağacı Model Performansları

SRA veri madenciliği algoritması ile üç kategorili PISA okuduğunu anlama başarı durumu değişkenini yordayabilen değişkenlerden ilk sırada seçilen 10 değişken Şekil 15'te ve Modeller programında bulunan regresyon ağacından Türkiye'de beş, alt grupta yedi, orta grupta üç, üst grupta üç ve çalışma örneğinde dört tane seçilen 10'dan az sayıdaki önemli değişkenler elde edilip Tablo 11'de gösterilmişti. Burada ise, önce 34 bağımsız değişken kullanılarak, bağımlı değişken olan PISA okuduğunu anlama başarısı üç kategorili alınarak; tüm veri, çapraz geçerlik ve test verisi için farklı denemeler gerçekleştirilerek model performansları Weka programı kullanılarak hesaplanmıştır. Daha sonra, aynı hesaplamalar, üç kategorili PISA okuduğunu anlama başarı durumunu yordayan ilk sırada seçilen 10 bağımsız değişken ve bu 10 bağımsız değişkenden seçilen 10'dan az sayıdaki önemli değişkenler kullanılarak, performans hesaplamaları tekrar yapılmıştır.

Tablo 18

Üç Kategorili Başarı Durumu için SRA Model Performansları

			Mutlak Performanslar			Görelî Performanslar		
Değişken	Veri		DSY	OMH	HKOK	Kappa	GMH	GHKK
Türkiye Örnekleme	Tüm Değişkenler (34)	Tüm veri	73,057	0,260	0,360	0,458	76,619	87,538
		Geçerlik verisi	66,452	0,288	0,388	0,319	84,878	94,199
		Test verisi	65,994	0,293	0,389	0,301	86,290	94,571
	Seçilen değişkenler (10)	Tüm veri	71,657	0,272	0,368	0,423	79,989	89,442
		Geçerlik verisi	67,327	0,288	0,386	0,334	84,696	93,714
		Test verisi	65,780	0,294	0,389	0,302	86,712	94,523
Önemli değişkenler (5)	Tüm veri	69,704	0,281	0,375	0,381	82,749	90,973	
	Geçerlik verisi	66,540	0,290	0,386	0,317	85,558	93,644	
	Test verisi	65,308	0,295	0,390	0,295	86,859	94,816	
Alt Grup Örnekleme	Tüm Değişkenler (34)	Tüm veri	84,037	0,164	0,286	0,315	81,815	90,458
		Geçerlik Verisi	83,328	0,165	0,290	0,291	82,585	91,839
		Test verisi	83,277	0,165	0,290	0,272	82,126	91,559
	Seçilen değişkenler (10)	Tüm veri	83,793	0,167	0,289	0,281	83,551	91,412
		Geçerlik verisi	82,476	0,173	0,296	0,212	86,481	93,685
		Test verisi	82,570	0,175	0,298	0,208	87,414	93,855
Önemli değişkenler (7)	Tüm veri	82,693	0,176	0,296	0,199	87,886	93,754	
	Geçerlik verisi	82,465	0,174	0,296	0,200	86,821	93,759	
	Test verisi	82,466	0,175	0,297	0,195	87,508	93,780	
Orta Grup Örnekleme	Tüm Değişkenler (34)	Tüm veri	71,813	0,268	0,366	0,428	78,395	88,543
		Geçerlik verisi	68,288	0,279	0,378	0,354	81,669	91,560
		Test verisi	68,561	0,277	0,377	0,355	81,134	91,306
	Seçilen değişkenler (10)	Tüm veri	71,494	0,271	0,368	0,423	79,185	88,988
		Geçerlik verisi	67,564	0,282	0,381	0,343	82,638	92,107
		Test verisi	67,497	0,282	0,382	0,340	82,390	92,366
Önemli değişkenler (3)	Tüm veri	68,660	0,286	0,378	0,363	83,681	91,480	
	Geçerlik verisi	67,543	0,288	0,381	0,342	84,243	92,256	
	Test verisi	67,481	0,291	0,383	0,344	85,015	92,718	
Üst Grup Örnekleme	Tüm Değişkenler (34)	Tüm veri	68,274	0,301	0,388	0,427	77,864	88,241
		Geçerlik verisi	62,709	0,323	0,407	0,322	83,693	92,602
		Test verisi	62,595	0,328	0,408	0,322	84,844	92,850
	Seçilen değişkenler (10)	Tüm veri	62,896	0,328	0,405	0,328	84,974	92,182
		Geçerlik verisi	60,922	0,331	0,410	0,293	85,710	93,236
		Test verisi	61,299	0,335	0,410	0,297	86,738	93,446
Önemli değişkenler (3)	Tüm veri	62,515	0,328	0,405	0,319	84,943	92,166	
	Geçerlik verisi	61,447	0,330	0,408	0,300	85,281	92,891	
	Test verisi	61,157	0,331	0,408	0,293	85,781	92,904	
Çalışma Örnekleme	Tüm Değişkenler (34)	Tüm veri	74,088	0,248	0,352	0,441	75,903	87,123
		Geçerlik verisi	72,294	0,254	0,360	0,399	77,531	88,935
		Test verisi	71,637	0,257	0,361	0,385	78,386	89,101
	Seçilen değişkenler (10)	Tüm veri	73,146	0,253	0,356	0,419	77,476	88,021
		Geçerlik verisi	71,049	0,260	0,363	0,367	79,512	89,717
		Test verisi	70,548	0,270	0,369	0,345	82,323	91,061
Önemli değişkenler (4)	Tüm veri	71,265	0,262	0,362	0,368	80,018	89,453	
	Geçerlik verisi	70,639	0,265	0,365	0,356	80,931	90,236	
	Test verisi	70,596	0,272	0,369	0,360	83,051	91,164	

DSY: Doğru sınıflama yüzdesi, OMH: Ortalama mutlak hata, HKOK: Hata kareler ortalamasının karekökü, GMH: Görelî mutlak hata, GHKK: Görelî hata karelerinin karekökü

Tablo 18 incelendiğinde Türkiye, alt grup, orta grup, üst grup ülkeler örnekleme ve çalışma örnekleme için tüm veri, çapraz geçerlik ve test verileri için yapılan analizlerde yordayıcı ilk 10 değişken ve önemli 10'dan az sayıda değişken kullanıldığında doğru sınıflama yüzdesinin (DSY) Türkiye, alt grup, orta grup ülkeler örnekleme ve çalışma örnekleminde önemli düzeyde değişmediği görülmektedir. Örneğin çalışma örnekleminde 34 tane değişken için başarı yüzdesi 74,088 iken 10 tane değişken için başarı yüzdesi 73,046, 4 tane değişken için 71,265'tir. Burada, değişken sayısının azalması DSY için büyük ölçüde bir değişikliğe neden olmamaktadır. Buradan çıkarılacak sonuç örneğin çalışma örnekleme için 34 değişkenden elde edilen DSY'ye 4 değişkenle yaklaşılabilmektedir. Benzer sonuçların Türkiye, alt grup ve orta grup ülkeler örnekleme için de aynı olduğu görülmektedir. Ancak bu durum üst grup ülkeler örnekleme için aynı değildir. Üst grup ülkeler örnekleminde değişken sayısının azalması DSY'de önemli düzeyde azalmaya neden olmuştur. Örneğin üst grup ülkeler örnekleminde 34 tane değişken için başarı yüzdesi 68,274 iken 10 tane değişken için başarı yüzdesi 62,896, 3 tane değişken için 61,157'dir. Burada, değişken sayısının azalması DSY için önemli ölçüde bir değişikliğe neden olmaktadır.

Bununla birlikte önemli değişkenlerle yapılan SRA analiziyle kurulan azaltılmış modelin DSY bakımından en başarılı olandan en başarısız olana sırası alt grup, çalışma örnekleme, Türkiye, orta grup, üst grup olarak sıralanmaktadır. Buna ek olarak alt grup ülkeler örnekleminde Kappa katsayısı değişken sayısının 34 ve 10 tane olduğu durumda 0,20-0,40 arasında olduğu için kayda değer ancak değişken sayısının 7 tane olduğu durumda 0,20'in altında olduğu için düşük, GMH (görelî mutlak hata) ve GHKK (görelî hata karelerinin karekökü) değerleri ise yüksek çıkmıştır. Bunun nedeni hem alt gruptaki öğrencilerin başarı kategorilerine dengeli dağılmaması hem de değişken sayısındaki azalmanın modeli zayıflatması olarak düşünülebilir. Diğer yandan Kappa katsayısının Türkiye örnekleme, orta grup, üst grup ülkeler örnekleme ve çalışma örnekleminde kayda değer olduğu ve alt grup ülkeler örnekleminde daha yüksek olduğu görülmektedir. Tablodaki bulgulara göre değişken sayısının artması Kappa katsayısını bir miktar yükseltmiştir. Bu anlamda değişken sayısının fazla olduğu durumda model ile sınıflama sürecinde karışan tesadüfî hataların az olduğu söylenebilir. Bunun

nedeninin deęişken sayısının atmasının modeli bir miktar güçlendirdiđi düşünülebilir. Bu durumda SRA yöntemiyle yapılan analizde en iyi doğru sınıflama performansının elde edildiđi alt grup ülkeler örnekleme iken Kappa katsayısı, GMH ve GHKK ölçüleri bakımından en iyi modelin Türkiye örnekleme ve çalışma örnekleme olduđu söylenebilir. Bunun nedeninin Türkiye örnekleme ve çalışma örneklemindeki öğrencilerin puanlarının üç kategoriye göre ayrılmış puanlara göre dengeli olarak paylaşılmasından kaynaklı olduđu düşünülebilir.

Üç Kategorili Başarı Durumu için Rastgele Orman Model Performansları

RO veri madenciliđi yöntemi ile üç kategorili PISA okuduđunu anlama başarı durumu deęişkenini yordayan deęişkenlerden ilk sırada seçilen 10 yordayıcı bağımsız deęişken Şekil 16'da ve bu 10 deęişkenden yordayıcılığı en düşük olan deęişkenleri çıkartarak azaltılmış model ile WEKA programında sınıflama performansının 10 deęişkenle elde edilen performansa yakın olacak şekilde deęişken azaltarak ayarlama yapıldıktan sonra 10'dan daha az sayıdaki önemli deęişkenler elde edilip Tablo 12'de gösterilmişti. Burada ise, önce 34 bağımsız deęişken kullanılarak, bağımlı deęişken olan PISA okuduđunu anlama başarısı üç kategorili alınarak; tüm veri, çapraz geçerlik ve test verisi için farklı denemeler gerçekleştirilerek model performansları Weka programı kullanılarak hesaplanmıştır. Daha sonra, aynı hesaplamalar, üç kategorili PISA okuduđunu anlama başarı durumunu yordayan ilk sırada seçilen 10 bağımsız deęişken ve bu 10 bağımsız deęişkenden seçilen 10'dan az sayıdaki önemli deęişkenler kullanılarak, performans hesaplamaları tekrar yapılmıştır.

Tablo 19

Üç Kategorili Başarı Durumu için RO Model Performansları

		Mutlak Performanslar			Bağıl Performanslar			
Değişken	Veri	DSY	OMH	HKOK	Kappa	GMH	GHKK	
Türkiye Örnekleme	Tüm Değişkenler (34)	Tüm veri	100	0,100	0,134	1,000	29,441	32,653
		Geçerlik verisi	70,491	0,274	0,362	0,399	80,564	87,849
		Test verisi	70,197	0,275	0,364	0,393	81,057	88,333
	Seçilen değişkenler (10)	Tüm veri	100	0,106	0,143	1,000	31,437	34,728
		Geçerlik verisi	65,097	0,292	0,384	0,291	85,860	93,126
		Test verisi	65,480	0,292	0,383	0,303	85,989	92,994
	Önemli değişkenler (8)	Tüm veri	100	0,109	0,146	1,000	32,289	35,521
		Geçerlik verisi	63,041	0,299	0,392	0,249	87,972	95,262
		Test verisi	64,022	0,298	0,391	0,271	87,657	94,837
Alt Grup Örnekleme	Tüm Değişkenler (34)	Tüm veri	100	0,057	0,101	1,000	28,766	32,046
		Geçerlik Verisi	84,336	0,157	0,271	0,316	78,494	85,856
		Test verisi	84,216	0,158	0,272	0,313	78,774	85,666
	Seçilen değişkenler (10)	Tüm veri	99,976	0,061	0,108	1,000	30,883	34,146
		Geçerlik verisi	82,973	0,168	0,287	0,242	83,765	90,726
		Test verisi	83,068	0,169	0,287	0,241	84,371	90,649
	Önemli değişkenler (6)	Tüm veri	99,791	0,063	0,114	0,993	31,857	36,045
		Geçerlik verisi	81,779	0,172	0,299	0,211	86,046	94,563
		Test verisi	81,724	0,172	0,297	0,202	86,005	93,683
Orta Grup Örnekleme	Tüm Değişkenler (34)	Tüm veri	100	0,097	0,132	1,000	28,423	32,082
		Geçerlik verisi	72,051	0,265	0,354	0,432	77,444	85,761
		Test verisi	71,816	0,266	0,355	0,425	77,749	86,011
	Seçilen değişkenler (10)	Tüm veri	99,967	0,107	0,142	0,999	31,287	34,475
		Geçerlik verisi	66,479	0,291	0,381	0,311	85,156	92,224
		Test verisi	66,449	0,292	0,383	0,303	85,449	92,780
	Önemli değişkenler (8)	Tüm veri	99,908	0,109	0,146	0,998	31,963	35,281
		Geçerlik verisi	64,627	0,298	0,389	0,274	87,035	94,147
		Test verisi	65,115	0,298	0,389	0,282	87,104	94,129
Üst Grup Örnekleme	Tüm Değişkenler (34)	Tüm veri	100	0,114	0,144	1,000	29,611	32,883
		Geçerlik verisi	66,686	0,312	0,386	0,395	80,721	87,947
		Test verisi	66,536	0,313	0,386	0,388	81,126	88,052
	Seçilen değişkenler (10)	Tüm veri	99,987	0,123	0,154	0,999	31,773	35,047
		Geçerlik verisi	59,684	0,334	0,412	0,267	86,406	93,734
		Test verisi	60,660	0,334	0,410	0,284	86,503	93,294
	Önemli değişkenler (8)	Tüm veri	99,987	0,122	0,155	0,999	31,687	35,297
		Geçerlik verisi	59,002	0,334	0,415	0,259	86,314	94,548
		Test verisi	59,186	0,333	0,414	0,261	86,273	94,407
Çalışma Örnekleme	Tüm Değişkenler (34)	Tüm veri	100	0,088	0,126	1,000	26,941	31,178
		Geçerlik verisi	74,938	0,240	0,337	0,457	73,313	83,339
		Test verisi	74,736	0,242	0,339	0,453	73,878	83,598
	Seçilen değişkenler (10)	Tüm veri	99,978	0,096	0,135	0,999	29,393	33,384
		Geçerlik verisi	70,754	0,261	0,360	0,360	79,789	88,958
		Test verisi	70,587	0,262	0,361	0,358	80,099	88,995
	Önemli değişkenler (6)	Tüm veri	99,876	0,097	0,139	0,997	29,591	34,437
		Geçerlik verisi	69,158	0,262	0,369	0,331	80,024	91,218
		Test verisi	68,816	0,263	0,369	0,324	80,341	91,193

DSY: Doğru sınıflama yüzdesi, OMH: Ortalama mutlak hata, HKOK: Hata kareler ortalamasının karekökü, GMH: Görel mutlak hata, GHKK: Görel hata karelerinin karekökü

Tablo 19 incelendiğinde Türkiye, alt grup, orta grup, üst grup ülkeler örnekleme ve çalışma örnekleme için tüm veri, çapraz geçerlik ve test verileri için yapılan analizlerde yordayıcı ilk 10 değişken ve önemli 10'dan az sayıda değişkenler kullanıldığında DSY'nin tüm veri için değişmediği, çapraz geçerlik ve test verisi için ise çok az miktarda değiştiği görülmektedir. Örneğin Türkiye örnekleminde tüm veri ile oluşturulan modelde 34 tane değişken için başarı yüzdesi 100 iken 10 ve 8 tane değişken için yine başarı yüzdesi 100'dür. Bu durumda 34 tane değişkenden 8 tane değişkene düştüğünde tüm veri için DSY değişmemekte, çapraz geçerlik ve test kümesi için DSY'nin bir miktar azaldığı görülmektedir. Buna göre değişken sayısının azalması tüm veri ile oluşturulan modelde DSY'de önemli bir değişikliğe neden olmamaktadır. Buradan çıkarılacak sonuç örneğin Türkiye için 34 değişkenden elde edilen DSY'ye 8 değişkenle ulaşılabilmesidir. Benzer sonuçların alt grup, orta grup, üst grup ülkeler örnekleme ve çalışma örnekleme için de hemen hemen aynı olduğu görülmektedir. Bununla birlikte grupların tamamında çapraz geçerlik ve test verisinden elde edilen DSY, tüm veriden elde edilen DSY'ye göre düşük çıkmıştır. Bunun sonucu olarak RO yönteminin ilişki belirlemedeki performansının çapraz geçerlik ve tahmin performansına göre daha iyi olduğu görülmektedir. Ayrıca, önemli değişkenlerle yapılan RO analiziyle kurulan azaltılmış modelin tüm veri çapraz geçerlik ve test verisi bakımından DSY en başarılı olandan en başarısız olana sırası alt grup, çalışma örnekleme, orta grup, Türkiye ve üst grup olarak sıralanmaktadır. Buna ek olarak Kappa katsayısı Türkiye, alt grup, orta grup, üst grup ülkeler örnekleme ve çalışma örnekleminde 34 tane değişken ve tüm veri için mükemmel düzeydedir. Diğer yandan, 34 tane değişken için çapraz geçerlik ve test verisi için Türkiye, alt grup, üst grup ülkeler örnekleminde makul düzeyde iken orta grup ve çalışma örnekleminde orta düzeydedir. Değişken sayısı azaltıldığında Türkiye, alt grup, orta grup, üst grup ülkeler örnekleme ve çalışma örnekleminde tüm veri için Kappa katsayısı hemen hemen değişmezken çapraz geçerlik ve test verisi üzerinden hesaplanan Kappa katsayısında bir miktar düşme gözlenmektedir. Gerek tüm veri, çapraz geçerlik ve test verisi bakımından gerekse değişken sayısı azaltılarak oluşturulan model bakımından Kappa katsayısının en yüksek çıktığı grup çalışma örneklemidir. Bunun nedeni olarak; çalışma örnekleminin hacminin diğer gruplardan daha geniş olması bu model için avantajlı olduğunu gösterilebilir. Bu durumda tüm gruplarda RO yöntemiyle kurulan modelde değişken sayısı 34 iken

tüm veri üzerinden hesaplanan Kappa katsayısı mükemmel düzeyde iken çapraz geçerlik ve test verisi üzerinden hesaplanan Kappa katsayısı tüm veriye göre düşük çıkmıştır. Ayrıca değişken sayısı azalırken gruplarda tüm veri için Kappa katsayısı hemen hemen hiç değişmez iken çapraz geçerlik ve test verisi için düşmüştür. Böylece tüm gruplar için modelin değişken azaltılmasından önemli ölçüde etkilendiği söylenebilir. Bu sonuçlar modelin bir sınırlılığı olarak düşünülebilir.

