



**HACETTEPE ÜNİVERSİTESİ**  
**EĞİTİM BİLİMLERİ ENSTİTÜSÜ**

Eğitim Bilimleri Ana Bilim Dalı  
Eğitimde Ölçme ve Değerlendirme Programı

ÖĞRENCİLERİN PISA MATEMATİK BAŞARILARININ YORDANMASINDA VERİ  
MADENCİLİĞİ YÖNTEMLERİNİN KARŞILAŞTIRILMASI

İlhan KOYUNCU

Doktora Tezi

Ankara, 2018



Liderlik, arařtırma, inovasyon, kaliteli eęitim ve deęiřim ile

*Daha ileriye ... En İyiyeye ...*



**HACETTEPE ÜNİVERSİTESİ**  
**EĞİTİM BİLİMLERİ ENSTİTÜSÜ**

Eğitim Bilimleri Ana Bilim Dalı  
Eğitimde Ölçme ve Değerlendirme Programı

ÖĞRENCİLERİN PISA MATEMATİK BAŞARILARININ YORDANMASINDA  
VERİ MADENCİLİĞİ YÖNTEMLERİNİN KARŞILAŞTIRILMASI

COMPARISON OF DATA MINING METHODS IN PREDICTING PISA  
MATHEMATICAL ACHIEVEMENTS OF STUDENTS

İlhan KOYUNCU

Doktora Tezi

Ankara, 2018

## Kabul ve Onay

Eđitim Bilimleri Enstitüsü M¼d¼rl¼đ¼ne,

İlhan KOYUNCU'nun hazırladığı "Öđrencilerin PISA Matematik Başarılarının Yordanmasında Veri Madenciliđi Yöntemlerinin Karşılaştırılması" başlıklı bu çalışma j¼rimiz tarafından **Eđitim Bilimleri Ana Bilim Dalı, Eđitimde Ölçme ve Deđerlendirme Bilim Dalında Doktora Tezi** olarak kabul edilmiştir.

J¼ri Başkanı Prof. Dr., H¼lya KELECİOđLU



J¼ri Üyesi (Danışman) Prof. Dr., Selahattin GELBAL



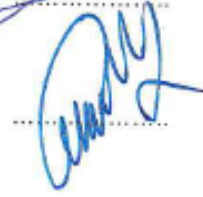
J¼ri Üyesi Doç Dr., Nuri DOđAN



J¼ri Üyesi Doç Dr., Kaan Z¼lfikar DENİZ



J¼ri Üyesi Yard. Doç. Dr., Murat AKYILDIZ



İkinci Tez Danışmanı Unvan, Ad SOYADI

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 22 / 01 / 2018 tarihinde uygun gör¼lm¼ş ve Enstit¼ Y¼netim Kurulunca .... / .... / ..... tarihinde kabul edilmiştir.

Prof. Dr. Ali Ekber ŞAHİN  
Eđitim Bilimleri Enstitüsü M¼d¼r¼

## Öz

Bu çalışmanın amacı, PISA (2012) çalışmasına katılan öğrencileri, çeşitli özellikleri bakımından matematik başarılarına göre sınıflandırmada Naive Bayes, en yakın komşuluk, yapay sinir ağları ve lojistik regresyon analizlerinin sınıflandırma performanslarını örneklem büyüklüğü ve test verisi oranı açısından incelemektir. Araştırmanın evreni PISA (2012) uygulamasına katılan 15 yaş grubundaki öğrencilerdir. Hedef evren OECD ülkelerinden çalışmaya katılan ve ilgili değişkenlere ait kayıp verisi olmayan 62728 öğrencidir. Hedef evrenden yerine koyma yöntemiyle örneklem büyüklüğü için 500 (100 veri seti), 1000 (50 veri seti) ve 5000 (30 veri seti) kişilik 180 dosya oluşturulmuştur. Her bir örneklemde %11, %22, %33, %44 ve %55 oranında veri ile yöntemlerin performansları test edilmiştir. Verinin tek ve çok değişkenli analizlerin varsayımlarının ne düzeyde sağladığı kontrol edilmiştir. Her bir veri seti için test verisinin her defasında rastgele seçildiği 100 analiz gerçekleştirilmiştir. Değerlendirme ölçütleri olarak Kappa hata matrisi uyumu, ROC eğrisinin altında kalan alan ile doğruluk oranları ve standart sapma değerleri kullanırken manidar farklılıkları da istatistiksel olarak test edilmiştir. Araştırma sonuçlarına göre, örneklem büyüklüğü arttıkça yöntemlerin sınıflandırma performansında artış görülürken, test verisi oranının artması yöntemlerin performanslarında farklı etkiler yaratmıştır. Naive Bayes yöntemi küçük örneklemelerde bile yüksek performans göstermiş, analizleri çok kısa sürede gerçekleştirmiş ve test verisi oranının değişiminden önemli düzeyde etkilenmemiştir. Lojistik regresyon analizi büyük örneklemelerde en etkili yöntem iken küçük örneklemelerde düşük performans göstermiştir. Yapay sinir ağları benzer bir eğilim gösterirken, genel olarak Naive Bayes ve lojistik regresyona göre daha düşük performans göstermiştir. Tüm koşullarda en düşük performanslar en yakın komşuluk yöntemi ile elde edilmiştir. Genel olarak, öğrencilerin matematik performanslarına göre sınıflandırılmasında yüksek doğruluk değerleri elde edilmiştir. Araştırmanın sonuç ve öneriler bölümünde bulgular detaylı bir şekilde ele alınarak teori ve uygulamaya yönelik bazı önerilerde bulunulmuştur.

**Anahtar sözcükler:** Naive Bayes, en yakın komşuluk, lojistik regresyon, yapay sinir ağları, çok katmanlı algılayıcı, PISA, matematik performansı, sınıflandırma performansı.

## Abstract

The purpose of this study is to examine the performance of Naive Bayes, nearest neighborhood, artificial neural networks, and logistic regression analysis in terms of sample size and test-data ratio in classifying students participated in the PISA (2012) study according to their mathematics performance. The population is students in the 15-year-old group who are participated in the PISA (2012) study. The target population is 62728 students from OECD countries who have participated in the study and have no missing data for the relevant variables. A total of 180 datasets were created by selecting from the target population for the sample sizes including 500 (100 datasets), 1000 (50 datasets) and 5000 (30 datasets) students. The performance of each algorithm was tested by using 11%, 22%, 33%, 44% and 55% of each dataset. It has been checked to what extent the assumptions of the univariate and multivariate analyzes satisfy. For each dataset, 100 analyzes in which test-sample is randomly selected at each time were performed. As the evaluation criteria, accuracy rates and their standard deviations, Kappa values and the area under ROC curve were used. For each dataset, methods' means of accuracy rates and their standard errors were statistically tested. According to the results of the study, while the classification performance of the methods increased as the sample size increased, the increase of the test-data ratio had different effects on the performance of the methods. The Naive Bayes method showed high performance even in small samples, performed the analyzes very quickly and was not affected by the change in the test-data ratio. Logistic regression analysis was the most effective method in large samples, but had poor performance in small samples. While neural networks method showed a similar tendency, its overall performance was lower than Naive Bayes and logistic regression. The lowest performances in all conditions were obtained by the nearest neighbor method. In the conclusions and suggestions part of the present study, the findings were discussed in detail and some suggestions for theory and practice were made.

**Keywords:** Naive Bayes, nearest neighborhood, logistic regression, artificial neural networks, multilayer perceptron, PISA, math performance, classification performance.

## Teşekkür

Doktora eğitimim sürecince ve tezimin her aşamasında desteğini benden esirgemeyen çok değerli danışmanım Prof. Dr. Selahattin GELBAL'a sonsuz teşekkür ederim. Tez izleme komitesinde yer alarak kıymetli fikirlerini paylaşan ve tezimin gelişmesinde emeği olan değerli hocalarım Prof. Dr. Hülya KELECİOĞLU ve Doç. Dr. Kaan Zülfikar Deniz ile tez savunma sınavında bulunarak değerli katkılarını sunan Doç. Dr. Nuri DOĞAN'a ve Yrd. Doç. Dr. Murat AKYILDIZ'a çok teşekkür ederim.

Tezimin hazırlanması sürecinde akademik anlamda fikir alışverişinde bulunduğum ve faydalı önerileriyle katkılarını esirgemeyen değerleri arkadaşlarım Dr. Sakine GÖÇER ŞAHİN'e, Arş. Gör. Başak ERDEM KARA'ya, Arş. Gör. Osman TAT'a, Arş. Gör. Abdullah Faruk KILIÇ'a, Arş. Gör. Ahmet KESKİN'e ve Seda DEMİR'e çok teşekkür ederim. Çalışma arkadaşlarım Arş. Gör. Emine TUNÇ'a, Arş. Gör. Zahide TONGA'ya, Arş. Gör. Dr. Funda UYSAL'a, Arş. Gör. Mustafa GÖKCAN'a, Arş. Gör. Sibel AYDOĞAN'a, Arş. Gör. Muharrem KOÇ'a, Arş. Gör. Öznur BAYAR'a, Arş. Gör. Sultan KÖPRÜLÜ'ye, Arş. Gör. Hakan BÜYÜKÇOLPAN'a ve Arş. Gör. Tolga ZENCİR'e ayrıca teşekkür ederim.

Doktora eğitimim süresince araştırma görevlisi olarak çalıştığım Hacettepe Üniversitesi Eğitim Bilimleri Bölümü ve Eğitim Bilimleri Enstitüsünün gülyüzünü ve desteklerini eksik etmeyen değerli akademik ve idari çalışanlarına teşekkür ederim.

Lisans yıllarımdan beri hep yanımda bildiğim değerli dostlarım Mustafa UĞURLU'ya, Servet ÇETİN'e, Fikri AKKAYA'ya, Hasan Yavuz SEYİDOĞLU'na, Yavuz MACUN'a ve Mustafa Kemal ŞEN'e sonsuz teşekkürler...

Doktora eğitimimin boyunca dostlukları, cana yakınlıkları ve yardımseverlikleriyle çok yakın gördüğüm değerli arkadaşlarım Arş. Gör. Başak ERDEM KARA'ya, Hakan KARA'ya, Arş. Gör. Dr. Funda UYSAL'a, Arş. Gör. Emine TUNÇ'a ve Arş. Gör. Zahide TONGA'ya çok teşekkürler...

Hayatım boyunca desteklerini hep yanımda gördüğüm çok kıymetli annem, babam ve kardeşlerime sonsuz teşekkürler...

## İçindekiler

Öz .....	ii
Abstract.....	iii
Teşekkür .....	iv
Tablolar Dizini .....	vii
Şekiller Dizini .....	viii
Simgeler ve Kısaltmalar Dizini .....	ix
Bölüm 1 Giriş .....	1
Problem Durumu.....	1
Araştırmanın Amacı ve Önemi.....	7
Araştırma Problemi .....	9
Sayıtlar.....	10
Sınırlılıklar.....	10
Tanımlar .....	10
Bölüm 2 Araştırmanın Kuramsal Temeli ve İlgili Araştırmalar .....	12
Araştırmanın Kuramsal Temeli .....	12
İlgili Araştırmalar .....	38
Bölüm 3 Yöntem .....	46
Araştırmanın Evreni ve Örnekleme .....	46
Veri Toplama Süreci .....	47
Veri Toplama Araçları .....	48
Verilerin Analizi .....	49
Bölüm 4 Bulgular ve Yorumlar .....	71
Birinci Alt Probleme İlişkin Bulgular .....	71
İkinci Alt Probleme İlişkin Bulgular .....	75
Üçüncü Alt Probleme İlişkin Bulgular .....	81
Dördüncü Alt Probleme İlişkin Bulgular.....	86
Beşinci Alt Probleme İlişkin Bulgular.....	91
Bölüm 5 Sonuç, Tartışma ve Öneriler .....	97
Sonuçlar .....	97
Tartışma .....	107
Öneriler.....	114
Kaynaklar .....	118
EK-A: 5000 Kişilik Örneklemede Test Verisi Oranı %11 için Elde Edilen Analiz Sonuçları.....	126



EK-B: 5000 Kişilik Örneklemde Test Verisi Oranı %22 için Elde Edilen Analiz Sonuçları.....	127
EK-C: 5000 Kişilik Örneklemde Test Verisi Oranı %33 için Elde Edilen Analiz Sonuçları.....	128
EK-D: 5000 Kişilik Örneklemde Test Verisi Oranı %44 için Elde Edilen Analiz Sonuçları.....	129
EK-E: 5000 Kişilik Örneklemde Test Verisi Oranı %55 için Elde Edilen Analiz Sonuçları.....	130
EK-F: 1000 Kişilik Örneklemde Test Verisi Oranı %11 için Elde Edilen Analiz Sonuçları.....	131
EK-G: 1000 Kişilik Örneklemde Test Verisi Oranı %22 için Elde Edilen Analiz Sonuçları.....	132
EK-H: 1000 Kişilik Örneklemde Test Verisi Oranı %33 için Elde Edilen Analiz Sonuçları.....	133
EK-I: 1000 Kişilik Örneklemde Test Verisi Oranı %44 için Elde Edilen Analiz Sonuçları.....	134
EK-İ: 1000 Kişilik Örneklemde Test Verisi Oranı %55 için Elde Edilen Analiz Sonuçları.....	135
EK-J: 500 Kişilik Örneklemde Test Verisi Oranı %11 için Elde Edilen Analiz Sonuçları.....	136
EK-K: 500 Kişilik Örneklemde Test Verisi Oranı %22 için Elde Edilen Analiz Sonuçları.....	138
EK-L: 500 Kişilik Örneklemde Test Verisi Oranı %33 için Elde Edilen Analiz Sonuçları.....	140
EK-M: 500 Kişilik Örneklemde Test Verisi Oranı %44 için Elde Edilen Analiz Sonuçları.....	142
EK-N: 500 Kişilik Örneklemde Test Verisi Oranı %55 için Elde Edilen Analiz Sonuçları.....	144
EK-O: Etik Komisyonu Onay Bildirimi .....	146
EK-P: Etik Beyanı .....	147
EK-R: Doktora Tez Çalışması Orijinallik Raporu .....	148
EK-S: Dissertation Originality Report .....	149
EK-T: Yayımlama ve Fikrî Mülkiyet Hakları Beyanı.....	150

## Tablolar Dizini

Tablo 1. Hedef Evrenin Ülkelere Göre Dağılımı .....	47
Tablo 2. Değişkenlerin Yöntemlere Göre Sınıflandırmaya Katkı Düzeyleri .....	51
Tablo 3. Sürekli Değişkenlere İlişkin Betimsel İstatistikler .....	52
Tablo 4. Annesinin ve Babasının Eğitim Düzeyi (ISCED) .....	54
Tablo 5. Hesap Makinesi Kullanımı .....	54
Tablo 6. Sürekli Değişkenlerin Kategorilere Dağılımları .....	57
Tablo 7. Varyansların Homojenliği Testi Sonuçları .....	57
Tablo 8. Box's M Kovaryans Matrislerinin Homojenliği Testi .....	58
Tablo 9. Değişkenler Arası Korelasyon Katsayıları .....	59
Tablo 10. Çoklu Bağlantı İstatistikleri .....	60
Tablo 11. Hata Matrisi .....	64
Tablo 12. Performans Değerlendirme Ölçütleri .....	66
Tablo 13. NB Yöntemi İçin Hesaplanan Performans Ölçüt Değerleri .....	71
Tablo 14. NB Yönteminde Örneklem Büyüklüğü İçin F Değerleri .....	74
Tablo 15. NB Yönteminde Test Verisi Oranı İçin F Değerleri .....	75
Tablo 16. KNN Yöntemi İçin Hesaplanan Performans Ölçüt Değerleri .....	76
Tablo 17. KNN Yönteminde Örneklem Büyüklüğü İçin F Değerleri .....	79
Tablo 18. KNN Yönteminde Test Verisi Oranı İçin F Değerleri .....	80
Tablo 19. MLP Yöntemi İçin Hesaplanan Performans Ölçüt Değerleri .....	81
Tablo 20. MLP Yönteminde Örneklem Büyüklüğü İçin F Değerleri .....	84
Tablo 21. MLP Yönteminde Test Verisi Oranı İçin F Değerleri .....	85
Tablo 22. LR Yöntemi İçin Hesaplanan Performans Ölçüt Değerleri .....	86
Tablo 23. LR Yönteminde Örneklem Büyüklüğü İçin F Değerleri .....	89
Tablo 24. LR Yönteminde Test Verisi Oranı İçin F Değerleri .....	90
Tablo 25. Tüm Yöntemler İçin Performans Ölçüt Değerleri .....	91
Tablo 26. Yöntem Karşılaştırması İçin F Değerleri .....	92
Tablo 27. Farklı Koşullarda Yöntemler Arası Ortalama Fark Değerleri .....	93

## Şekiller Dizini

Şekil 1. Veri Madenciliğini Eğitim Sistemlerine Uygulama Döngüsü (Romero ve Ventura, 2007) .....	2
Şekil 2. Bağımsız Değişkenlerin ( $x_1, x_2, \dots, x_k$ ), S Sınıflandırma Değişkenine Göre Koşullu Bağımsızlığını Gösteren Naive Bayes Modelinin Bayes Ağı Gösterimi ....	14
Şekil 3. KNN Yöntemi ile Sınıflandırma.....	17
Şekil 4. Sinir Hücresinin Yapısı (Akpınar, 2014, s. 237).....	22
Şekil 5. Tek ve Çok Katmanlı Yapay Sinir Ağları .....	23
Şekil 6. Eşik Fonksiyonları (Akpınar, 2014, s. 242).....	24
Şekil 7. Algılayıcı Model (Tan ve diğerleri, 2014).....	30
Şekil 8. Doğrusal ve Doğrusal Olmayan İlişkiler.....	33
Şekil 9. Örnek Lojistik Eğri (Dunham, 2003, s. 86).....	35
Şekil 10. Araştırmada Kullanılan Sürekli Değişkenlerin Bağımlı Değişkene Göre Dağılımları.....	53
Şekil 11. Araştırmada Kullanılan Kategorik Değişkenlerin Bağımlı Değişkene Göre Dağılımları.....	55
Şekil 12. Değişkenlerin Koşullu Bağımsızlığını Gösteren ICS Bayes Ağı .....	61
Şekil 13. Analizlerden Elde Edilen Örnek Veri .....	68
Şekil 14. NB Yöntemi İçin Doğruluk Oranının Tüm Koşullara Göre Değişimi.....	72
Şekil 15. NB Yöntemi İçin Doğruluk Oranlarının Standart Sapma Miktarının Tüm Koşullara Göre Değişimi .....	73
Şekil 16. KNN Yöntemi İçin Doğruluk Oranının Tüm Koşullara Göre Değişimi .....	77
Şekil 17. KNN Yöntemi İçin Doğruluk Oranlarının Standart Sapma Miktarının Tüm Koşullara Göre Değişimi .....	78
Şekil 18. MLP Yöntemi İçin Doğruluk Oranının Tüm Koşullara Göre Değişimi .....	82
Şekil 19. MLP Yöntemi İçin Doğruluk Oranlarının Standart Sapma Miktarının Tüm Koşullara Göre Değişimi .....	83
Şekil 20. LR Yöntemi İçin Doğruluk Oranının Tüm Koşullara Göre Değişimi .....	87
Şekil 21. LR Yöntemi İçin Doğruluk Oranlarının Standart Sapma Miktarının Tüm Koşullara Göre Değişimi .....	88
Şekil 22. Tüm Yöntemler İçin Doğruluk Oranlarının Farklı Koşullara Göre Değişimi .....	94
Şekil 23. Tüm Yöntemler İçin Doğruluk Oranlarının Standart Sapma Miktarının Farklı Koşullara Göre Değişimi .....	95
Şekil 24. Yöntemlerin Analiz Sürelerinin Örneklem Büyüklüğü ve Test Verisi Oranına Göre Değişimi .....	96

## **Simgeler ve Kısaltmalar Dizini**

**EVM:** Eđitsel Veri Madenciliđi

**ISCED:** International Standard Classification of Education

**KNN:** K- En Yakın Komşuluk

**LR:** Lojistik Regresyon

**MLP:** Multilayer Perceptron

**NB:** Naive Bayes

**OECD:** The Organisation for Economic Co-operation and Development

**PISA:** The Programme for International Student Assessment

**ROC:** Receiver Operating Characteristic

**YSA:** Yapay Sinir Ağları

## Bölüm 1

### Giriş

Bu bölümde, problem durumu, araştırma problemi, alt problemler, sayıtlılar, sınırlılıklar, araştırmanın amacı ve önemi ile tanımlara yer verilmiştir.

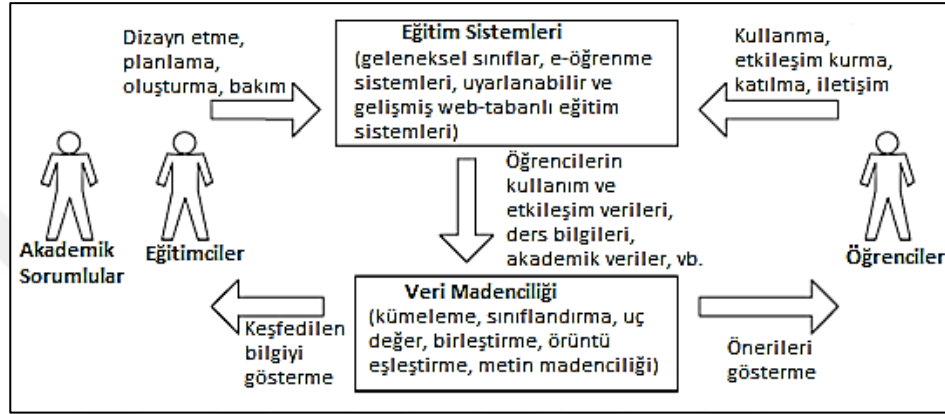
#### Problem Durumu

Veri madenciliği, büyük veri yığınlarını işleyerek karar vermede yardımcı olan gizli örüntüleri ve ilişkileri keşfetmek amacıyla kullanılır (Bhardwaj ve Pal, 2011). Birçok bilim dalında tahminleme (yordama), kümeleme ve ilişki ağlarını ortaya çıkarmak amacıyla matematiksel ve istatistiksel algoritmalara dayalı çok çeşitli yöntemlerden yararlanır. Veri madenciliğinin kökleri makine öğrenmesi, yapay zeka, bilgisayar bilimleri ve istatistiğe dayanır (Dunham, 2003). Pazarlamadan mühendisliğe, sağlık bilimlerinden işletmeye geniş bir alanda kullanılan veri madenciliği yöntemleri, teknolojik gelişmelerle birlikte son yıllarda eğitim alanında da hızla artan büyük ve karışık veri setlerini incelemek amacıyla kullanılmaya başlamıştır. Veri madenciliği çok sayıda endüstriye ve sektöre uygulanmasına rağmen eğitim bağlamında uygulamaları sınırlıdır (Ranjan ve Malik, 2007).

Öğrenci başarısının yordanması eğitimde yapılan birçok araştırmanın odak noktasını oluşturur. Özellikle, teknolojinin hızla geliştiği ve eğitimde daha fazla önem kazandığı günümüzde öğrenci başarısını etkileyen birçok faktörü içinde barındıran veri tabanları bulunmaktadır. Angel, Blackboard, Webct ve Moodle gibi zengin eğitimsel veri kaynaklarını içeren ders yönetim sistemlerinin yanında, uluslararası düzeyde yapılan TIMMS (Uluslararası Matematik ve Fen Eğilimleri Araştırması), PISA (Uluslararası Öğrenci Değerlendirme Programı) ve PIRLS (Uluslararası Okuma Becerilerinde Gelişim Projesi) gibi çalışmalarda öğrenci, öğretmen, okul, bölge ve ülke düzeyinde bilgiler toplanmaktadır. Elde edilen eğitimsel içerikli veri yığınlarını analiz etmek ve öğrencileri karşılaştırarak başarılarını yordamak son yıllarda gittikçe önem kazanmaktadır. Bu amaçla, eğitsel veri madenciliği (EVM) son yıllarda bağımsız bir araştırma alanı olarak ortaya çıkmıştır (Baker, 2010).

EVM, veri madenciliği tekniklerini eğitim içerikli verilere uygulamak amacıyla ortaya çıkan yeni bir disiplindir (Baker ve Yacef, 2009; Huebner, 2013). Öğretim programlarının etkililiğinden öğrenci başarısının yordanmasına, eğitim kurumlarından öğretmenlerin performansına kadar eğitimin her alanında

kullanılabilmektedir. İlgili alan yazında EVM ile ilgili farklı tanımlamalar mevcuttur. Baker ve Yacef (2009), EVM'yi, eğitim ortamlarından elde edilen kendine özgü verilerden keşifler yapmak amacıyla yeni metotların geliştirilmesini merkez alan, öğrencileri ve öğrenme ortamlarını daha iyi anlamak için bu metotları kullanan bilimsel araştırma alanı olarak tanımlamaktadır. Ancak, Huebner (2013) bu şekilde tanımlamaların sınırlı olduğunu, EVM'nin çok geniş bir alanı kapsadığını ve ileride yapılacak çalışmalarla birlikte bu alanın kapsamının ve tanımlarının değişeceğini belirtmiştir. Eğitim sistemleri ve veri madenciliği ilişkisi Şekil 1'deki gibi özetlenmiştir.



Şekil 1. Veri Madenciliğini Eğitim Sistemlerine Uygulama Döngüsü (Romero ve Ventura, 2007)

Romero ve Ventura (2007) eğitimde veri madenciliğinin hipotez oluşturma, test etme ve geliştirmeden oluşan iteratif döngüsel bir süreç olduğunu ifade etmişlerdir. Şekil 1'de görülen bu döngüsel süreçte, eğitimcilerin ve akademik sorumluların, eğitim sistemlerini tasarılama, planlama ve geliştirme yükümlülükleri vardır. Öğrencilerin bu sistemleri kullanması ve etkileşimde bulunmasıyla veri madenciliğinde çeşitli amaçlarla (kümeleme, sınıflandırma, birleştirme, vb.) kullanılacak çıktılar (kullanım ve etkileşim verileri, ders bilgileri, akademik veriler, vb.) elde edilir. Keşfedilen yararlı bilgiler hem sorumlular hem de öğrenciler tarafından kullanılabilir (Romero ve Ventura, 2007).

Bazı EVM araştırmacıları (örn., Baker, 2010; Baker ve Yacef 2009) eğitimde veri madenciliğinin amaçlarını aşağıdaki gibi sıralamaktadır:

1. Öğrencilerin bilgi, motivasyon, üstbilis ve tutum gibi detaylı bilgilerini içeren öğrenci modelleri oluşturarak öğrencilerin gelecekteki öğrenme davranışlarını yordamak,

2. Öğrenme içeriğini ve optimal öğretimsel gidişatı niteleyen alan modellerini keşfetmek veya geliştirmek,

3. Öğrenilen yazılım tarafından sağlanan farklı pedagojik destek çeşitlerinin etkilerini araştırmak,

4. Öğrenci modellerini, alanı ve yazılımın pedagojisini içeren sayısal modeller kurarak öğrenme ve öğrenenler hakkındaki bilimsel bilgiyi iletmek.