Üç kategorili PISA okuduğunu anlama başarısını yordama da önemli değişkenleri belirlemede kullanılan yöntemlerin tahmin performansı ve Kappa istatistiği gruplara göre incelendiğinde; Türkiye örnekleminde en iyi performans gösteren LR ve SRA yöntemleridir. Diğer yandan RO yöntemi diğer yöntemlere göre tahmin performansı bakımından düşüktür. Alt grup ülkeler örnekleminde en yüksek ve gerçeğe uygun tahmin performansına sahip yöntemin SRA olduğu ve RO yönteminin ise iyi düzeyde tahmin performansına sahip olduğu saptanmıştır. Ancak LR yöntemi gerçeğe uygun tahmin performansı vermemiştir. Orta grup ülkeler örneklemini için en iyi performans gösteren yöntemin LR yöntemi olduğu ve SRA yönteminin de iyi düzeyde tahmin performansına sahip olduğu belirlenmiştir. Ancak orta grup ülkeler örnekleminde RO yönteminin diğer yöntemlere göre tahmin performansı düşük çıkmıştır. Üst grup ülkeler örnekleminde tahmin performansı en yüksek çıkan yöntemin LR yöntemi olduğu belirlenmiştir. Bunu daha sonra, SRA yöntemi takip ederken en düşük tahmin performansına sahip RO yöntemidir. Türkiye, alt grup, orta grup, üst grup ülkeler örneklemini ve çalışma örneklemini ile üç yöntemden oluşturulan modeller için en düşük tahmin performansının elde edildiği grup üst grup ülkeler örnekleminidir. Bunun nedeni olarak da üst grup ülkeler örnekleminin puanlar dağılımından kaynaklı olduğu düşünülebilir. Çalışma örneklemini için en yüksek tahmin performansına sahip yöntemlerin LR yöntemi ve SRA yöntemleri olduğu saptanmıştır. RO yönteminin ise tahmin performansının bir miktar düşük olduğu saptanmış ancak kabul edilebilir bir performans düzeyinde olduğu söylenebilir. Üç kategorili PISA okuduğunu anlama başarısını yordama da önemli değişkenleri belirlemede kullanılan üç yöntem arasından genellikle LR ve SRA yöntemlerinin iyi düzeyde tahmin performansına sahip olduğu, RO yönteminin ise daha düşük tahmin performansına sahip olduğu saptanmıştır. Sonuç olarak iki ve üç kategorili başarı

durumu için geçerlik ve test verisi üzerinden oluşturulan modellerde genellikle RO yöntemi diğer yöntemlere göre daha düşük tahmin performansı göstermiştir.

İki ve üç kategorili başarı durumu için tüm veri, geçerlik verisi ve test verisi üzerinden LR, SRA ve RO yöntemleriyle oluşturulan modellerin doğru sınıflama performansı karşılaştırıldığında iki kategorili başarı durumu için doğru sınıflama yüzdesinin daha yüksek çıktığı görülmüştür. İki kategorili başarı durumu için tüm veri üzerinden hesaplanan doğru sınıflama performansı en yüksek RO yöntemi iken diğer yöntemlerinde doğru sınıflama performansları yüksek çıkmıştır. İki kategorili başarı durumu için geçerlik verisi ve test verisi için üç yöntemin tamamında doğru sınıflama performansı yüksek ve birbirine yakın çıkmıştır. Üç kategorili başarı durumu için tüm veri üzerinden hesaplanan doğru sınıflama performansı en yüksek çıkan RO yöntemi iken diğer yöntemlerinde doğru sınıflama performansları kabul edilebilir seviyede çıkmıştır. Üç kategorili başarı durumunda geçerlik verisi için üç yöntemin tamamında doğru sınıflama performansı kabul edilebilir seviyede ve birbirine yakın çıkmıştır. Üç kategorili başarı durumunda test verisi için LR ve RO yönteminde doğru sınıflama performansı birbirine yakın ve kabul edilebilir seviyenin üstünde çıkarken SRA yönteminde daha düşük ve kabul edilebilir seviyede çıkmıştır. Diğer yandan iki kategorili ve üç kategorili başarı durumu için değişken azaltılması LR ve SRA yöntemlerinde doğru sınıflama yüzdesinde çok az miktarda azalma olurken RO yönteminde daha fazla azalmaya neden olmuştur. Sonuç olarak değişken azaltılması RO yönteminin performansını daha fazla etkilemiştir. Diğer yandan İki kategorili PISA okuduğunu anlama başarı durumu için alt grup ülkeler örneğinde üç yöntemin hiçbiri gerçeğe uygun tahmin performansı vermemiştir. Ancak üç kategorili PISA okuduğunu anlama başarı durumu için RO ve SRA yöntemlerinin gerçeğe uygun tahmin performansı verdiği saptanmıştır. Bu durumda alt grupta üç kategorili başarı durumuna göre yapılan analizler daha doğru sonuç vermiştir.

İki ve üç kategorili başarı durumu için yapılan analizler sonucunda 34 adet bağımsız değişken yerine iki ile sekiz adet bağımsız değişken aralığında değişkenin kullanılmasının yeterli olacağı bulgusu bu tez çalışmasının önemli bir sonucu olarak ortaya çıkmaktadır.

Bölüm 5

Sonuç, Tartışma ve Öneriler

Bu bölümde, araştırmadan elde edilen sonuçlara göre araştırmanın alan yazındaki diğer araştırmalardan farkı ve benzerliği ortaya çıkarılmış ve alan yazına getirdiği yenilik belirlenmiştir. Buna ilave olarak gelecekte yapılacak araştırmalara yönelik önerilerde bulunulmuştur.

Sonuç

Birinci alt probleme ilişkin sonuçlar. PISA 2018 iki kategorili okuduğunu anlama başarı durumunu yordamak için LR yöntemi ile yapılan analizlerde grupların tamamı için önemli ortak değişkenlerin PISA testinin zorluk algısı, ebeveynlerin en yüksek mesleki statüsü ve evdeki eğitimsel eşyalar olarak belirlenmiştir. Diğer yandan, LR yöntemiyle yapılan analizlerde okuma keyfi değişkeni alt grup, orta grup ve üst grup ülkeler örnekleminde, öğrenciden beklenen mesleki statü değişkeni orta grup ve üst grup ülkeler örnekleminde, bilgi iletişim teknolojileri kaynakları değişkeni alt grup ve orta grup ülkeler örnekleminde, anne eğitim düzeyi değişkeni alt grup ülkeler örneklemini ve çalışma örnekleminde, öz okuma yetkinlik algısı değişkeni üst grup ülkeler örneklemini ve çalışma örnekleminde önemli ortak değişken olarak ortaya çıkmıştır. Baba eğitim düzeyi değişkeni sadece alt grup ülkeler örnekleminde 2018 PISA okuduğunu anlama başarısını yordayan önemli değişken olarak belirlenmiştir.

İki kategorili başarı durumu için SRA yöntemi ile yapılan analizlerde PISA testinin zorluk algısı değişkeni alt grup, orta grup, üst grup ülkeler örneklemini ve çalışma örnekleminde, okuma keyfi değişkeni orta grup, üst grup ülkeler örneklemini ve çalışma örnekleminde, Sosyo-ekonomik durum değişkeni orta grup ülkeler örneklemini ve çalışma örnekleminde 2018 PISA okuduğunu anlama başarısını yordayan önemli ortak yordayıcılar olarak belirlenmiştir.

İki kategorili başarı durumu için RO yöntemi ile yapılan analizlerde öğrenci rekabeti değişkeni orta grup, üst grup ülkeler örneklemini ve çalışma örnekleminde, okuma keyfi değişkeni alt grup ülkeler örneklemini ve çalışma örnekleminde, Öğretmenin eğitimi yönlendirmesi değişkeni alt grup, orta grup ülkeler örneklemini ve çalışma örnekleminde 2018 PISA okuduğunu anlama başarısını yordayan önemli ortak yordayıcılar olarak saptanmıştır.

Türkiye örnekleminde iki kategorili başarı durumu için LR yöntemi ile oluşturulan modelde 2018 PISA okuduğunu anlama başarısını yordayan değişkenlerin önem derecesi en fazla olandan en az olana doğru sırası okuma keyfi, öğrenciden beklenen mesleki statü, PISA testinin zorluk algısı, ebeveynlerin en yüksek mesleki statüsü, evdeki eğitimsel eşyalar biçimindedir. SRA yöntemi ile oluşturulan modelde okuduğunu anlama başarısını yordayan değişkenlerin önem sırası okuma keyfi, öğrenciden beklenen mesleki statü ve sosyo-ekonomik durum değişkeni biçimindedir. RO yöntemleri ile oluşturulan modelde ise değişkenlerin önem sırası ileri düzey görevlere motivasyon, başarısızlık korkusu, yaşamın anlamı, öz okuma yetkinlik algısı, okuma keyfi ve öğrenci rekabeti olarak sıralanmıştır.

İkinci alt probleme ilişkin sonuçlar. PISA 2018 üç kategorili okuduğunu anlama başarı durumunu yordamak için LR yöntemi ile yapılan analizlerde grupların tamamı için önemli ortak değişkenlerin evdeki eğitimsel eşyalar ve PISA testinin zorluk algısı olduğu belirlenmiştir. Diğer yandan, ebeveynlerin en yüksek mesleki statüsü değişkeni orta grup, üst grup ülkeler örneklemini ve çalışma örnekleminde, bilgi iletişim teknolojileri kaynakları değişkeni alt grup, orta grup ülkeler örneklemini ve çalışma örnekleminde, öğrenciden beklenen mesleki statü değişkeni orta grup, üst grup ülkeler örneklemini ve çalışma örnekleminde, okuma keyfi değişkeni orta grup ve üst grup ülkeler örnekleminde PISA okuduğunu anlama başarısını yordayan önemli ortak yordayıcı olarak bulunmuştur.

Üç kategorili başarı durumu için SRA yöntemi ile yapılan analizlerde 2018 PISA okuduğunu anlama testinin zorluk algısı değişkeni orta grup, üst grup ülkeler örneklemini ve çalışma örnekleminde, evdeki eğitimsel eşyalar değişkeni orta grup ülkeler örneklemini ve çalışma örnekleminde, okuma keyfi değişkeni alt grup ve üst grup ülkeler örnekleminde önemli ortak yordayıcı olarak bulunmuştur. Öğrenciden beklenen mesleki statü değişkeni ise sadece orta grup ülkeler örnekleminde önemli yordayıcı olarak saptanmıştır.

Üç kategorili başarı durumu için RO yöntemi ile yapılan analizde haftalık test dili öğrenme süresi değişkeni alt grup, orta grup, üst grup ülkeler örneklemini ve çalışma örnekleminde, okuma keyfi değişkeni alt grup, orta grup ve çalışma örnekleminde, PISA testinin zorluk algısı değişkeni, alt grup ülkeler örneklemini ve

çalışma örnekleminde önemli ortak yordayıcı olarak bulunmuştur. Öğretmen geri bildirim, Öğretmen desteği, Öğretmenin okumaya teşviki değişkenleri orta grup ülkeler örnekleminde önemli yordayıcılar olarak ortaya çıkmıştır.

Türkiye örnekleminde üç kategorili başarı durumu için LR yöntemi ile oluşturulan modelde 2018 PISA okuduğunu anlama başarısını yordayan değişkenlerin önem derecesi en fazla olandan en az olana doğru sırası evdeki eğitimsel eşyalar, PISA testinin zorluk algısı, ebeveynlerin en yüksek mesleki statüsü, bilgi iletişim teknolojileri kaynakları, öğrenciden beklenen mesleki statü biçimindedir. SRA yöntemi ile oluşturulan modelde okuduğunu anlama başarısını yordayan değişkenlerin önem sırası PISA testinin zorluk algısı, ebeveynlerin en yüksek mesleki statüsü, öğrenciden beklenen mesleki statü, okuma keyfi ve evdeki eğitimsel eşyalar değişkeni biçimindedir. RO yöntemi ile oluşturulan modelde ise değişkenlerin önem sırası okuma keyfi, Öğretmen geri bildirim, Öğretmenin okumaya teşviki, yaşamın anlamı, Öğretmen desteği, öğrenci rekabeti, PISA testinin zorluk algısı, başarısızlık korkusu olarak sıralanmıştır.

Üçüncü alt probleme ilişkin sonuçlar. Türkiye örneklemini, alt grup, orta grup ve üst grup ülkeler örneklemini ve çalışma örnekleminde iki kategorili PISA okuduğunu anlama başarı durumunu yordama da kullanılan LR, SRA ve RO yöntemlerinin sınıflama ve tahmin performansları karşılaştırıldığında yapılan analizlerde tüm veri bakımından en yüksek doğru sınıflama yüzdesine sahip yöntemin RO yöntemi olduğu saptanmıştır. Tüm veri için grupların tamamında LR ve SRA yönteminden elde edilen doğru sınıflama yüzdeleri birbirine yakın ve yüksek seviyede çıkmıştır. Diğer yandan grupların tamamı için geçerlik ve test verisi için RO yönteminden hesaplanan Kappa katsayıları düşük çıkmıştır. Bu nedenle grupların tamamında iki kategorili başarı durumunu yordama da RO yöntemi gerçeğe uygun sınıflama yapamamıştır. Ayrıca, alt grup ülkeler örnekleminde iki kategorili başarı durumunu yordama da kullanılan üç yöntemden elde edilen sonuçların Kappa katsayıları düşük çıkmıştır. Sonuç olarak, veri madenciliğinde kullanılan modelin tahmin performansının önemi dikkate alındığında alt grup ülkeler örneklemini hariç diğer grupların tamamında iki kategorili başarı durumunu yordama da LR ve SRA yöntemleri gerçeğe uygun sınıflama yaptıkları için tahmin performansları yüksek çıkmıştır.

Türkiye, alt grup, orta grup, üst grup ülkeler örnekleme ve çalışma örnekleminde üç kategorili PISA okuduğunu anlama başarı durumunu yordama da kullanılan LR, SRA ve RO yöntemlerinin sınıflama ve tahmin performansları karşılaştırıldığında yapılan analizlerde grupların tamamında tüm veri için en yüksek doğru sınıflama yüzdesine sahip yöntemin RO yöntemi olduğu saptanmıştır. Tüm veri için grupların tamamında LR ve SRA yönteminden elde edilen doğru sınıflama yüzdeleri birbirine yakın kabul edilebilir düzeyde çıkmıştır. Geçerlik ve test verisi bakımından LR ve SRA yöntemlerini tahmin performansı kabul edilebilir düzeyde iken RO yöntemi diğer yöntemlere göre bir miktar düşük çıkmıştır. Diğer yandan, alt grup verileriyle iki kategorili başarı durumu için oluşturulan modellerde Kappa katsayısı düşük iken üç kategorili başarı durumu için oluşturulan modellerde Kappa katsayısı makul düzeyde çıkmıştır.

Bu çalışmada SPSS Modeller programında bulunan Lojistik Regresyon, Sınıflama ve Regresyon Ağacı ve Rastgele Orman algoritması kullanılarak başarıyı yordayan önemli değişkenler belirlendikten sonra, Weka programı kullanılarak en fazla sekiz bağımsız değişken ile elde edilen tahmin performanslarının 34 bağımsız değişken ile elde edilenlere yakın düzeyde olduğu belirlenmiştir. Böylece, başarıyı yordamak için hangi sınıflama modeli kullanılırsa kullanılsın, 34 değişkene gerek kalmadan iki ile sekiz adet arasında değişken kullanarak yüksek performansa sahip tahmin modellerinin elde edilebildiği gösterilmiştir.

Tartışma

İki kategorili başarı durumu için LR yöntemi ile yapılan analizde grupların tamamında önemli ortak değişkenlerin PISA testinin zorluk algısı, ebeveynlerin en yüksek mesleki statüsü ve evdeki eğitimsel eşyalar olduğu belirlenmiştir. Ebeveynlerin en yüksek mesleki statüsü değişkeni ile ilgili elde edilen sonucun, alan yazında mesleki statüsü yüksek ebeveynlere sahip olan öğrencilerin okuduğunu anlama becerisinin daha yüksek olduğuna yönelik araştırmalar (Vilenius-Tuohimaa ve ark., 2008; Gülleroğlu ve ark., 2014; Urfalı Dadandı ve ark., 2018) bu araştırmadaki sonuç ile benzerlik göstermektedir. Evdeki eğitimsel eşyalar değişkeni ile ilgili elde edilen sonuç; öğrencinin evdeki çalışma odası ve çalışma masası gibi ders çalışma ortamıyla ilgili evdeki eğitimsel eşyaların okuma

başarısını artırdığına yönelik Güzle Kayır (2012) tarafından yapılan araştırma bulguları ile benzerlik göstermektedir. Okuma keyfi değişkeni alt grup, orta grup ve üst grup ülkeler örnekleminde önemli ortak yordayıcı olarak belirlenmiştir. Tavşancıl ve arkadaşları (2019) tarafından yapılan araştırmada okuma keyfi değişkeninin PISA okuduğunu anlama başarısını önemli ölçüde etkilediğine yönelik bulguları bu araştırma sonuçları ile uyumludur. Bilgi iletişim teknolojileri kaynakları değişkeni alt grup ve orta grup ülkeler örnekleminde önemli ortak değişken olarak görülmekle birlikte alt grup ülkeler örnekleminde daha fazla öneme sahiptir. Bu sonuç, Urfalı Dadandı ve arkadaşları (2018) tarafından yapılan araştırmada BİT kaynaklarının okuduğunu anlama başarısını anlamlı düzeyde yordamasına yönelik elde edilen bulgu ile uyumludur. Anne eğitim düzeyi değişkeni alt grup ülkeler örnekleminde ve çalışma örnekleminde önemli ortak yordayıcı olarak çıkmıştır. Bu değişken bakımından alt gruptaki ülkeler örnekleminde çalışma örneklemindeki ülkelere benzerlik göstermektedir. Bu sonuçların Urfalı Dadandı ve ark. (2018) tarafından yapılan çalışmada anne eğitim düzeyinin PISA okuduğunu anlama başarısını anlamlı düzeyde yordamasına ilişkin bulgu ile tutarlı olduğu belirlenmiştir.

Yordayıcı değişkenler bakımından alt grup, orta grup ve üst grup ülkeler örnekleminde karşılaştırılacak olursa; grupların tamamı birbirinden farklılık göstermektedir. Örneğin LR yöntemi ile 2018 PISA okuduğunu anlama başarısını yordayan önemli değişkenler bakımından gruplar karşılaştırıldığında PISA testinin zorluk algısı, ebeveynlerin en yüksek mesleki statüsü ve evdeki eğitimsel eşyalar değişkenleri bakımından benzerlik göstermekte anne eğitim düzeyi, baba eğitim düzeyi, öz okuma zorluk algısı, öğrenciden beklenen mesleki statü, bilgi iletişim teknolojileri kaynakları ve öz okuma yetkinlik algısı değişkenleri bakımından farklılık göstermiştir. En çok farklılık gösteren grup ise alt grup ülkeler örnekleminde. Bu sonuca göre farklı başarı düzeyine sahip gruplarda PISA okuduğunu anlama başarısını yordayan önemli değişkenlerin farklılık gösterdiği saptanmıştır.

İki kategorili başarı durumu için SRA yöntemi ile yapılan analizlerde PISA testinin zorluk algısı değişkeninin önem derecesinin üst grup ülkeler örnekleminde diğer gruplara göre daha fazla olması nedeniyle üst grup ülkeler örneklemindeki öğrencilerin PISA testine yönelik zorluk algılarının daha fazla olduğu belirlenmiştir.

Okuma keyfi deęişkeni orta grup, üst grup ülkeler örnekleme ve çalışma örnekleminde önemli ortak yordayıcı olarak saptanmıştır. Bu deęişkenin en çok da üst grupta önemli olduęu gözlenmiştir. Sosyo-ekonomik durum deęişkeninin orta grup ülkeler örneklemindeki önem derecesinin çalışma örneklemine göre daha fazla olduęu saptanmıştır. Arıcı ve Altıntaş (2014) tarafından yapılan araştırmada sosyo-ekonomik durum deęişkeninin öğrencilerin PISA 2009 okuduęunu anlama başarısının anlamlı bir yordayıcısı olduęuna yönelik bulgusu bu araştırmamızın sonuçları ile benzerlik göstermektedir. Yordayıcı deęişkenler bakımından alt grup, orta grup ve üst grup ülkeler örneklemleri karşılaştırılacak olursa; orta grup ile üst grup arasında üç tane deęişken farklılık gösterirken alt grup ile orta veya üst grup arasında dört tane deęişken farklılık göstermektedir. Bu durumda en çok farklılık gösteren alt gruptur. Bu sonuca göre SRA yönteminde de LR yönteminde olduęu gibi farklı başarı düzeyine sahip gruplarda PISA okuduęunu anlama başarısını yordayan önemli deęişkenlerin farklılık gösterdięi belirlenmiştir.

İki kategorili başarı durumu için RO yöntemi ile yapılan analizlerde öğrenci rekabeti deęişkeni orta grup, üst grup ülkeler örnekleme ve çalışma örnekleminde 2018 PISA okuduęunu anlama başarısını yordayan önemli ortak deęişken olarak ortaya çıkmıştır. Öğrenci rekabeti deęişkeninin okuduęunu anlama başarısını yordama da en önemli olduęu üst grup ülkeler örnekleme iken öğrenci rekabetinin önemsiz olduęu alt grup ülkeler örneklemidir. Özkan (2020) tarafından yapılan araştırmada öğrenci rekabetinin öğrencilerin akademik başarısının anlamlı bir yordayıcısı olduęuna yönelik bulgusu araştırma sonucu ile benzerlik göstermektedir. Okuma keyfi deęişkeni alt grup ülkeler örnekleme ve çalışma örnekleminde aynı önem derecesine sahip önemli ortak yordayıcı olarak saptanmıştır. Öğretmenin eğitimi yönlendirmesi deęişkeni alt grup, orta grup ülkeler örnekleme ve çalışma örnekleminde önemli ortak yordayıcı olarak saptanmıştır. Bu önem orta grup ülkeler örnekleminde daha fazladır. Yordayıcı deęişkenler bakımından alt grup, orta grup ve üst grup ülkeler örneklemleri karşılaştırılacak olursa; üç grubun tamamı birbirinden farklılık göstermektedir. En çok farklılık gösteren grup ise üst grup ülkeler örneklemidir. Ayrıca RO yönteminde farklı başarı düzeyine sahip gruplardaki önemli deęişkenler LR ve SRA yöntemlerine göre gruptan gruba çok fazla farklılaşmaktadır.

LR, SRA ve RO yöntemleri ile iki kategorili PISA okuduğunu anlama başarısını yordayan önemli değişkenlerin her bir yöntem için alt grup, orta grup ve üst grup ülkeler örnekleme için farklılık gösterdiği tespit edilmiştir. Gruplardaki önemli ortak değişkenler bakımından farkın en az olduğu yöntem LR yöntemi iken farkın en fazla olduğu yöntem RO yöntemidir. Bu durumda LR yönteminin değişken seçmede daha etkili olduğu söylenebilir. Ayrıca her bir grupta kullanılan üç yöntemden elde edilen önemli değişkenlerin yöntemden yönteme farklılık gösterdiği saptanmıştır. Bu farkın en fazla olduğu yöntem RO yöntemidir. Bu bakımdan LR ve SRA yöntemleri için her bir grupta bazı önemli değişkenler bakımından benzerlik olduğu belirlenmiştir.

Üç kategorili başarı durumu için LR yöntemi ile yapılan analizde grupların tamamı için önemli ortak değişkenlerin evdeki eğitimsel eşyalar ve PISA testinin zorluk algısı olduğu belirlenmiştir. PISA testinin zorluk algısı değişkeninin önemi üst grup ülkeler örnekleminde daha fazladır. Bu bulgu iki kategorili başarı durumu için LR ve SRA yöntemlerinden elde edilen bulgu ile aynıdır. Evdeki eğitimsel eşyalar; alt grup, orta grup ülkeler örnekleme ve çalışma örnekleminde birinci sırada öneme sahip değişken iken üst grup ülkeler örnekleminde üçüncü sırada öneme sahip değişken olarak saptanmıştır. Bu değişkenin önem derecesinin üst ülkeler örnekleminde diğer gruplara göre düşük olması üst grup ülkelerin sosyo-ekonomik düzeylerinin diğer gruplara göre iyi olduğu düşünüldürse beklenen bir sonuçtur. Ebeveynlerin en yüksek mesleki statüsü değişkeni orta grup, üst grup ülkeler örnekleme ve çalışma örnekleminde önemli ortak yordayıcı olarak belirlenmiştir. Alt grup ülkeler örnekleminde iki kategorili LR modelinde bu değişken önemli yordayıcı değişken olarak bulunmasına karşın üç kategorili LR modelinde önemli yordayıcı değişken olarak bulunmamıştır. Buna göre alt başarı grubuna sahip az gelişmiş ülkelerde ebeveynlerin mesleki statüleri düşük olsa da öğrencilerin PISA okuduğunu anlama başarısının yüksek olması mümkündür. Bilgi iletişim teknolojileri kaynakları değişkeni alt grup, orta grup ülkeler örnekleme ve çalışma örnekleminde önemli ortak yordayıcı olarak saptanmıştır. Bu değişkenin alt grup ülkeler örnekleminde yordayıcılık önem derecesi diğer gruplardan daha yüksektir. Alt grup ülkelerin genellikle az gelişmiş ülkeler olduğu düşünüldüğünde bu ülkelerde bilgi iletişim teknolojilerinin önemi beklenen bir sonuçtur.

Öğrenciden beklenen mesleki statü değişkeni orta grup, üst grup ülkeler örnekleme ve çalışma örnekleminde önemli ortak yordayıcı olarak çıkmıştır. Bu değişkenin bu gruptaki önem derecesi birbirine yakın çıkmıştır. Sonuç olarak, üç kategorili başarı durumu için alt grup ülkeler örnekleminde öğrenciden beklenen mesleki statünün PISA okuduğunu anlama başarısını belirlemede öneminin olmadığı saptanmıştır. Okuma keyfi değişkeni orta grup ve üst grup ülkeler örnekleminde önemli ortak yordayıcı olarak bulunmuştur. Diğer yandan iki kategorili LR modelinde alt grup, orta grup ve üst grup ülkeler örnekleminde okuma keyfi değişkeni önemli yordayıcı olarak saptanmıştır. LR yöntemi ile iki ve üç kategorili başarı durumuna göre yapılan analize göre alt grupta bu değişkenin önemi farklılık göstermiştir. Yordayıcı değişkenler bakımından alt grup, orta grup ve üst grup ülkeler örneklemi karşılaştırılacak olursa; üç grubun tamamı birbirinden farklılık göstermektedir. En çok farklılık gösteren grup ise iki kategorili modelde olduğu gibi alt grup ülkeler örneklemdir. Bu sonuca göre farklı başarı düzeyine sahip gruplarda PISA okuduğunu anlama başarısını yordayan önemli değişkenlerin farklılık gösterdiği belirlenmiştir.

Üç kategorili başarı durumu için SRA yöntemi ile yapılan analizlerde PISA testinin zorluk algısı değişkeni orta grup, üst grup ülkeler örnekleme ve çalışma örnekleminde 2018 PISA okuduğunu anlama başarısını yordayan önemli ortak değişken olarak ortaya çıkmıştır. Bu değişkenin önemi üst grup ülkeler örnekleminde en fazladır. Evdeki eğitimsel eşyalar değişkeni orta grup ülkeler örnekleme ve çalışma örnekleminde önemli ortak yordayıcı olarak saptanmıştır. Ayrıca bu değişken çalışma örnekleminde birinci sırada önemli yordayıcı olarak bulunmuştur. Ancak evdeki eğitimsel eşyalar değişkeni iki kategorili SRA modelinde sadece alt grupta birinci sırada önemli yordayıcı olarak bulunmuştur. Bu durumda iki kategorili SRA modeli işlevini yerine getirememiştir. Çünkü bu değişken hem iki ve üç kategorili LR modelinde hem de üç kategorili SRA modelinde çalışma örnekleminde yapılan analizde birinci sırada öneme sahip yordayıcı olarak çıkmıştır. Okuma keyfi değişkeni alt grup ve üst grup ülkeler örnekleminde önemli ortak yordayıcı olarak tespit edilmiştir. Bu değişkenin üst grup ülkeler örnekleminde önem derecesi daha fazladır. Bu durumda üst grup ülkeler örneklemindeki öğrencilerin okumadan keyif almasının PISA okuduğunu anlama başarısını daha fazla etkilediği belirlenmiştir. Öğrenciden beklenen

mesleki statü değişkeni orta grup ülkeler örneklemindeki öğrencilerin başarılarını etkilediği saptanmıştır. Sosyo-ekonomik durum değişkeni üst grup ülkeler örneklemini ve çalışma örnekleminde önemli ortak yordayıcı olarak saptanmıştır. Bu değişken bakımından üst grup ülkeler örneklemini çalışma örneklemine benzerlik göstermiştir. Yordayıcı değişkenler bakımından alt grup, orta grup ve üst grup ülkeler örneklemini karşılaştırılacak olursa üç grubun tamamı birbirinden farklılık göstermektedir. En çok farklılık gösteren grup ise yine alt grup ülkeler örnekleminidir. Bu sonuca göre LR yönteminde olduğu gibi farklı başarı düzeyine sahip gruplarda PISA okuduğunu anlama başarısını yordayan önemli değişkenlerin gruptan gruba farklılık gösterdiği saptanmıştır.

Üç kategorili başarı durumu için RO yöntemi ile yapılan analizde haftalık test dili öğrenme süresi değişkeni alt grup, orta grup, üst grup ülkeler örneklemini ve çalışma örnekleminde 2018 PISA okuduğunu anlama başarısını yordayan önemli ortak değişken olarak ortaya çıkmıştır. Bu değişken alt grup ülkeler örnekleminde birinci sırada öneme sahiptir. Bu değişken iki kategorili RO yönteminde üst grup ülkeler örneklemini ve çalışma örnekleminde önemli yordayıcı olarak bulunmuşken üç kategorili modelde alt grup, orta grup, üst grup ülkeler örneklemini ve çalışma örnekleminde önemli yordayıcı olarak bulunmuştur. Bu durumda üç kategorili RO modelinin daha fazla grupta haftalık ders dili öğrenme süreci değişkenini önemli değişken olarak seçmesi modelinin iki kategorili modelden daha hassas olduğunun göstergesidir. Okuma keyfi değişkeni alt grup, orta grup ülkeler örneklemini ve çalışma örnekleminde önemli yordayıcı olarak bulunurken üst grupta önemli yordayıcı olarak bulunmamıştır. Bu modele göre okuma keyfi değişkeni üst grup ülkeler örneklemindeki öğrencilerin başarılarını belirlemede etkili olmadığı saptanmıştır. PISA testinin zorluk algısı değişkeni alt grup ülkeler örneklemini ve çalışma örnekleminde önemli yordayıcı değişken olarak bulunmuştur. İki kategorili RO modelinde ise PISA testinin zorluk algısı sadece alt grup ülkeler örnekleminde önemli yordayıcı olarak bulunmuştur. Ancak iki ve üç kategorili SRA ve LR modellerinin tümünde bu değişken grupların çoğunda önemli bulunması iki kategorili RO modelinin bu değişken seçmedeki zayıflığının bir göstergesi olarak düşünüldüğünde bu değişken bakımından üç kategorili RO modelinin daha iyi çalıştığı söylenir. Yordayıcı değişkenler bakımından alt grup, orta grup ve üst grup ülkeler örneklemini karşılaştırılacak olursa; üç grubun tamamı birbirinden farklılık

göstermektedir. En çok farklılık gösteren grup ise üst grup ülkeler örnekleimidir. LR ve SRA yöntemlerinde yordayıcı değişkenler bakımından en çok farklılık alt grup ülkeler örnekleminde olduğu için bu bakımdan RO yöntemi diğer yöntemlerden ayrılmıştır. Sonuç olarak diğer yöntemlerde olduğu gibi bu yöntemde de farklı başarı düzeyine sahip gruplarda PISA okuduğunu anlama başarısını yordayan önemli değişkenlerin farklılık gösterdiği saptanmıştır.

Türkiye örnekleminde LR, SRA ve RO yöntemleri ile iki kategorili PISA okuduğunu anlama başarısını yordayan önemli değişkenler incelendiğinde sadece LR ve SRA yöntemlerinin seçtiği okuma keyfi ve öğrenciden beklenen mesleki statü değişkenlerinin ortak oldukları saptanmıştır. RO yönteminin seçtiği değişkenler diğer yöntemlerden tamamen farklı bulunmuştur. Türkiye örnekleminde LR, SRA ve RO yöntemleri ile üç kategorili PISA okuduğunu anlama başarısını yordayan önemli değişkenler incelendiğinde LR ve SRA yöntemlerinin seçtikleri evdeki eğitimsel eşyalar, PISA testinin zorluk algısı, ebeveynlerin en yüksek mesleki statüsü, öğrenciden beklenen mesleki statü değişkenlerinin ortak olduğu saptanmıştır. Diğer yandan SRA ve RO yöntemlerinin seçtikleri ortak değişkenler ise okuma keyfi ve PISA testinin zorluk algısı olarak belirlenmiştir. Buna göre LR ve SRA yöntemlerinin seçmiş oldukları ortak değişken sayısının daha fazla olduğu saptanmıştır. Sonuç olarak iki veya üç kategorili okuduğunu anlama başarısını yordama da etkili olan değişkenlerin ortak olması bakımından benzerliği LR ve SRA yöntemlerinde daha fazla iken RO yönteminde daha az bulunmuştur.

LR, SRA ve RO yöntemleri ile üç kategorili PISA okuduğunu anlama başarısını yordayan önemli değişkenlerin her bir yöntem için alt grup, orta grup, üst grup ülkeler örneklemini ve çalışma örneklemini için farklılık gösterdiği tespit edilmiştir. Gruplardaki önemli ortak değişkenler bakımından farkın en az olduğu yöntem LR yöntemidir. Bu durumda LR yönteminin değişken seçmede daha etkili olduğu söylenebilir. Ayrıca her bir grupta kullanılan üç yöntemden elde edilen önemli değişkenlerin yöntemden yöntem farklılık gösterdiği saptanmıştır. Bu farkın en fazla olduğu yöntem RO yöntemidir.

İki ve üç kategorili 2018 PISA okuduğunu anlama durumu için LR, SRA ve RO yöntemleri önemli değişkenleri belirleme bakımından karşılaştırıldığında alt grup, orta grup, üst grup ülkeler örneklemini ve çalışma örnekleminde her bir yöntem

için her bir grupta önemli yordayıcıların değiştiği saptanmıştır. Üç kategorili modellerin beklentiye daha uygun modeller olduğu belirlenmiştir.

Grupların tamamında iki kategorili PISA okuduğunu anlama başarı durumunu yordama da kullanılan LR, SRA ve RO yöntemlerinin sınıflama ve tahmin performansları karşılaştırıldığında yapılan analizlerde tüm veri bakımından en yüksek doğru sınıflama yüzdesine sahip yöntemin RO yöntemi olduğu saptanmıştır. Ancak tüm veri için RO yönteminden elde edilen doğru sınıflama yüzdesinin %100 olması veri madenciliğinde aşırı uyum (overfitting) sorunu olarak ifade edilir (Domingos, 2012). Bu sorunun üstesinden gelmenin en iyi yolu geçerlik verisi üzerinden modeli yorumlamaktır (Ng, 1997). Tüm veri için grupların tamamında LR ve SRA yönteminden elde edilen doğru sınıflama yüzdeleri birbirine yakın ve yüksek seviyede çıkmıştır. Diğer yandan grupların tamamı için geçerlik ve test verisi için RO yönteminden hesaplanan Kappa katsayıları düşük çıkmıştır. Bu nedenle grupların tamamında iki kategorili başarı durumunu yordamada RO yöntemi gerçeğe uygun sınıflama yapamamıştır. Ayrıca, alt grup ülkeler örnekleminde iki kategorili başarı durumunu yordamada kullanılan üç yöntemden elde edilen sonuçların Kappa katsayıları düşük çıkmıştır. Sonuç olarak, veri madenciliğinde kullanılan modelin tahmin performansının önemi dikkate alındığında alt grup ülkeler örneklemini hariç grupların tamamında iki kategorili başarı durumunu yordamada LR ve SRA yöntemleri gerçeğe yakın sonuçlar vermiştir.