Veri madenciliğinde istatistik, makine öğrenmesi ve yapay zekâ gibi teknikler kullanıldığından EVM araştırmaları da öncelikle nicel analizlere odaklanır. Ancak, alan yazında yapılan birçok araştırma durum araştırmalarına dayanır ve genellenebilirlik açısından sorunludur. Bu nedenle, tahminleme, gruplama, sınıflama veya birleştirme formunda olan nicel uygulamalar EVM'nin odak noktasıdır ve yapılacak araştırmalar veri madenciliği bulgularının daha çok nasıl genellenebilirliği üzerine olmalıdır (Huebner, 2013).

Baker (2010), eğitsel veri madenciliğinde popüler çok çeşitli metotların yordama, kümeleme, ilişki arama, modellerle keşfetme ve bireyleri değerlendirme amacıyla verilerin damıtılması şeklinde beş ana kategori altında toplandığını belirtmiştir. Yordama, verinin büyük bir kısmını oluşturan değişkenlerden, tek bir parçası hakkında çıkarımlar yapmaya dayanır. Öğrencilerin matematik performansları hakkında çıkarımda bulunmak amacıyla verinin kalan kısmında yer alan kaygı, tutum, özyeterlik, vb. özelliklerin kullanılması buna örnek gösterilebilir. Yordama, sınıflandırma, regresyon ve yoğunluk (density) kestirimi olmak üzere üçe ayrılır (Baker, 2010). Sınıflandırmada, yordanan değişken kategorik; regresyonda, sürekli ve yoğunluk kestiriminde bir olasılık yoğunluk fonksiyonudur. Bazı popüler yordama algoritmaları, karar ağaçları, lojistik regresyon, destek vektör makineleri, sinir ağları, Bayes algoritmaları, k-en yakın komşuluk ve çeşitli kernel fonksiyonlarına dayanan yoğunluk kestiricileridir. Bir kestiricinin doğruluğunu değerlendirmek amacıyla hata matrisine dayanan dönüştürülmüş performans değerlendirme ölçütleri (kesinlik, çağrışım, F ölçütü, vb.), Cohen'in Kappa'sı, ROC eğrisinin altında kalan alan ve yordama hata oranları gibi ölçütler kullanılmaktadır.

Eğitim alanında yapılan sınıflandırma çalışmalarında karar ağaçları, destek vektör makineleri, lojistik regresyon, sinir ağları, Bayes algoritmaları, k-en yakın komşuluk gibi yöntemlerin performanslarını inceleyen ve karşılaştıran uluslararası

alan yazında (Barker, Trafalis ve Rhoads, 2004; Dekker, Pechenizkiy ve Vleeshouwers, 2009; Kotsiantis, Pierrakeas ve Pintelas, 2003; Hamalainen ve Vinni, 2006; Hamalainen ve Vinni, 2011; Minaei-Bidgoli, Kashy, Kortemeyer ve Punch, 2003; Nghe, Janecek ve Haddawy, 2007; Osmanbegović ve Suljić, 2012; Romero, Espejo, Zafra, Romero ve Ventura, 2013; Romero, Ventura, Espejo ve Hervas, 2008; Shahiri, Husain ve Rashid, 2015) ve Türkiye’de (Bahadır, 2013; Bulut, 2010; Çırak, 2012; Göker, 2012; Şengür, 2013; Tepehan, 2011; Tezbaşaran, 2016; Tosun, 2007; Yurdakul ve Topal, 2015) yapılan çalışmalar bulunmaktadır. Çalışmalarda ayrıca bağımlı değişkeninin farklı kategorik durumları (Minaei-Bidgoli, Kashy, Kortemeyer ve Punch, 2003; Nghe ve diğerleri, 2007), veri yapısı (Romero ve diğerleri, 2008; Romero ve diğerleri, 2013), kayıp ve gürültülü veri (Hamalainen ve Vinni, 2011) ve örneklem büyüklükleri (Hamalainen ve Vinni, 2006; Hamalainen ve Vinni, 2011) açısından yöntemler karşılaştırılmıştır. Bu araştırmada ise önceki çalışmalardan farklı olarak Naive Bayes ve k-en yakın komşuluk yöntemlerini lojistik regresyon ve sinir ağları ile örneklem büyüklüğü ve test verisi oranı açısından karşılaştırmak amaçlanmıştır. Bu nedenle, öncelikle, yöntemlerin genel yapısına kısaca değinilecektir.

Veri madenciliğinde en çok kullanılan sınıflandırma algoritmalarından biri Bayes teoremine dayanan Naive Bayes yöntemidir. Bu sınıflandırıcı, sınıf üyeliği olasılıklarını tahmininde karar ağaçları ve YSA sınıflandırıcılarıyla karşılaştırılabilir performans gösterir. Sınıflandırıcının ‘naif’ (naive) olarak adlandırmasının sebebi bir özelliğe ait herhangi bir değer bir sınıfa ait olma olasılığının diğer özelliklere ait değerlerin aynı sınıfa ait olma olasılığından bağımsız olması varsayımından kaynaklanır (Han, Kamber ve Pei, 2011). Bu sınıflandırıcının, basit, kullanışlı, yorumlaması kolay ve karmaşıklığa dayanıklı olması, küçük veri setlerinde kullanılabilmesi ve kategorik ile sürekli veriye (Gauss dağılımından) uygulanabilmesi gibi avantajlara sahip iken; koşullu bağımsızlık varsayımının sağlanmasının zor olması ve kategorik veride sınıfların sınırlarının karmaşık olduğu durumlarda gücünün kestirilememesi gibi dezavantajları vardır (Hamalainen ve Vinni, 2011).

En çok kullanılan bir diğer yöntem ise k-en yakın komşuluk algoritmasıdır. Bu algoritma, kestirim ve tahminlemenin yanında daha çok sınıflandırma amacıyla kullanılır. Yöntem, sınıflandırılacak yeni bir örneğin kaydedilmiş olan eğitim



verisindeki örneklere benzerliğine göre sınıflandırılması prensibine dayanır (Larose, 2004). Örneğin yer alacağı sınıf, komşu örnekler arasında en çok bulunan sınıf ya da komşuluktaki bir sınıf dağılımı olabilir. Yapılacak hesaplamalarda karşılaşılabilecek en önemli sorunlar  $k$ 'nın değerinin ne olacağı ve uzaklığın ( $d$ ) nasıl hesaplanacağıdır. Akıllara gelebilecek bir diğer soru ise eğitim setindeki örnek durumlarının ağırlıklandırılmasının nasıl olacağıdır.  $k$ -en yakın komşuluk algoritmasının, diğer sınıflandırma yöntemlerinde olduğu gibi bazı avantaj ve dezavantajları vardır. Modelin eğitilmesinde ve sınıflandırmada sadece iki parametrenin bulunması ( $k$  ve  $d$ ), bazı problemlerde sınıflandırma performansının çok iyi olması ve sınıflandırmanın karmaşıklığa ve kayıp verilere dayanıklı olması yöntemin bazı avantajlarıdır. Uzaklık fonksiyonunun ( $d$ ) ve  $k$  değerinin seçiminde sıkıntılar yaşanması en önemli dezavantajlarından biridir. Eğitime uygulandığında verilerin uygun ölçeğe yerleştirilmesi, eğitimde yeterli büyüklükte veri bulunamaması ve eğitim verilerindeki (öğrenci anketleri, vb.) gereksiz kısımların ayıklanmasının gerekmesi bazı diğer dezavantajlarıdır (Hamalainen ve Vinni, 2011).

Yapay Sinir Ağları (YSA), belirli matematiksel ve istatistiksel algoritmalar kullanılarak bir veri setindeki ilişkileri ve örüntüleri keşfetmek amacıyla kullanılır. Sinir ağlarının ilişkileri keşfetmesi (eğitilmesi) sonucunda belirli kararların alınmasında yol gösterici bilgiler elde edilir (Sivanandam, Sumathi ve Deepa, 2011). YSA, bilgisayar bilimcileri, farklı alanlarda çalışmalar yapan mühendisler, bilişsel bilimciler, nörofizyologlar, fizikçiler, biyologlar ve çevre bilimleri ile pazarlama alanında çalışan bilim insanları başta olmak üzere hemen her alanda etkin kullanım alanlarına sahiptir. Eğitim teknolojileri alanına uygulandığında ise yeterli miktarda sayısal veri olmadığında ve modelin nasıl eğitileceği tam olarak bilinmediğinde problemlerle karşılaşabilmektedir (Hamalainen ve Vinni, 2011). YSA, biyolojik gerçek hücre ağlarının yapısından yararlanılarak geliştirilmiştir. 1940'lardan beri üzerinde çalışılan bir konu olan sinir ağları, gerçek sinir hücrelerinin yapılarının karmaşıklığından ve yeterli düzeyde anlaşılmasından dolayı alan yazında birçok ağ mimarisi rapor edilmiştir (Sivanandam ve diğerleri, 2011). YSA'nın bazı avantajları, doğrusal olmayan sınırları kolayca öğrenebilmesi, temelde farklı tür sınıflandırıcıları temsil edebilmeleri, orijinal değişkenler ayırıcı olmadıklarında onları tam olarak dönüştürebilmeleri, karmaşıklığa (noise) karşı dayanıklı olması ve yeni veri ile güncellenebilmeleridir. Bazı dezavantajları ise eğitimdeki tipik veri setlerinin

içerdiğinden çok daha fazla veri gerektirmesi, aşırı uyuma (overfitting) karşı çok hassas olmaları ve bu problemin küçük eğitim verilerinde daha belirgin hale gelmesi, verinin sayısal olmasını ve kategorik verinin nicel hale dönüştürülmesini gerektirmesidir (Hamalainen ve Vinni, 2011).

Lojistik regresyon analizi diğer yöntemlere göre daha fazla kullanılan yordama ve sınıflandırma algoritmalarındandır. Bu analiz yönteminde, yordanan değişkenin kategorik; yordayıcıların ise sürekli, kategorik veya ikisinin karışımından oluştuğu durumlarda grup üyeliklerinin tahmininde etkili bir yöntemdir. Diskriminant analizi ve çoklu regresyon analizleri, lojistik regresyonundaki benzer araştırma problemlerine yanıt arar. Ancak, lojistik regresyonunun normallik, doğrusallık, varyansların homojenliği, vb. katı varsayımları yoktur (Cox ve Snell, 1989; Tabachnick ve Fidell, 2013). 1960'ların başında önerilen bu analiz yöntemi (Cabrera, 1994), 1980'lerin başından itibaren istatistik yazılımlarında rutin bir paket olarak yer almaya başlamıştır (Peng, Lee ve Ingersoll, 2002). Günümüze kadar da sosyal bilimlerde ve eğitimde sıklıkla kullanılan bir yöntem haline gelmiştir (Cabrera, 1994; Peng ve So, 2002). Lojistik regresyon analizi, yordayıcı değişkenlerin yapısından bağımsız olması, çok çeşitli ve karmaşık veri setlerinde etkili olması ve yordayıcı değişkenlerin dağılımına yönelik varsayımlarının olmaması gibi avantajları sayesinde popüler hale gelmiştir. Ancak, analizin etkili olabilmesi için yordayıcıların iyi seçilmesi ve teorik temelinin olması, değişkenlerde ve kategori dağılımlarında yeterli düzeyde durumların bulunması, sürekli yordayıcılar ile yordanan değişkenin lojit hali arasında doğrusal ilişki olması, çoklu-bağlantı olmaması, uç değerlerin temizlenmesi, hataların ve gözlemlerin birbirinden bağımsız olması gerekir (Tabachnick ve Fidell, 2013).

Veri madenciliği yöntemlerinin eğitim verileri üzerinde uygulanabilirliği ve etkililiği üzerine son on yıllık süreçte birçok araştırmaya rastlamak mümkündür. Bu araştırmalar, genel olarak öğrenci performansının yordanması, değerlendirilmesi ve performansı etkileyen faktörlerin belirlenmesi amacı taşımaktadır. Romero ve Venturo (2007) 1995 ve 2005 yılları arasında eğitim alanında yapılan veri madenciliği çalışmalarını derleyerek çeşitli özelliklerine göre sınıflandırmışlardır. Ancak, bu araştırmalardan çok az bir kısmı veri madenciliği algoritmalarının karşılaştırılmasının yanında örneklem büyüklüğü ve eğitim setinin büyüklüğü bu algoritmaların performansına etkisine değinmiştir. Hâlbuki istatistik, mühendislik,

sağlık ve sosyal bilimler gibi birçok alanda eğitim setinin ve örneklem büyüklüğünün veri madenciliği algoritmaları üzerindeki etkileri önemli bir araştırma konusu haline gelmiştir. Ayrıca, Türkiye’de EVM ile ilgili uygulamalara ve yukarıda anlatılan yöntemlerden Naive Bayes ve k-en yakın komşuluk tekniklerine yönelik çalışmalar sınırlı düzeydedir. Bu çalışmada, alan yazında görülen bu eksikliklere yönelik PISA (2012) uygulamasında alınan bir veri kullanılarak kapsamlı bir uygulama yapılması hedeflenmiştir.

PISA çalışması, üç yıllık aralıklarla dünya genelindeki eğitim sistemlerini değerlendirmek için 15 yaş grubunda öğrencilerin matematik, fen ve okuma alanlarındaki bilgi ve becerilerinin incelendiği bir uygulamadır (OECD, 2014b). Her bir periyottaki uygulamada öğrencilerin belirli bir alandaki performansları test edilir. 2012 yılında yapılan çalışmada matematiğe ağırlık verilerek bu alanla ilgili kapsamlı veri elde edilmiştir. Uygulamada, öğrencilerin her bir alandaki akademik performanslarını ölçmek amacıyla geliştirilen bilişsel testler ve okul, öğretmen ve öğrenci düzeyinde bilgilerin elde edildiği anketler kullanılan veri toplama araçlarıdır. Matematik bilişsel testi, değişim ve ilişkiler, nicelikler, uzaklıklar ve şekiller, belirsizlik ve veri, görevler, formüle etme ve yorumlama alt alanlarından oluşmaktadır. Öğrenci anketinde ise öğrencilerin evleri, okulları, kendileri ve öğrenme deneyimleri hakkında çeşitli bilgileri içeren formları doldurmaları beklenmiştir (OECD, 2014a).

### **Araştırmanın Amacı ve Önemi**

Bu çalışmanın amacı, PISA (2012) çalışmasına katılan öğrencilerin, çeşitli özellikleri bakımından matematik başarılarını yordamada Naive Bayes, k-en yakın komşuluk, lojistik regresyon ve yapay sinir ağlar yöntemlerinin performanslarının farklı örneklem büyüklükleri ve test verisi oranlarına göre nasıl değiştiğini gözlemlemektir. Yöntemlerin sınıflandırma performansları analiz tekrarlarından elde edilen doğruluk oranlarının ortalamaları ve standart sapmaları, Hata matrisi Kappa uyumu ve ROC eğrisinin altında kalan alan değerleri kullanılmıştır.

Öğrencilerin PISA (2012) matematik performanslarına göre sınıflandırılmasında kullanılan değişkenler, veri madenciliğinde sıklıkla kullanılan bilgi kazanımı, Kay-kare, oran kazanımı ve simetrik belirsizlik sıralama filtresi özellik seçme yöntemlerinden yararlanılarak seçilmiştir. Buna göre, sınıflandırmaya en çok katkı sağlayan ilk 10 değişken olan matematik öz-yeterliği, matematiksel benlik

algısı, matematik kaygısı, ekonomik, sosyal ve kültürel statü indeksi, problem çözmeye açık olma, ülke, baba eğitim düzeyi (ISCED), anne eğitim düzeyi (ISCED), öğretmen davranışı: öğrenciyi yönlendirme ve hesap makinesi kullanımı değişkenleri analizlere dahil edilmiştir.

PISA uygulamaları ile dünya genelindeki eğitim sistemleri değerlendirildiğinden veri toplama sürecinin her aşamasında özenli ve sistematik bir yol izlenir. Bu nedenle, her uygulama sonunda ölçme ve değerlendirme süreçleri açısından güvenilirliği ve geçerliği yüksek olan geniş bir veri havuzu elde edilir. Bu çalışmada, PISA (2012) uygulamasına katılan öğrencilere ait büyük ve psikometrik açıdan güvenilir bir veri kullanıldığından, yöntemlere yönelik elde edilen sonuçların gerçek hayattaki uygulamada karşılığının olması bakımından önemli görülmektedir. Ayrıca, farklı performans ölçütlerinden elde edilen sonuçların güvenilirliğini yükseltmek amacıyla yerine koyma yöntemiyle farklı veri setleri seçilerek analizler 100'er defa tekrarlanmıştır. Böylece, eğitsel verilerin incelenmesinde kullanılan yöntemlere ilişkin gerçek bir veri üzerinde yüksek kesinlikte sonuçlara ulaşılması hedeflenmiştir.

Eğitim çalışmalarında özellikle Naive Bayes sınıflandırıcısı, K-en yakın komşuluk ve yapay sinir ağları algoritmaları kullanımı ve karşılaştırmalı incelenmesi diğer çalışma alanlarına göre sınırlı düzeydedir. Bu çalışma ile Naive Bayes sınıflandırıcısı ve K-en yakın komşuluk yöntemlerinin Türkiye'de eğitim alanında geniş çaplı bir uygulamasına yer verilecektir. Lojistik regresyon analizinin daha fazla kullanılmasına rağmen diğer sınıflandırıcılarla karşılaştırmasının, performansı bilinen bir yöntemle karşılaştırmak açısından yararlı olacağı düşünülmüştür. Çalışma dört yöntemi farklı değerlendirme ölçütlerine göre karşılaştırması ve karakteristik analiz süreçleri açısından Türkiye'de bu alanda bir yenilik katma özelliği taşımaktadır.

Araştırmada kullanılan yöntemlerin öğrencileri çeşitli özelliklerine göre sınıflandırmasında örneklem büyüklüğü ve ideal test verisi oranı açısından performanslarının karşılaştırılması eğitim verileri üzerinde belirli koşullar için hangi yöntemin daha kullanılabilir olduğunun tespit edilmesine olanak sağlayacaktır. Eğitsel veri madenciliği uygulamalarında bu konuda önemli bir gereksinim olduğu görülmektedir. Bu çalışma ile ilgili alan yazın ışığında Türkiye'de eğitim bilimleri alanında veri madenciliği konusunda kapsamlı bir uygulamaya yer verilerek eğitsel

verinin incelenmesinde kullanılan yöntemlerin etkililiğine yönelik önemli bulgulara ulaşılmıştır.

### **Araştırma Problemi**

Öğrencilerin PISA (2012) matematik performanslarının yordanmasında Naive Bayes, k-en yakın komşuluk, yapay sinir ağları çok katmanlı algılayıcı ve lojistik regresyon yöntemlerinin performansları farklı örneklem büyüklükleri ve test verisi oranları için nasıl farklılaşmaktadır?

**Alt problemler.** 1. 500, 1000 ve 5000 kişilik örneklem büyüklükleri için Naive Bayes yönteminin test verisi oranı %11, %22, %33, %44 ve %55 olduğunda sınıflandırma doğruluk oranları ile standart sapma miktarları, Kappa uyum katsayıları ve ROC eğrisinin altında kalan alan değerleri nasıl farklılaşmaktadır?

2. 500, 1000 ve 5000 kişilik örneklem büyüklükleri için k-en yakın komşuluk yönteminin test verisi oranı %11, %22, %33, %44 ve %55 olduğunda sınıflandırma doğruluk oranları ile standart sapma miktarları, Kappa uyum katsayıları ve ROC eğrisinin altında kalan alan değerleri nasıl farklılaşmaktadır?

3. 500, 1000 ve 5000 kişilik örneklem büyüklükleri için yapay sinir ağları çok katmanlı algılayıcı yönteminin test verisi oranı %11, %22, %33, %44 ve %55 olduğunda sınıflandırma doğruluk oranları ile standart sapma miktarları, Kappa uyum katsayıları ve ROC eğrisinin altında kalan alan değerleri nasıl farklılaşmaktadır?

4. 500, 1000 ve 5000 kişilik örneklem büyüklükleri için lojistik regresyon yönteminin test verisi oranı %11, %22, %33, %44 ve %55 olduğunda sınıflandırma doğruluk oranları ile standart sapma miktarları, Kappa uyum katsayıları ve ROC eğrisinin altında kalan alan değerleri nasıl farklılaşmaktadır?

5. Naive Bayes, k-en yakın komşuluk, yapay sinir ağları çok katmanlı algılayıcı ve lojistik regresyon yöntemlerinin sınıflandırma doğruluk oranları ile standart sapma miktarları, analiz süreleri, Kappa uyum katsayıları ve ROC eğrisinin altında kalan alan değerleri farklı örneklem büyüklükleri ve test verisi oranlarına göre birbirinden nasıl farklılaşmaktadır?

## **Sayıtlılar**

PISA (2012) uygulamasına katılan öğrenciler anketleri isteyerek ve içtenlikle cevaplamışlardır.

## **Sınırlılıklar**

Bu araştırma;

- PISA (2012) uygulamasına katılan OECD ülkelerindeki 15 yaş grubu öğrenciler,
- PISA (2012) uygulaması matematik performans testi ve öğrenci anketleri,
- YSA yöntemlerinden ileri beslemeli geri yayılım algoritmasına dayanan çok katmanlı algılayıcı ile sınırlıdır.
- Hesaplanan analiz işlem süreleri kullanılan bilgisayarın özellikleri ile sınırlıdır.

## **Tanımlar**

*PISA Matematik performansı:* PISA 2012 uygulamasının odak noktası bireylerin matematik okuryazarlığını birçok bağlamda yorumlayarak, matematiği işe koşma ve formüle etme kapasitelerini ölçmek üzerinedir. Matematik okuryazarlığı, matematiksel akıl yürütmeyi ve matematiksel kavramlar, süreçler, olaylar ve araçları kullanarak olayları tanımlama, açıklama ve tahmin etmeyi içermektedir. Matematik okuryazarı olan bir öğrenci, matematiğin dünyada oynadığı rolü fark ederek yapıcı, bağlılık duygusuna sahip akıl vatandaşlardan beklenen sağlam temeli olan değerlendirmeler yapar ve kararlar verir (OECD, 2014a).

*Sınıflandırma performansı:* Bir sınıflandırma yönteminin herhangi bir gözlemi önceden belirlenmiş bir sınıfa yerleştirmede gösterdiği başarı derecesidir. Bir analiz yönteminin sınıflandırma performansı, doğruluk, hata oranı, kesinlik, hassaslık, F ölçütü, Kappa uyum değeri ve ROC eğrisinin altında kalan alan gibi hata matrisinden hesaplanan değerlerin yanında hız, dayanıklılık, ölçeklenebilirlik ve yorumlanabilirlik gibi çeşitli ölçütlere göre değerlendirilebilir ve diğer yöntemlerle istatistiksel olarak karşılaştırılabilir (Han ve diğerleri, 2012).

*Test verisi oranı:* Veri madenciliği uygulamalarında bir veri setinin belirli bir bölümü kullanılarak ilk analizler gerçekleştirilir ve bir yordama modeli oluşturulur.

Sonraki aşamada, elde edilen bu modelden yararlanılarak verinin kalan kısmındaki bireyler ya da nesnelere için yordama işlemi gerçekleştirilir. Yöntemin etkililiğinin test edildiği verinin bu parçasına test verisi denir. Bu veri, tüm verinin belirli bir oranından edildiğinden dolayı test verisi oranı olarak ifade edilir. Veri madenciliğinde yöntemlerin etkililiğinin bu şekilde test edilmesinin nedeni model hata oranlarının yanlış kestirimlerinin önüne geçmektir. Benzer amaçlar için kullanılan diğer yöntemler, önyükleme (Efron, 1983) ve çapraz geçişleme (Lachenbruch ve Mickey, 1968) teknikleridir (Michie, Spiegelhalter ve Taylor, 1994). Ancak, tüm veriden belirli oranda test verisi seçilerek bu veri ile yordama işleminin gerçekleştirilmesi sıklıkla tercih edilen ve büyük örneklem için de çoğunlukla kullanılan etkili bir yöntemdir.



## Bölüm 2

### Araştırmanın Kuramsal Temeli ve İlgili Araştırmalar

#### Araştırmanın Kuramsal Temeli

Veri madenciliğinde bireylerin ya da gözlemlerin belirli bir kategorik değişkene göre sınıflandırılması en temel yordama tekniklerinden biridir (Baker, 2010). Bu amaçla, çok çeşitli yöntem veya algoritmalarla yararlanılmakla birlikte karar ağaçları, Bayes yöntemleri, sinir ağları, destek vektör makineleri, en yakın komşuluk ve lojistik regresyon gibi yöntemleri en çok kullanılan istatistiksel veya nesne temelli tekniklerdir. Bu bölümde araştırmada kullanılan veri madenciliği yöntemlerinden olan Naive Bayes, k-en yakın komşuluk, YSA çok katmanlı algılayıcı ve lojistik regresyon analizlerine yönelik kuramsal bilgilere yer verilmiştir.

**Naive Bayes.** Bayes teoremine dayanan Naive Bayes yöntemi, veri madenciliğinde sıklıkla kullanılan sınıflandırma tekniklerinden biridir. Bu sınıflandırıcı, sınıf üyeliği olasılıklarını tahmininde karar ağaçları ve YSA sınıflandırıcılarıyla karşılaştırılabilir performans gösterir. Sınıflandırıcının 'naif' (naive) olarak adlandırılmasının sebebi bir özelliğe ait herhangi bir değer bir sınıfa ait olma olasılığının diğer özelliklere ait değerlerin aynı sınıfa ait olma olasılığından bağımsız olması varsayımından kaynaklanır (Han ve diğerleri, 2011). Basit ve kullanışlı bir yöntem olan Naive Bayes sınıflandırıcısının çalışma prensibini ve sınıflandırma problemlerinde kullanımını anlamak için Bayes teoremini incelemek gerekir. Bayes teoremi, bir olayın gerçekleşme olasılığının, diğer olayların önsel ve koşullu olasılıkları arasındaki ilişkiyle tanımlanmasıdır. Teoremi daha iyi anlamak açısından koşullu olasılığı aşağıdaki örnek üzerinden açıklamak yararlı olacaktır.

*“İki kalem kutusunun birincisinde 5 kurşun kalem ve 10 tükenmez kalem, ikincisinde ise 10’ar adet kurşun ve tükenmez kalem olduğu ve bir öğrencinin bu kutulardan aldığı bir kalemin kurşun kalem olduğunu düşünürsek öğrencinin birinci kutudan kalemi almış olması olasılığı nasıl hesaplanabilir?”*

Bu örnekte öğrencinin herhangi bir kutuyu diğerine tercih etme gibi bir seçiminin olmadığı varsayıldığında Bayes teoremi verilen problem durumu için kesin bir çözüm sunar. Bu durumun en önemli nedeni, kalemin birinci kutudan seçilme olasılığının diğer kutudaki olasılıktan bağımsız olmaması ve teoremin hesaplamada



bu durumu da göz önünde bulundurmasıdır. X ve Y rastgele olayları için Bayes kuralı şu şekilde tanımlanır (Tan, Steinbach ve Kumar, 2014):

$$P(X | Y) = \frac{P(Y|X)P(X)}{P(Y)}. \quad (1.1)$$

Bu denklemde,  $P(X | Y)$ : Bilinen Y olayı için X olayının koşullu olasılığı,  $P(Y | X)$ : Bilinen X olayı için Y olayının koşullu olasılığı,  $P(X)$ : X olayı için önsel olasılık ve Y olayı ile ilgili herhangi bir bilgi içermemekte,  $P(Y)$ : Y olayı için önsel olasılıktır.

Örneğimize, Bayes teoremini uyguladığımızda, X olayı öğrencinin birinci kutudan seçim yapması ve Y olayı öğrencinin bir kurşun kalem seçmesi olsun. Birinci kutudan kurşun kalem seçme olasılığı  $5/15=1/3$ , ikinci kutudan kurşun kalem seçme olasılığı  $10/20=1/2$  olur. Herhangi bir kutudan seçim yapma olasılığı  $1/2$  olduğundan, iki kutudan rastgele bir kurşun kalem seçme olasılığı  $(1/3)*(1/2)+(1/2)*(1/2)=5/12$  olacaktır. Verilenleri denklemde yerine yazdığımızda öğrencinin birinci kutudan kalem almış olma olasılığı  $[(1/3)*(1/2)]/(5/12)=0.4$  olacaktır. Bu sonuca göre, öğrencinin ikinci kutudan kalemi seçmiş olma koşullu olasılığı daha yüksek olacaktır.

Bayes sınıflandırıcısını eğitimde sınıflandırma uygulamalarında kullanabilmek için  $X_1$ ,  $X_2$  ve  $X_3$  bağımsız değişkenleri ile Y sınıf değişkeni arasındaki bağımlı ilişkilerin grafiksel olarak tanımlanması gerekir. Eğer  $X_1$  değişkeni,  $X_2$  ve  $X_3$  değişkenlerine bağımlı ise, Bayes modeli,  $X_1$ ,  $X_2$  ve  $X_3$  değişkenlerinin tüm birleşimleri için tüm  $P(X_1|X_2,X_3)$  koşullu olasılıkları tanımlamalıdır. Veriden öğrenilen parametreler, tüm y sınıf değerleri ve olası  $t \in S$  veri noktaları için  $P(t|Y=y)$  sınıf-koşullu dağılımlarını tanımlar. Yeni bir veri noktası sınıflandırıldığında, Bayes kuralını kullanılarak  $P(Y=y|t)$  sınıf olasılıkları hesaplanabilir (Hamalainen ve Vinni, 2011, John ve Langley, 1995):


$$P(Y = y | t) = \frac{P(t|Y=y)P(Y=y)}{P(t)}. \quad (1.2)$$

**Naive Bayes sınıflandırıcısının yapısı.** Değişken sayısı çok fazla olduğunda bağımsız değişkenlerin tüm kombinasyonları için sınıf koşullu olasılıkları da çok sayıda olacağından bu olasılıkların kestirilmesi uzun ve çaba gerektiren bir sürece dönüşecektir. Naive Bayes sınıflandırıcısı, bu probleme etkili bir çözüm

olarak geliştirilmiştir. Bu sınıflandırıcı, sınıf-koşullu olasılıklarını kestirmede kullanışlı bir sınıflandırma algoritmasıdır. Analiz yönteminin temel varsayımı, bağımsız değişkenlerin bağımlı değişkenin kategorilerinden koşullu bağımsız olmasıdır. Koşullu bağımsızlık varsayımı,  $X_1, X_2, \dots, X_k$  bağımsız değişkenler ve  $Y$  bir sınıflandırma değişkeni iken şu şekilde tanımlanır (Hamalainen ve Vinni, 2011):

$$P(X_1, X_2, \dots, X_k | Y) = \prod_{i=1}^k P(X_i | Y). \quad (1.3)$$

Naive Bayes sınıflandırıcısı sayesinde, bir  $X$  bağımsız değişkeninin tüm kombinasyonları için sınıf-koşullu olasılıklarını hesaplamak yerine, verilen bir  $Y$  bağımlı değişkeni için her  $X_i$  değişkeninin koşullu olasılıklarını hesaplamak yeterli olacaktır. Şekil 2'de koşullu bağımsızlık varsayımının Bayes ağı şeklinde gösterimi verilmiştir (John ve Langley, 1995).



Şekil 2. Bağımsız Değişkenlerin ( $x_1, x_2, \dots, x_k$ ),  $S$  Sınıflandırma Değişkenine Göre Koşullu Bağımsızlığını Gösteren Naive Bayes Modelinin Bayes Ağı Gösterimi

Şekil 2 incelendiğinde, tüm bağımsız değişkenler  $S$  bağımlı değişkenine göre koşullu bağımsızdır. Koşullu bağımsızlık varsayımı nadir sağlanmasına karşın Naive Bayes sınıflandırıcısı uygulamada iyi sonuçlar verdiğini kanıtlanmıştır (Hamalainen ve Vinni, 2011). Bir nesneyi ya da bireyi sınıflandırmak için Naive Bayes sınıflandırıcısı, her bir sınıf  $Y$  için sonsal olasılık dağılımı hesaplar (Tan ve diğerleri, 2014):

$$P(Y | X) = \frac{P(Y) \prod_{i=1}^k P(X_i | Y)}{P(X)}. \quad (1.4)$$

Eğer koşullu bağımsızlık varsayımı sağlanırsa  $P(X)$  her sınıf için sabitlenmiş olacak ve 1.4'teki denklemin payını maksimize eden sınıf seçilecektir. Naive Bayes modelinin eğitilmesi için kullanılan bir öğrenme verisi üzerinden her sınıf için önsel koşullu olasılıklar hesaplandıktan sonra, test verisi üzerinde hesaplanan koşullu

olasılıklardan hareketle sonsal dağılımlar elde edilir ve bireyler ya da nesnelere buna göre sınıflara yerleştirilir (Dunham, 2003).

***Kategorik ve sürekli değişkenler için koşullu olasılıkların hesaplanması.***

Naive Bayes sınıflandırıcısı, koşullu olasılıklar üzerinden kategorik verilerin sınıflandırmasında kullanılır. Modelin eğitilmesi sırasında bağımsız değişkenin belirli bir kategorisinde yer alan bireylerin sıklık tabloları kullanılarak bağımlı değişkenin herhangi bir kategorisinde bulunma olasılığı hesaplanır. Daha sonra, test verisi kullanılarak bireylerin bir kategoride bulunma olasılığı diğer kategoride bulunma olasılığından büyükse bireyler ilk kategoriye atanır. Ancak, bağımsız değişkenler sürekli olduğunda Naive Bayes sınıflandırıcısı sınıf-koşullu olasılıklarını kestiremez (Dunham, 2003). Bu sorunu çözmek amacıyla kullanılan başlıca iki yöntem bu değişkenlerin kesikli hale getirilmesi ya da eğitim verisi üzerinde sürekli değişkenler için farklı koşullu olasılık dağılımları elde edilerek bu dağılımların parametrelerinin hesaplanmasıdır. Sürekli değişkenlerin kesikli hale getirilmesi ile sıralı ölçeklenmiş değişkenler elde edilir. Ölçek aralıklarının çok geniş olması öğrenme verisinde çok az öge olacağından güvenilir kestirimlerin yapılmasına engel olur. Bu aralıklar çok dar olduğunda ise bazı aralıklar farklı sınıflarda yer alan bireyleri kümeleştireceğinden doğru sınıf sınırları gözden kaçabilir. Bu açıdan, sınıflandırma işleminde elde edilecek hatalar kullanılan kesikle hale getirme stratejisi ve sınıf aralığı sayısına göre değişecektir (Tan ve diğerleri, 2014).

Naive Bayes yönteminde her bir sürekli değişken, kendi değer aralıklarında bazı sürekli dağılım fonksiyonları ile modellenir (John ve Langley, 1995). Bir olasılık yoğunluk fonksiyonu üzerinden sürekli değişkenin belirli değer aralıkları için koşullu olasılıklar hesaplanır. Sınıf-koşullu olasılıklarının elde edilmesinde genellikle Gauss dağılımı kullanılır.  $\mu$  dağılımın ortalaması,  $\sigma^2$  varyansı olmak üzere  $X_i$  değişkeni için her  $y_j$  sınıfı koşullu olasılıklarının yoğunluk fonksiyonu şu şekildedir (Tan ve diğerleri, 2014):

$$P(X_i = x_i | Y = y_j) = \frac{1}{\sqrt{2\pi\sigma_{ij}}} \exp \left( -\frac{(x_i - \mu_{ij})^2}{2\sigma_{ij}^2} \right). \quad (1.5)$$

Fonksiyonda  $x_i$ ,  $X_i$  değişkeninin değerlerini göstermektedir. Öğrenme verisi üzerinde  $X_1, X_2, \dots, X_k$  değişkenleri için öğrenme verisi üzerinde ortalama ve varyans değerleri kestirildikten sonra test verisinde kullanılmak üzere veri aralığı için koşullu

olasılık deęerleri elde edilmektedir. Bu alıřmada kullanılan Naive Bayes algoritması, Gauss daęılımını kullanarak srekli deęiřkenleri analize dahil etmektedir (Frank, Hall ve Witten, 2016).


**Naive Bayes sınıflandırıcısının zellikleri.** Naive Bayes algoritmasının bazı avantajları řu řekildedir (Dunham, 2003; Hamalainen ve Vinni, 2011; Tan ve dięerleri, 2014):

- Basit, kullanıřlı ve yorumlaması kolaydır.
- Dięer yntemlerinden farklı olarak ęrenme verisinin bir kere kullanılması model parametre kestirimleri iin yeterlidir.
- Kayıp ve grltl veriye dayanaklıdır.
- Deęiřkenler arası basit iliřkilerde bile sıklıkla iyi sonular verir.
- Analizdeki gereksiz deęiřkenlere karřı dayanaklıdır.
- Kk veri setlerinde de iyi sonular verebilmektedir.

Algoritmanın bazı dezavantajları ise řu řekildedir (Dunham, 2003; Hamalainen ve Vinni, 2011; Tan ve dięerleri, 2014):

- Kořullu baęımsızlık varsayımının saęlanması zordur.
- İliřkili deęiřkenler sınıflandırma performansını nemli lde dřrebilmektedir.
- Srekli veri iin bir takım modifikasyonlar gerektirir.
- Kategorik veride sınıfların sınırlarının karmařık olduęu durumlarda sınıflandırıcısının gc kestirilememektedir.

**k- en yakın komřuluk.** k-en yakın komřuluk (KNN) yntemi en ok kullanılan basit matematiksel yapıdaki sınıflandırma algoritmalarından biridir (Akpınar, 2014). Yntem, uzaklık llerine dayalı nesne temelli sınıflandırıcılar grubunda yer alır. ęrenme verisindeki nesnelere ya da bireylere olan yakınlıklarına gre test verisinin sınıflandırılmasını esas alır (Larose ve Larose, 2014). Bu algoritmanın iřleyiřine temsil olması aısından “Eęer rdek gibi yryorsa, rdek gibi vaklıyorsa ve rdek gibi grnyorsa, bu muhtemelen rdektir” rneęi verilebilir (Tan ve dięerleri, 2014). řekil 3’te rnek bir veri setinin grafiksel gsterimi verilmiřtir.



Şekil 3. KNN Yöntemi ile Sınıflandırma

Şekil 3'te öğrenme verisindeki bir grup verinin koordinat düzlemindeki yerleri verilmiştir. Algoritmanın test verisinde yer alan  $y$  veri noktasının sınıflandırması için en yakın komşuluk  $k=3$  olarak belirlenmiştir. Buna göre,  $y$  birey ya da nesnesi,  $x$  değerlerine en yakın olduğundan, bu değerlerin büyük oranda yer aldığı sınıfa yerleştirilecektir. Bu örneğe göre, KNN yöntemi ile ilgili akıllara aşağıdaki sorular gelmektedir (Larose ve Larose, 2014).

1. En yakın komşu sayısı, yani  $k$  değeri ne olmalıdır?
2. Veri noktaları arasındaki uzaklık nasıl ölçülmelidir?
3. Eğer noktalar farklı kategorilere benzer uzaklıktaysa sınıflandırmaya nasıl karar verilmelidir?
4. Tüm veri noktaları eşit mi ağırlıklandırılmalı yoksa sınıflandırmada bazı noktalar daha mı etkili olmalıdır?

**$k$  değerinin seçilmesi.** KNN yönteminin etkili sonuçlar vermesi açısından en uygun  $k$  değerinin belirlenmesi önemli bir yere sahiptir (Akpınar, 2014). Basit istatistiksel yapısından dolayı yöntem belirlenen  $k$  değerine aşırı duyarlıdır. Eğer  $k$  çok büyük olursa sınıflanacak yeni örneklerin gerçek sınıflarından uzaklaşma ihtimalini doğuracaktır. Bunun nedeni, sınıflandırma işleminde bölgesel olarak bazı veri noktalarının göz ardı edilmesidir. Benzer şekilde, eğer  $k$  çok küçük olursa uç değer veya gürültülü verilerin sınıflandırmada etkili hale gelmesi ile algoritmanın

öğrenme verisini ezberlemesi ve aşırı genelleme yapması sonucunda hatalı sınıflandırma yapılacaktır (Larose ve Larose, 2014; Tan ve diğerleri, 2014). KNN algoritmasında en uygun  $k$  değerinin belirlenmesinde çeşitli yöntemler kullanılmaktadır. Kesin bir yargıda bulunulması zor olmakla birlikte en uygun  $k$  değerinin belirlenmesinde kullanılan bazı yöntemler şu şekildedir (Aha, Kibler ve Albert, 1991; Dunham, 2003; Ghosh, 2006; Hall, Park ve Samworth, 2008; Hamalainen ve Vinni, 2011):

- Öğrenme verisindeki birey ya da nesne sayısının karekökünü alınması
- Küçük örneklerde 5 ile 10 arasında alınması
- Ticari amaçlı uygulamalarda sıklıkla 10 alınması
- Çift veya asal sayıların tercih edilmesi
- Bayes yöntemlerinin kullanılması
- Önyükleme yönteminin kullanılması
- $k$ -katmanlı çapraz geçerlik yönteminin kullanılması

Bu soruna en etkili çözüm getiren yöntemler verinin kendisini için en uygun  $k$  değerini seçmesine imkân tanıyan Bayes yöntemleri, önyükleme ve  $k$ -katmanlı çapraz geçerlik yöntemleridir. En çok kullanılan yöntem  $k$ -katmanlı çapraz geçerliktir. Bu yöntem sayesinde, rastgele seçilen öğrenme verisi üzerinde farklı  $k$  değerleri elde edilerek sınıflandırma hatasını minimize eden değerin seçilmesidir (Larose ve Larose, 2014). Bu prosedürü kullanmak amacıyla belirlenen bir  $k$  değerinden hareketle belirli bir aralıktaki tüm  $k$  değerleri için analizler gerçekleştirilir. Doğru sınıflandırma performansının en yüksek elde edildiği  $k$  değeri seçilerek test verisi için sınıflandırmada kullanılır. Başlangıç noktası olarak bir  $k$  değerinin belirlenmesinde, en uygun  $k$  değerinin seçilmesinde başlıca bir kural olan öğrenme verisindeki kişi sayısının karekökünün alınması kullanılabilir. Örneğin, 900 kişilik bir öğrenme verisini ele alalım. Burada, kuralımıza göre alınabilecek  $k$  değeri  $\sqrt{900}=30$ 'dur. Buna göre, 1'den başlanarak 30 kadar tüm değerler için analizler gerçekleştirilir. Sonuçta, hata oranının en düşük olduğu  $k$  değeri kullanılarak yeni birey ya da nesnelere bu en yakın komşuluğa göre sınıflandırılacaktır.

**Uzaklık fonksiyonu.** Veri noktalarının birbirlerine uzaklıklarını hesaplamada Öklit ve Manhattan uzaklıkları aynı sonucu verir (Dunham, 2003). Ancak, genellikle

kullanılan uzaklık ölçütü Öklid fonksiyonudur.  $\mathbf{x} = x_1, x_2, \dots, x_n$  ve  $\mathbf{y} = y_1, y_2, \dots, y_n$ : iki değişkene ait n tane değeri göstermek üzere Öklit uzaklığı şu şekilde hesaplanır:

$$d_{\text{öklit}}(\mathbf{x}, \mathbf{y}) = \sqrt{\sum_i (x_i - y_i)^2} \quad (1.6)$$

Sürekli veriler için bu denklem aynı ölçekteki veriler için uygulanabilirken, kategorik verilerde parçalı bir fonksiyonla veriler yeniden kodlandıktan sonra Öklid denkleminde yerine koyulabilir. Sürekli verilerde en çok kullanılan yöntemler minimum-maksimum normalleştirilmesi veya z puanı standartlaştırmasıdır (Larose ve Larose, 2014).

**Birleştirme fonksiyonu.** En yakın komşuluktaki değerlerin sınıflandırmada eşit düzeyde etkili olması KNN yönteminin  $k$  değerine olan duyarlılığını daha da artırmaktadır (Tan ve diğerleri, 2014). Bu değerlerin her birinin ayrı kategoride olması durumunda da veri noktalarının sınıflandırılma işlemi başarısız olacaktır. Böyle durumlarda, kullanılacak en uygun yöntem, en yakın komşuların etkisini uzaklıklarına göre ağırlıklandırmaktır. Bir  $x_i$  veri noktasının sınıflandırılacak yeni veri noktasına ( $y'$ ) olan uzaklığı  $d$  olduğunda, ağırlıklandırma faktörü  $w_i$  şu şekilde hesaplanabilir (Larose ve Larose, 2014):

$$w_i = \frac{1}{d(y, x_i)^2}. \quad (1.7)$$

Bu denklemden hareketle,  $z=(x', y')$ , öğrenme verisi  $(x, y) \in D$  ve en yakın komşular  $D_z$  olmak üzere,  $y'$  noktasının sınıfı şu şekilde hesaplanır (Tan ve diğerleri, 2014):

$$y' = \underset{v}{\operatorname{argmax}} \sum_{(x_i, y_i) \in D_z} w_i \times I(v = y_i). \quad (1.8)$$

Öğrenme verisi fazla olduğunda bu işlem biraz zaman almasına karşın kullanışlı indeksleme teknikleri ile bu süre azaltılabilmektedir (Hamalainen ve Vinni, 2011).

**En yakın komşuluk sınıflandırıcısının karakteristik özellikleri.** KNN yönteminin diğer yöntemlerde olduğu gibi uygulama açısından bazı avantaj ve dezavantajları vardır. Yöntemin bazı üstünlükleri şu şekilde sıralanabilir (Akpınar, 2014; Hamalainen ve Vinni, 2011; Larose ve Larose, 2014; Tan ve diğerleri, 2014):

- İstatistiksel yapısının basit olması

- Uzaklık ölçüsü ( $d$ ) ve komşuluk sayısı ( $k$ ) uygun seçildiğinde yüksek sınıflandırma performansı göstermesi
- Gürültülü ve kayıp veriye dayanıklı olması
- Modelin elde edilmesi için öğrenme verisinin bir kere kullanılması ve bir model gerektirmemesi

Bu avantajlarla birlikte yöntemin birçoğu kendine özgü olmakla birlikte bazı önemli dezavantajları bulunmaktadır. Bu sınırlılıklar şu şekildedir (Hamalainen ve Vinni, 2011; Larose ve Larose, 2014; Tan ve diğerleri, 2014)

- $d$  ve  $k$  değerlerine karşı çok hassas olması
- Verilerin uygun ölçekte olmasının gerekmesi
- Yeterli büyüklükte örneklem gerektirmesi
- Sınıflandırmada önemsiz değişkenlerin ayıklanması gerekmesi

**Yapay sinir ağları.** Pazarlama, işletme, ekonomi ve kriminoloji gibi birçok alanda etkin kullanılan yapay sinir ağları karmaşık yapısı ile sınıflandırma ve örüntü tanıma gibi işlemleri gerçekleştirebilmektedir. Karar ağaçlarında olduğu gibi sinir ağları ile bir veri tabanındaki gözlemlerin nasıl sınıflandırılacağını gösteren bir model oluşturulur (Dunham, 2003). Bu model, katmanlar ve düğümlerden oluşan bir ağ mimarisinin işleyişini ifade eder. Yapay sinir ağları, yapısal olarak biyolojik sinir ağlarının taklit edilerek biyokimyasal işleyişinin numerik hale getirilmesiyle ortaya çıkmıştır (Nisbet, Elder ve Miner, 2009). Ancak, günümüzde kullanılan modeller sinir hücrelerinin işleyişi ve oluşturdukları ağların karmaşıklığını yansıtmak konusunda henüz çok geridedir (Akpınar, 2014).

Yapay sinir ağları, bir bilgisayar bilimi olarak McCulloch ve Pitts (1943) tarafından yapılan çalışma ile ortaya çıkmıştır. 1949 yılında Hebb tarafından ilk öğrenme kuralı geliştirilmiştir. Rossenbalt (1961) tarafından ortaya atılan algılayıcı modeli ilk defa iteratif bir süreç önermekteydi. Daha sonra, Minsky ve Papert (1969), bu modelin karmaşık problemlerin çözümünde etkili olmadığını göstererek çok katmanlı modelleri önermişlerdir. Sonraki yıllarda Kohonen, Rummelhart, Hinton ve Williams (1986) ile Chua ve Yang (1988) tarafından geliştirilen modeller yeni modellerin geliştirilmesi ve günümüzde de kullanılmasına önemli katkılar sağlamıştır.




Yapay sinir ağlarının uygulama alanları çok geniş olmakla birlikte bazı kullanım alanları şu şekildedir (Chattamvelli, 2009):

- Sınıflandırma: Medikal görüntüleme (ECG, EEG, X-ray cihazları), internet siteleri, iş başvuruları, dolandırıcılık tespiti, para transferi gibi mali işlemler, e-mail (spam belirlemede).
- Tahminleme ve yordama: Borsa, bono getirileri, gelecek yatırımlar, kiralar, gayrimenkul maliyetleri, sağlıkla ilgili uygulamalar.
- Kümeleme: Değişken kümeleme, internet sayfalarının veri kümelemesi, müşterileri, öğrencileri, vb. gruplama.
- Optimizasyon: Kategorik, sürekli çok değişkenli optimizasyonlar, 0-1 optimizasyonu, diğer bileşimli optimizasyon problemleri.
- Fonksiyon değerlendirme ve yakınsama.
- Modelleme ve model değerlendirme.
- Yönetim sistemleri (Çevrimiçi mali işlemler, hastanelerdeki otomatik ilaç yönetim sistemleri, araçlardaki seyir kontrol sistemleri).
- Uzmanlık sistemleri (Eğitilen bir ağ modeli olası yeni durumlar için yansımalar sağlar, uzaktan eğitim sistemleri).

Sinir ağları, robot teknolojileri ve makineleşmenin temelini oluşturduğundan günümüzde kullanılan birçok teknolojik aletin üretilmesinde etkin bir şekilde kullanılmaktadır. Yöntem, insan beyninin işleyişine olan benzerliğinden dolayı uygun parametreler girildiğinde diğer istatistiksel yöntemlere göre daha güvenilir sonuçlar elde edilebilmektedir. Örneğin, karar ağaçları ile kıyaslandığında, yapay sinir ağları düğümler arası ağırlıklandırmalar sayesinde kayıp ve gürültülü veriye daha dayanıklı bir yöntemdir (Dunham, 2003). Çoklu doğrusal regresyon ve lojistik regresyon ile kıyaslandığında ise modelle ilgili herhangi bir varsayım gerektirmemekle birlikte bağımlı değişkenin sürekli ve kategorik olduğu durumlarda etkili bir performans gösterebilmektedir (Chattamvelli, 2009).

***Sinir hücresinin yapısı ve sinir ağları.*** Yapay sinir ağları, temel olarak nöron olarak adlandırılan sinir hücresinden esinlenerek geliştirilmiştir (Akpınar, 2014). Yapay sinir ağlarının gelişimi, insan beyninin girdi ve çıktılardan oluşan

paralel ve dağıtımli sinyalleri iletmesi, deneyimlerden öğrenmesi, yüksek modifiye edilebilir bağlantılılık, ampirik veriden ön öğrenmenin gerçekleşmesi, hatanın minimize edilebilmesi, ileri ve geri bağlantıların olması gibi karakteristik özelliklerinden önemli ölçüde etkilenmiştir (Chattamvelli, 2009). İnsan beyni yaklaşık olarak  $10^{11}$  nörondan oluşmaktadır (Larose ve Larose, 2014). Nörologlar, insan beyninin nöronlar arasındaki sinaptik bağlantıların etkileşimini değiştirerek öğrendiğini keşfetmişlerdir (Tan ve diğerleri, 2014). Basit bir sinir hücresi, çekirdek, akson, dendritler ve sinaplardan oluşur (Şekil 4).

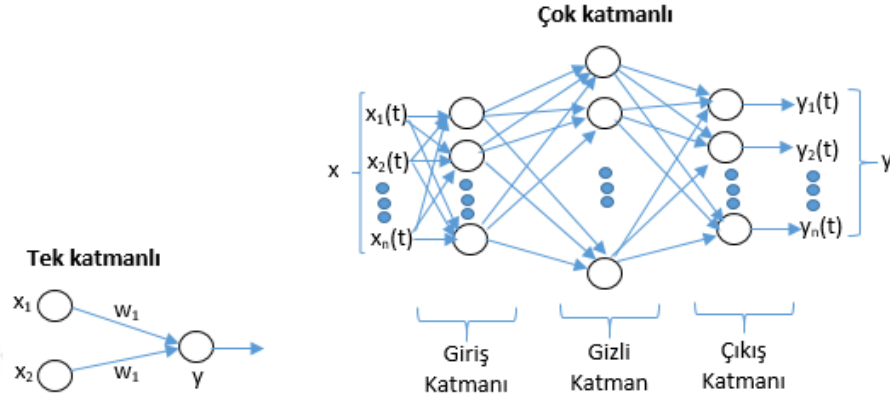


Şekil 4. Sinir Hücresinin Yapısı (Akpınar, 2014, s. 237)

Sinir hücreleri birbirine bir sinir hücresi uyarıldığında oluşan etkiye diğer sinir hücrelerine aktaran akson denilen boğumlu liflerle bağlıdır. Hücre gövdesinde yer alan dendritler sayesinde hücreler diğer sinir hücrelerine bağlanır. Dendritler ile aksonlar arasındaki bağlantı noktaları ise sinaps olarak adlandırılmaktadır. Bir veya birden fazla sinir hücresinden gelen uyarılma eğer belirli bir eşik değere ulaşırsa diğer sinir hücrelerine aktarılır. Elektro-kimyasal olan bu iletişim süreci oldukça karmaşıktır. Ortalama 1,5 kg olan insan beynindeki yüzbinlerce hücre arasında gerçekleşen sinaptik birleştirmeleri gerçekleştirecek bir bilgisayarın gezegenimizden büyük bir hacmi kaplayacağı düşünülmektedir (Cüceloğlu, 1991).