Grupların tamamında üç kategorili PISA okuduğunu anlama başarı durumunu yordama da kullanılan LR, SRA ve RO yöntemlerinin sınıflama ve tahmin performansları karşılaştırıldığında yapılan analizlerde tüm veri için en yüksek doğru sınıflama yüzdesine sahip yöntemin RO yöntemi olduğu saptanmıştır. Ancak tüm veri için RO yönteminin doğru sınıflandırma yüzdesinin %100 olması aşırı uyum (overfitting) sorunu olarak görüldüğü için RO yöntemini geçerlik verisi bakımından yorumlamak daha doğru sonuçlar verecektir. Tüm veri için grupların tamamında LR ve SRA yönteminden elde edilen doğru sınıflama yüzdeleri birbirine yakın ve kabul edilebilir düzeyde çıkmıştır. Geçerlik ve test verisi bakımından LR ve SRA yöntemlerini tahmin performansı kabul edilebilir düzeyde iken RO yöntemi diğer yöntemlere göre bir miktar düşük çıkmıştır. Diğer yandan, alt grup verileriyle iki kategorili başarı durumu için oluşturulan modellerde

Kappa katsayısı düşük iken üç kategorili başarı durumu için oluşturulan modellerde Kappa katsayısı makul düzeydedir. Bu durumda alt grup için üç kategorili başarı durumuna dayalı olarak oluşturulan modellerin iki kategorili başarı durumuna dayalı olarak oluşturulan modellerden daha uygun olduğu belirlenmiştir.

Bu araştırmada sonuçların doğruluğu için her bir modelin doğru sınıflama ve tahmin performansı o modelin seçmiş olduğu önemli değişkenlerle belirlenmiştir. Türkiye, alt grup, orta grup, üst grup ülkeler örnekleme ve çalışma örnekleme için iki kategorili başarı durumunu yordayan değişken sayısı azaltılarak oluşturulan modellerin geçerlik verisi ve test verisi için tahmin performansı ve oluşturulan modellerinin uyumu birlikte ele alındığında LR ve SRA modelinde birbirine yakın ve iyi düzeyde olduğu, RO yönteminde ise diğer yöntemlere nazaran düşük olduğu saptanmıştır. Ayrıca değişken sayısı azalırken RO yönteminde Kappa katsayısı kabul edilebilir düzeyin altına düşmüştür. Bu durumda RO yönteminin geçerlik ve test verisi için değişken sayısının azaltıldığı modelde tahmin performansı çok fazla düşmüştür. Sonuç olarak değişken sayısının azalması RO orman yönteminin tahmin performansını diğer yöntemlere nazaran daha fazla düşürmüştür. Bunun nedeni, RO yöntemi algoritmasındaki olasılık hesabındaki hassasiyetten dolayı değişken sayısına duyarlı bir yöntem olmasındandır. Veri madenciliği uygulamalarında kullanılan modellerin geleceğe yönelik tahmin kapasitesinin öneminden dolayı RO yönteminin tahmin performansı bakımından LR ve SRA modellerine nazaran zayıf bir model olduğu saptanmıştır. İki kategorili başarı durumu için alt grup ülkeler örnekleminde geçerlik ve test verisi için değişken sayısı azaltılırken üç yöntemden elde edilen Kappa katsayıları düşük çıkmıştır. Bunun nedeni alt grup ülkelerin örnekleminin veri dağılımından kaynaklanmıştır. Alt grupta geçerlik ve test verisi için kullanılan üç yöntemin tümü amaca hizmet edememiştir.

Diğer yandan üç kategorili başarı durumuna göre değişken sayısı azaltılarak oluşturulan modellerin geçerlik ve test verisi için tahmin performansı ve oluşturulan modellerin Kappa uyum katsayısı birlikte ele alındığında alt grup ülkeler örnekleminde SRA ve RO modellerinden elde edilen tahmin performansları iyi düzeyde ve Kappa uyum katsayıları kayda değer iken LR yönteminde tahmin performansı yüksek ve modelin Kappa uyum katsayısı düşük çıkmıştır. Türkiye, orta grup, üst grup ülkeler örnekleme ve çalışma örnekleminde ise LR ve SRA

yöntemlerinin geçerlik verisi ve test verisi için tahmin performansı birbirine yakın ve kabul edilebilir seviyede ve Kappa uyum katsayısının ise makul düzeyde olduğu saptanmıştır. Ancak Rastgele Orman yönteminin diğer yöntemlere göre geçerlik verisi ve test verisi için tahmin performansı biraz düşük olsa da orta düzey olduğu ve Kappa uyum katsayısının makul düzeyde olduğu saptanmıştır. Sonuç olarak, Türkiye örnekleme, alt grup, orta grup, üst grup ülkeler örnekleme ve çalışma örnekleme dayalı olarak tüm veri, geçerlik verisi ve test verisi ile LR, SRA ve RO yöntemleri ile oluşturulan tüm modeller için, sınıflama, tahmin performansı ve model uyumu birlikte düşünüldüğünde üç kategorili modellerin daha iyi sonuçlar verdiği belirlenmiştir.

Öneriler

Araştırma bulgularından elde edilen fikirler doğrultusunda ortaya konulan uygulamaya ve araştırmaya yönelik öneriler iki başlık altında verilmiştir.

Araştırmaya yönelik öneriler

1. Türkiye örnekleminde LR, SRA ve RO yöntemlerini kullanarak 34 bağımsız değişken ile iki ve üç kategorili okuduğunu anlama başarısını yordama da oluşturulan modellerin hemen hemen tamamında okuma keyfi değişkeni önemli yordayıcı olarak saptanmıştır. Türkiye’de ulusal düzeyde yapılan Abide ve LGS gibi sınavlardaki okuduğunu anlama başarısını yordayan değişkenlerin belirlenmesi sürecinde okuma keyfi değişkeninin yordayıcılık önemini incelenmesi önerilebilir.
2. Çalışmada LR, SRA ve RO yöntemleri ile PISA okuduğunu anlama başarısını yordayan önemli değişkenlerin yöntemden yönteme farklılık gösterdiği belirlenmiştir. Elde edilen bu bulgular doğrultusunda PISA okuduğunu anlama başarısının yordanmasına yönelik yapılacak araştırmalarda farklı veri madenciliği yöntemleri ile elde edilecek sonuçların karşılaştırılması önerilebilir.
3. Araştırma kapsamında kullanılan yöntemlerden bir ya daha fazlasını kullanarak Abide okuduğunu anlama testinin Türkiye örnekleminde uygulamasından elde edilen verilere dayanarak Abide okuduğunu anlama

başarısını yordayan önemli değişkenler belirlenip PISA okuduğunu anlama başarısını yordayan önemli değişkenler ile karşılaştırılması önerilmektedir.

4. PISA okuduğunu anlama başarısını yordamak için kullanılan 34 değişken ile LR, SRA ve RO yöntemlerini kullanarak Türkiye örnekleme, alt grup, orta grup, üst grup ülkeler örnekleme ve çalışma örnekleminde seçilen önemli değişkenlerin sayısı azaltılarak iki ile sekiz arasında değişmiştir. Benzer bir çalışmanın PISA fen ve matematik alanında yapılması önerilmektedir.
5. Öğrencilerin fen, matematik, Türkçe vb. derslerindeki başarısını yordamak için MEB e-okul veri tabanından elde edilen veriler ile veri madenciliği yöntemlerini kullanarak bu derslerdeki başarıyı yordayan önemli değişkenlerin belirlenmesine yönelik çalışmalar yapılabilir.
6. Bu çalışmaya benzer bir çalışma olarak ÖSYM tarafından yapılan TYT, AYT, DGS ve ALES gibi sınavlardaki başarıyı yordayan önemli değişkenlerin belirlenmesine yönelik veri madenciliği yöntemlerine dayalı analizlerin yapılması önerilmektedir.

Uygulamaya yönelik öneriler

1. İki ve üç kategorili okuduğunu anlama başarı durumuna göre araştırmada kullanılan yordayıcı değişkenlerin tamamının sayısı azaltılarak yordayıcılığı yüksek önemli değişkenlerle geçerlik ve test verisi üzerinden yapılan analiz sonunda doğru sınıflama yüzdesi bakımından en iyi modellerin ise LR ve SRA yöntemleri olduğu belirlenmiştir. İki veya üç kategorili başarı durumunun geçerlik ve test verisi kullanılarak az sayıda bağımsız değişken ile yordanması amaçlanıyorsa LR ve SRA yöntemleri önerilmektedir.
2. Bu araştırmada Türkiye örnekleme, alt grup, orta grup, üst grup ülkeler örnekleme ve çalışma örnekleme verileriyle azaltılmış değişkenler ile iki ve üç kategorili PISA okuduğunu anlama başarısının yordama da LR, SRA ve RO yöntemlerinin kullanarak tüm veri, geçerlik ve test verisi için sınıflama ve tahmin performanslarının belirlenmesinde her bir grup için her bir modelin seçtiği önemli değişkenler kullanılmıştır. Aksi durumda bir modelin seçtiği

önemli deęişkenle ile başka bir modelin test edilmesi hataya neden olacaktır. Bundan sonraki benzer çalışmalarda bu yolun izlenmesi önerilir.

3. Bu araştırmada azaltılmış deęişkenlere dayalı olarak oluşturulan bazı modellerde doğru sınıflama yüzdesi 34 deęişkenden elde edilen deęerlere göre düşük çıkmıştır. Bu sorunun önüne geçmek için deęişken azaltma sonrası düşük doğru sınıflama yüzdesine sahip olan modellere önem derecesi yüksek deęişken eklenerek doğru sınıflama yüzdesi artırılabilir.
4. İki ve üç kategorili PISA okuduğunu anlama başarısını yordamak için tüm veri, geçerlik verisi ve test verisi ile Modeller programında yer alan LR, SRA ve RO yöntemlerini kullanarak her bir grupta her bir yöntemin seçtięi önemli deęişkenler farklılık göstermiştir. Her bir grupta üç modelin seçtięi önemli deęişkenler birleştirilerek farklı bir öğrenme algoritması ile her bir grup için önemli deęişkenlerin seçilmesi önerilebilir.

Kaynaklar

- Abad, F. M., Gamazo, A., ve Rodriguez Conde, M. J. (2020). Educational data mining: Identification of factors associated with school effectiveness in pisa assessment. *Studies in Educational Evaluation* 66,100875.
- Abad, F. M., ve Lopez, A. C. (2017) Data-mining techniques in detecting factors linked to academic achievement, School Effectiveness and School Improvement. *School Effectiveness and School Improvement*, 28 (1), 39-55.
- Abdous, M., He, W., ve Yen, C. J. (2012). Using data mining for predicting relationships between online question theme and final grade. *Journal of Educational Technology ve Society*, 15 (3), 77-88.
- Agresti, A. (1996). *An introduction to categorical data analysis*. New York: John Wiley and Sons.
- Agyapong, K.B., Hayfron-Acquah, J.B.,ve Asante, M. (2016). An overviev of data mining models (decriptive and predictive). *Journals International Journal of Software and Hardware Resarch in Engineering*, (4)5, 53-60
- Ahmed, A. B., ve Elaraby, I. S. (2014). Data mining: A prediction for student's performance using classification method. *World Journal of Computer Application and Technology*, 2 (2), 43-47.
- Akçapınar, G. (2014). *Çevrimiçi öğrenme ortamındaki etkileşim verilerine göre öğrencilerin akademik performanslarının veri madenciliği yaklaşımı ile modellenmesi*. (Doktora Tezi). Hacettepe Üniversitesi Eğitim Bilimleri Enstitüsü, Ankara.
- Akkurt, Z., ve Karabağ Köse, E. (2019). Öğrenci başarısının okul, Öğretmen ve aileyle ilgili değişkenler açısından incelenmesi. *Pamukkale Üniversitesi Eğitim Fakültesi Dergisi*, 47, 1-16.
- Akman, M. (2010). *Veri madenciliğine genel bakış ve random forests yönteminin incelenmesi: Sağlık alanında bir uygulama* (Yüksek Lisans Tezi). Ankara Üniversitesi Sağlık Bilimleri Enstitüsü, Ankara.

- Aksoy, E. (2014). *Matematik alanında üstün yetenekli ve zekâlı öğrencilerin bazı değişkenler Açısından veri madenciliği ile belirlenmesi* (Yüksek Lisans Tezi). Dokuz Eylül Üniversitesi Eğitim Bilimler Enstitüsü, İzmir.
- Aksu, G., ve Güzeller, C. O. (2016). Classification of PISA 2012 mathematical literacy scores using decision-tree method: Turkey sampling. *Education and Science* 41(185), 101-122.
- Aksu, G. (2018). *PISA başarısını tahmin etmede kullanılan veri madenciliği yöntemlerinin incelenmesi* (Doktora Tezi). Hacettepe Üniversitesi Eğitim Bilimleri Enstitüsü, Ankara.
- Aksu, N. (2019). *Farklı ülkelerden pisa sınavına katılan öğrencilerin matematik okuryazarlığını etkileyen faktörlerin tahmin edilmesi* (Yüksek Lisans Tezi). Adnan Menderes Üniversitesi Sosyal Bilimleri Enstitüsü, Aydın
- Altunkaynak, B. (2019). *Veri madenciliği yöntemleri ve r uygulamaları*. (2.Baskı). İstanbul: Seçkin yayıncılık.
- Arıcı, Ö.,ve Altıntaş, Ö. (2014). An investigation of the PISA 2009 reading literacy in terms of socio-economical backgrounds and receiving pre-school education "Turkey Example", Ankara University, Journal of Faculty of Educational Sciences, year: 2014, vol: 47, issue: 1, 423-448
- Atalay, M.,ve Çelik, E. (2017). Büyük veri analizinde yapay zekâ ve makine öğrenmesi Uygulamaları. *Mehmet Akif Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 22(9), 161-168.
- Atasever, Ü. H. (2011). *Uydu görüntülerinin sınıflandırılmasında hızlandırma (boosting), destek vektör makineleri, rastgele orman (random forest) ve regresyon ağaçları yöntemlerinin kullanılması* (Yüksek Lisans Tezi). Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Kayseri.
- Azen, R., Budescu, D. V., 2003. The Dominance Analysis Approach for Comparing Predictors in Multiple Regression. *Psychol. Methods* 8, 129-148.
- Azen, R., Traxel, N., 2009. Using Dominance Analysis to Determine Predictor Importance in Logistic Regression. *J. Educ. Behav. Stat.* 34, 319-347.

- Baker, R. S.(2014). "Educational data mining: An advance for intelligent systems in education", *IEEE Intelligent Systems*, 29, 3.
- Barros, R. C., De Carvalho, A.C.,ve Freitas, A.A.(2015). Automatic design of decision-tree induction algorithms. *Springer Briefs in Computer Science*, 176, 7-45.
- Bauer, E.,ve Kohavi, R. (1999). An empirical comparison of voting classification algorithms: Bagging, boosting, and variants. *Machine Learning*, 36, 105-139.
- Ben David, A. (2008). "Comparison of classification accuracy using Cohen's Weighted Kappa".*Expert Systems with Applications: An International Journal*, 34(2), 825-832.
- Berberođlu, G., alıřkan, M., ve Karslı, N. (2017). PISA 2015 sonularına gre trk đrencilerinin ulařtıđı dřnme sreleri ve bu srelerle iliřkili olan deđiřkenler. Working Paper, August 2017. doi: 10.13140/RG.2.2.10601.39529
- Bezek Gre, ., Kayri, M., ve Erdođan, F. (2020). Analysis of factors effecting PISA 2015 mathematics literacy via educational data mining. *Education and Science* 45(202), 393-415.
- Bhalla, D. (2014). Random forest in R: Step by Step Tutorial. <http://www.listendata.com/2014/11/random-forest-with-r.html> sayfasından eriřilmiřtir.
- Bilen, ., Hotaman, D., Ařkın, .E., ve Bykl, A.H. (2014). LYS bařarılarına gre okul performanslarının eđitsel veri madenciliđi teknikleriyle incelenmesi: 2011 İstanbul rneđi. *Eđitim ve bilim*, 39 (172), 78-94.
- Boss, D. D. (2003). Introduction to the Bootstrap World. *Statistical Science*, 18 (2), 168-174.
- Bramer, M. (2013). *Principles of data mining* (2nd ed.), London: Springer-Verlag.
- Bradshaw, J., Ager, R., Burge, B.,ve Wheeler, R. (2010). *PISA 2009: Achievement of 15- year-olds in England*. Slough: NFER.
- Breiman, L. (1996). Bagging predictors. *Machine Learning*, 24, 123-140.

- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5-32.
- Breiman, L. (2004). *Consistency for a simple model of random forests*. Technical Report 670, Statistics Department, University Of California At Berkeley.
- Breiman, L. ve Cutler, T. Y. (2004). *A manual-setting up, using, and understanding random forests*. University of California, At Berkeley.
- Budescu, D. V., (1993). Dominance analysis: A new approach to the problem of relative importance of predictors in multiple regression. *Psychol. Bull.* 114, 542-551.
- Büyükkıdık, C., ve Mutluer, S. (2017). PISA 2012 verilerine göre matematik okuryazarlığının lojistik regresyon ile kestirilmesi. *Marmara Üniversitesi Atatürk Eğitim Fakültesi Eğitim Bilimleri Dergisi*, 46, 97-112.
- Büyüköztürk, Ş. (2012). *Sosyal bilimler için çok değişkenli istatistik spss ve lisrel uygulamaları*.(4.Baskı). Ankara: Pegem Yayıncılık.
- Büyüköztürk, Ş., Kılıç-Çakmak, E., Akgün, Ö.E., Karadeniz, Ş. ve Demirel, F. (2018). *Bilimsel Araştırma Yöntemleri*. (25.Baskı). Ankara: Pegem Yayıncılık.
- Calders, T., ve Pechenizkiy, M. (2012). Introduction to the special section on educational data mining. *SIGKDD Explor. Newsl.*, 13(2), 3–6.
- Chapelle, O.,Schölkopf, B.,ve Zien, A. (2006). *Semi-supervised learning: Adaptive computation and machine learning*. Massachusetts: Massachusetts Institute of Technology.
- Chien, C., Wang, W., ve Cheng, J. (2007). “*Data Mining for Yield Enhancement in Semiconductor Manufacturing and an Empirical Study*”, Department of Industrial Engineering and Engineering Management, National Tsing Hua University, Expert Systems with Applications, Taiwan, 192–198.
- Cutler, A., Cutler, D. R., ve Stevens, J. R. (2012). *Ensemble machine learning*. New York: Springer. 157-175.
- Çokluk, Ö., Şekercioğlu, G.,ve Büyüköztürk, Ş. (2018). *Sosyal bilimler için çok değişkenli istatistik: SPSS ve LİSREL uygulamaları*. (5.Baskı). Ankara: Pegem Akademi Yayınları.