İnsan beyin yapısına benzer şekilde, yapay sinir ağları birbirine bağlanmış bir grup düğüm ve yönlendirilmiş bağlantılardan oluşur. Bazı parametrelerden oluşan her düğüm, girdide verilen bilgiyi kullanarak çıktıyı belirler. Parametrelerinin

değiştirilmesi farklı düğüm fonksiyonlarının oluşmasını sağlar. Her bir ağda sinyaller nöronlar arasında belirli ağırlıklandırmalara sahip bağlantı linkleri ile iletilir. Genel olarak tek katmanlı ve çok katmanlı yapıda olabilen sinir ağlarının en temel modeli Şekil 5'te görselleştirmiştir (Sivanandam ve diğerleri, 2011).




Şekil 5. Tek ve Çok Katmanlı Yapay Sinir Ağları

Şekil 5'te verilen tek katmanlı (basit) model, iki giriş nöronu ( $x_1$  ve  $x_2$ ), iki bağlantı ağırlıklandırması ( $w_1$  ve  $w_2$ ) ve bir çıkış nöronundan ( $y$ ) oluşmaktadır. Çok katmanlı model ise üç tabakadan oluşmaktadır. Giriş katmanından gelen sinyaller ağırlıklandırmalarına göre gizli katmana aktarılır. Çıkış katmanından elde edilecek çıktılar gizli katmandaki nöronlara ve gizli katman ile çıkış katman arasındaki ağırlıklandırmalara göre farklılık gösterir. Buna göre, katman sayısı, katmanlardaki nöron sayısı ve bağlantılara göre çok farklı çıktılar elde edilebilmektedir. Optimum sonuç elde edilene kadar ağırlıklandırma eğitimi fikri sonuçların bu şekilde farklılaşmasından ileri gelmektedir.

Yapay sinir ağları model temelli sınıflandırma yaklaşımlarındandır. Öğrenme verisi üzerinde bir aktivasyon fonksiyonu ile (genellikle sigmoid) net girdi hesaplanır. Temel bir YSA modeli, Şekil 5'te verilen çok katmanlı yapıdaki gibi girdi, gizli ve çıktı olmak üzere üç katmandan oluşur. Bir sinir hücresinin aktive edilmesi, bu sinir hücresine gelen ağırlıklandırılmış girdi sinyallerinin toplamıdır (Jalali-Heravi, 2008).  $W_{ij}$  gizli katmandaki  $j$  sinir hücresinin önceki katmandaki  $i$  hücresine ağırlıklandırılmış bağlantısı ve  $yanlılık_j$ :  $j$  sinir hücresinin yanlılığı olmak üzere aktivasyon değeri şu şekilde hesaplanır:

$$Ağ_j = \sum_i W_{ij} X_i - yanlılık_j \quad (1.9)$$

Elde edilen bu değer, uygun bir fonksiyon ile çıktı düzeyine dönüştürülür. Tercih edilen YSA modeline göre çıktı değerini elde etmek amacıyla kesin sınırlı, lineer tanjant, hiperbolik tanjant ya da sigmoid fonksiyonlarından biri kullanılabilir (Şekil 6).



Şekil 6. Eşik Fonksiyonları (Akpınar, 2014, s. 242)

Sigmoid fonksiyonu, en çok tercih edilen dönüştürme fonksiyonudur (Jalali-Heravi, 2008). Buna göre,  $y_i$   $j$  hücresinin çıktısı olmak üzere Sigmoid fonksiyonu kullanarak çıktı değeri şu şekilde elde edilmektedir:

$$y_i = \frac{1}{1+e^{-A\tilde{g}_j}} \quad (1.10)$$

Elde edilen bu çıktı değeri, girdideki değer belirlenmiş bir sınıfa ait olma olasılığını gösterir. Bu olasılıklar hesaplanarak belirli bir birey ya da nesne, ait olma olasılığı en yüksek olan sınıfa atanır. Ağa alınan her bir veri için yapılan sınıflandırma eğrisi gerçek sınıflandırmalarla karşılaştırılabilir. Ağın öğrenme sürecinde verinin daha iyi sınıflandırılabilmesi için sınıflandırma eğrileri modifiye edilir (Dunham, 2003). Bir sinir ağında bir düğüm birden fazla düğümden etkilenebildiğinde, yetersiz veya bozuk veri olduğunda bile ağın sınıflandırma performansı önemli ölçüde etkilenmemektedir (Akpınar, 2014). Yapay sinir ağı modellerinin bu karmaşık yapısı,

sinir ağlarının öğrenme sürecinin karar ağaçları gibi model temelli algoritmalara göre çok daha fazla zaman almasına neden olmaktadır (Larose ve Larose, 2014).

**Yapay sinir ağlarının kullanımı ve karşılaşılan sorunlar.** Sinir ağları, karmaşık istatistiksel ve matematiksel alt yapısından dolayı uygulamada birtakım süreçlerin göz önünde bulundurulmasını gerektirir. Dunham (2003), sinir ağları ile bir sınıflandırma probleminin çözülmesinde aşağıdaki adımların takip edilmesini önermektedir:

1. Girdi olarak hangi değişkenlerin kullanılacağı ve çıktı düğümlerinin sayısının belirlenmesi
2. Grafik için hangi ağırlıklandırmaların ve fonksiyonların kullanılacağı belirlenmesi
3. Öğrenme verisindeki her bir veri için ağın yeniden eğitilmesi ve yordanan çıktı değeri ile olması gereken sonucun değerlendirilmesi
4. Sınıflandırılacak her bir veri için ağın tekrar eğitilerek en uygun sınıflandırmanın elde edilmesi

Bu süreçte kaynak düğümleri olan değişkenlerden ayırıcı değişkenlerin belirlenmesi gerekir. Tan ve diğerleri (2014)'a göre girdi katman sayısı, sürekli ve iki kategorili değişkenler için bir, kategorik değişkenler için ise her bir kategori değeri için bir düğüm olmalı; çıkış katmanındaki düğüm sayısı için ise iki kategorili değişkenlerde bir,  $k$  kategorili değişkenlerde ise  $k-1$  tane çıktı düğümü olmalıdır. Yapay sinir ağlarında gizli katman sayısının ne olacağı yanı sıra her bir katmanda bulunması gereken düğüm sayısı da sınıflandırma performansını etkileyen önemli faktörlerdir (Heaton, 2008; Tan ve diğerleri, 2014). Gizli katman sayısı en basit modelde bir olmasına karşın bu sayı yeterli düzeyde olmalıdır (Dunham, 2003). Akpınar (2014) birçok sınıflandırma probleminin çözümünde katman sayısının üç olmasının yeterli olacağını belirlemekle birlikte zamandan tasarruf sağlamak için gerekirse ilave katmanların incelenmesinin yararlı olacağını belirtmektedir. Tan ve diğerleri (2014), yeterli büyüklükte gizli katman ve düğüm sayısından başlayarak sayıyı azaltmak ve en uygun olanını bulmak (budama=pruning) çok zaman alacağından oluşturulan bir model üzerinden bazı düğümlerin kaldırılarak en uygun modelin belirlenebileceğini belirtmektedir. Son yıllarda kullanılan gelişmiş bilgisayar yazılımları sayesinde budama işlemi hızlı bir şekilde yapılarak en uygun ağ mimarisi

elde edilebilmektedir. Heaton (2008) ise iki tane gizli katman gerektiren problemlerin nadir olduğunu, ikiden fazla gizli katman için teorik bir neden olmadığını ve birçok uygulamada sadece bir katmanın yeterli olduğunu belirtmektedir. 1950'lilerde önemli bir Rus matematikçi olan Andrey Kolmogorov'a göre iki veri seti arasındaki ağın ikiden fazla gizli katman içermemesi gerekir (Dunham, 2003). Her bir gizli katmanda bulunması gereken düğüm sayısı için ise başlıca kurallar şu şekildedir (Heaton, 2008):

- Gizli düğüm sayısı girdi ve çıktı katmalarının büyüklükleri arasında bir değer olmalıdır.
- Gizli düğüm sayısı girdi katmanının büyüklüğünün  $2/3$ 'ü ile çıktı katmanının büyüklüğünün toplamı kadar olmalıdır.
- Gizli düğüm sayısı girdi katmanının büyüklüğünün iki katından az olmalıdır.

Ağın topolojisinin belirlenmesi için gerekli olan öğrenme verisi ile ilgili herhangi kesin bir kural bulunmamaktadır (Akpınar, 2014). Ancak, öğrenme verisi oranı çok yüksek olduğunda aşırı uyum (overfitting), çok az olduğunda ise doğru sınıflandırma yapabilmek için ağın yeterince eğitilememesi sorunları ortaya çıkmaktadır (Dunham, 2003). Aşırı uyum sorunu, bir sınıflandırma modelinin öğrenme verisine iyi uyum göstermesine rağmen test verisinde yüksek hata vermesidir. Bu sorun, öğrenme verisi oranı yüksek olmasına rağmen test verisini temsil edici örneklemin yetersiz olmasından dolayı genelleme hatalarının oluşmasına neden olmaktadır (Tan ve diğerleri, 2014).

YSA analizlerinin gerçekleştirilmesinde gizli katman sayısı, katmanlardaki düğüm sayısı ve algoritmanın eğitilmesinde kullanılan veri oranının yanında analiz sonuçlarına etki eden birçok parametre bulunmaktadır. Bu parametreler, çıkış düğümü sayısı, düğümler arası bağlantılar ve ağırlıklandırılmaları, kullanılan aktivasyon fonksiyonu (örn, Sigmoid), öğrenme tekniği (örn. Geri yayılım) ve durdurma kuralıdır. Çıkış düğümü sayısı genellikle bağımlı değişkenin kategori sayısından 1 çıkarılmasıyla elde edilirken, her bir düğüm kendinden sonraki tüm düğümlerle bağlantılıdır (Dunham, 2003). YSA ile yapılan analizler tüm test verisi ağdan geri yayılım gösterdiğinde, geçen zaman veya hata oranına göre sonlandırılır. Bazı öğrenme kuralları ise McCulloch-Pitts Modeli, Hebb Kuralı, Algılayıcı modeli, Adaline, Hopfield Kuralı, geri yayılım ağı ve genelleştirilmiş Delta

kuralı örnek verilebilir. Geri yayılım ağı en çok kullanılan YSA öğrenme modelidir (Akpınar, 2014; Dunham, 2003).

**Yapay sinir ağları modellerin sınıflandırılması.** YSA, öğrenme algoritmalarına göre danışmanlı, danışmansız ve destekleyici olmak üzere üç ana gruba ayrılır. Danışmanlı (supervised) öğrenmede, çıktı değerleri eğitim verisinde tanımlandığından ağın parametreleri eğitim verisinden elde edilir (Krenker ve diğerleri, 2011). Geri Yayınımlı (Back-propagation) algoritma ve Hebb Kuralı danışmanlı öğrenmeye örnek algoritmalarıdır. *Geri yayılım ağları*, yapay sinir ağına alınan her bir gözlemin çıktı düğümünde elde edilen değerinin gerçek değeri ile karşılaştırılması ve hatayı minimize eden modelin elde edilmesini temel alır (Larose ve Larose, 2014). 1949 yılında Donald Hebb tarafından sunulan *Hebb modeli* ise Ivan Pavlov'un öğrenimde klasik koşullanma çalışmalarına dayanır. Buna göre, yeterli uyarılma gerçekleştiğinde iki sinir hücresinin bir düzenleme gerçekleştirdiğini ve uyarıcı verilmediğinde dahi bir hücrenin diğerini uyarabildiği savunulmuştur (Akpınar, 2014). Hebb'in çalışmalarının, sonraki yıllarda yapılan sinir ağları çalışmalarına yön verici etkisi olmuştur. Veri setlerinde eğer öğrenme verisi kullanılacak ise danışmanlı öğrenme yöntemlerinden birinin tercih edilmesi yerinde olacaktır (Krenker, Beşter ve Kos, 2011).

Danışmansız (unsupervised) öğrenmede ise sinir ağının parametreleri veriden ve minimize edilecek bir maliyet fonksiyonundan elde edilir (Krenker ve diğerleri, 2011). Kohonen ağları olarak da adlandırılan danışmansız YSA'nın Öğrenme Vektörü Nicemlemesi (Learning Vector Quantization) ve Kendini Düzenleyen Haritalar gibi algoritmaları vardır. *Kohonen ağları*, bir gizli katmanı olmayan sadece girdi ve çıktı katmanlarından oluşan tam bağlantılı ağlardır. Girdi katmanına alınan öğrenme verisindeki gözlemler çıktıda seçilen değer olmak için yarışırken çıktıda elde edilen değerler için düğümlerin optimal ağırlıklandırmaları elde edilir ve model tüm öğrenme verisi için güncellenir (Chattamvelli, 2009). Teuvo Kohonen tarafından önerilen *Öğrenme Vektörü Nicemlemesi*, uygun bir uzaklık ölçüsü kullanılarak sınıfların örnek temsilcilerinin uzaklıklarına dayanan bir model oluşturma esas alınır (Akpınar, 2014). Tam bağlantılı bir diğer model olan *Kendini Düzenleyen Haritalar*, çok boyutlu doğrusal olmayan yapıdaki veriyi haritalayarak topolojik ilişkileri koruyan daha az boyutlu (genellikle iki boyutlu) bir uzay ya da düzlemde gösterir. Giriş katmanında bağımsız değişken sayısı kadar sinir hücresi,

çıktı katmanında ise komşu düğümlerden oluşan grid yapıdaki düğümler yer alır (Chattamvelli, 2009).

Destekleyici (reinforcement) öğrenmede ise sinir ağının parametreleri belirli bir veriden değil, çevreyle iletişimden elde edilen verilerle sağlanır (Krenker ve diğerleri, 2011). Destekleyici öğrenme algoritmalarına Hopfield Ağları örnek gösterilebilir. Fizikçi John Hopfield tarafından 1982 yılında geliştirilen *Hopfield Ağları* yapay sinir ağlarının basit bir analog modelidir (Akpınar, 2014). Bu model, geri yayılım öğrenme yöntemi yerine düğümler arası bağlantıların dayanıklılıklarını (ağırlıklandırmalarını) iteratif olarak modifiye eden Hebb öğrenme algoritmasını kullanarak bir ateşleme fonksiyonu ile eşik değeri geçen nöronların seçilmesini temel alır (Chattamvelli, 2009).

Sinir ağları, yapısına göre ileri ve geri beslemeli olmak üzere ikiye ayrılır. Eğer nöronlar arasındaki bağlantılar çıktıya doğru olmanın yanında kendi katmanında veya bir önceki katmanda bulunan sinir hücrelerine doğru ise buna geri beslemeli ağlar denilmektedir. İleri beslemeli ağlarda ise sinyal iletimi ileriye doğru olmaktadır (Chattamvelli, 2009). Şekil 5'te verilen tek ve çok katmanlı ağ yapısında tüm bağlantılar çıktıya doğru olduğundan ileri beslemeli ağlara örnek oluşturur. Bazı ileri beslemeli algoritmalar, Algılayıcı, Radyal Temelli Fonksiyonlar ve Çok Katmanlı Algılayıcı ağlarıdır. *Algılayıcı*, birçok giriş ve bir çıkıştan oluşan tek bir sinir hücrelerini karşılık gelen en basit yapıdaki sinir ağıdır (Dunham, 2003). *Çok Katmanlı Algılayıcı*, birden fazla algılayıcıdan oluşan içinde gizli katmanlar ve gizli düğümler barındıran karmaşık yapıdaki ağlardır (Tan ve diğerleri, 2014). *Radyal Temelli Fonksiyonlar* ise eşik fonksiyonu olarak Gauss fonksiyonunu kullanır. Çıktı katmanındaki Sigmoid fonksiyonu ise sonsal olasılığa karşılık gelen gizli katman değerlerinin doğrusal birleşimidir (Akpınar, 2014).

Chattamvelli (2009), yapay sinir ağlarının Bilgi Temelli Ağlar, Bulanık Sinir Ağları, Rastgele Sinir Ağları, Olasılıksal Sinir Ağları, Genelleştirilmiş İleri Beslemeli Ağlar, Modüler Ağlar, Hücresel Sinir Ağları, Kendini Düzenleyen Sinir Ağları, Dinamik Ağlar, Hibrit Ağlar, Çok Boyutlu Ağlar ve Gecikmiş (Time Delay) Sinir Ağları gibi çok çeşitli özel türlerinin olduğunu belirtmiştir. Akpınar (2014) ise YSA modellerinin ağ yapısına, ağdaki düğümlerin özelliklerine, eşik fonksiyonunun yapısına, düğüme uygulanan değerlerin özelliğine ve kullanılan öğrenme kuralına göre çok çeşitli olabileceğini ifade etmiştir. Bazı araştırmacılar ise temelde en çok tercih



edilen yöntemler olan geri yayılım, radyal temelli fonksiyonlar, algılayıcı ve çok katmanlı algılayıcı üzerinde durmuşlardır (Dunham, 2003; Larose ve Larose, 2014; Nisbet ve diğerleri, 2009; Silahtaroglu, 2013; Tan ve diğerleri, 2014).

Sinir ağlarının yapısına göre geri yayımlı ileri beslemeli sinir ağları en çok kullanılan YSA çeşididir (Chattamvelli, 2009; Hamalainen ve Vinni, 2011). Bu ağlar, geri yayımlı öğrenme algoritmasına dayanan çok katmanlı, danışmanlı olarak eğitilen modellerdir (Akpınar, 2014; Jalali-Heravi, 2008). Bu çalışmada, ileri beslemeli yapay sinir ağları ile analizler gerçekleştirildiğinden sonraki kısımlarda geri yayılım ağları, algılayıcı ve çok katmanlı algılayıcı ile ilgili daha ayrıntılı bilgiler verilecektir.

*Geri yayılım ağları.* Geri yayılım (backpropagation) ağları, Werbos tarafından düzenlenmiş ve sonradan Parker, Rummelhart ve McClelland tarafından geliştirilmiştir (Akpınar, 2014). Bu öğrenme algoritması çok katmanlı sinir ağlarının eğitilmesinde kullanılır. Algoritmanın öğrenme verisindeki her bir gözlem sinir ağından geçirilerek çıktı düğümünde bir çıktı değeri elde edilir. Elde edilen bu değer, gözlemin gerçek değeri ile karşılaştırılır. Kestirilen değer ile gerçek değer arasındaki hata kareleri toplamı farkını minimize eden bir model oluşturmak amaçlanır. Elde edilen hatalar regresyondaki artık değerlere, optimal ağırlıklandırma katsayıları ise parametrelere benzer (Larose ve Larose, 2014). Her düğümde toplama ve aktivasyon fonksiyonları kullanılarak bir çıktı kümesi elde edene kadar düğümlerden tekrar geçirilir ve en uygun model kurulur (Dunham, 2003). Geri yayılım öğrenme algoritmasına göre, YSA'nın çıktısı ile istenen değeri arasındaki her bir iterasyondan sonra hesaplanır.  $\Delta w_{ij}$ , her ağ düğümünün ağırlıklandırma faktöründeki değişim;  $\delta_i$ ,  $i$  düğümünün gerçek hatası;  $O_j$ ,  $j$  düğümünün çıktısı;  $\eta$ , öğrenme oranı; ve  $\alpha$ , momentum faktörü olmak üzere ağırlıklandırma değerlerindeki değişimler şu şekilde elde edilir (Jalali-Heravi, 2008):


$$\Delta w_{ij}(n) = \eta \delta_i O_j + \alpha \Delta w_{ij}(n - 1) \quad (1.11)$$

Öğrenme oranı ve momentum faktörü değişkenleri, öğrenme sürecinin verimliliğini ve hızını kontrol altına alınmasında kullanılır. Öğrenme sürecinin amacı, katmanlar arasındaki ağırlıklandırmaların yönünü hatayı minimum yapacak şekilde azaltmaktır. Bu hata ( $E$ ) şu şekilde hesaplanır:

$$E = \frac{1}{2} \sum_p \sum_k (y_{pk} - t_{pk})^2 \quad (1.12)$$

Ağın hatası,  $y$  çıktısı ile  $t$  hedef değeri arasındaki farkın  $k$  çıktı düğümüne ve  $p$  öğrenme örüntüsüne göre toplamının yarısına eşittir. Hatanın geriye doğru kestirilmesi sonucunda, aynı hataların tekrarlanmasını önlemek amacıyla ağırlıklandırmalar ayarlanır ve hata minimize edilir. Model yeterli düzeyde eğitildiğinde ağırlıklandırmalar kaydedilir ve yeni girdiler için kestirimlerin yapılmasında kullanılır (Jalali-Heravi, 2008). Temelde *Genelleştirilmiş Delta Kuralı* olarak bilinen bu süreç, algoritmanın öğrenme verisi için hata değerleri kabul edilebilir düzeye ulaşana kadar tekrarlanır (Akpınar, 2014).

*Algılayıcı.* Algılayıcı en basit sinir ağı modelidir. YSA'nın ilk kullanımlarında olan algılayıcılar sadece bir katmandan oluşur ve sadece doğrusal olarak ayrılabilen örüntüleri sınıflandırabilir (Chattamvelli, 2009). 1950'li yılların sonlarında Rosenblatt (1958) tarafından yapılan çalışma algılayıcı kuramının temelini oluşturur. Şekil 7'de ağırlıklandırma faktörleri eşit ve 0.3 olan üç girdi düğümü ile yanlılık faktörü  $t=0.4$  olan bir algılayıcı modeli verilmiştir.



Şekil 7. Algılayıcı Model (Tan ve diğerleri, 2014)

İki kategorili bir sınıflandırma problemi için Şekil 7'de verilen algılayıcının  $y$  aktivasyon değeri  $x_1$ ,  $x_2$  ve  $x_3$  girdi düğümleri olmak üzere;

$$y = \begin{cases} 1, & \text{eğer } 0.3x_1 + 0.3x_2 + 0.3x_3 - 0.4 > 0; \\ -1, & \text{eğer } 0.3x_1 + 0.3x_2 + 0.3x_3 - 0.4 < 0. \end{cases} \quad (1.13)$$

olacaktır (Tan ve diğerleri, 2014). Bu denklem, eşitlik 1.9'da verilen aktivasyon formülünün sınıflandırma problemine uygulanmış halidir. Elde edilen  $y$  değeri için bir çıktı elde edilerek eşik değere göre sınıflandırma işlemi gerçekleştirilir. Algılayıcı modeli temelde bir girdi vektörü ve belirli bir eşik değer kullanarak bir karar sınırı elde edilmesini sağlar. Bir sınıflandırma probleminde sınıflar doğrusal olarak

ayrılabilir ise algılayıcı yöntemi, en uygun sonuca sınırlı sayıda tekrar sonucunda yakınsayacaktır (Chattamvelli, 2009; Tan ve diğerleri, 2014).

Ancak, Minsky ve Papert (1969) algılayıcı kuramına birçok eleştiri getirmişlerdir. Sınıflandırma örüntülerinin birçoğunun doğrusal olarak ayrılabilir olmadığını ve algılayıcıda kullanılan tek bir katmanın basit problemlerde yeterli olmasına karşın karmaşık problemlerde çözüm üretmediğini göstermişlerdir. 1970'lerden sonra gittikçe önem kazanan ve ilgi odağı haline gelen yapay sinir ağları çalışmaları hız kazanmış ve sonuçta çok katmanlı ağlar sınıflandırma problemlerinin çözümünde kullanılmaya başlanmıştır (Akpınar, 2014).

*Çok katmanlı algılayıcı.* Yapay sinir ağı modelleri genel olarak bir algılayıcıdan daha karmaşık yapıdadır. Algılayıcıların birleşiminden oluşan çok katmanlı ağlar algılayıcılara getirilen eleştirileri ortadan kaldırmak ve karmaşık problemlere etkili çözümler getirmek amacıyla geliştirilmişlerdir. Çok katmanlı algılayıcılar genel olarak bir veya daha fazla gizli katmandan oluşabilir (Şekil 2). Ayrıca, bir sınıflandırma probleminde bir işaret fonksiyonu yerine Şekil 3'te verilen farklı yapılardaki aktivasyon fonksiyonları kullanılabilir. Böylece, algılayıcının en çok eleştiri alan sınıfların doğrusal ayrılabilirliği şartını sağlamaya gerek kalmadan gizli ve çıktı katmanlarının girdi parametrelerinden doğrusal olmayan çıktı değerleri üretmesini sağlayacaktır (Tan ve diğerleri, 2014). Kullanılan gizli katman sayısı ve her bir katmanda bulunması gereken düğüm sayısı modellerin sınıflandırma performansını önemli ölçüde etkilemektedir (Heaton, 2008). Geri yayılım algoritması ile eğitilen çok katmanlı algılayıcılar, gizli katmanlarda yeterli düzeyde düğüm olması halinde, doğrusal olarak ayrılabilir olmayan örüntüleri başarılı bir şekilde sınıflandırabilmektedir (Chattamvelli, 2009).

Çok katmanlı algılayıcılar için  $Ağ_j = \sum_i W_{ij}X_i - yanlılık_j$  formülü ile bir eşik değeri hesaplanır. Daha sonra, bu eşik değeri uygun bir aktivasyon (ateşleme) fonksiyonu ile sınıf olasılıklarının hesaplanmasında kullanılır. Elde edilen çıktı değerleri, geri yayılım algoritması kullanılarak gerçek çıktı değerleri ile karşılaştırılır. Dinamik olan bu süreçte ağırlıklandırılmalar ve sınıf olasılıkları en düşük hata ile en uygun model elde edilene kadar tekrar tekrar elde edilir (Larose ve Larose, 2014). Elde edilen model, test verisi üzerinde kullanılarak gözlemler sınıflara atanır. Çok katmanlı algılayıcı ile bir sınıflandırma problemini çözmek için sinir ağını eğitmeden önce aşağıdaki hususlara dikkat edilmelidir (Tan ve diğerleri, 2014):


- Girdi ve çıktı katmanlarındaki düğüm sayısı uygun yöntemlerle belirlenmelidir.
- Ağın yapısı (gizli katman sayısı, katmanlardaki düğüm sayısı, aktivasyon fonksiyonu çeşidi, ağın ileri veya geri beslemeli olması, vb.) farklı koşullar için tekrarlanarak ya da budama yöntemi ile en uygun hale getirilmelidir.
- Ağırlıklandırmalar ve yanlılıklar girilmelidir.
- Öğrenme verisindeki eksik ya da kayıp değerlerin yerine uygun bir yöntemle yakın değerler atanmalıdır.

**Yapay sinir ağlarının özellikleri.** Diğer veri madenciliği yöntemleri ile karşılaştırıldığında yapay sinir ağlarının birçok avantajı bulunmaktadır. Dunham (2003), sinir ağlarının ağırlıklandırma faktörlerinden dolayı karar ağaçlarına göre gürültülü ve kayıp veriye daha dayanıklı olması, yöntemin sürekli öğrenerek performansını artırabilmesi, uygun şekilde eğitildiğinde düşük hata oranları elde edilebilmesi gibi üstünlükleri olduğunu ifade etmiştir. Chattamvelli (2009) ise sinir ağlarının veriye yönelik herhangi bir varsayım gerektirmemesi, modelin uyarlanabilir (adaptive) öğrenme gerçekleştirmesi, kendi kendini organize edebilme, gerçek zamanlı işlemler yapabilmesi, gereksiz veriye tolerans gösterebilmesi ve diğer istatistiksel tekniklere göre bağımlı ve bağımsız değişkenler açısından daha esnek olmasını önemli avantajları olarak göstermiştir. Tan ve diğerleri (2014), uygun ağ mimarisi seçildiğinde en uygun modelin elde edilebildiğini ve gereksiz değişkenlerin öğrenme sırasında daha az ağırlıklandırılması sayesinde etkisinin elimine edilebildiğini belirtmişlerdir.

Ancak, karmaşık yapısından dolayı yapay sinir ağları kullanmanın bazı sınırlılıkları bulunmaktadır. Dunham (2003), yöntemin çalışma prensibinin anlaşılmasının zor olması, girdi değerlerinin sayısal olması gerekmesi, test etme ve doğrulama aşamalarının olması, öğrenmenin yakınsamayabilmesi, aşırı uyum sorunun oluşabilmesi ve kullanımının maliyetli olmasının bazı sınırlılıkları olduğunu ifade etmiştir. Sinir ağlarının, geri yayılım hatasına karşı hassas ve uygulamada zahmetli olması, yerel minimum sorunu görülmesi ve sinir ağları ile ilgili yeterli düzeyde alan bilgisi gerektirmesi gibi diğer bazı dezavantajları bulunmaktadır (Chattamvelli, 2009). Bu sınırlılıkların yanında, Tan ve diğerleri (2014), öğrenme verisindeki kayıp ve gürültülü veriye karşı hassas olduğunu ve özellikle gizli düğüm

sayısı fazla olduğunda çok zaman alan bir sürece dönüştüğünü belirtmektedir. Ayrıca, eğitim verisi seçme yöntemi, oluşturulacak ağın katman sayısı ve katmanlardaki düğüm sayısı, başlangıç ağırlık değerleri, öğrenme hızı ve momentum değerlerinin belirlenmesi yöntemin performansını etkileyen önemli faktörlerdir (Akpınar, 2014).

**Lojistik regresyon.** Regresyon problemlerinin çözümünde belirli girdi verisi kullanılarak çıktı değerleri kestirilir. Regresyon analizi, tahminleme ve yordamada kullanıldığı gibi sınıflandırmada da sıklıkla kullanılan bir yöntemdir. Sınıflandırmada kullanıldığında girdi verisi bağımsız değişkenlere ait değerler iken çıktı değeri ise bir sınıflandırma değişkenidir. İstatistik temelli algoritmalarından olan regresyon analizi, yapay sinir ağları gibi birçok farklı tekniğe uygulanabilmektedir (Dunham, 2003). Yordama amacıyla kullanıldığında basit ve çoklu doğrusal regresyon, sınıflandırma amacıyla kullanıldığında ise lojistik ya da probit regresyon gibi türleri bulunmaktadır. Doğrusal regresyon analizi verinin doğrusal bir denkleme karşılık gelen uyum çizgisine olan yakınlığına göre kestirimde bulunulmasını temel alır. Ancak, doğada değişkenler arasındaki ilişkiler genellikle doğrusal değildir (Nisbet ve diğerleri, 2009). Başka bir ifadeyle, elde bulunan veri genellikle doğrusal bir denkleme karşılık gelmeyebilir. Şekil 8'de  $X$  ve  $Y$  değişkenleri arasındaki doğrusal ve doğrusal olmayan ( $Y=\ln X$ ) ilişkiler verilmiştir.



Şekil 8. Doğrusal ve Doğrusal Olmayan İlişkiler

Şekil 8 incelendiğinde, doğrusal olmayan ilişki logaritmik formattadır. Bu fonksiyon üstel, polinom veya üs şeklinde de olabilmektedir. Sosyal bilimlerde elde edilen verilerin genellikle kategorik yapıda olması ve sürekli değişkenlerle yapılan doğrusal regresyon analizlerinin katı varsayımlara sahip olması doğrusal olmayan yöntemlerin kullanılmasını teşvik etmektedir (Çokluk, Şekercioğlu ve Büyüköztürk,

2014). Bu amaçla, lojistik, probit, poisson ve parçalı doğrusal regresyon gibi teknikler kullanılmaktadır. *Probit Regresyon*, bir normal olasılık eğrisinin altındaki alanı hesaplamakta, *Poisson Regresyonu*, değişkenler arası ilişkileri bir poisson dağılımı ile göstermekte ve *Parçalı Doğrusal Regresyon* ise doğrusal olmayan ilişkileri parçalara ayırarak farklı doğrusal ilişkilere dönüştürmektedir (Nisbet ve diğerleri, 2009).

Lojistik regresyon analizi ise en yaygın kullanılan doğrusal olmayan regresyon tekniklerinden biridir (Dunham, 2003). Bağımlı değişkenin kategorik ya da sınıflandırılmalı olduğu durumlar için kullanılan bu analiz yöntemi diğer yöntemlere göre daha kullanışlı olmasından dolayı geniş bir kullanım alanına sahiptir. Analiz tekniği, grup üyeliklerinin kestirmek ve bağımlı ile bağımsız değişkenler arasındaki ilişkileri ortaya çıkarmak gibi temel amaçları vardır (Mertler ve Vannatta, 2005). Lojistik regresyonun, diskriminant analizi ve çoklu regresyona göre değişkenlerin dağılımına yönelik katı varsayımları yoktur (Tabachnick ve Fidell, 2013). Bu nedenle, diğer istatistik temelli analiz yöntemlerine göre daha esnek bir yapıdadır (Çokluk ve diğerleri, 2014).


Lojistik fonksiyonu, 19. yüzyılda nüfus artışı ve otokatalitik kimyasal reaksiyonların seyrini tanımlamak için keşfedilmiştir. Fonksiyonun temelleri 1838 ve 1845 yılları arasında Pierre-François Verhulst (1804-1849) tarafından yapılan çalışmalara dayanır. Ancak, Verhulst'un çalışmalarından habersiz olan Raymond Pearl (1879-1940) ve Lowel J. Reed (1886-1966), 1920'de Amerika Birleşik Devletleri'nin nüfus artışı ile ilgili bir çalışmada lojistik fonksiyonu yeniden keşfetmişlerdir. Ancak, sonraki çalışmalarında Verhulst'un çalışmalarına yer vermişlerdir. 1925'de George Udny Yule (1871-1951) yaptığı çalışmasında Verhulst'un çalışmalarına atıfta bulunarak 'lojistik' kavramını ilk kez Verhulst tarafından kullanıldığını ifade etmiştir. İlk zamanlarda (1935-1969) bilimsel çalışmalarda genellikle 'probit' kavramı kullanılırken 1970'li yıllardan sonra sıklıkla 'lojistik' kavramının kullanımına yer verilmiştir. Analiz yönteminin kullanışlı olması birçok bilim dalında geniş uygulama alanlarına ulaşmasını sağlamıştır (Cramer, 2002).

Lojistik regresyon analizi, normal dağılım, doğrusallık ve varyans-kovaryans matrislerinin homojenliği gibi varsayımların karşılanmasını gerektirmez. Ancak, örneklem büyüklüğü yeterli büyüklükte olmadığı yansız ve sapmasız istatistikler

elde edilmesi güçleşmektedir. Yordanan değişken ikide fazla kategoriden oluştuğunda her yordayıcı değişken için 50 kişilik bir örneklem büyüklüğü ya da her bir değişken için 20 kişi toplamda 60 kişilik bir örneklem büyüklüğüne ihtiyaç duyulur. Eğer normallik ve varyans-kovaryans matrislerinin homojenliği varsayımları sağlanırsa diskriminant analizi daha iyi ve kolay yorumlanabilir sonuçlar verebilmektedir (Çokluk ve diğerleri, 2014; Tabachnick ve Fidell, 2013; Tatlıdil, 2002).

Lojistik regresyonunun en önemli üstünlüğü bağımlı değişkene logit dönüşüm uygulanmasından ileri gelir. Bu sayede, uç değerlerin doğrusal bir eğilim (trend) göstermemesi ve tüm veri boyunca artıkların sabit olmaması ve normal dağılmamasından kaynaklanan sorunlar giderilmiş olur (Peng ve diğerleri, 2002). Analiz yöntemi, yordanan değişkenin kategori sayısına ve kategori çeşidine göre iki kategorili, çok kategorili veya sıralı olarak adlandırılır. Eğer bağımlı değişken iki kategoriden oluşuyorsa *İkili Lojistik Regresyon*, ikiden fazla sınıflamalı kategoriden oluşuyorsa *Çok Kategorili Lojistik Regresyon*, sıralama ölçeği ile elde edilmişse *Sıralı Lojistik Regresyon* olarak adlandırılmaktadır (Çokluk ve diğerleri, 2014).

**Lojistik regresyonun istatistiksel yapısı.** Lojistik regresyon analizi, doğrusal olmayan ilişkileri doğrusal bir denkleme uydurmak yerine Şekil 9'daki örnekte verilen bir lojistik eğri kullanılır.



Şekil 9. Örnek Lojistik Eğri (Dunham, 2003, s. 86)

Bağımlı ve bağımsız değişkenler arasındaki lojit ilişkinin kurulması ile doğrusal olmayan modeller üretilerek ve bu ilişki korunarak logaritmik dönüştürmeler uygulanır (Çokluk ve diğerleri, 2014). Bir lojistik eğri için kullanılan formül denklem 1.14'te verilmiştir. Buna göre,  $Y_i$  iki kategorili bir bağımlı değişken ve  $u$  doğrusal regresyon denklemi olmak üzere,  $i$ . deneğin  $Y$ 'nin kategorilerinden birisinde bulunma olasılığı (Tabachnick ve Fidell, 2013);

$$Y_i = \frac{e^u}{1 + e^u} \quad (1.14)$$

şeklinde ifade edilir.  $A$  sabit,  $B_j$  katsayılar ve  $j=1,2,\dots,k$  için  $X_j$  yordayıcı değişkenler olmak üzere  $u$  doğrusal regresyon denklemi şu şekildedir:

$$u = A + B_1X_1 + B_2X_2 + \dots + B_kX_k \quad (1.15)$$

$Y_i$  belirli bir kategoride bulunma olasılığı iken  $1 - Y_i$  tahmin edilen kategoride bulunmama olasılığını gösterir. Bu iki değer birbirine oranı *odds* değerini verir (Mertler ve Vannatta, 2005). Bu değer doğal logaritması alındığında;

$$\ln\left(\frac{Y_i}{1-Y_i}\right) = A + \sum B_jX_{ij} \quad (1.16)$$

eşitliği elde edilir. Katsayıların kestirilmesinde, doğrusal regresyonda en küçük kareler yöntemi kullanılırken, lojistik regresyonda en çok olabilirlik yöntemi kullanılır. Bu yöntemin kullanılmasının amacı, gözlenen çıktılarının sıklığının olabilirliğini maksimize etmek için iterasyonlar kullanarak yordayıcıların en iyi doğrusal birleşimini bulmaktır (Tabachnick ve Fidell, 2013). Denklem 1.15'deki  $B$  katsayıları standart hale getirilerek ( $\beta$ ) ilişkinin yönü, yordayıcıların denklemdeki ağırlıkları, anlamlılık değerleri ve önem sıraları belirlenir.  $\beta$  katsayısının sıfıra eşit olması yokluk hipotezidir ve bunun reddedilmesi en az bir katsayının sıfıra eşit olduğunu gösterir. Sonuç olarak, yokluk hipotezinin reddedilmesi, lojistik regresyon denkleminin çıktının olasılığını bağımlı değişkenin ortalamasından daha iyi yordadığını gösterir (Peng ve diğerleri, 2002).

Lojistik regresyon analizinde, çoklu regresyonda olduğu gibi en az yordayıcı ile en iyi kestirimde bulunmak amaçlanır. Bunun için sabit ve bağımsız değişkenlerin yer aldığı modeller kurularak karşılaştırılır. Eğer bağımsız değişkenlerin eklendiği modeller, sabit veya diğer modellerden manidar bir farklılık gösteriyorsa modele eklenen değişken ya da değişkenlerin modeli iyileştirdiği söylenebilir. Değişkenlerin



modele eklenme durumuna göre lojistik regresyon modelleri doğrudan (standart, enter), ardışık ve adımsal olmak üzere üçe ayrılır (Tabachnick ve Fidell, 2013). *Doğrudan* modellerde, tüm değişkenler aynı anda modele alınarak her bir yordayıcının modele ne kadar katkı yaptığı değerlendirilir (Field, 2005). *Ardışık* modellerde yordayıcı değişkenlerin modele dahil edilme sürecini kendisi kontrol eder (Tabachnick ve Fidell, 2013). *Adımsal* modeller ise ileriye doğru ve geriye doğru olmak üzere ikiye ayrılır. İleriye doğru modellerde sabit terimden sonra puan istatistikleri anlamlı olan değişkenler önem sırasına göre modele dahil edilirken geriye doğru modellerde sabit ve tüm değişkenler başta modelde iken yine aynı ölçüde göre modelden çıkartılır. Model karşılaştırmalarında durum indeksi ve Wald istatistiği yöntemleri de kullanılmasına karşın genellikle en iyi sonuçlar olabilirlik oran istatistiği ile elde edilebilmektedir (Agresti, 1996; Çokluk ve diğerleri, 2014; Field, 2005).

Tabachnick ve Fidell (2013), lojistik regresyon analizinde, grup üyelikleri veya çıktıların yordanması, yordayıcıların önem sırası, yordayıcılar arasındaki etkileşimler, parametre kestirimleri, durumların sınıflandırılması, ortak değişkenli (covariates) yordamının önemliliği ve etki büyüklüğüne yönelik araştırma sorularının yer aldığını belirtmişlerdir. Analiz sonuçlarının değerlendirilmesinde ise modelin genel değerlendirilmesi, her bir yordayıcı için istatistiksel testler, uyum iyiliği indeksleri ve kestirilen olasılıkların değerlendirilmesi konularından araştırmacıların yeterli bilgi sunmaları gerekmektedir (Peng ve diğerleri, 2002).

***Lojistik regresyon analizinin özellikleri.*** Lojistik regresyon analizi sınıflandırma problemlerine uygulandığında, lojistik model öğrenme verisi kullanılarak eğitilir. Elde edilen regresyon modeli, test verisinin sınıflandırılmasında kullanılır. Bu süreçte lojistik regresyon analizinin diğer kural ve model temelli analiz yöntemlerine göre bir takım üstünlükleri ve sınırlılıklar gözlemlenebilir. Yöntemin genel özelliklerinden bazıları şu şekildedir:

- Kullanışlı olmasından dolayı geniş bir uygulama alanına sahiptir (Cramer, 2002; Dunham, 2003; Nisbet ve diğerleri, 2009).
- Diskriminant analizi ve çoklu regresyona göre değişkenlerin dağılımına yönelik katı varsayımları yoktur (Mertler ve Vannatta, 2005; Tabachnick ve Fidell, 2013).

- Diğer birçok istatistik temelli analiz yöntemlerine göre daha esnek bir yapıdadır (Çokluk ve diğerleri, 2014).
- Bağımlı değişkenin kategorileri ve bağımsız değişkenler için veri matrisi gözlemlerinde yeterli düzeyde gözlem olmasını gerektirmektedir (Çokluk ve diğerleri, 2014; Tabachnick ve Fidell, 2013; Tatlıdil, 2002).
- Regresyon modeli uç değerlere ve çoklu doğrusal bağlantı sorununa oldukça duyarlıdır (Mertler ve Vannatta, 2005; Tabachnick ve Fidell, 2013).
- Bağımlı değişkenin kategorik ya da sınıflandırmalı, bağımsız değişkenlerin ise sadece sayısal formatta (kategorik ya da sürekli) olması yeterlidir (Çokluk ve diğerleri, 2014; Mertler ve Vannatta, 2005).
- Grup üyelikleri, yordayıcıların önem sırası, sınıflandırılma oranları, yordayıcılar arasındaki etkileşimler ve etki büyüklüğü gibi konularda sorulabilecek birçok araştırma problemine yanıt bulunabilir (Tabachnick ve Fidell, 2013).
- Analizi gerçekleştirmeyi sağlayan birçok yazılım (SPSS, SAS, vb.) mevcuttur (Çokluk ve diğerleri, 2014).

## İlgili Araştırmalar

Farklı bilim dallarında veri madenciliği çalışmalarında farklı tekniklerin karşılaştırılması üzerine birçok araştırmaya rastlamak mümkündür. Ancak eğitim alanında daha az çalışma mevcuttur. Bu durum eğitsel verinin kendine özgü yapısıyla yakından ilişkilidir. Çünkü eğitsel veri, gözlemlerin ve gürültülü (noisy) verinin az olması, uç değer ve kayıp değerlerle sıklıkla karşılaşılması, modelin anlaşılabilir olması ve hesaplamada kolaylığın olmasının gerekliliği ve farklı veri yapısının önemi açısından birçok bilimdeki veriden ayrılmaktadır (Hamalainen ve Vinni, 2011). Bu bölümde, öncelikle uluslararası alan yazında veri madenciliği ile ilgili eğitim alanında yapılan çalışmalara, daha sonra ise Türkiye’de yapılan çalışmalara yer verilmiştir.

**Yurtdışında yapılan bazı çalışmalar.** Kotsiantis ve diğerleri (2003) uzaktan eğitim programını yarıda bırakan öğrencileri belirleyebilmek amacıyla veri madenciliği yöntemlerinden karar ağaçları, YSA, Naive Bayes, nesne tabanlı öğrenme algoritmaları, lojistik regresyon ve destek vektör makineleri tekniklerini

karşılaştırmışlardır. 350 öğrenci verisi ile gerçekleştirilen analiz sonuçlarına göre, Naive Bayes ve Geri Yayılımlı YSA algoritmaları diğer yöntemlere göre daha yüksek performans (yaklaşık %80) göstermişlerdir. Naive Bayes algoritması genel olarak diğer tüm yöntemlerden daha iyi sonuçlar vermiştir. Elde edilen bu algoritmanın bir prototipi web tabanlı bir destek aracına dönüştürülerek uzaktan eğitim programını yarıda bırakma ihtimali yüksek olan öğrencileri belirlemek için kullanılabilir hale getirilmiştir.

Minaei-Bidgoli, Kashy, Kortemeyer ve Punch (2003), web tabanlı bir eğitim ortamından alınan veriyle öğrencilerin final notlarının yordamak amacıyla farklı sınıflandırıcılar kullanarak öğrencileri sınıflandırmışlardır. Bağımlı değişkenin 2 sınıftan oluştuğu durumda k- en yakın komşuluk yöntemi %82.3 sınıflandırma oranı ile Bayes (%76.4) ve çok katmanlı algılayıcılara (%79.5) göre daha yüksek performans göstermiştir. 3 sınıf olduğu durumda üç yöntem benzer sonuçlar vermekle birlikte çok katmanlı algılayıcılar (%50.9), k- en yakın komşuluk yöntemi (50.4) ve Bayes (%48.6) performans göstermiştir. Bağımlı değişkenin 9 sınıftan oluştuğu durumda ise çok katmanlı algılayıcılar performans göstermiş; k- en yakın komşuluk yöntemi (28.5) ve Bayes (%23) ile çok düşük performans göstermiştir. Sınıflandırıcıları birleştirerek geliştirilen yeni bir yaklaşım ise her koşulda daha iyi performans göstermiş ve bağımsız değişkenlerin ağırlıklandırılmasına dayanan genetik bir algoritma sınıflandırma performanslarını önemli oranda (%10) yükseltmiştir.

Barker ve diğerleri (2004) yaptıkları çalışmada Oklahoma Üniversitesi öğrenci veri tabanındaki birçok akademik, demografik ve davranışsal değişken ile YSA ve destek vektör makineleri tekniklerini kullanarak öğrencilerin mezun olma durumlarını incelemişlerdir. Ayrıca çalışmada, algoritmaların eğitim setleri 1995, 1996 ve 1997 yıllarına göre değiştiğinde (aynı yıl ya da bir önceki yıl olduğunda) performansları da karşılaştırılmıştır. Buna göre, tüm yılların eğitim ve veri setleri birleştirildiğinde farklı tekniklerin aynı sonuçlar ürettiği görülmüştür. Bir öğretim yılının test verisi için eğitim seti bir önceki yıldan alındığında radyal tabanlı destek vektör makinesi yöntemi daha iyi sonuç vermiştir. Benzer şekilde, her bir yıl için yapılan analizlerde aynı yılın eğitim ve veri setleri kullanıldığında radyal tabanlı destek vektör makinesi yöntemi daha iyi sınıflandırma performansı göstermiştir. Ancak her bir yılın test verileri eğitim seti olarak kullanıldığında YSA yöntemi daha

iyi sonuç vermiştir. Bu sonuçlarla birlikte genel olarak, doğru sınıflandırma oranı 2/3'lük oranla yine düşük denilebilecek seviyededir.

Hamalainen ve Vinni (2006), genellikle küçük örneklemelerden oluşan eğitim verileri üzerinde kullanılabilir uygun bir teknik belirlemek amacıyla 125 ve 88 kişilik iki veri kümesinde doğrusal regresyon, destek vektör makineleri, Naive Bayes ve Bayes ağları modellerini karşılaştırmışlardır. Analize daha fazla değişken eklendiğinde destek vektör makineleri daha iyi performans göstermiştir. Ancak, iki programın birincisi için yapılan analizlerde Naive Bayes başarısız öğrencileri doğru sınıflandırmada daha iyi performans göstermiştir. Bayes yöntemleri karşılaştırıldığında ise birinci programda Bayes ağları çok az iyileştirme gösterse de ikinci programda Naive Bayes daha iyi performans göstermiştir. Sonuç olarak, dikkatli ön bir ön süreç çalışması ve uygun modelleme algoritmasının seçilmesi durumunda en doğru sınıflandırıcının seçilebileceği görülmüştür.

Nghe ve diğerleri (2007), öğrenci performanslarını yordamak amacıyla farklı yapıdaki iki yükseköğrenim kurumu için Bayes ağları ve karar ağaçları yöntemlerinin performanslarını karşılaştırmışlardır. Araştırma sonuçlarına göre iki yöntem de iki kurumda benzer sonuçlar üretmekle birlikte karar ağaçları %3-12 aralığında daha iyi performans göstermiştir. Araştırma sonuçları başarısız öğrencileri belirleyip önlemler almak ve aynı zamanda çok başarılı olanları burslu öğrenim için seçmek açısından önemlidir. Bu araştırma açısından diğer önemli bir sonuç ise yordanan değişkenin 2, 3 ve 4 kategorili olduğu durumlarda veri madenciliği yöntemlerinin karşılaştırılmasıdır. Buna göre, karar ağaçları, bağımlı değişkenin tüm kategorik durumları için Bayes ağlarından daha iyi sonuç üretmiştir. Kategori sayısı arttıkça yöntemlerin performansında düşüş gözlenmiştir.

Romero ve diğerleri (2008) yaptıkları çalışmada, numerik kategorik ve dengelenmiş veride (gruplardaki kişi sayısının dengelenmesi) istatistiksel sınıflandırıcılar, karar ağaçları, kural indüksiyonu, bulanık öğrenme ve sinir ağları yöntemleri altında yer alan 25 algoritmayı karşılaştırmışlardır. Araştırma sonuçlarına göre, numerik veri ile en iyi performans (%65'ten fazla) gösteren yöntemler sinir ağları, karar ağaçları, kural indüksiyonu ve bulanık öğrenme yöntemleridir. Kategorik veri ile en iyi performans (%65'ten fazla) gösteren yöntemler karar ağaçları algoritmalarıdır. Dengelenmiş veride ise en iyi performans (%60'tan fazla) gösteren yöntemler kural indüksiyonu ve bulanık öğrenme algoritmalarıdır.

Performansın %70'i geçmemesinde veri setlerindeki eksik veriden ve kullanılan geometrik ortalamalardan kaynakladığı öne sürülmüştür. Gruplardaki kişi sayılarının dengelenmesinin birçok algorithmada daha iyi sonuçlar elde edilmesini sağladığı görülmüştür. Sonuç olarak, çevrimiçi ortamdan alınan öğrenci verilerini kullanarak öğretmenlerin öğrenciler hakkında önemli kararlar alırken kullanabileceği bir model geliştirilerek bu öğrenme ortamına entegre edilmiştir.

Dekker ve diğerleri (2009), farklı sınıflandırıcıların (karar ağaçları, Bayes sınıflandırıcısı, lojistik regresyon, kural tabanlı öğrenme algoritması ve Random Forest) üniversite birinci sınıf öğrencilerinin okulu bırakma durumlarını ve performansı etkileyen faktörleri belirlemek amacıyla bir durum çalışması yapmışlardır. Çalışma sonuçlarına göre tüm sınıflandırıcılar %78-80 arası performans göstermiştir. Karar ağaçları ve lojistik regresyon en yüksek doğruluk oranına sahip iken Bayes ağları biraz daha düşük performans göstermiştir. Öğrenci danışmanının fikirleri alındığında ve model değerlendirme kriterleri göz önünde bulundurulduğunda yanlış sınıflandırmaların sınıflandırma ölçütünden ve eğitilen modelden kaynaklandığı yorumu yapılmıştır. Öğrencinin okulu bırakma durumunun en güçlü yordayıcısı Lineer Cebir dersi iken, diğer önemli yordayıcıların Calculus, Ağlar ve fen derslerinin ortalama puanı olduğu görülmüştür.