- Coşkuner, T. (2013). *Uluslararası öğrenci başarı değerlendirme programı (PISA) 2009 uygulaması okuma becerileri okuryazarlığı'nı etkileyen faktörler* (Yüksek Lisans Tezi). Akdeniz Üniversitesi Eğitim Bilimleri Enstitüsü, Antalya.
- Coulombe S., Tremblay, J. F., ve Marchand, S. (2004). *Literacy scores, human capital and growth across fourteen OECD countries*, Statistics Canada, Ottawa.
- Cromley, J. G. (2009). Reading achievement and science proficiency: International comparisons from the programme on international student assessment. *Reading Psychology*, 30, 89-118.
- Deconinck, E., Hancock, T., Coomans D., Massart D.L. ve Vander Heyden, Y. (2005). Classification of drugs in absorption classes using the classification and regression trees (CART) methodology. *Journal of Pharmaceutical and Biomedical Analysis*, 39, 91–103.
- Dekking, F. M., Kraaikamp, C., Lopuhaa, H. P. Ve Meester, L. E. (2005) A modern introduction to probability and statistics: Understanding why and how, United States of America: Springer Science+Business Media.
- Doğan, N. (2020). *Eğitimde Ölçme ve Değerlendirme*, Ankara: Pegem Akademi Yayınları.
- Domingos, P. (2012), A few useful things to know about machine learning, *Communications of the ACM*, 55 (10), 78–87.
- Ercire, M. (2019). *Kısa Süreli Güç Kalitesi Bozulmalarının Dalgacık Analizi Ve Rastgele Orman Yöntemi İle Sınıflandırılması* (Yüksek Lisans Tezi). Kütahya Dumlupınar Fen Bilimler Enstitüsü, Kütahya.
- Ersöz, F. (2019). *Veri madenciliği Teknikleri ve Uygulamaları*. Ankara: Seçkin yayınları.
- Field, A. (2009). *Discovering Statistics using SPSS*. London: Sage.
- Fountas, I. C., ve Pinnell, G. S. (2001). *Guiding readers and writers: Grades 3–6. teaching comprehension, genre, and content literacy*. Portsmouth, NH: Heinemann.

- Fürnkranz, J. (1999). Separate-and-Conquer Rule Learning. *Artificial Intelligence Review*, 13, 3-54
- Galdi, P., ve Tagliaferri, R. (2017). *Data mining: Accuracy and error measures for Classification and prediction, in reference module in Life sciences*, Holland: Elsevier.
- Gamazo, A., ve Abad, F. M. (2020). An exploration of factors linked to academic performance in PISA 2018 through data mining techniques. *Journal Frontiers in Psycholog*, 11, 575167.
- Gülleroğlu, H. D., Bilican Demir, S. B., ve Demirtaşlı, N. (2014). Türk öğrencilerinin PISA 2003-2006-2009 dönemlerindeki okuma becerilerini yordayan sosyoekonomik ve kültürel değişkenlerin araştırılması. *Eğitim Bilimleri Fakültesi Dergisi*, 47(2), 201-221.
- Güner, Z. B. (2014). Veri madenciliğinde cart ve lojistik regresyon analizinin yeri: ilaç provizyon sistemi verileri üzerinde örnek bir uygulama. *Sosyal Güvence Dergisi*, 6, 53-99.
- Gürsakal, S. (2012). PISA 2009 öğrenci başarı düzeylerini etkileyen faktörlerin değerlendirilmesi. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 17(1), 441-452.
- Güzle Kayır, Ç. (2012). *PISA 2009 Türkiye verilerine dayanarak okuma becerileri alanında başarılı okullar ile başarısız okulları ayırt eden okul içi etmenler ve sosyo-ekonomik faktörler* (Yüksek lisans tezi). Akdeniz Üniversitesi Sosyal Bilimler Enstitüsü, Antalya.
- Hair, J. F., Black, W. C., Babin, B. J. ve Anderson, R. E. (2014). *Multivariate data analysis* (7th edition). London: Pearson Education Limited.
- Han, J., Kamber, M., ve Pei, J., (2012). "Data mining: Concepts and techniques", (3rd Edition). Waltham: Morgan Kaufmann Publishers, 18.
- He, Y.(2006). *Missing data imputation for tree-based models*. (Yayınlanmamış Doktora Tezi). California Üniversitesi, 81 p.
- Holsheimer, M., Kersten, M., Mannila, H. ve Toivonen, H. (1995). A perspective on databases and data mining. *Proceeding of KDD-95, The Association for The Advancement of Artificial Intelligence*, 150-155.

- Hosmer D.W. ve Lemeshow, S. (2000). Applied lojistic regression. John WileySons, Inc: Canada.
- IBM, (2021, 10 Ekim). *Predictor Importance*. https://www.ibm.com/docs/en/spss-modeler/18.1.0?topic=SS3RA7_18.1.0/modeler_mainhelp_client_ddita/clementine/idh_common_predictor_importance.html
- Jiang, Y. H., Javaad, S. S., ve Golab, L. (2015). Data mining of undergraduate course evaluations. *Informatics in Education*, 15 (1), 85–102.
- Kalaycı, Ç. (2009). *SPSS uygulamalı çok değişkenli istatistik teknikleri*. Ankara: Asil Yayın.
- Kiray, S.A., Gok, B., ve Bozkir, A.S. (2015). Identifying the factors affecting science and mathematics achievement using data mining methods. *Journal of Education in Science, Environment and Health (JESEH)*, 1(1), 28-48.
- Kayri, M.,ve Okut, H. (2008). Özel yetenek sınavındaki başarıya ilişkin risk analizinin karışımli lojistik regresyon modeli ile incelenmesi. *Hacettepe Üniversitesi Eğitim Fakültesi Dergisi*, 35, 227-239.
- Kayri, M. (2008). Elektronik portfolyo değerlendirmeleri için veri madenciliği yaklaşımı. *Yüzüncü Yıl Üniversitesi Eğitim Fakültesi Dergisi*, 5(1), 98-110.
- Kohavi, R. (1995). *A study of cross-validation and bootstrap for accuracy estimation and model selection*, Appears in the International Joint Conference on Artificial Intelligence, 2, 1137-1143.
- Kotte, D., Liez, P. ve Lopez, M. M. (2005). Factors influencing reading achievement in germany and spain: Evidence from pisa 2000. *International Education Journal*, 6 (1), 113-124.
- Köse, İ. (2018). *Veri madenciliği teori uygulama ve felsefesi*, (1.Baskı), İstanbul: Papatya yayıncılık, 48-50.
- Kurt, Ç., ve Erdem, O. A. (2012). Öğrenci başarısını etkileyen faktörlerin veri madenciliği yöntemleriyle incelenmesi. *Journal of Polytechnic*, 15(2),111-116.

- Landis, J. R., ve Koch, G. G. (1977) The measurement of observer agreement for categorical data. *Biometrics*, 31 (3), 159-174.
- Larose, D. T. (2005). *Discovering knowledge in data: An introduction to data mining*. John Wiley ve Sons, New Jersey.
- Liao, Z., Ju, Y., ve Zou, Q. (2016). Prediction of G protein-coupled receptors with Veri Madenciliği-Prot features and random forest. *Scientifica*, 8309253. doi: 10.1155/2016/8309253.
- Liaw, A., ve Wiener, M. (2002). Classification and regression by random forest. *R news*, 2(3), 18-22.
- Lietz, P., ve Kotte, D. (2004). Factors influencing reading achievement in germany and Finland: Evidence from PISA 2000. http://works.bepress.com/petra_lietz/14/ adresinden alınmıştır.
- Loh, W.Y. (2011). Classification and regression trees. *Wires Data Mining and Knowledge Discovery*, 1, 14-23
- Luo, W. Ve Azen, R. (2013). Determining Predictor Importance in Hierarchical Linear Models Using Dominance Analysis. *J. Educ. Behav. Stat.* 38, 3-31.
- Maimon, O., ve Rokach, L. (2005) *Data mining and knowledge discovery handbook*, Secaucus, NJ: Springer-Verlag Inc.
- Maslowski, R., Scheerens, J. ve Luyten, H. (2007). The effect of school autonomy and school internal decentralization on students' reading literacy. *School Effectiveness and School Improvement*, 18 (3), 303 – 334.
- Mathworks, (2021). *Compute predictor importance estimates for all predictor variables*. https://www.mathworks.com/help/stats/compactclassificationtree.predictorimportance.html#responsive_offcanvas
- MEB (2010). PISA 2009 ulusal ön raporu. Ankara: <http://pisa.meb.gov.tr/wp-content/uploads/2013/07/PISA-2009-Ulusal-On-Rapor.pdf>.
- MEB (2015). *PISA 2012 araştırması ulusal nihai raporu*. Ankara: İşkur Matbaacılık.
- MEB (2018). *2018 Liselere geçiş sistemi (LGS): Merkezi sınavla yerleşen öğrencilerin performansı*. *Eğitim Analiz ve Değerlendirme Serisi No:3*. Ankara: MEB Yayınları.

- MEB (2019). PISA 2018 Ulusal Ön Raporu. Ankara: T.C. Milli Eğitim Bakanlığı
- Menard, S. (1995). *Applied logistic regression analysis*. Thousand Oaks, CA: Sage.
- Menard, S. (2004a). Six approaches to calculating standardized logistic regression coefficients. *The American Statistician*, 58, 218-223.
- Menard, S. (2004b). Correction to "Six approaches to calculating standardized logistic regression coefficients." *The American Statistician*, 58, 364.
- Mishra, T., Kumar, D., ve Gupta, S. (2014). Mining students' data for performance Prediction, 2014 Fourth International Conference on Advanced Computing ve Communication Technologies, ACCT, 255–262.
- Mitchell, T.M. (1997). *Machine learning*. Newyork: McGraw-Hill Education.
- Ng, A.Y. (1997). Preventing "overfitting" of cross-validation data. In D.H. Fisher (Ed.), *Proceedings of the 14th International Conference on Machine Learning*, Nashville, TN, USA, July 8–12, San Francisco, CA: Morgan Kaufmann.
- Nonoyama, Y. (2006). *A Cross-national, multi-level study of family background and school resource effects on student achievement*. Unpublished doctoral thesis. Columbia University, Columbia.
- OECD (2009). *PISA 2009 assessment framework: Key competencies in reading, Mathematics and Science*.
- OECD (2016). *PISA 2015 results: Excellence and equity in education*, Volume I, OECD, Paris.
- OECD (2019). *PISA 2018 Technical Report*, OECD Publishing, Paris.
- OECD (2019a). PISA 2018 assessment and analytical framework. Paris: OECD Publishing. doi:<https://doi.org/10.1787/b25efab8-en>
- OECD (2019b). PISA 2018 results volume I: What students know and can do. Paris: OECD Publishing.
- Önder, R., Gelbal, S. (2016). PISA 2012 sonuçlarına göre matematik öz-yeterlik ve kaygı puanlarının bazı değişkenlere göre incelenmesi. *Eğitim ve Öğretim Araştırmaları Dergisi* 5(3),271-278.

- Özarıslan, S. (2014). *Öğrenci performansının veri madenciliği yöntemleri ile belirlenmesi* (Yüksek Lisans Tezi). Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü, Kırıkkale.
- Özer Özkan, Y., ve Acar Güvendir, M. (2014). Socioeconomic factors of students' relation to mathematic achievement: Comparison of PISA and öbbs. *International Online Journal of Educational Sciences*, 6 (3), 776-789.
- Özkan, Y. (2008). *Veri madenciliği yöntemleri*. İstanbul: Papatya yayıncılık.
- Özkan, U. B. (2020). Öğrencilerde eudaimonianın ve akademik başarının yordayıcısı olarak ekonomik, sosyal ve kültürel düzey. *Yaşadıkça Eğitim*, 34(2),344-359.
- Pal, M., ve Mather, P. M. (2003). An assessment of the effectiveness of decision tree methods for land cover classification. *Remote Sensing of Environment*, 86(4), 554-565.
- Pal, M. (2005). Random forest classifier for remote sensing classification. *International Journal of Remote Sensing*, 26(1), 217-222.
- Park, H. A. (2013). An introduction to logistic regression: From basic concepts to interpretation with particular attention to nursing domain. *J Korean Acad Nurs*, 43(2), 154-164.
- Polikar, R. (2006). Ensemble based systems in decision making. *IEEE Circuits and Systems Magazine*, 6(3),21–44.
- Quinlan, J.R. (1986) Induction of Decision Trees. *Machine Learning*, 1, 81-106.
- Rastogi, R., ve Shim, K. (2000). A Decision Tree Classifier that Integrates Building and Pruning, *Data Mining and Knowledge Discovery*, 4, 315–344.
- Rokach, L., ve Maimon, O. (2014). *Data mining with decision tree theory and applications*, 2.Edition, World Scientific Publishing.
- Romero, C.,ve Ventura, S. (2010). Educational data mining: A review of the state of the art. *IEEE Transactions on Systems, Man, and Cybernetics Part C: Applications and Reviews*, 40(6), 601-618.

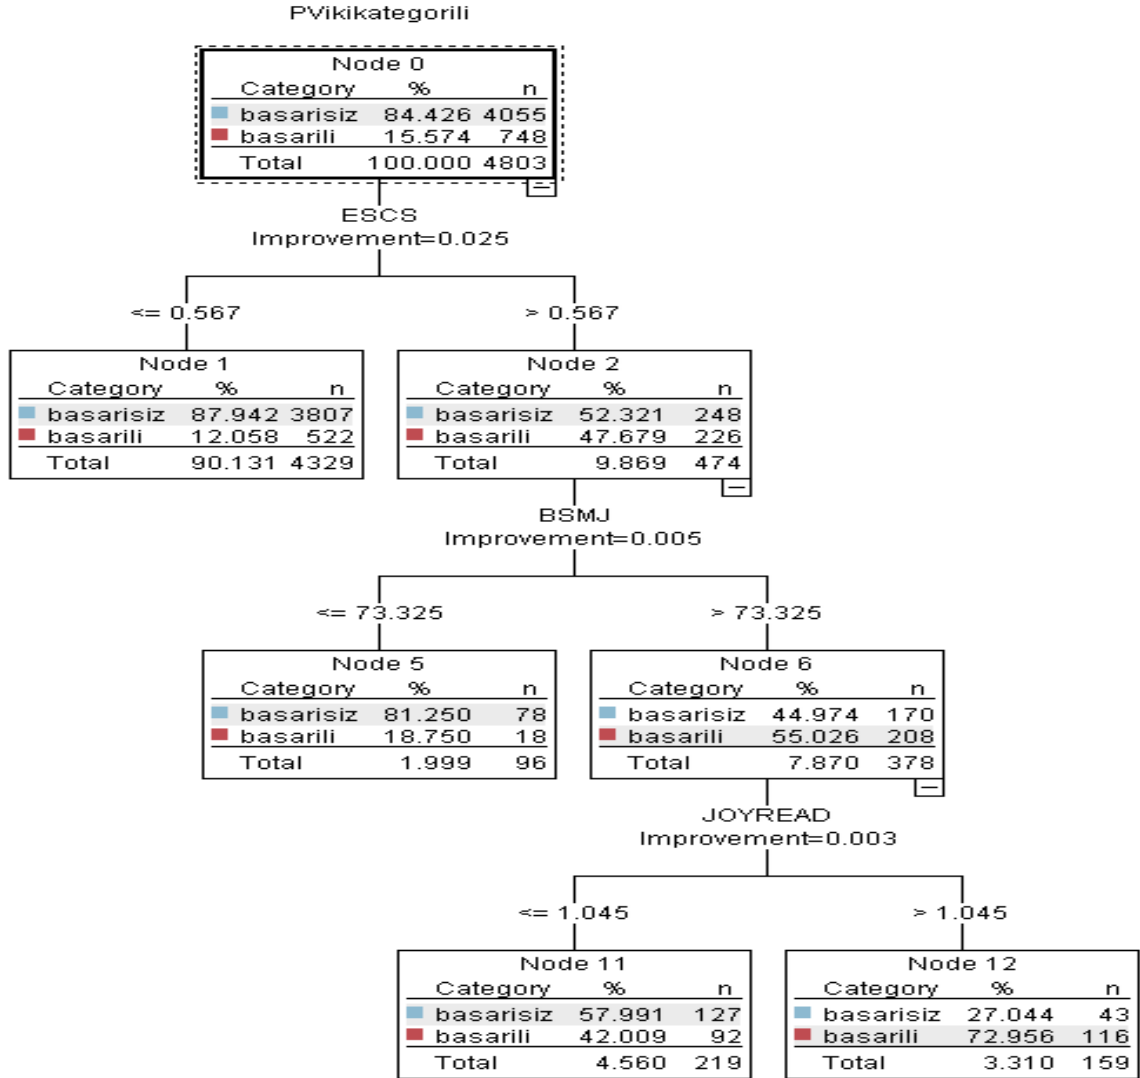
- Ronaghan, S. (2021, 10 Ekim). *The Mathematics of Decision Trees, Random Forest and Feature Importance in Scikit-learn and Spark*. Towards data sciences. <https://towardsdatascience.com/the-mathematics-of-decision-trees-random-forest-and-feature-importance-in-scikit-learn-and-spark-f2861df67e3>
- Saatçiođlu, Ö. (2014). *PISA 2009 uygulamasına katılan ölkelerin okuma becerileri alt test sonuçlarının profil analizi ile deđerlendirilmesi*. (Yayınlanmamış Yüksek Lisans Tezi). Ankara Üniversitesi Eğitim Bilimleri Enstitüsü, Ankara.
- Savaş, S., Topalođlu, N., ve Yılmaz, M. (2012). Veri madenciliđi ve Türkiye'deki uygulama örnekleri. *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*, 11(21), 1-23.
- Sieber, J. E. (2008). Data mining: Knowledge discovery for human research ethics, *J Empir Res Hum Res Ethics*, 3 (3), 1-2.
- Silahtarođlu, G. (2016). *Veri madenciliđi kavram ve algoritmaları*. (3.Baskı). İstanbul: Papatya yayıncılık. 12.
- Singh, N., Raw, R. S. ve Chauhan, R. K. (2012). Data mining with regression technique. *Journal of Information Systems and Communication*, (3)1, 199-202.
- Sinharay, S. (2016). An NCME instructional module on data mining methods for classification and regression. *Educational Measurement: Issues and Practice*, 35 (3), 38–54.
- Swani, L. ve Tyagi, P. (2017). Predictive modelling analytics through data mining. *International Research Journal of Engineering and Technology (IRJET)*, 4(9), 5-11.
- Tabachnick, B. G., ve Fidell, L. S. (2007). *Using multivariate statistics*. Boston: Pearson/Allyn ve Bacon.
- Tamilselvi, R. ve Kalaiselvi, S. (2013). An overview of data mining techniques and applications. *International Journal of Science and Research (IJSR)*, 2(2), 506-509.