Hamalainen ve Vinni (2011), bazı kriterler açısından eğitimsel verinin analizinde en çok kullanılan yöntemleri karşılaştırmışlardır. Buna göre, küçük örneklemdeki doğrulukları açısından Naive Bayes sınıflandırıcıları etkili iken, İBYSA ve en yakın komşuluk sınıflandırıcıları çok daha büyük örneklem gerektirmektedir. Hatalı veriye dayanıklılık açısından Naive Bayes sınıflandırıcıları, İBYSA ve en yakın komşuluk sınıflandırıcıları; kayıp veriye dayanıklılık açısından ise yine Bayes sınıflandırıcıları ve en yakın komşuluk yöntemleri etkilidir. Naive Bayes, İBYSA ve en yakın komşuluk sınıflandırıcılarının numerik ve kategorik değişkenleri analiz edebildiği ancak İBYSA'nın kategorik verilerde problemlili olduğu görülmüştür. Yapay sinir ağları dışındaki diğer yöntemler anlaşılabilir modeller sunarken, özellikle karar ağaçları ve Bayes sınıflandırıcıları görsel olarak da anlaşılabilir.

Osmanbegović ve Suljić (2012) ders performansının yordamak (geçti, kaldı) amacıyla bazı danışma öğrenme yöntemlerini (Naive Bayes, YSA-Çok katmanlı algılayıcı ve karar ağacı-J48) uygulamış ve bu yöntemleri yordama doğruluğu,

öğrenme kolaylığı ve kullanıcı dostu olma durumuna göre değerlendirmişlerdir. Araştırma sonuçlarına göre, Naive Bayes sınıflandırıcısı %76,65 ile en iyi performans gösterirken, karar ağaçları %73,93 ve yapay sinir ağları yöntemi 71,2 performans göstermiştir. Öğrenme kolaylığı açısından YSA yöntemi az da olsa zaman alırken diğer yöntemler kullanılan değişkenlerle sınırlı olmak şartıyla nerdeyse hiç zaman almamıştır. Çalışmada, iyi bir sınıflandırma modelinin hem yüksek doğruluk hem de anlaşılabilir olması gerektiği gösterilmiştir.

Romero ve diğerleri (2013) yaptıkları çalışmada, üniversite öğrencilerinin final sınav notlarını yordamak amacıyla çevrimiçi öğrenme ortamından elde edilen veri üzerinde farklı istatistiksel sınıflandırıcılar, karar ağaçları, bulanık kural ve kural indüksiyon metotları ve sinir ağlarını karşılaştırmışlardır. 21 farklı algoritmanın performansları incelendiğinde, en iyi performansı (%65 ve üzeri) sinir ağları, karar ağaçları, bulanık kural ve kural indüksiyon metotları göstermiştir. Satırlara göre filtrelenmiş veride en yüksek performansı (%50 ve üzeri) k- en yakın komşuluk ve kural indüksiyonu gösterirken, sütunlara göre filtrelenmiş veride en yüksek performansı (%64 ve üzeri) karar ağaçları ve bulanık öğrenme algoritmaları göstermiştir. Numerik ve kategorik veri için sinir ağları iyi performans (%62-64) gösterirken, k- en yakın komşuluk biraz daha düşük performans (%60) göstermiştir. Bağımlı değişkenin kategorilerindeki birey sayısına göre dengelenmiş veride ise iki yöntem de düşük performans (%37-54) göstermiştir. Farklı koşullar ve veriler için bu değerlerin değişiminden dolayı her durum için bir sınıflandırma yönteminin en iyi olduğunu söylemek doğru değildir. Araştırma sonucunda geliştirilen model bir çevrimiçi öğrenme ortamına entegre edilmiştir.

Shahiri ve diğerleri (2015), öğrenci performansının yordanmasında kullanılan veri madenciliği tekniklerini incelemek amacıyla 2002 ile 2015 yılları arasında uluslararası veri tabanlarında yayınlanan çalışmalarını incelemiştir. Buna göre, en çok kullanılan algoritmalar karar ağaçları, yapay sinir ağları, Naive Bayes, k- en yakın komşuluk ve destek vektör makineleridir. Bu yayınlardan hesaplanan ortalama doğru sınıflandırma oranlarına bakıldığında, %98 yordama doğruluğu olan sinir ağlarını, %91 doğruluk oranı ile karar ağaçları izlemiştir. Bu iki yöntemden sonra %83'lük oran ile destek vektör makineleri ve k- en yakın komşuluk algoritmaları aynı sırada yer almıştır. Naive Bayes ise %76 yordama doğruluğu ile son sırada yer almıştır. Ancak, araştırmacılar, bu doğruluk oranlarının analizlerde

kullanılan deęişkenlerin durumuna ve sayısına göre deęişkenlik gösterdiğini vurgulamışlardır.

**Türkiye’de yapılan bazı çalışmalar.** Tosun (2007) tarafından yapılan çalışmada yapay sinir aęları ve karar aęaçları yöntemlerinin üniversite öğrencilerinin başarı durumlarına göre sınıflandırmadaki performansları karşılaştırılarak öğrencilerin başarısı etkileyen faktörler incelenmiştir. Araştırma sonucuna göre yapay sinir aęları %91,77 doğru sınıflandırma performansı gösterirken, karar aęaçları %86 başarı göstermiştir. Öğrenci başarısını etkileyen faktörlere bakıldığında ise öğrencilerin, sınıfı, derse devam durumu, kaldığı yer, babasının hayatta olma durumu ve babasının eğitim durumu deęişkenlerin etkili olduğu görülmüştür.

Bulut (2010), öğrencilerin gelecekte madde baęımlısı olma riskini yordamak amacıyla veri madencilięi tekniklerini (Karar aęaçları, Naive Bayes ve k- en yakın komşuluk) kullanmıştır. Analiz sonuçlarına göre uzaklık ve baęımsız deęişken aęırlıklandırılmalı k- en yakın komşuluk yöntemi %98,20 performans gösterirken bir karar aęacı algoritması %97,3 performans göstermiştir. k- en yakın komşuluk yönteminde k deęeri 3 ve 10 alındığında sınıflandırma performansı Naive Bayes yöntemine yakın veya daha düşük çıkmıştır.

Tepehan (2011) PISA 2003, 2006 ve 2009 uygulamalarına katılan Türk öğrencilerin başarılarının yordanmasında lojistik regresyon ve yapay sinir aęları yöntemlerinin performanslarını karşılaştırmıştır. Araştırma sonuçlarına göre matematik başarısının yordanmasında yapay sinir aęları %78,6 ve lojistik regresyon %76,8 başarı göstermiştir. Ayrıca, yapay sinir aęları başarılı öğrencilerin doğru sınıflandırılmasında da daha yüksek başarı göstermiştir. Fen bilimleri başarısının yordanmasında yapay sinir aęları %78,5 ve lojistik regresyon %78,1 başarı göstermiştir. Okuma başarısının yordanmasında yapay sinir aęları %79,4 ve lojistik regresyon %78,4 başarı göstermiştir. Ayrıca, yapay sinir aęları başarısız öğrencilerin doğru sınıflandırılmasında da kısmen daha yüksek başarı göstermiştir. Araştırmada YSA’nın en az lojistik regresyon kadar başarılı olduğu görülmüştür.

Çırak (2012), tez çalışmasında üniversitelerde öğrenci başarısının yordanmasında yapay sinir aęları ve lojistik regresyon yöntemlerini karşılaştırmıştır. Araştırma sonuçlarına göre, lojistik regresyon analizinin doğru sınıflandırma

performansı (%66,1), yapay sinir ağlarının performansından (%70,16) düşük çıkmıştır. Yapay sinir ağları analizine göre öğrenci başarısının en önemli yordayıcısı üniversiteye giriş puanı iken lojistik regresyon için mezun olunan lise türüdür.

Göker (2012), yaptığı çalışmada üniversite giriş sınavına giren öğrencilerin başarılarını veri madenciliği yöntemleri ile yordamayı amaçlamıştır. Öncelikle bir veri kümesi üzerine giriş sınavı başarısında etkili olan değişkenler belirlenmiştir. Daha sonra ise alan yazında en çok kullanılan farklı yöntemlerden (Naive Bayes, k- en yakın komşuluk, karar ağaçları, bayes ağları ve sinir ağları) en yüksek doğru sınıflandırma oranına (%87,27) sahip olan Naive Bayes yöntemi yazılım geliştirmek için seçilmiştir. Bu yöntem kullanılarak geliştirilen yazılım sayesinde öğrencilerin ve ailelerinin sınava girmeden önce öğrencilerin başarı durumlarını tahmin etmeleri sağlanmıştır.

Bahadır (2013), yapay sinir ağlarını ve lojistik regresyonu kullanarak öğretmen adaylarının başarılarını tahminleme amaçlanmıştır. Öğrencilerin lisans eğitimi ders başarı durumları, genel not ortalaması, üniversiteye giriş puanı ve kariyer yapmaya ilişkin tutumları yordayıcı değişkenler olarak kullanılmıştır. Araştırma sonuçlarına göre yapay sinir ağları ile yapılan yordamanın lojistik regresyon yöntemi ile yapılan daha iyi olduğu görülmüştür.

Şengür (2013) çalışmasında üniversite öğrencilerinin mezuniyet notlarının yordanmasında yapay sinir ağları ve karar ağaçları yöntemlerinin etkililikleri incelenmiştir. Öğrencilerin 1. ve 2. sınıfta aldığı dersler ile 1., 2. ve 3. sınıfta aldığı dersler iki grup halinde ele alınmış ve her birine iki analiz yöntemi uygulanmıştır. Araştırma sonuçlarına göre YSA, karar ağaçlarına göre daha yüksek doğru sınıflandırma performans göstermiştir. Ayrıca, ilk üç sınıf düzeyindeki derslerin birlikte mezuniyet notlarını daha iyi tahmin ettiği görülmüştür.

Yurdakul ve Topal (2015), ortaöğretim 11. Sınıf öğrencilerine uygulanan bir anketten elde edilen veriyi kullanarak öğrencilerin başarı durumlarına etkileyen faktörlerin saptanması ve bu faktörler kullanılarak veri madenciliği yöntemlerinin (Yapay sinir ağları, k- en yakın komşuluk ve karar ağaçları) karşılaştırılması amaçlanmıştır. Araştırma sonuçlarına göre yapay sinir ağları %88,73'lük, k- en yakın komşuluk %85,9'luk ve Naive Bayes yöntemi %81,69'luk doğru sınıflandırma performansı göstermiştir. Ailenin eğitim düzeyi ve ekonomik durumun en önemli



yordayıcılar olduğu, ders dışı etkinliklere katılma durumu, uygun çalışma ortamı olup olmaması ve aile-öğretmen iletişiminin diğer önemli faktörler olduğu görülmüştür.

Tezbaşaran (2016), geliştirilen bir ölçeğin yapı geçerliğine ilişkin kanıt sağlamak amacıyla sıkça kullanılan temel bileşenler analizi (TBA) yerine yapay sinir ağlarının kullanılabilirliğini incelemiştir. Öğretmenlere Yönelik Tutum Ölçeği geliştirilerek TBA ve YSA modelleri ile ölçek yapıları incelenmiştir. Genelleştirilmiş Hebb algoritması ve TBA ile elde edilen yapılar doğrulayıcı faktör analizi ile incelendiğinde iki yapının oldukça benzer olduğu, hata ve uyum indekslerinin birbirine çok yakın olduğu görülmüştür. Döndürme sonrasında elde edilen yapı ile kendini düzenleyen haritalamadan elde edilen yapılar karşılaştırıldığında ise yapıların birbirinden farklı olduğu ancak kendi içlerinde uyum gösterdikleri görülmüştür.

**İlgili araştırmalar özet.** İlgili araştırmalar birlikte değerlendirildiğinde bu çalışmada kullanılan yapay sinir ağları, Naive Bayes, k- en yakın komşuluk ve lojistik regresyon yöntemlerin yordama amaçlı kullanılmasında eğitimsel açıdan önemli sonuçları olduğu görülmektedir. Eğitim alanında tüm yöntemlerin birlikte değerlendirildiği sınırlı sayıda çalışma olmak birlikte, bu yöntemlerin performansını önemli ölçüde etkileyen örneklem büyüklüğü ve test verisi oranı gibi faktörleri birlikte inceleyen bir çalışmaya rastlanmamıştır. Bu yüzden, öğrencilerin matematik performanslarına göre sınıflandırılmasında kullanılacak yapay sinir ağları, Naive Bayes, k- en yakın komşuluk ve lojistik regresyon yöntemlerinin örneklem büyüklüğü ve test verisi oranının açısından farklı veri kümeleri üzerinde karşılaştırılması planlanmıştır. Bu çalışma ile farklı koşullarda farklı yöntemlerin performansını belirlemek amacıyla kapsamlı bir inceleme yapılacaktır.

## **Bölüm 3**

### **Yöntem**

Bu bölümde, araştırmanın türü, evren ve örneklem, verilerin toplanması ve analizine yönelik bilgilere yer verilmiştir.

Bu araştırma ile aynı amaç için kullanılan yapay sinir ağları, Naive Bayes, k-en yakın komşuluk ve lojistik regresyon yöntemlerini örneklem büyüklüğü ve test verisi oranı açısından karşılaştırılarak farklı analiz yöntemleri için en iyi koşulları belirlemek ve bunları olduğu gibi tasvir etmek amaçlandığından bir tarama (betimsel) araştırmasıdır. Tarama araştırmalarında, geniş bir kitleyi en iyi temsil eden uygun bir örneklemin (kişilerin) belirli bir konuyla ilgili görüşlerini ya da özelliklerini betimlemek amaçlanır (Büyüköztürk, Çakmak-Kılıç, Akgün, Karadeniz ve Demirel, 2013). Bu araştırmalarda, görüşlerin veya özelliklerin nedenlerinden çok örneklemdaki bireylere nasıl dağıldığı incelenir (Frankel ve Wallen, 2011). Araştırma, aynı zamanda, yöntemler arasındaki ilişkileri incelemesi açısından ilişkisel; yöntemleri karşılaştırması açısından kuramsal bir yapıdadır.

#### **Araştırmanın Evreni ve Örneklemi**

Araştırmanın evreni, PISA uygulamasına katılan OECD ülkelerindeki 15 yaş grubundaki öğrencilerdir. Her bir ülke için evreni temsil eden örneklem PISA uygulayıcıları tarafından tabakalı tesadüfi örnekleme yoluyla seçilmiştir. OECD ülkelerinden PISA uygulamasına katılan toplam kişi sayısı 295416 kişidir. Bu çalışmada, kayıp veriler, artık ve uç değerler incelenip çıkartıldıktan sonra 62728 kişilik hedef evrene ulaşılmıştır. Tablo 1'de hedef evrende yer alan öğrencilerin OECD ülkelerine göre dağılımları verilmiştir.

Tablo 1

*Hedef Evrenin Ülkelere Göre Dağılımı*

Ülke	Sayı	%	Ülke	Sayı	%	Ülke	Sayı	%
Avustralya	2982	4.75	Finlandiya	2001	3.19	Meksika	6062	9.66
Avusturya	976	1.56	Fransa	993	1.58	Hollanda	1054	1.68
Belçika	1754	2.80	Birleşik Krallık	2647	4.22	Norveç	1032	1.65
Kanada	4910	7.83	Yunanistan	1190	1.90	Yeni Zelanda	852	1.36
İsviçre	2558	4.08	Macaristan	1088	1.73	Polonya	1010	1.61
Şili	1480	2.36	İrlanda	1237	1.97	Portekiz	1210	1.93
Çek Cumhuriyeti	1339	2.13	İzlanda	780	1.24	Slovakya	1072	1.71
Almanya	833	1.33	İtalya	7479	11.92	Slovenya	1269	2.02
Danimarka	1614	2.57	Japonya	1512	2.41	İsveç	977	1.56
İspanya	5502	8.77	Kore	1242	1.98	Türkiye	834	1.33
Estonya	1140	1.82	Lüksemburg	1017	1.62	ABD	1082	1.72
Genel Toplam	62728	100.0						

Veri madenciliğinde, analizlerde kullanılacak örneklem 1000 kişi olduğundan orta, bu değerden az kişi olduğunda küçük ve 1000 kişiden çok daha fazla olduğunda büyük örneklem olarak ifade edilmektedir (Michie ve diğerleri, 1994). Analizlerde en uygun ve karşılaştırılabilir sonuçlar elde etmek amacıyla Efron (1983) tarafından önerilen önyükleme (bootstrapping) metodu kullanılmıştır. Buna göre, araştırmanın örneklemini hedef evrenden yerine koyma işlemi ile rastgele örnekleme yöntemi kullanılarak seçilen 500 (küçük), 1000 (orta) ve 5000 kişilik (büyük) örneklemelerdir. Araştırmada, incelenen yöntemlerin performanslarına yönelik yüksek kesinlikte sonuçlar elde etmek amacıyla;

- 500 kişilik örneklem için 100 veri dosyası
- 1000 kişilik örneklem için 50 veri dosyası
- 5000 kişilik örneklem için 30 veri dosyası olmak üzere toplam 180 veri dosyası oluşturulmuştur.

Örneklem küçüldükçe tüm veriden daha fazla sayıda veri dosyasının çekilmesinin nedeni, küçük örneklemelerin hedef evreni temsil edilebilirliği artırarak yanlış veya hatalı genellemelerin önüne geçmektedir.

### Veri Toplama Süreci

PISA (2012) araştırmasında, kağıt-temelli testler için iki saat, bazı ülkelerde (32 ülke) ise bilgisayar-temelli testler için ek 40 dakika süre tanınmıştır. Farklı öğrencilerin test maddelerinin farklı kombinasyonlarını almaları ile tüm test

maddeleri toplam 390 dakikalık süreyi kapsamaktadır. Uygulamada, test maddeleri toplam 13 kitapçıya ayrılarak her bir ülkede öğrencilerin sosyo-ekonomik düzey ve cinsiyet gibi değişkenlerin her bir kategorisinde anlamlı çıkarımlar ve genellemeler yapılabilmesini sağlayacak sayıda öğrenciye uygulanmıştır. 44 ülkede uygulanan problem çözme testi için her biri 20 dakikalık süreyi kapsayan 4 küme şeklinde uygulanmıştır. Öğrenci anketi için tanınan süre 30 dakikadır. Bazı ülkeler opsiyonel olarak öğrencileri için iki anket daha seçebilmişlerdir (OECD, 2014a). Bu çalışmada, PISA uygulayıcıları tarafından takip edilen süreçler sonucunda elde edilen veri OECD'nin herkese açık veri tabanından alınarak kullanılmıştır.

### **Veri Toplama Araçları**

Araştırmanın veri toplama araçları, PISA (2012) uygulamasında öğrencilerin matematik alanındaki akademik performanslarını ölçmek amacıyla geliştirilen matematik bilişsel testi ve öğrenciyi var olan tüm özellikleri ile değerlendirmeyi amacıyla hazırlanan öğrenci anketidir. Matematik bilişsel testi, değişim ve ilişkiler, nicelikler, uzaklıklar ve şekiller, belirsizlik ve veri, görevler, formüle etme ve yorumlama alt alanlarından oluşmaktadır. Test maddeleri öğrencilerin kendi cevaplarını oluşturduğu ve çoktan seçmeli maddelerin karışımından oluşmaktadır. Maddeler, gerçek yaşam durumunu ifade eden metin paçalarına dayanan gruplar şeklinde organize edilmiştir. Öğrenci anketinde ise öğrencilerin evleri, okulları, kendileri ve öğrenme deneyimleri hakkında çeşitli bilgileri içeren formları doldurmaları beklenmiştir. Öğrenci anketinin yanında bazı ülkelerin opsiyonel olarak öğrencileri için seçtiği anketlerden biri öğrencilerin bilgi ve iletişim teknolojilerine olan aşinalığı, diğeri ise eğitimleri süresince ara verme durumları ve gelecekleri için bir kariyer hazırlığında olup olmadıklarını sorgulayan eğitim süreçleri ile ilgilidir. Öğrenci anketi, üç formdan oluşmaktadır. İki form 53 maddeden oluşurken diğeri 54 maddeden oluşmaktadır. PISA uygulamasında kullanılan bu formlardan her bir öğrencileri üçte biri tarafından yanıtlanırken, formlardaki ortak maddelerin yanı sıra iki formu cevaplayan öğrenciler de bulunmaktadır (OECD, 2014a).

## Verilerin Analizi

**Verilerin işlenmesi ve çözümlenmesi. Değişken çıkartma ve veri temizleme.** Öncelikle, PISA (2012) öğrenci anketinden elde edilen veriden öğrencilerin demografik bilgileri ve matematiğe ilişkin tüm değişkenleri alınmıştır. Daha sonra OECD (2014b) tarafından yayınlanan PISA 2012 teknik raporu göz önünde bulundurularak diğer değişkenlerin bileşiminden oluşan değişkenler alınmış ve kalan değişkenler dosyadan çıkartılmıştır. Bu şekilde elde edilen veri üzerinde, matematik kaygısı ve öz-yeterliği gibi temel duyuşsal değişkenlere ilişkin kayıp veri içeren tüm bireyler veriden çıkartılmıştır. Böylece, okul dışı alınan matematik dersleri, sınıf büyüklüğü, okulda temel ve uygulamalı matematikle ilgili deneyim, matematik kavramlarına aşinalık, haftalık matematiğe ayrılan zaman ve okul dışı çalışma süresi değişkenleri tamamen kayıp veriden oluşmuştur. Bölge değişkeni ise her ülkede benzer şekilde yorumlanmamış ve bazı ülkelerde okul türü de bir katman olarak eklenmiştir. Bu durumda tüm veriden belirli bir örneklem seçildiğinde bu bağımsız değişkenin bazı hücreleri boş kalmakta ve bu durum özellikle lojistik regresyon analizi için sorun oluşturmaktadır. Benzer bir durum test dili değişkeni için de geçerlidir. Bu nedenlerle, sözü edilen tüm değişkenler analizden çıkartılıp dosyadaki tüm kayıp veriler ve uç değerler silindiğinde matematik performansı ile birlikte 35 değişken ve 62728 kişiden oluşan hedef evren elde edilmiştir. Bu değişkenler Tablo 2'de verilmiştir.

**Değişken seçme.** Veri madenciliği yöntemleri çok fazla değişkenle çalışmakla birlikte, sınıflandırmaya katkısı olmayan değişkenlerin analizde bulundurulması yapılacak analizlerin çok zaman almasına ve sınıflandırma performansının düşmesine neden olmaktadır. Bu amaçla, bir veri ön işleme süreci olan değişken seçme veri madenciliğinde sıkça kullanılan önemli tekniklerden biridir (Blum ve Langley, 1997; Liu ve Motoda, 2001). Farklı değerlendirme ölçütlerine göre tasarlanan değişken seçme yöntemleri genellikle filtreleme, sargı modeli ve melez modeller olarak üçe ayrılır (Liu ve Yu, 2005). Filtreleme modelleri dışındaki modeller bir analiz yönteminin de kullanılmasını gerektirmektedir. Bu araştırmada, karşılaştırılacak analiz yöntemleri farklılaştığından bir analiz yöntemi gerektirmeden değişkenleri bilgi kazanımına göre sıralama imkanı veren filtreleme metodu kullanılmıştır. Filtreleme metodu, herhangi bir veri madenciliği yöntemini sürece

dahil etmeden verinin genel karakteristiğine dayanarak değişken alt kümesini seçmeyi ve değerlendirmeyi amaçlar (Liu ve Yu, 2005).

Bu çalışmada, WEKA Version 3.9.0 yazılımında yer alan Bilgi Kazanımı Sıralama Filtresi (Information Gain Ranking Filter), Kay-kare Sıralama Filtresi (Chi-squared Ranking Filter), Oran Kazanımı Değişken Değerlendiricisi (Gain Ratio Feature Evaluator) ve Simetrik Belirsizlik Sıralama Filtresi (Symmetrical Uncertainty Ranking Filter) metotları kullanılmıştır. Bilgi kazanımı sıralama filtresi sınıflara göre elde edilen bilgiyi ölçerek, Kay-kare sıralama filtresi sınıfa göre Kay-kare değerini hesaplayarak, oran kazanımı değişken değerlendiricisi sınıfa göre elde edilen oranları ölçerek, simetrik belirsizlik sıralama filtresi ise sınıfa göre simetrik belirsizliği ölçerek bir özelliğin önem sırasını değerlendirir (Frank, Hall ve Witten, 2016).

Araştırmada, değişken seçme işlemi hedef evren (N=62728) üzerinden yapılmıştır. PISA (2012) uygulamasında öğrencilerin matematik performanslarına karşılık gelen 5 tane makul (plausible) değer bulunmaktadır. Ancak, Wu (2005) tarafından yapılan benzetim çalışmasında makul değerlerden herhangi birini tek başına kullanılmasının evren parametrelerinin yüksek oranda doğrulukla kestiriminde yeterli olduğu görülmüştür. Bu nedenle, birinci makul değer olan PV1MATH (Plausible Value 1) değişkeni, PISA uygulayıcıları tarafından belirlenen ve öğrencilerin matematikte yeterliğini temsil eden altı düzeyden (OECD, 2014a, s.61) orta düzeyin altında ve üstünde yer alan öğrenciler şeklinde iki kategorili bir değişkene dönüştürülmüştür.

Buna göre, öğrencileri matematik performansına göre alt ve üst kategorilere ayırmak amacıyla dördüncü düzeyin alt sınırı (545) kesme noktası olarak alınmıştır. Daha sonra analizlere geçilerek öğrencilerin matematik performanslarına göre sınıflandırmaya en çok katkısı olan değişkenler seçilmiştir. Tablo 2'de bu değişkenlerin neler olduğu ve sınıflandırmaya yaptıkları katkı miktarları verilmiştir.