- Tan, P., Steinbach, M., ve Kumar, V. (2005). Introduction to data mining. Boston, USA: Addison-Wesley Longman Publishing Co.
- Tan, P. N., Steinbach, M., Karpatne, A., ve Kumar, V. (2018). Introduction to data mining (2nd ed.), USA: Pearson.
- Tatlıdil, H. (1996). *Uygulamalı çok değişkenli istatistiksel analiz*. Ankara: Engin Yayınları.
- Tavşancıl, E., Yıldırım, Ö., ve Bilican Demir, S. (2019). Direct and indirect effects of learning strategies and reading enjoyment on PISA 2009 reading performance. *Eurasian Journal of Educational Research*, 82, 169-190.
- Urfalı Dadandı, P., Dadandı, İ., ve Koca, F. (2018). PISA 2015 türkiye sonuçlarına göre sosyoekonomik faktörler ile okuma becerileri arasındaki ilişkiler. *Uluslararası Türkçe Edebiyat Kültür Eğitim Dergisi*, 7(2), 1239-1252.
- Uyulgan, M. A., ve Akkuzu, N. (2017). Ortaöğretim öğrencilerinin akademik başarılarını yordayan kişisel faktörler üzerine bir araştırma. *Bartın Üniversitesi Eğitim Fakültesi Dergisi*, 6(3), 1211-1226.
- Vanwinckelen, G., ve Blockeel, H. (2012) *On estimating model accuracy with repeated cross-validation*, Belgian-Dutch Conference on Machine Learning (BeneLearn) edition:21 location, 24-25 May 2012.
- Vilenius Tuohimaa, P. M., Aunola, K., ve Nurmi, J. E. (2008). The association between mathematical word problems and reading comprehension. *Educational Psychology*, 28(4), 409-426.
- Williams, G. (2011). *Data mining with rattle and R: The art of excavating data for knowledge discovery*, New York, USA: Springer Science+Business Media
- Witten, I. H., ve Frank, E. (2005) *Data minig: Practical machine learning tools and techniques*, United States of America: Morgan Kaufmann publications
- Witten, I. H., Frank, E., ve Hall, M. (2016). *Data minig: Practical machine learning tools and techniques*, United States of America: Morgan Kaufmann publications.

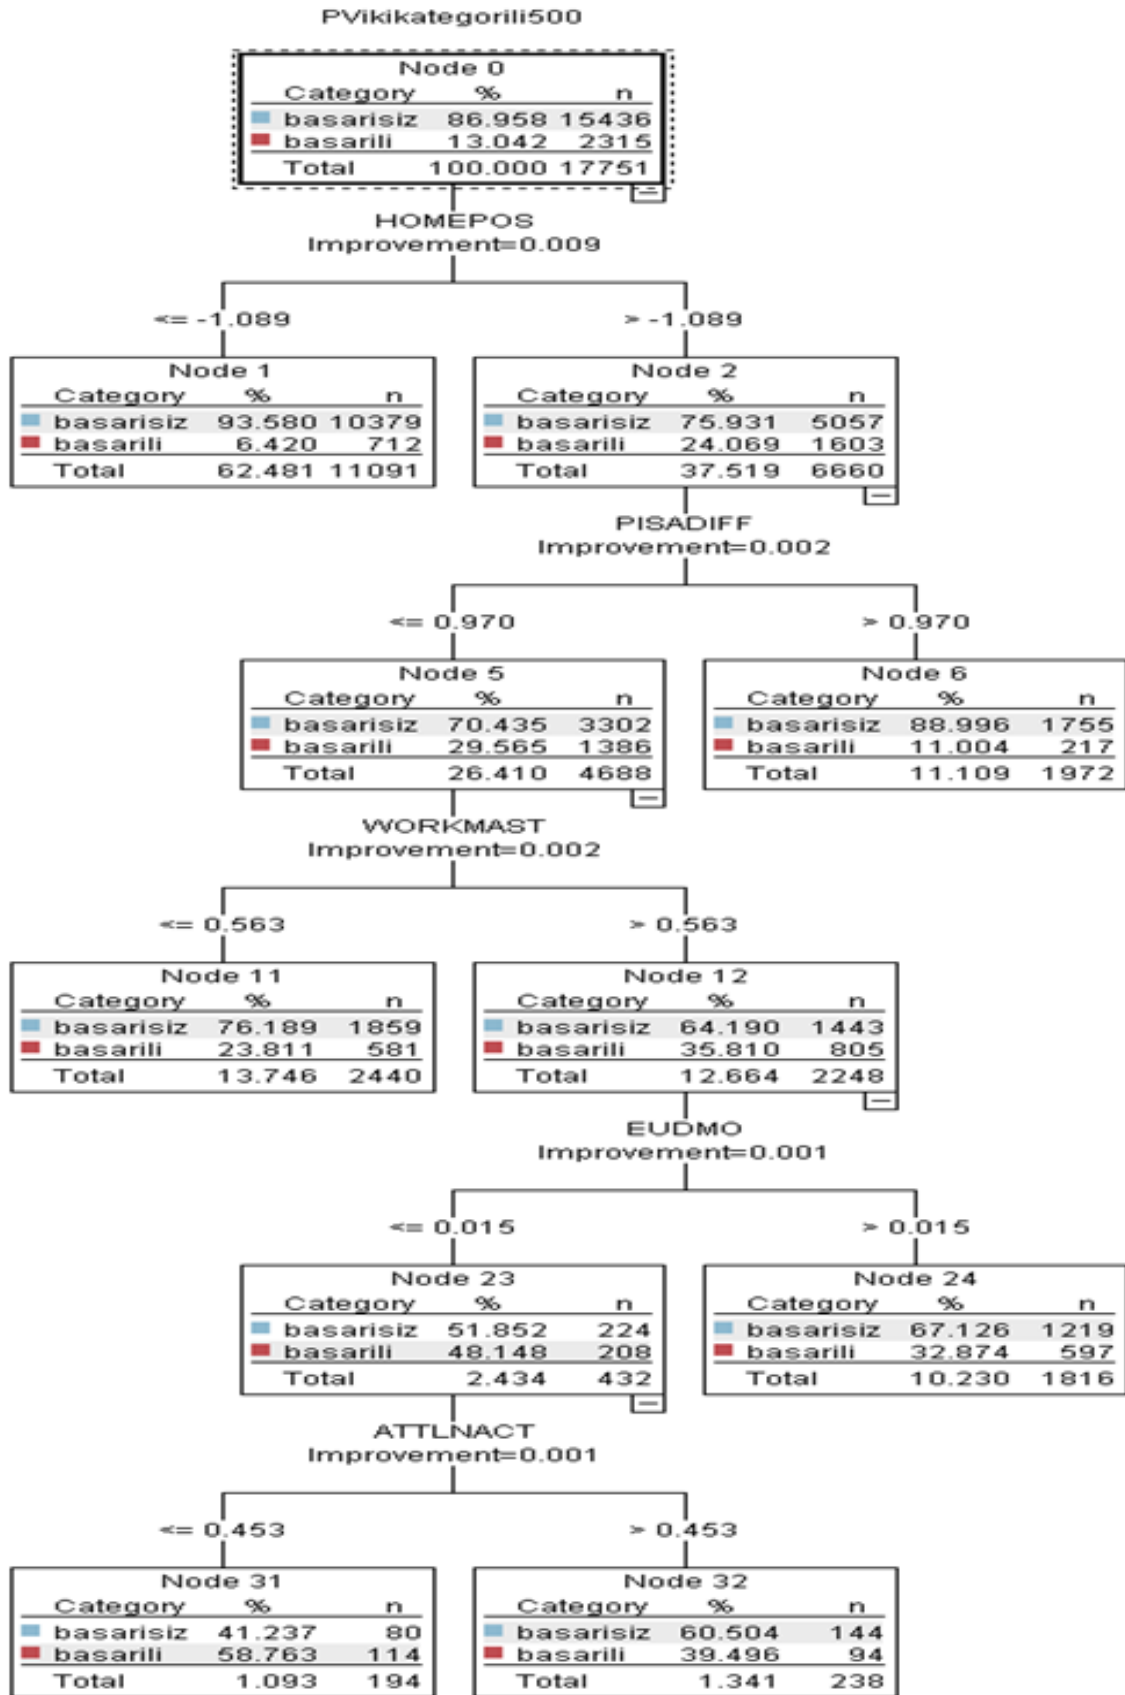
- Wu, M. L., and Adams, R. J., (2002). Plausible Values: Why they are important. Paper presented at the International Objective Measurement workshop, New Orleans, LA.
- Yan, J. (2017). Multi-class ROC random forest for imbalanced classification. Doctoral dissertation, The Graduate School, Stony Brook University: Stony Brook, NY.
- Yıldırım, Ö. (2012). *Okuduğunu anlama başarısıyla ilişkili faktörlerin aşamalı doğrusal modellemeyle belirlenmesi (PISA 2009 hollanda, kore ve türkiye karşılaştırması) (Doktora Tezi)*.Ankara Üniversitesi Eğitim Bilimleri Enstitüsü Ankara.
- Yu, C. H., Kaprolet C., Pennel, A. J.,ve Digangi, S. (2012). A data mining approach to comparing american and canadian grade 10 students' pisa science test performance.*Journal of Data Science* 10, 441-464.
- Yue, Y. (2021). The prediction model of college english performance based on data mining under the concept of obe. *Engineering Intelligent Systems*, 2,89–96.
- Yung, J. L., Hsu, Y. C., ve Rice, K. (2012). Integrating data mining in program evaluation of k-12 online education. *Journal of Educational Technology ve Society*, 15 (3), 27-41.

EK-A: İki Kategorili Başarı Durumu İçin Sınıflama ve Regresyon Ağaçları

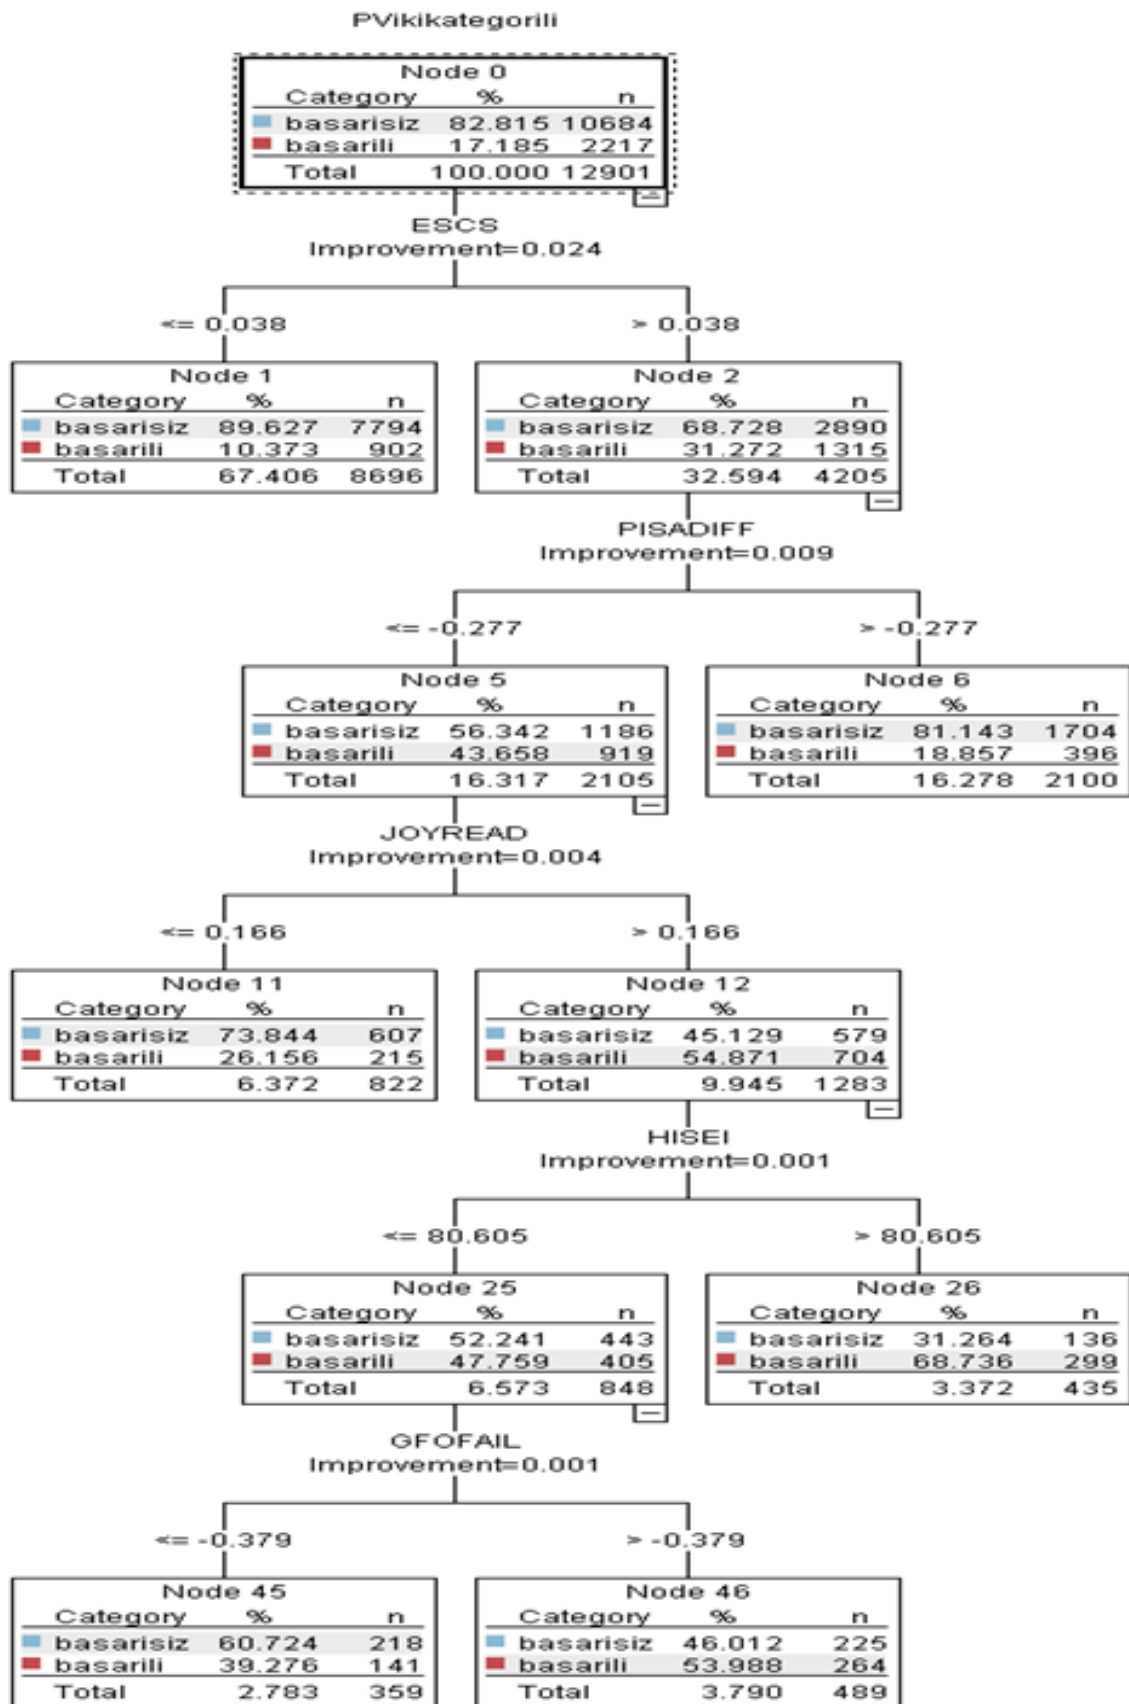
Türkiye örneklemi



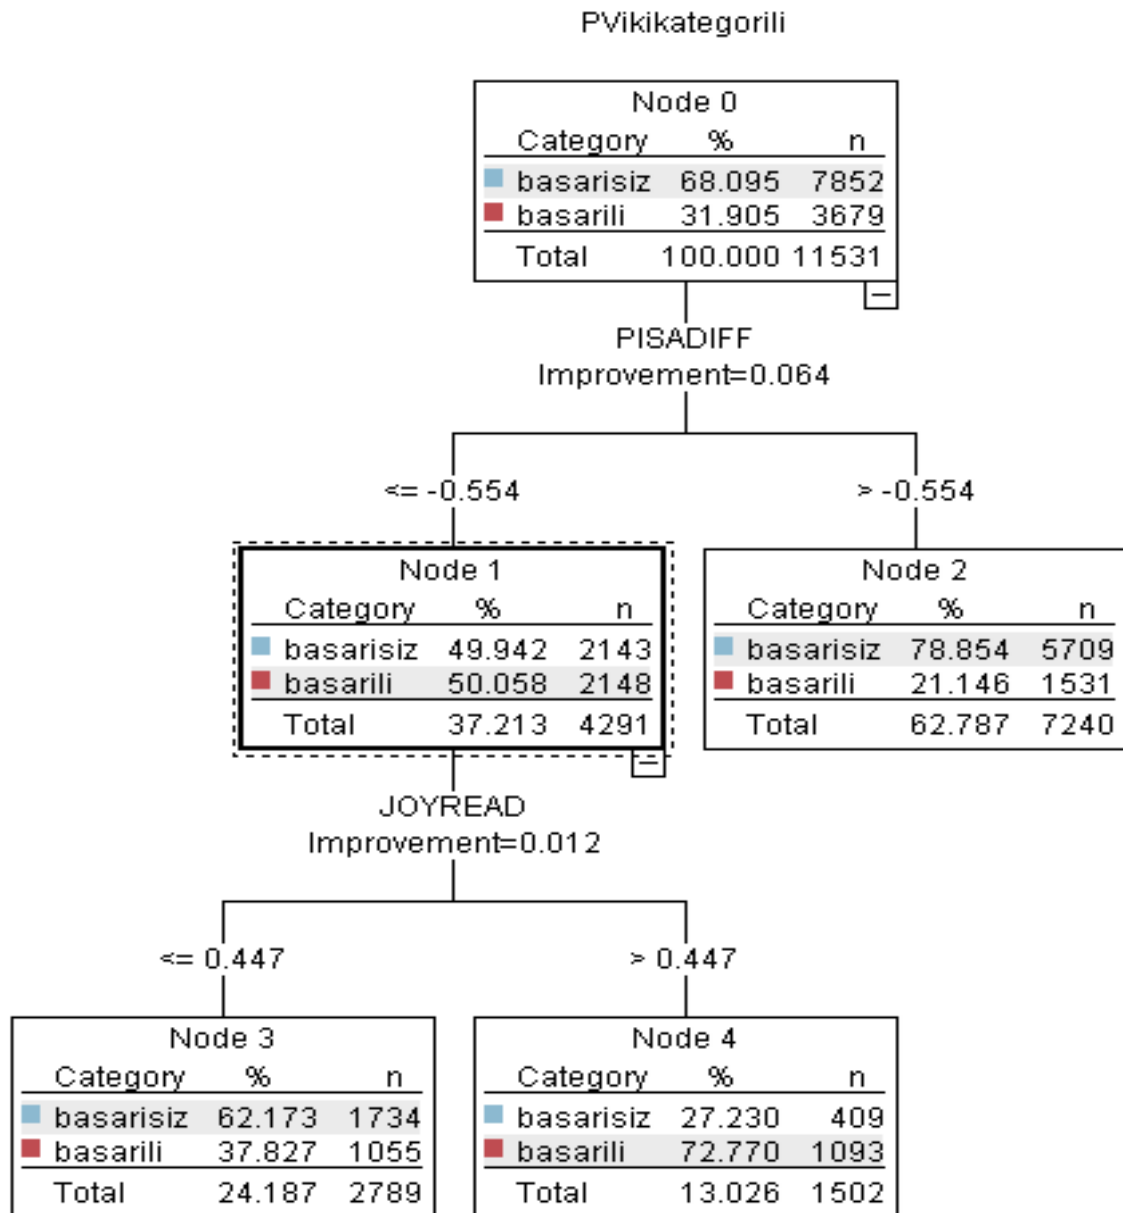
Alt grup ülkeler örnekleme



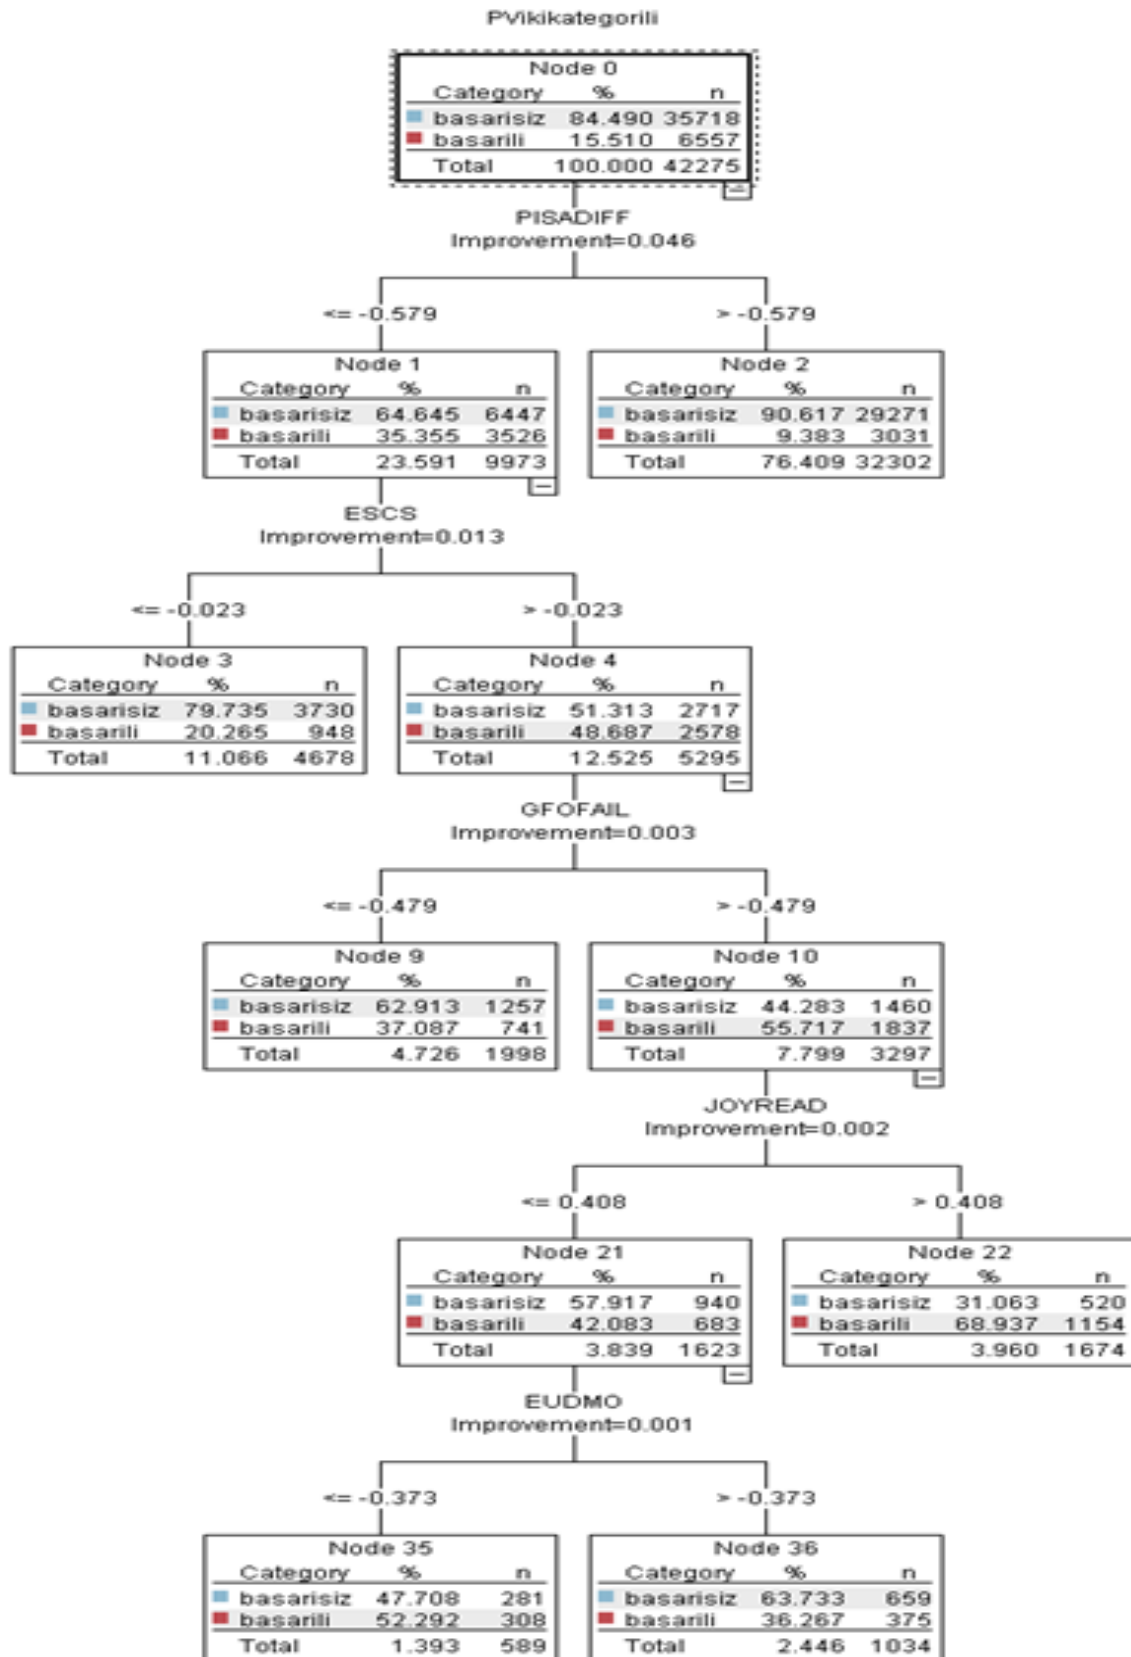
Orta grup ülkeler örnekleme



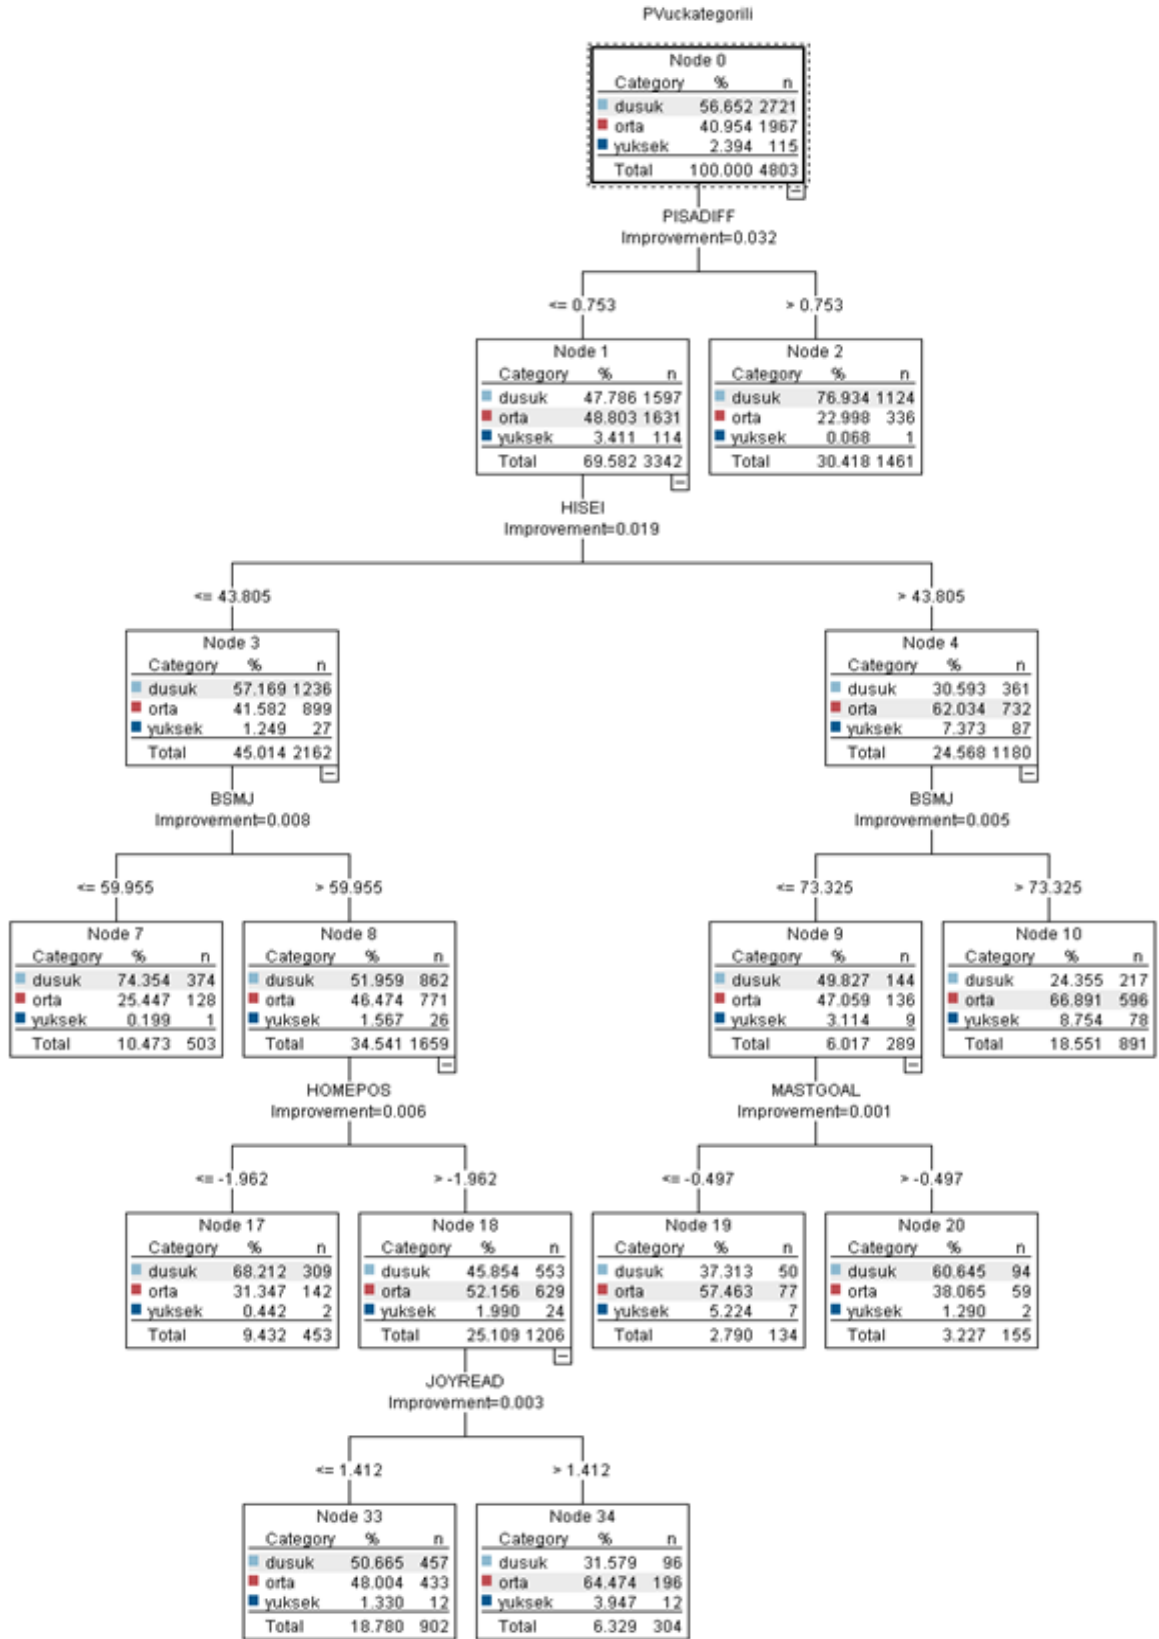
Üst grup ülkeler örnekleme



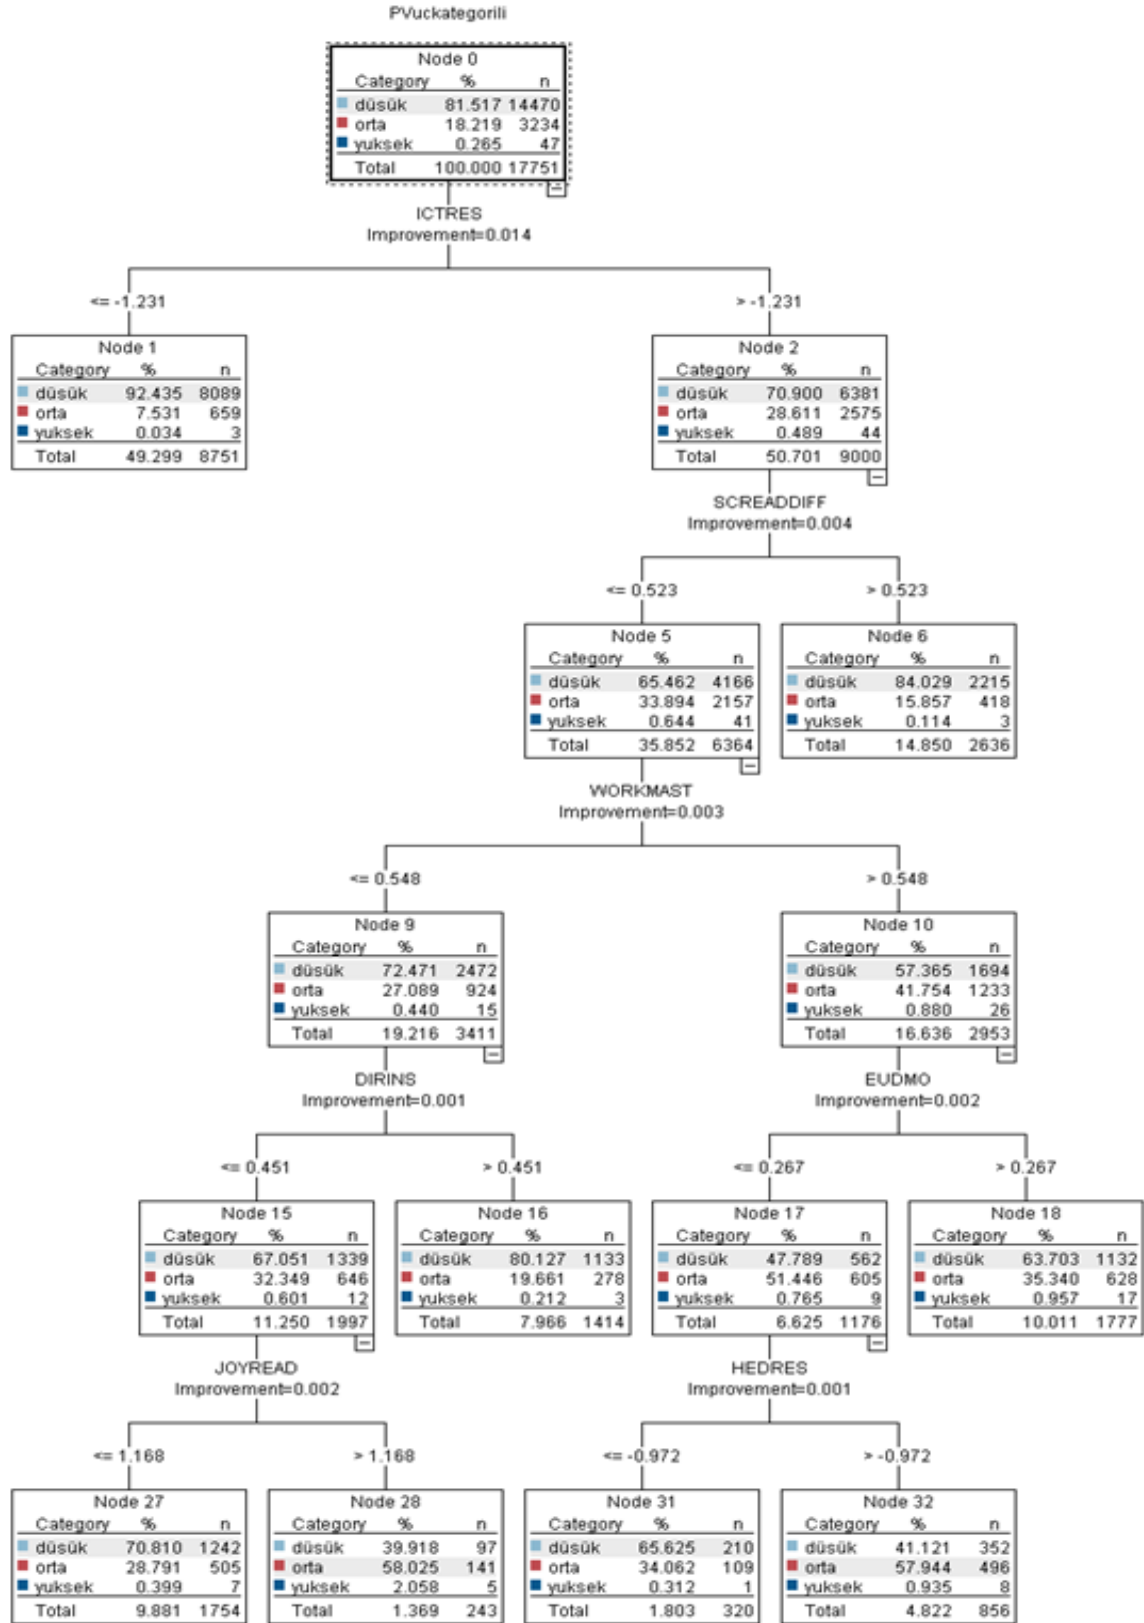
Çalışma Örnekleme



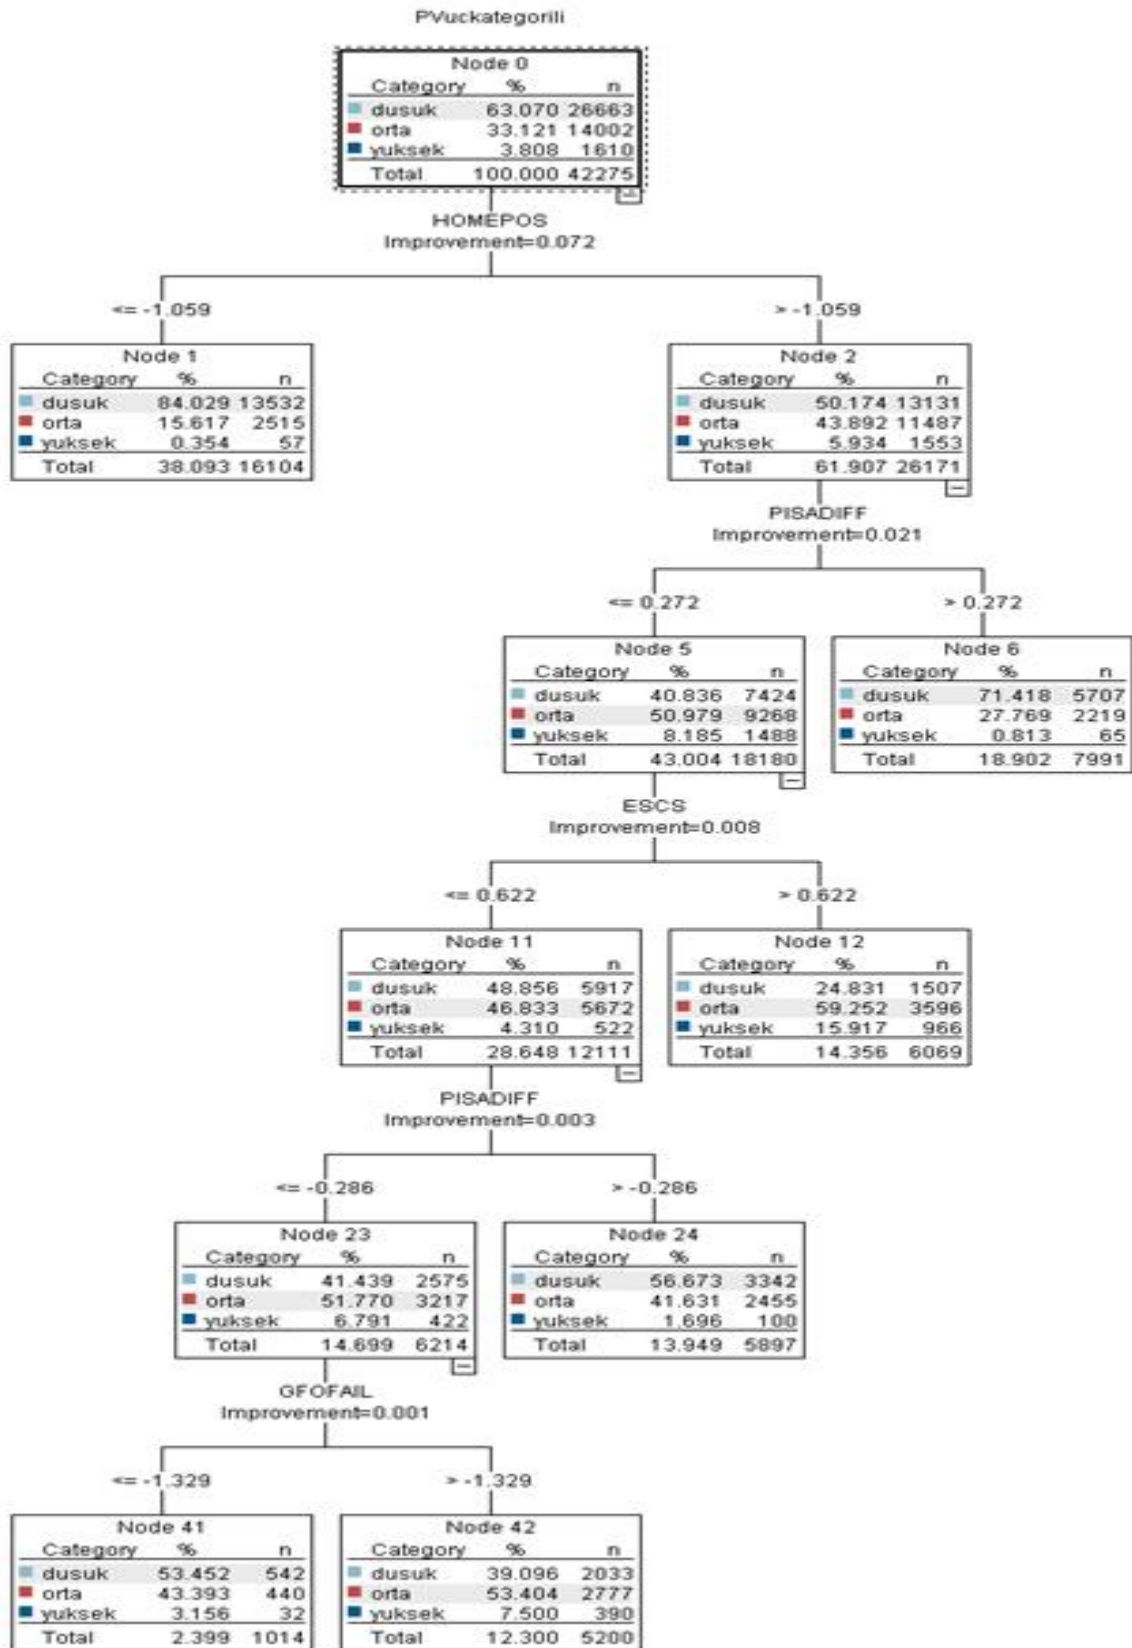
EK-B: Üç Kategorili Başarı Durumu İçin Sınıflama ve Regresyon Ağaçları Türkiye örneklemi



Alt grup ülkeler örneklemi



Çalışma Örneklemi



EK-C: Etik Komisyonu Onay Bildirimi



T.C.
HACETTEPE ÜNİVERSİTESİ
Rektörlük

Tarih: 17/07/2020
Sayı: 35853172-300-E.00001160884

0001160884

Sayı : 35853172-300
Konu : Yusuf KASAP (Etik Komisyon İzni)

EĞİTİM BİLİMLERİ ENSTİTÜSÜ MÜDÜRLÜĞÜNE

İlgi : 30.06.2020 tarihli ve 51944218-300/00001133396 sayılı yazı.

Enstitünüz Eğitim Bilimleri Anabilim Dalı Eğitimde Ölçme ve Değerlendirme Bilim Dalı Doktora programı öğrencilerinden **Yusuf KASAP**'ın **Prof. Dr. Nuri DOĞAN** danışmanlığında yürüttüğü “**Veri Madenciliği Yöntemleri ile Ülkelerin PISA Başarı Düzeylerini Etkileyen Değişkenlerin İncelenmesi**” başlıklı tez çalışması Üniversitemiz Senatosu Etik Komisyonunun **14 Temmuz 2020** tarihinde yapmış olduğu toplantıda incelenmiş olup, etik açıdan uygun görülmüştür.

Bilgilerinizi ve gereğini saygılarımla rica ederim.

e-imzalıdır
Prof. Dr. Ahmet SERPER
Rektör Yardımcısı

Evrakın elektronik imzalı suretine <https://belgedogrulama.hacettepe.edu.tr> adresinden a109d242-919b-44f7-9891-bb224d289e56 kodu ile erişebilirsiniz.
Bu belge 5070 sayılı Elektronik İmza Kanunu'na uygun olarak Güvenli Elektronik İmza ile imzalanmıştır.

Hacettepe Üniversitesi Rektörlük 06100 Sıhhiye-Ankara
Telefon:0 (312) 305 3001-3002 Faks:0 (312) 311 9992 E-posta:yazimd@hacettepe.edu.tr İnternet
Adresi: www.hacettepe.edu.tr

Sevda TOPAÇ



EK-Ç: Etik Beyanı

Hacettepe Üniversitesi Eğitim Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada,

- tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- görsel, işitsel ve yazılı bütün bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- başkalarının eserlerinden yararlanması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- atıfta bulunduğum eserlerin bütününe kaynak olarak gösterdiğimi,
- kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- bu tezin herhangi bir bölümünü bu üniversitede veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

26/01/2022

(İmza)
Yusuf KASAP

EK-D: Yüksek Lisans/Doktora Tez Çalışması Orijinallik Raporu

22/02/2022

HACETTEPE ÜNİVERSİTESİ
Eğitim Bilimleri Enstitüsü
Eğitim Bilimleri Ana Bilim Dalı Başkanlığına,

Tez Başlığı: Veri madenciliği yöntemleri ile ülkelerin pisa başarı düzeylerini etkileyen değişkenlerin incelenmesi

Yukarıda başlığı verilen tez çalışmamın tamamı (kapak sayfası, özetler, ana bölümler, kaynakça) aşağıdaki filtreler kullanılarak **Turnitin** adlı intihal programı aracılığı ile kontrol edilmiştir. Kontrol sonucunda aşağıdaki veriler elde edilmiştir:

Rapor Tarihi	Sayfa Sayısı	Karakter Sayısı	Savunma Tarihi	Benzerlik Oranı	Gönderim Numarası
22/02/2022	144	247.796	26/01/2022	%7	1767874375

Uygulanan filtreler:

1. Kaynaklar hariç
2. Alıntılar dâhil
3. 5 kelimedenden daha az örtüşme içeren metin kısımları hariç

Hacettepe Üniversitesi Eğitim Bilimleri Enstitüsü Tez Çalışması Orijinallik Raporu Alınması ve Kullanılması Uygulama Esasları'nı inceledim ve çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunun beyan eder, gereğini saygılarımla arz ederim.

Ad Soyadı: Yusuf KASAP

Öğrenci No.: N16245919

Ana Bilim Dalı: Eğitim Bilimleri

Programı: Eğitimde Ölçme ve Değerlendirme

Statüsü: Y.Lisans Doktora Bütünleşik Dr.

İmza

DANIŞMAN ONAYI

UYGUNDUR.
(Prof. Dr., Nuri DOĞAN, İmza)

EK-E: Thesis/Dissertation Originality Report

22/02/2022

HACETTEPE UNIVERSITY
Graduate School of Educational Sciences
To The Department of Educational Sciences

Thesis Title: Investigation of variables affecting pisa success levels of countries by data mining methods

The whole thesis that includes the *title page, introduction, main chapters, conclusions and bibliography section* is checked by using **Turnitin** plagiarism detection software take into the consideration requested filtering options. According to the originality report obtained data are as below.