Tablo 2

*Değişkenlerin Yöntemlere Göre Sınıflandırmaya Katkı Düzeyleri*

Değişkenler	Bilgi Kazanımı Sıralama Filtresi	Kay-kare Sıralama Filtresi	Oran Kazanımı Değişken Değerlendiricisi	Simetrik Belirsizlik Sıralama Filtresi
1. Matematik öz-yeterliği	0.152298	12489.8825	0.040678	0.065162
2. Matematiksel benlik algısı	0.084427	7239.9284	0.024719	0.038853
3. Matematik kaygısı	0.081324	6994.9327	0.02464	0.038442
4. Ekonomik, sosyal ve kültürel statü indeksi	0.070021	5623.0732	0.02169	0.033674
5. Problem çözmeye açık olma	0.055397	4633.9136	0.016801	0.026207
6. Ülke	0.053061	4082.1813	0.0114	0.019001
7. Baba eğitim düzeyi (ISCED)	0.039784	3288.2084	0.01597	0.023254
8. Anne eğitim düzeyi (ISCED)	0.03904	3155.0297	0.015801	0.022957
9. Öğretmen davranışı: Öğrenciyi yönlendirme	0.021981	1780.1121	0.007309	0.011164
10. Hesap makinesi kullanımı	0.016716	1406.1006	0.010028	0.012871
11. Problem çözme azmi	0.016916	1452.2136	0.006676	0.009766
12. Matematiksel eğilimler	0.016053	1377.2062	0.00639	0.009326
13. Matematik ilgisi	0.013953	1183.4424	0.005744	0.008307
14. Disiplin ortamı	0.013756	1196.4859	0.005074	0.007555
15. Matematiksel davranışlar	0.011713	950.306	0.006036	0.008159
16. Matematikte başarısız olma nedenleri	0.011523	963.4023	0.005026	0.00715
17. Anne çalışma durumu	0.01059	888.1062	0.006306	0.008115
18. Baba çalışma durumu	0.008674	712.5957	0.008876	0.009093
19. Matematikte araçsal güdüleme	0.007619	659.3653	0.003495	0.004899
20. Cinsiyet	0.007357	639.5215	0.007369	0.007628
21. Öğretmen davranışı: Öğretmen yönlendirmeli eğitim	0.003332	273.2079	0.00206	0.002615
22. Öğretmen davranışı: Biçimlendirici değerlendirme	0.003302	280.7671	0.002023	0.002577
23. Matematikte öznel normlar	0.002856	232.26	0.002921	0.002993
24. Matematik çalışma disiplini	0.002825	243.5875	0.001744	0.002215
25. Matematik öğretmenin sınıf yönetimi	0.002255	195.978	0.001437	0.001805
26. Öğretmen öğrenci ilişkileri	0.002239	190.343	0.001041	0.001453
27. Aile yapısı	0.002238	174.3219	0.003996	0.003003
28. Matematik derslerindeki bilişsel aktivasyon	0.001284	110.9374	0.001385	0.001383
29. Öğretmen desteği	0.001201	103.0498	0.001008	0.001132
30. Matematik öğretmenin desteği	0.001027	88.3346	0.000795	0.000924
31. Okula karşı tutum: Öğrenme Çıktıları	0.000744	64.8387	0.000577	0.000824
32. Okula karşı tutum: Öğrenme Etkinlikleri	0.000741	63.9566	0.000853	0.00067
33. Okula ait olma duygusu	0.000614	53.2737	0.000524	0.000584
34. Seviye (ISCED)	0.000443	35.5794	0.000454	0.000464

Tablo 2’de verilen tüm değişkenlerden sınıflandırmaya en çok katkı sağlayan ilk 10 değişken çalışmaya dâhil edilmiştir. Bu değişkenler, matematik öz-yeterliği, matematiksel benlik algısı, matematik kaygısı, ekonomik, sosyal ve kültürel statü indeksi, problem çözmeye açık olma, ülke, babanın eğitim düzeyi (ISCED), anne eğitim düzeyi (ISCED), öğretmen davranışı: öğrenciyi yönlendirme ve hesap

makinesi kullanımınıdır. Bu çalışmada, tüm analizler bu değişkenler kullanılarak gerçekleştirilecektir.

**Değişkenlere yönelik betimsel istatistikler.** Öğrencilerin matematik performanslarına göre sınıflandırılmasında en etkili olan değişkenlerin dağılımlarına ait tanımlayıcı istatistikler ve değişkenler arası ilişkilerin bilinmesi kullanılacak olan verinin analizlere uygun olup olmadığını görmek ve analiz sonuçlarını değişkenlerin var olan durumu çerçevesinde değerlendirmek açısından önemlidir. Bu amaçla, Tablo 3'te analizlerde kullanılan sürekli değişkenlere ilişkin betimsel istatistikler verilmiştir.

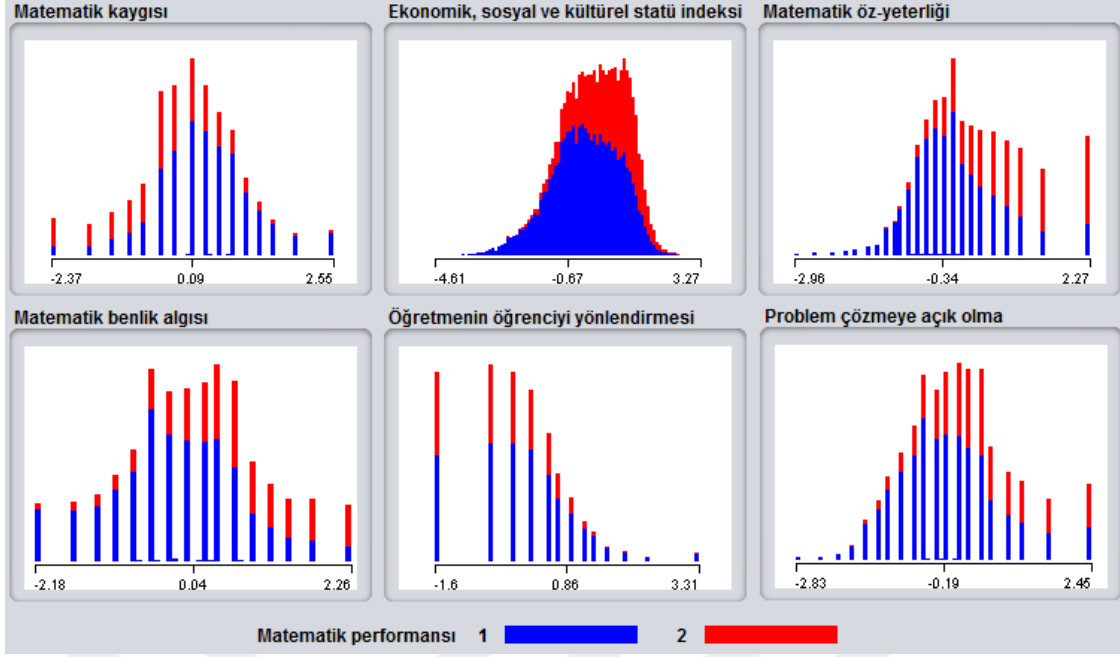
Tablo 3

*Sürekli Değişkenlere İlişkin Betimsel İstatistikler*

	N	Ranj	Minimum	Maksimum	Ortalama	Standart Sapma	Çarpıklık Değer SH	Basıklık Değer SH
Matematik kaygısı	62728	4.92	-2.37	2.55	0.100	0.89	-0.188 0.010	0.875 0.020
Ekonomik. sosyal ve kültürel statü indeksi	62728	7.88	-4.61	3.27	0.063	1.01	-0.450 0.010	-0.074 0.020
Matematik öz-yeterliği	62728	5.23	-2.96	2.27	0.065	0.90	0.668 0.010	0.414 0.020
Problem çözmeye açık olma	62728	5.27	-2.83	2.45	0.001	0.91	0.518 0.010	0.637 0.020
Matematik benlik algısı	62728	4.44	-2.18	2.26	0.048	0.95	-0.013 0.010	0.062 0.020
Öğretmenin Öğrenciyi yönlendirmesi	62728	4.91	-1.60	3.31	-0.028	0.94	0.075 0.010	0.376 0.020
Toplam	62728							

Tablo 3'e göre, değişkenlerin çarpıklık ve basıklık değerleri [-1:1] aralığındadır. Bu değerlerin [-1:1] aralığında olması dağılımın normale yakın olduğunu gösterir (Çokluk ve diğerleri, 2014). Ayrıca, küçük örneklerde anlamlılık testlerinin manidar olmaması, büyük örneklerde ise dağılım grafiğinin normalden önemli sapma göstermemesi gerekir (Tabachnick ve Fidell, 2012). Araştırmada kullanılan örneklem geniş olduğundan Şekil 10'da verilen değişkenlerin matematik performansının kategori durumuna göre grafiksel gösteriminin incelenmesi normallik için fikir verecektir.





Şekil 10. Araştırmada Kullanılan Sürekli Değişkenlerin Bağımlı Değişkene Göre Dağılımları

Şekil 10 incelendiğinde matematik öz-yeterliği ve öğretmenin öğrenciyi yönlendirmesi değişkenleri normalden az da olsa sapma göstermektedir. Ancak, genel olarak değişkenlerin normalden önemli sapma göstermediği görülmektedir. Sürekli değişkenlerin dağılımları incelendikten sonra kategorik değişkenlere geçilmiştir. Ülke değişkenine ait frekans dağılımları araştırmanın katılımcılar bölümünde verildiğinden burada tekrar verilmemiştir. Bu kısımda annenin ve babanın eğitim düzeyleri ile hesap makinesi kullanımı değişkenlerine yönelik betimsel istatistikler verilmiştir. Tablo 4'te öğrencilerin anne ve babalarının ISCED eğitim düzeyleri matematik performansına göre alt ve üst gruptaki dağılımları yer almaktadır.

Tablo 4

*Annesinin ve Babasının Eğitim Düzeyi (ISCED)*

	Anne						Baba					
	Alt		Üst		Toplam		Alt		Üst		Toplam	
	N	%	N	%	%	N	N	%	N	%	N	%
Hiçbiri	1156	2.8	83	0.4	1239	2.0	1101	2.7	83	0.4	1184	1.9
ISCED 1	2555	6.2	395	1.8	2950	4.7	2766	6.7	491	2.3	3257	5.2
ISCED 2	6875	16.8	1719	7.9	8594	13.7	7451	18.2	2069	9.5	9520	15.2
ISCED 3B. C	3755	9.2	1890	8.7	5645	9.0	4288	10.5	2101	9.7	6389	10.2
ISCED 3A. ISCED 4	11441	27.9	5947	27.4	17388	27.7	11088	27.0	5541	25.5	16629	26.5
ISCED 5B	6460	15.7	3595	16.6	10055	16.0	5647	13.8	2997	13.8	8644	13.8
ISCED 5A. 6	8778	21.4	8079	37.2	16587	26.9	8679	21.2	8426	38.8	17105	27.3
Toplam	41020	100.0	21708	100.0	62728	100.0	41020	100.0	21708	100.0	62728	100.0

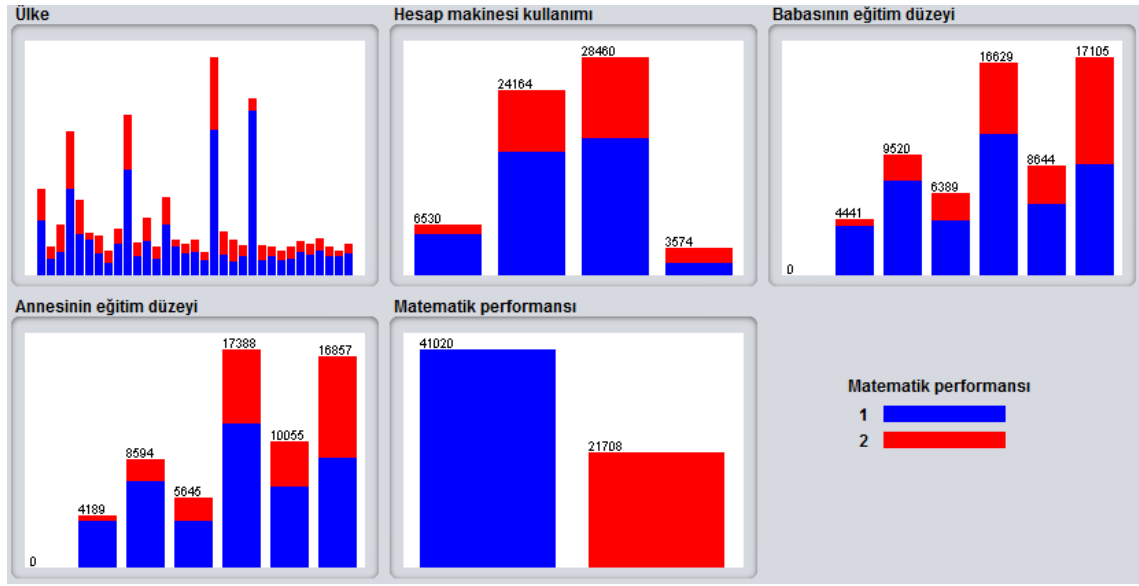
Tablo 4 incelendiğinde, anne ve babalarının ISCED düzeylerinin hiçbirinde yer almadığı ve Düzey 1’de yer aldığı çok az öğrenci yer almaktadır. Bu nedenle, sınıflandırma yöntemlerinin model hatalarına yol açabilecek bu durumu ortadan kaldırmak amacıyla bu düzeyler ISCED 1 ve altı olacak şekilde tek bir düzeye indirgenmiştir. Benzer durum, Tablo 5’te hesap makinesi kullanımı değişkeni için de geçerlidir.

Tablo 5

*Hesap Makinesi Kullanımı*

	Alt		Üst		Toplam	
	N	%	N	%	N	%
Kullanmıyor	5322	13.0	1208	5.6	6530	10.4
Basit	16038	39.1	8126	37.4	24164	38.5
Bilimsel	17972	43.8	10488	48.3	28460	45.4
Grafik	1209	2.9	1551	7.2	2760	4.4
BCS	479	1.2	335	1.5	814	1.3
Toplam	41020	100.0	21708	100.0	62728	100.0

Tablo 5 incelendiğinde, Grafik ile Bilgisayar Cebir Sistemleri (BCS) hesap makinelerini kullanan çok az öğrenci bulunmaktadır. Model hatalarının önüne geçmek amacıyla bu iki kategori birleştirilerek Grafik ve CBS hesap makinelerinin kullananlar şeklinde yeni bir kategori oluşturulmuştur. Son durumda, araştırmada kullanılan kategorik değişkenlere ait çubuk grafikleri matematik performansına göre Şekil 11’de verilmiştir.



Şekil 11. Araştırmada Kullanılan Kategorik Değişkenlerin Bağımlı Değişkene Göre Dağılımları

Şekil 11'e göre matematik performansının her bir kategorisi, kategorik değişkenlerin her bir düzeyine yaklaşık olarak dengeli bir dağılım göstermektedir. Benzer şekilde, matematik performansının kategorilerine düşen birey sayılarının eşit olmamasına karşın neredeyse dengeli bir dağılım gösterdiği görülmektedir. Branco, Torgo ve Ribeiro (2015) yaptıkları çalışmada dengesiz dağılımın önüne geçmek amacıyla alınabilecek önlemleri, analiz yönteminde modifikasyonlar yapma, analizlere başlamadan önce verinin yapısında değişikliklerin yapma veya öğrenme modellerinin tahmin değerlerine dönüşümler uygulanma şeklinde sınıflamışlardır. Araştırmada kullanılan veri düşük düzeyde dengesizlik gösterdiğinden değerlendirme ölçüt değerlerine dönüşümlerin uygulanması etkili bir çözüm olacaktır. Bu amaçla, model performans değerlendirme ölçütü olarak doğruluk oranlarının yanında, F-ölçütü (Rijsbergen, 1979), geometrik ortalama (Kubat, Holte, Matwin, 1998), alıcı işletim karakteristik (ROC ) eğrisi (Egan, 1975) veya Kappa uyum istatistiğinin (Cohen, 1960) kullanılması önerilmektedir (Branco, Torgo ve Ribeiro, 2015). Bu çalışmada, dengesiz dağılımdan gelen hataların önünde geçebilmek amacıyla model performans değerlendirme ölçütleri olarak doğruluk oranları, doğruluk oranlarının önyükleme standart sapmaları, Kappa uyum değerleri ve ROC eğrisinin altın kalan alan değerleri kullanılmıştır. Böylece, hata matrisi değerlerine yapılan dönüşümler sonucunda analiz sonuçlarının geçerliğine yönelik elde edilen farklı kanıtlar bir arada sunulmuştur.

**Varsayımların incelenmesi.** Araştırmada kullanılacak değişkenlere karar verildikten sonra analizlerin varsayımları kontrol edilmiştir. Lojistik regresyon analizi, bağımsız değişkenlerin dağılımına ilişkin herhangi bir varsayım gerektirmemekle birlikte bazı varsayımları, birey sayısının değişken sayısına oranı beklenen sıklıkların uygunluğu, sürekli değişkenler arasında orta düzeyde doğrusal ilişki, kayıp ve uç değerlerin olmaması ile model uyum değerlerinin yeterli düzeyde olmasıdır (Tabachnick ve Fidell, 2013). Naive Bayes algoritması tüm bağımsız değişkenlerin birbirinden koşullu bağımsızlığını temel almasına rağmen bu varsayım nadiren sağlanır ancak bu algoritma yine de iyi sonuçlar vermektedir (Hamalainen ve Vinni, 2011). KNN algoritmasında uygun k değeri ve d uzaklık ölçütü seçilmesi önemli gerekliliklerdir (Larose, 2004). YSA'da ise yeteri kadar numerik veri olduğunda ve model iyi eğitildiğinde eğitimsel veride iyi sonuçlar elde edilmektedir (Hamalainen ve Vinni, 2011). Bu kısımda, tek ve çok değişkenli analizlerin varsayımları incelenerek analizlerin yapıldığı koşulların saptanması amaçlanmıştır.

Katılımcılar kısmında belirtildiği gibi bu çalışmada tüm kayıp veriler analizlerden çıkartılarak tüm yöntemler için standart bir ön koşul sağlanmıştır. Daha sonra ise tüm uç değerler analiz dışı bırakılmıştır. Sürekli değişkenlerin bağımlı değişkenin kategorilerine normal dağılıp dağılmadığına yönelik çarpıklık ve basıklık değerleri Tablo 6'da verilmiştir.

Tablo 6

*Sürekli Değişkenlerin Kategorilere Dağılımları*

	Matematik Performansı	Çarpıklık		Basıklık	
		Değer	SH	Değer	SH
Matematik kaygısı	Alt	0.090	0.012	1.121	0.024
	Üst	-0.278	0.017	0.433	0.033
Ekonomik. sosyal ve kültürel statü indeksi	Alt	-0.334	0.012	-0.142	0.024
	Üst	-0.490	0.017	-0.136	0.033
Matematik öz-yeterliği	Alt	0.785	0.012	1.722	0.024
	Üst	0.415	0.017	-0.568	0.033
Problem çözmeye açık olma	Alt	0.558	0.012	0.946	0.024
	Üst	0.513	0.017	0.373	0.033
Matematik benlik algısı	Alt	-0.045	0.012	0.187	0.024
	Üst	-0.098	0.017	0.028	0.033
Öğretmenin öğrenciyi yönlendirmesi	Alt	0.086	0.012	0.515	0.024
	Üst	-0.067	0.017	-0.140	0.033

Tablo 6 ve sürekli değişkenlerin matematik performansının kategorilerine göre dağılımlarını gösteren Şekil 10 bir arada incelendiğinde, matematik kaygısı ve matematik öz-yeterliği değişkenlerinin basıklık değerlerinin [-1.1] aralığının dışında olduğu görülmektedir. Bu iki değişken biraz basık olmasına rağmen Şekil 10 incelendiğinde tüm sürekli değişkenlerin normalden önemli sapmalar göstermediği görülmektedir.

Sürekli değişkenlerin bağımlı değişkenin kategorilerine göre varyanslarının homojen olup olmadığı Levene testi ile incelenmiş ve sonuçlar Tablo 7’de verilmiştir.

Tablo 7

*Varyansların Homojenliği Testi Sonuçları*

	Levene İstatistiği	p
Matematik kaygısı	220.689	0.000
Ekonomik. sosyal ve kültürel statü indeksi	880.125	0.000
Matematik öz-yeterliği	1430.208	0.000
Problem çözmeye açık olma	10.054	0.002
Matematik benlik algısı	7.568	0.006
Öğretmenin öğrenciyi yönlendirmesi	35.124	0.000

Tablo 7’ye göre varyansların homojenliği varsayımı sağlanamamıştır ( $p < 0.05$ ). Levene testi çok katı olduğundan ve geniş örneklerde anlamlı istatistikler verme eğiliminde olduğundan bu sonucun çıkması beklenen bir

durumdur. Bu testin çok deęişkenli eş deęeri olan varyans-kovaryans matrislerinin homojenliğini Box's M testi sonuçları Tablo 8'de verilmiştir.

Tablo 8

*Box's M Kovaryans Matrislerinin Homojenliği Testi*

Box's M	3540.039
F	168.554
sd1	21
sd2	7476037696.653
<i>p</i>	0.000

Tablo 8 incelendiğinde varyansların homojenliği varsayımının sağlanamamasının doğal bir sonucu olarak kovaryans matrislerinin eşitliği varsayımının da sağlanmadığı görülmüştür. Bu araştırmada kullanılan analiz yöntemleri, bu varsayımın sağlanmasını gerektirmediğinden analiz sonuçları homojenlik varsayımının sağlanmadığı düşünülerek yorumlanmıştır.

Tek ve çok deęişkenli istatistikler için öngörülen bir diğer varsayım olan, tüm deęişkenler arası ikili ilişkiler ve çoklu bağlantı varsayımlarının sağlanıp sağlanmadığı incelenmiştir. Sürekli deęişkenler arasındaki ilişki Pearson, kategorik deęişkenler arasındaki ilişki Bağımlılık (Contingency C) ve sürekli ile kategorik deęişkenler arasındaki ilişki Eta katsayıları hesaplanarak incelenmiştir. Tablo 9'da elde edilen katsayı deęerleri anlamlılık deęerleri ile birlikte verilmiştir.

Tablo 9

## Değişkenler Arası Korelasyon Katsayıları

	Ekonomik. sosyal ve kültürel statü indeksi	Matematik Öz-yeterliği	Problem çözmeye açık olma	Matematik benlik algısı	Öğretmenin öğrenciyi yönlendirmesi	Hesap makinesi kullanımı	Babasının eğitim düzeyi	Annesinin eğitim düzeyi	Ülke
Matematik kaygısı	-0.156*	-0.370*	-0.285*	-0.637*	0.032*	0.062	0.122	0.127	0.247
Ekonomik. sosyal ve kültürel statü indeksi		0.227*	0.185*	0.117*	-0.088*	0.072	0.711	0.735	0.399
Matematik öz-yeterliği			0.488*	0.503*	0.002	0.090	0.161	0.153	0.178
Problem çözmeye açık olma				0.454*	0.070*	0.029	0.128	0.126	0.193
Matematik benlik algısı					0.082*	0.067	0.095	0.088	0.149
Öğretmenin öğrenciyi yönlendirmesi						0.056	0.093	0.107	0.272
Hesap makinesi kullanımı							0.085*	0.078*	0.491*
Babasının eğitim düzeyi								0.691*	0.534*
Annesinin eğitim düzeyi									0.567*

Not.

1. \*  $p < 0.001$ 

2. Renklendirilmeyen değerler Pearson, açık gri renkteki değerler Eta, açık mavi renkteki değerler ise bağımlılık katsayısı değerleridir.

Tablo 9 incelendiğinde, değişkenler arasındaki ilişkilerin 0 ile 0.74 arasında değiştiği görülmektedir. Çoklu bağlantı probleminin oluşmaması için değişkenler arası ilişki katsayısının 0,90'nın altında olması gerekir (Tabachnick ve Fidell, 2012). Değişkenler arasında ilişkiler bu değerlerin altında olması çoklu bağlantı olmadığı yönünde bir kanıt olmasına karşın sadece bu sonuçlarla çoklu bağlantı problemi olmadığını söylemek zordur. Bu nedenle, varyans şişkinlik değerleri (VIF), koşul indeksi ve tolerans değerlerinin incelenmesi kullanılan diğer başlıca yöntemdir. Varyans şişkinlik değerinin 10'a eşit ya da büyük olması, tolerans değerinin 0.10'dan küçük olması ve koşul indeksinin 30'dan büyük olması çoklu bağlantı problemi olduğunu gösterir (Çokluk ve diğ., 2014; Field, 2005; Mertler ve Vannatta, 2005; Tabachnick ve Fidell, 2012). Tablo 10'da çoklu bağlantı varsayımına yönelik elde edilen istatistikler verilmiştir.