Time Submitted	Page Count	Character Count	Date of Thesis Defense	Similarity Index	Submission ID
22/02/2022	144	247.796	26/01/2022	%7	1767874375

Filtering options applied:

1. Bibliography excluded
2. Quotes included
3. Match size up to 5 words excluded

I declare that I have carefully read Hacettepe University Graduate School of Educational Sciences Guidelines for Obtaining and Using Thesis Originality Reports; that according to the maximum similarity index values specified in the Guidelines, my thesis does not include any form of plagiarism; that in any future detection of possible infringement of the regulations I accept all legal responsibility; and that all the information I have provided is correct to the best of my knowledge.

I respectfully submit this for approval.

Name Lastname: Yusuf KASAP
Student No.: N16245919
Department: Educational Sciences
Program: Educational Measurement and Evaluation
Status: Masters Ph.D. Integrated Ph.D.

Signature

ADVISOR APPROVAL

APPROVED
(Prof. Dr., Nuri DOĞAN, Signature)

EK-F: Yayınlanma ve Fikrî Mülkiyet Hakları Beyanı

Enstitü tarafından onaylanan lisansüstü tezimin/raporumun tamamını veya herhangi bir kısmını, basılı (kâğıt) ve elektronik formatta arşivleme ve aşağıda verilen koşullarla kullanıma açma iznini Hacettepe Üniversitesine verdiğimi bildiririm. Bu izinle Üniversiteye verilen kullanım hakları dışındaki tüm fikri mülkiyet haklarım bende kalacak, tezimin tamamının ya da bir bölümünün gelecekteki çalışmalarda (makale, kitap, lisans ve patent vb.) kullanım hakları bana ait olacaktır.

Tezin kendi orijinal çalışmam olduğunu, başkalarının haklarını ihlal etmediğimi ve tezimin tek yetkili sahibi olduğumu beyan ve taahhüt ederim. Tezimde yer alan telif hakkı bulunan ve sahiplerinden yazılı izin alınarak kullanılması zorunlu metinlerin yazılı izin alınarak kullandığımı ve istenildiğinde suretlerini Üniversiteye teslim etmeyi taahhüt ederim.

Yükseköğretim Kurulu tarafından yayınlanan "**Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge**" kapsamında tezim aşağıda belirtilen koşullar haricince YÖK Ulusal Tez Merkezi / H.Ü. Kütüphaneleri Açık Erişim Sisteminde erişime açılır.

- o Enstitü/Fakülte yönetim kurulu kararı ile tezimin erişime açılması mezuniyet tarihinden itibaren 2 yıl ertelenmiştir.⁽¹⁾
- o Enstitü/Fakülte yönetim kurulunun gerekçeli kararı ile tezimin erişime açılması mezuniyet tarihimden itibaren... ay ertelenmiştir.⁽²⁾
- o Tezimle ilgili gizlilik kararı verilmiştir.⁽³⁾

26/01/2022

(imza)

Yusuf KASAP

"*Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge*"

(1) *Madde 6. 1. Lisansüstü teze ilgili patent başvurusu yapılması veya patent alma sürecinin devam etmesi durumunda, tez danışmanının önerisi ve enstitü anabilim dalının uygun görüşü üzerine enstitü veya fakülte yönetim kurulu iki yıl süre ile tezin erişime açılmasının ertelenmesine karar verebilir.*

(2) *Madde 6. 2. Yeni teknik, materyal ve metotların kullanıldığı, henüz makaleye dönüşmemiş veya patent gibi yöntemlerle korunmamış ve internette paylaşılması durumunda 3. şahıslara veya kurumlara haksız kazanç; imkânı oluşturabilecek bilgi ve bulguları içeren tezler hakkında tez danışmanının önerisi ve enstitü anabilim dalının uygun görüşü üzerine enstitü veya fakülte yönetim kurulunun gerekçeli kararı ile altı ayı aşmamak üzere tezin erişime açılması engellenebilir.*

(3) *Madde 7. 1. Ulusal çıkarları veya güvenliği ilgilendiren, emniyet, istihbarat, savunma ve güvenlik, sağlık vb. konulara ilişkin lisansüstü tezlerle ilgili gizlilik kararı, tezin yapıldığı kurum tarafından verilir*. Kurum ve kuruluşlarla yapılan işbirliği protokolü çerçevesinde hazırlanan lisansüstü tezlere ilişkin gizlilik kararı ise, ilgili kurum ve kuruluşun önerisi ile enstitü veya fakültenin uygun görüşü üzerine üniversite yönetim kurulu tarafından verilir. Gizlilik kararı verilen tezler Yükseköğretim Kuruluna bildirilir.*

Madde 7. 2. Gizlilik kararı verilen tezler gizlilik süresince enstitü veya fakülte tarafından gizlilik kuralları çerçevesinde muhafaza edilir, gizlilik kararının kaldırılması halinde Tez Otomasyon Sistemine yüklenir

** Tez danışmanının önerisi ve enstitü anabilim dalının uygun görüşü üzerine enstitü veya fakülte yönetim kurulu tarafından karar verilir.*