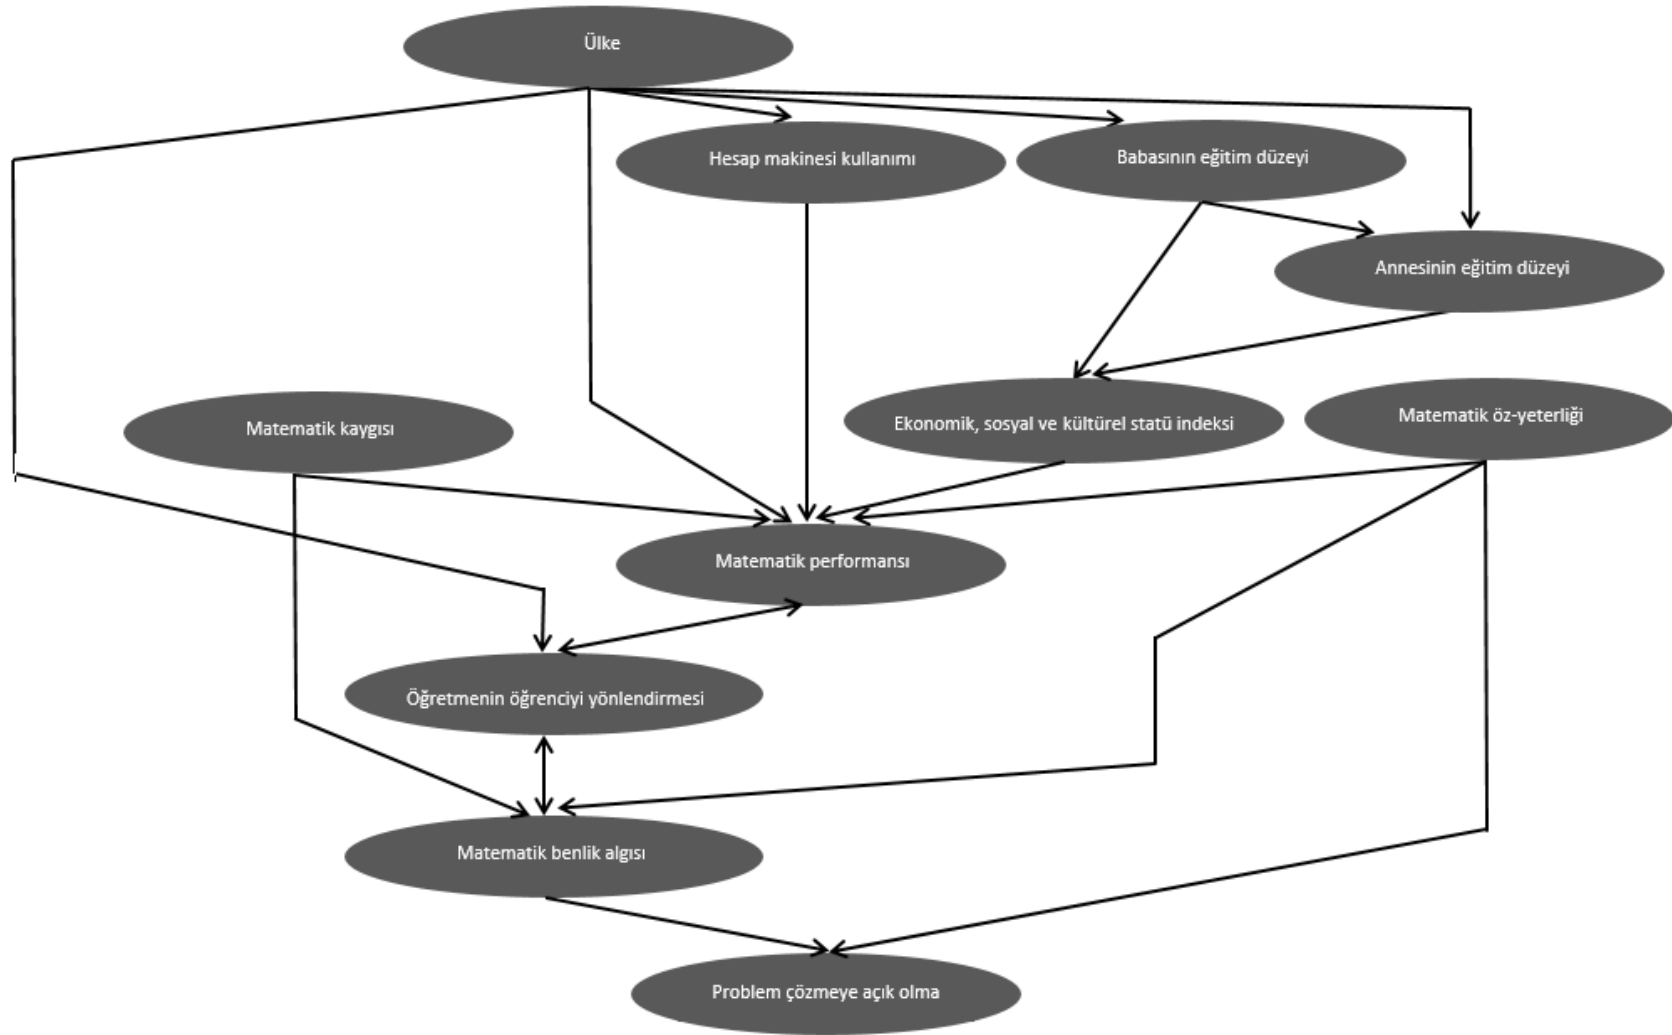
Tablo 10

*Çoklu Bağlantı İstatistikleri*

Boyutlar	Çoklu Bağlantı İstatistikleri		Koşul İndeksi
	Tolerans	VIF	
Sabit			1.000
Hesap makinesi kullanımı	0.968	1.033	1.367
Matematik kaygısı	0.579	1.728	2.020
Ekonomik. sosyal ve kültürel statü indeksi	0.333	3.000	2.220
Babasının eğitim düzeyi	0.494	2.023	2.461
Matematik öz-yeterliği	0.639	1.565	3.036
Annesinin eğitim düzeyi	0.458	2.185	3.814
Problem çözmeye açık olma	0.694	1.441	4.612
Matematik benlik algısı	0.471	2.122	7.578
Öğretmenin öğrenciyi yönlendirmesi	0.967	1.034	8.919
Ülke	0.946	1.058	15.817

Tablo 10'a göre tolerans değerleri 0.10'nun üzerinde, VIF değerleri 10'dan küçük ve koşul indeksi 30'dan küçük olduğundan çoklu bağlantı problemi bulunmamaktadır. Değişkenler arası çoklu bağlantı probleminin bulunmaması, Naive Bayes yöntemi gibi Bayes teoremine dayanan yöntemler için gerekli bir ön koşul olan tüm bağımsız değişkenlerin sınıflandırma değişkeninden koşullu bağımsızlığının sağlandığını göstermemektedir. Koşullu bağımsızlık varsayımı herhangi bir bağımsız değişkenin sınıflandırma (bağımlı) değişkeni üzerindeki etkisinin diğer değişken ya da değişkenlerden bağımsız olması anlamına gelmektedir. Bu varsayımı incelemenin en etkili yolu bir Bayes ağı üzerinde değişkenlerin ilişkilerini görmektir. Bu amaçla, Weka yazılımında sınıflandırma yöntemleri Bayes ağları alt başlığında yer alan ICSSearchAlgorithm sıklıkla kullanılmaktadır. ICS Bayes ağı öğrenme algoritması, koşullu bağımsızlık testlerini kullanarak ağın iskeletini oluşturur, bağlantı düğümlerini bulur ve ağdaki bağlantı oklarının yönünü belirli kurallar uygulayarak belirler (Frank ve diğ., 2016). Bu yöntem kullanılarak elde edilen Bayes ağı Şekil 12'de verilmiştir.





Şekil 12. Değişkenlerin Koşullu Bağımsızlığını Gösteren ICS Bayes Ağı

ICS algoritması, en uygun sınıflandırıcıyı bulmak yerine nedensel ilişkileri keşfetmeye odaklanır (Bouckaert, 2008). Bu amaçla, herhangi bir değişken kümesi için alt kümelerin koşullu bağımsızlıklarını bulmak amacıyla bu kümenin kapsayıcılığı maksimum düzeye getirilerek alt kümelerin (düğümlerin) yakınlıklarını gösteren bir iskelet oluşturulur. Eğer herhangi bir bağımsızlık gözlenirse düğümler arası oklar kaldırılır. Okların yönü ise aynı alt kümede ve ilişkili olup olmama durumuna göre belirlenir. Buna göre, Şekil 12 incelendiğinde, ülke ve matematik öz-yeterliği değişkenleri için matematik performansına göre koşullu bağımsızlık söz konusudur. Benzer şekilde, hesap makinesi kullanımı ile babasının eğitim düzeyi değişkenleri birbirinden bağımsızdır. Ancak, bu iki değişkenin matematik performansı üzerindeki etkisi ülke değişkeninden bağımsız değildir.

Şekil 12'ye göre, annesinin eğitim düzeyi değişkeni matematik performansı açısından ülke ve babasının eğitim düzeyi değişkenlerinden bağımsız değil iken, ekonomik, sosyal ve kültürel statü indeksi değişkeni de annesinin eğitim düzeyi değişkeninde bağımsız değildir. Tüm ağ bir arada incelendiğinde, ülke ve matematik öz-yeterliği değişkenleri birbirinden bağımsız şekilde matematik performansı üzerinde etkiliyken diğer tüm değişkenlerin yarattığı etki en az bir değişkenle bağlantılıdır. Buna göre, Naive Bayes yöntemi için koşullu bağımsızlık varsayımının sağlanmadığı görülmektedir. Ancak, koşullu bağımsızlık varsayımının nadiren sağlandığı ve Naive Bayes yönteminin yine de iyi sonuçlar verdiği bilinmektedir (Hamalainen ve Vinni, 2011). Bu nedenle, analiz sonuçları bu varsayımın sağlanmadığı düşünülerek değerlendirilmiştir.

Sonuç olarak, bu çalışmada yapılacak analizlere yönelik olarak yapılan varsayım kontrollerinde aşağıdaki sonuçlar elde edilmiştir.

- Örneklem büyüklüğü yeterlidir.
- Kayıp veri bulunmamaktadır.
- Uç değer bulunmamaktadır.
- Sürekli değişkenler normal dağılımdan önemli bir sapma göstermemektedir.
- Varyans-kovaryans matrislerinin homojenliği sağlanamamıştır.
- Değişkenler arası ilişkiler düşük veya orta düzeydedir.
- Çoklu bağlantı veya teklik problemi yoktur.

- Naive Bayes yöntemi için koşullu bağımsızlık varsayımı sağlanamamıştır.

**Verilerin analizi.** Araştırmanın alt problemlerine cevap bulmak amacıyla 500, 1000 ve 5000 kişiden oluşan dosyalar oluşturulmuştur. Tüm veriden yerine koyma işlemi yapılarak rastgele alt örneklem seçmek amacıyla 500 kişilik örneklem için 100, 1000 kişilik örneklem için 50 ve 5000 kişilik örneklem için 30 adet veri dosyası oluşturulmuştur. Tüm analizlerde kullanılmak üzere yerine koyma işlemi uygulanarak rastgele örnekleme ile toplam 180 dosya elde edilmiştir. Daha sonra ise WEKA Version 3.9.0 yazılımında yer alan Deneysel (Experiment) kısmında farklı test verilerinin (%11, %22, %33, %44 ve %55) rastgele seçildiği durumlar için 100 tekrardan oluşan analizler gerçekleştirilmiştir. Böylece, her bir analiz işlemi yöntemi için 500 kişilik örneklemde 10000, 1000 kişilik örneklemde 5000 ve 5000 kişilik örneklemde ise 3000 analizin ortalaması alınarak elde edilen sonuçlar standart sapma değerleriyle birlikte yorumlanmıştır.

Tüm alt problemler için aynı değişkenler kullanılmış ve veri seçme işlemi aynı şekilde yapılmıştır. Ancak,  $k$ -en yakın komşuluk yönteminde  $k$  değerinin seçilmesi ve çok katmanlı algılayıcı yönteminde katman sayısının belirlenmesi analiz sonuçlarına etki eden önemli faktörlerdir.  $k$ -en yakın komşuluk yönteminde en uygun  $k$  değeri için en çok kullanılan yöntemlerin başında öğrenme verisindeki örneklem sayısının karekökünün alınması gelmektedir (Dunham, 2003). Bazı araştırmacılar, kesin bir yargıda bulunmanın zor olduğunu belirlemekle birlikte bu değere yakın değerlerin denenmesini, çift ve asal sayıların kullanılmasını, Bayes yöntemleri ve  $k$ -katmanlı çapraz geçerlik gibi yöntemlerin kullanılmasını önermektedir (Aha, Kibler ve Albert, 1991; Ghosh, 2006; Hall, Park ve Samworth, 2008). Bu çalışmada öğrenme verisindeki öğrenci sayısının karekökü alınmış (Dunham, 2003) ve bu değer altında kalan tüm değerlerden  $k$ -katlamalı çapraz geçerlik yöntemiyle (Frank, Hall, and Witten, 2016) her bir analiz için en uygun  $k$  sayısı kullanılmıştır.

Çok katmanlı algılayıcı yönteminde ise %33'lük test verisi oranında katman sayısı için 1'den 5'e kadar değerler denenmiştir. 5'ten fazla değerin denenmemesinin sebebi ise katman sayısı arttığında modelin karmaşık hale gelmesi ve analizlerin çok fazla zaman almasıdır. Katman sayısı için tasarlanan deneysel desen 3 değerinin en ideal sonuçlar verdiğini ortaya koymuştur. Ayrıca, Akpınar (2014) birçok sınıflandırma probleminin çözümünde katman sayısının üç olmasının yeterli olacağını belirlemekle birlikte zamandan tasarruf sağlamak için

gerekirse ilave katmanların incelenmesinin yararlı olacağını belirtmektedir. Bu nedenlerden dolayı, çalışmada çok katmanlı algılayıcı yöntemi için katman sayısı 3 alınmıştır. Analizlerde, IBM SPSS Statistics 23, Microsoft Office Excel 2016 ve WEKA Version 3.9.0 yazılımlarından yararlanılmıştır.

Araştırmanın ilk dört alt problemi için model değerlendirme süreçleri ve tüm alt problemler için model seçme ve karşılaştırma işlemleri benzer şekilde yürütülmüştür. Bu süreçler aşağıda özetlenmiştir.

**Model değerlendirme.** Sınıflandırma performanslarının değerlendirilmesinde doğru veya yanlış sınıflandırılan bireyler üzerinden farklı ölçüler hesaplamak mümkündür. Öncelikle, bu araştırmada konu edilen tüm yöntemlerde matematik performansına göre öğrencilerin sınıflandırılma durumlarına göre Tablo 11'deki hata matrisi elde edilir (Han ve diğerleri, 2011).

Tablo 11

*Hata matrisi*

		Tahmin edilen sınıf		
		Pozitif	Negatif	Toplam
Gerçek sınıf	Pozitif	TP	FN	P
	Negatif	FP	TN	N
Toplam		P'	N'	P+N

Tablo 11'e göre TP (True Positive), sınıflandırıcı tarafından doğru sınıflandırılan ve ilgilenilen sınıfta yer alan veriyi gösterir. TN (True Negative), sınıflandırıcı tarafından doğru sınıflandırılan ancak ilgilenilen sınıfta yer almayan veriyi gösterir. FP (False Positive), ilgilenilen grupta yer almayan ancak sınıflandırıcı tarafından yanlış bir şekilde ilgilenilen gruba atanan veriyi gösterir. FN (False Negative), ilgilenilen grupta yer alan ancak sınıflandırıcı tarafından yanlış bir şekilde ilgilenilmeyen gruba atanan veriyi gösterir. İyi sınıflandırma performansı için TP ve TN değerlerinin yüksek FN ve FP değerlerinin ise 0 ya da 0'a yakın olması beklenir.

Tablo 11'de verilen hata matrisi ikili ( $c=2$ ) sınıflı bağımlı değişkenler için kullanılır. Ancak, bağımlı değişken ikiden fazla sınıftan oluştuğunda ( $c \geq 2$ ) matris genişletilebilir ( $c \times c$ ). Bu matris kullanılarak model performansının değerlendirilmesine yönelik *doğruluk* (accuracy), *hata oranı* (error rate), *hassaslık* (sensitivity), *özgünlük* (specificity), *kesinlik* (precision), *çağrışım* (recall) ölçüleri ve ROC (Receiver Operating Curve) eğrisinin altında kalan alan hesaplanabilir. ROC

eğrisinin altında kalan dışındaki ölçülerin nasıl hesaplanacağı Tablo 12’de verilmiştir. Buna göre, doğruluk, bir sınıflandırıcının doğru sınıflandırma yüzdesini verir. Bireyler sınıflara dengeli dağıldığında bu ölçü en etkili değerlendirme kriterlerindedir. Hata oranı ise  $1 - doğruluk$  olarak hesaplanır ve yanlış sınıflandırma oranını verir. Eğer bireyler sınıflara dengeli bir şekilde dağılmıyorsa doğruluk ve hata oranı yanlış bilgi içerebilir. Bu durumda, sınıflandırıcının pozitif ve negatif veriyi ne ölçüde ayırt edebildiğini hassaslık ve özgünlük ile daha net görebiliriz. Hassaslık, doğru sınıflandırılan pozitif veri oranını verirken; Özgünlük, doğru sınıflandırılan negatif veri oranını verir. Bu iki ölçüt, doğruluğun bir fonksiyonu şeklinde yazılabilir (Han ve diğerleri, 2011):

$$doğruluk = hassaslık \frac{P}{P+N} + özgünlük \frac{N}{P+N}. \quad (3.1)$$

Model değerlendirmede kullanılan diğer iki ölçü ise kesinlik ve çağrışım. Kesinlik, pozitif olarak sınıflanan ve gerçekte pozitif olan veri yüzdesini gösterirken; Çağrışım ise pozitif olan veri miktarının pozitif olarak sınıflandırılma yüzdesini verir. Kesinlik, çok yüksek olduğunda çağrışım aksine düşük olabilir. Bu durumda, belirli bir çağrışım yüzdesinde sınıflandırıcı veya sınıflandırıcıların kesinlikleri karşılaştırılabilir.

Tablo 12

*Performans Değerlendirme Ölçütleri*

Ölçü	Formül
Doğruluk	$\frac{TP + TN}{P + N}$
Hata Oranı	$\frac{FP + FN}{P + N}$
Hassaslık (TP oranı)	$\frac{TP}{P}$
Özgünlük (TN oranı)	$\frac{TN}{N}$
Kesinlik	$\frac{TP}{TP + FP}$
Çağrışım	$\frac{TP}{TP + FN} = \frac{TP}{P}$
F ölçütü (Kesinlik ve çağrışımın harmonik ortalaması)	$\frac{2 * kesinlik * çağrışım}{kesinlik + çağrışım}$
$F_{\beta}$ ölçütü	$\frac{(1 + \beta^2) * kesinlik * çağrışım}{\beta^2 * kesinlik + çağrışım}$

Kesinlik ve çağrışımın alternatif bir kullanımı ise ikisinin  $F$  ölçüsü ile birleştirilmesidir. Bu ölçü, kesinlik ve çağrışımın eşit şekilde ağırlıklandırılmasına dayanır.  $\beta$  ağırlıklandırma faktörü olmak üzere,  $F_{\beta}$  bu iki ölçütün farklı şekillerde ağırlıklandırılmasını temel alır ve genellikle çağrışım, kesinliğin iki katı kadar ağırlıklandırılır (Han ve diğerleri, 2011). Model performansının değerlendirilmesinde kullanılan bir diğer ölçüt ROC eğrisinin altında kalan alandır. ROC eğrisi, hem grafiksel olarak model performansını gösterirken aynı zamanda eğrinin altında kalan alan hesaplandıktan sonra yorumlaması kolaydır. ROC eğrisi kullanarak modellerin değerlendirilmesinde alan değerinin 0.5'e yaklaşması model performansının düşük olduğunu, 1 veya 1'e yakın olması da performansın çok yüksek olduğunu gösterir (Han ve diğerleri, 2011).

Model değerlendirmede kullanılan bir diğer ölçüt Cohen'in Kappa uyum katsayısıdır. Bu katsayı, Tablo 11'de verilen hata matrisinin köşegeninin altında ve üstünde kalan hücreler arasındaki uyum için bir istatistik verir. Landis ve Koch'a (1977) göre, bu değer 0-0.20 aralığında olması düşük, 0.21-0.40 aralığında olması kabul edilebilir, 0.41-0.60 arasında olması orta, 0.61-0.80 arasında olması oldukça iyi ve 0.81-1.00 arasında olması mükemmel uyumu göstermektedir.

Modellerin değerlendirilmesinde kullanılan diğer ölçüler ise *hız*, *dayanıklılık* (gürültülü ve kayıp veri), *ölçeklenebilirlik* (verinin büyütülmesi) ve

*yorumlanabilirlik*'tir. Modellerin performansını artırmak amacıyla kullanılan başlıca yöntemler eğitim seti kullanmak, rastgele alt örneklem alma, çapraz geçirme (*k*-fold cross-validation) ve önyükleme (bootstrapping) yöntemleridir.

Bu çalışmada, bireyler sınıflara dengeli dağılıma yakın bir dağılım gösterdiğinden model değerlendirilmesinde doğruluk, tekrarlardan elde edilen ortalama standart sapma miktarları (güven aralıkları), Kappa hata matrisi uyum korelasyonu, ROC eğrisinin altında kalan alan ve modellerin işlem hızları kullanılmıştır. Modellerin performansını artırmak ve en uygun değerleri elde etmek amacıyla rastgele test verisi ve önyükleme yöntemleri kullanılmıştır. Bu amaçla, farklı sayılarda rastgele alt örneklem seçilmiş ve her bir veri seti ve analiz yöntemi için test verisinin rastgele seçildiği 100 tekrar yapılmıştır.

Çalışmada her bir yöntem ve koşulda her bir veri seti için elde edilen performans ölçütü değerleri 100 tekrarın ortalaması ve bu ortalama değerlerin standart sapmasıdır. Buna göre, her bir örneklem büyüklüğü için elde edilecek performans ölçütü değerleri tüm veri setlerinin ortalaması olacaktır. Bu durumda, elde edilen performans ölçütü değerleri ortalama değerlerin ortalamasıdır. Aşağıda daha açıklayıcı olması açısından bu durum bir örnek üzerinde açıklanmıştır.

5000 kişilik örneklem için tüm veriden (62728) rastgele seçilen 30 adet veri setinin her biri için yapılan ve test verisi oranının %33 alındığı 100 tekrardan elde edilen ortalama doğruluk oranı ve standart sapma miktarları Şekil 13'te verilmiştir.

Analysing: Percent\_correct ( stddev)  
 Datasets: 30  
 Resultsets: 4

Dataset	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk
1. MATH2 (100)	76.50(0.87)	78.18(0.91)	76.01(1.15)	73.87(0.76)
2. MATH2 (100)	76.46(0.93)	78.30(0.84)	76.11(1.14)	74.59(0.88)
3. MATH2 (100)	76.22(0.89)	77.79(0.81)	75.63(1.12)	74.46(0.80)
4. MATH2 (100)	76.63(0.93)	78.26(0.84)	76.09(1.16)	73.58(0.85)
5. MATH2 (100)	76.39(0.96)	77.91(0.86)	75.82(1.24)	74.25(0.87)
6. MATH2 (100)	76.61(0.85)	78.07(0.84)	76.13(1.19)	74.66(0.85)
7. MATH2 (100)	76.80(0.85)	78.45(0.90)	76.40(1.21)	74.07(0.95)
8. MATH2 (100)	76.64(0.84)	78.57(0.66)	76.28(1.16)	74.12(0.89)
9. MATH2 (100)	75.32(0.85)	77.35(0.86)	75.25(1.15)	75.01(0.88)
10. MATH2 (100)	76.73(0.89)	78.23(0.85)	75.94(1.04)	73.98(0.78)
11. MATH2 (100)	77.59(0.79)	78.66(0.78)	76.53(1.14)	73.64(0.83)
12. MATH2 (100)	76.17(0.73)	77.79(0.71)	75.61(0.99)	74.08(0.77)
13. MATH2 (100)	76.59(0.85)	78.19(0.84)	75.99(1.19)	75.56(0.76)
14. MATH2 (100)	76.35(0.87)	78.06(0.79)	76.20(1.01)	73.91(0.83)
15. MATH2 (100)	76.77(0.79)	78.28(0.78)	75.96(1.16)	74.02(0.76)
16. MATH2 (100)	77.00(0.81)	78.29(0.74)	76.02(1.11)	74.10(0.87)
17. MATH2 (100)	76.17(0.80)	77.90(0.80)	75.73(1.26)	75.09(0.88)
18. MATH2 (100)	77.16(0.88)	78.55(0.81)	76.41(0.95)	73.17(0.95)
19. MATH2 (100)	75.96(0.82)	77.55(0.75)	75.52(1.10)	73.84(1.02)
20. MATH2 (100)	78.10(0.86)	79.13(0.79)	77.02(1.26)	73.83(0.91)
21. MATH2 (100)	76.79(0.74)	77.77(0.73)	75.54(0.94)	73.28(0.90)
22. MATH2 (100)	76.76(0.95)	78.92(0.72)	76.64(1.18)	74.72(0.87)
23. MATH2 (100)	76.49(0.90)	78.81(0.91)	76.63(1.06)	73.60(0.81)
24. MATH2 (100)	77.29(0.88)	78.88(0.88)	76.77(1.24)	73.70(0.85)
25. MATH2 (100)	76.38(0.91)	77.97(0.78)	75.73(1.22)	74.01(0.87)
26. MATH2 (100)	75.91(0.88)	77.51(0.79)	75.50(1.15)	74.61(0.80)
27. MATH2 (100)	76.14(0.92)	78.24(0.82)	75.65(1.14)	74.11(0.86)
28. MATH2 (100)	75.96(0.95)	77.89(0.80)	75.77(1.21)	73.96(0.84)
29. MATH2 (100)	76.84(0.82)	78.99(0.90)	77.12(1.15)	74.26(0.89)
30. MATH2 (100)	76.49(0.80)	77.58(0.71)	75.67(1.13)	73.52(0.90)

Şekil 13. Analizlerden Elde Edilen Örnek Veri

Şekil 13'te her bir metot için ortalama doğruluk oranını elde etmek amacıyla 30 veri setinin ortalaması alındığında her bir veri setinin 100 tekrardan oluşan bir örneklemden geliyor olması nedeniyle bu tekrarların standart sapmalarını da göz önünde bulundurmaya gerektirecektir. Böyle bir durumda her bir yöntemin ağırlıklı ortalamasının hesaplanması gerekmektedir. Buna göre, ortalama ağırlıklandırma işlemi şu şekilde tanımlanmıştır:

$$\mu = \frac{\sum_{i=1}^n w_i x_i}{\sum_{i=1}^n w_i} \quad (3.2)$$

Bu denklemde,  $(x_1, x_2, \dots, x_n)$  veri setindeki her bir elemanı;  $(w_1, w, \dots, w_n)$  her bir ağırlıklandırma faktörünü,  $\mu$  ise ağırlıklandırılmış ortalamayı göstermektedir. Eğer tüm ağırlıklandırmalar eşit ise normal aritmetik ortalama formülü elde edilecektir.

$$\mu = \frac{w \sum_{i=1}^n x_i}{nw} = \frac{1}{n} \sum_{i=1}^n x_i \quad (3.3)$$



Çalışmada her bir veri seti için elde edilen ortalamalar ve örneklem varyans değerleri ağırlıklandırma faktörü olarak kullanılmıştır. Bu faktör şu şekilde tanımlanmıştır:

$$w_i = \frac{1}{\sigma_i^2} \quad (3.4)$$

Bu durumda ağırlıklandırma faktörünü 3.2 denkleminde yerine koyduğumuzda aşağıdaki denklem elde edilir.

$$\mu = \frac{\sum_{i=1}^n \sigma_i^{-2} x_i}{\sum_{i=1}^n \sigma_i^{-2}} \quad (3.5)$$

Ağırlıklandırılmış ortalamanın varyansı da şu şekilde olacaktır:

$$\sigma_{\bar{x}}^2 = \frac{1}{\sum_{i=1}^n \sigma_i^{-2}} \quad (3.6)$$

İki denklem birleştirildiğinde ise;

$$\bar{x} = \sigma_{\bar{x}}^2 \sum_{i=1}^n x_i / \sigma_i^2 \quad (3.7)$$

elde edilecektir. Buna göre, tüm yöntemler için farklı koşullarda elde edilen ortalama değerler bu prosedür izlenerek ağırlıklandırılmış ve raporlanmıştır.

**Model karşılaştırma ve seçme.** Veri madenciliğinde farklı metotları karşılaştırmak ve en az hata içeren metodu seçmek amacıyla hipotez testlerinden yararlanılır. Bu amaçla, parametrik analizlerin varsayımları sağlandığında en çok tercih edilen yöntem *t* testini kullanmaktır. Eğer koşul ve yöntem sayısı ikiden fazla ise F testi ya da varsayımlar sağlanmadığında parametrik olmayan eşdeğerinin kullanılması uygun olacaktır. Çalışmada, koşul ve yöntem sayıları ikiden fazla olduğundan istatistiksel fark testleri olarak tek yönlü ANOVA ve tekrarlı ölçümler için ANOVA testleri kullanılmıştır. Analizler yapılmadan önce elde edilen analiz sonuçları için ANOVA testlerinin varsayımları kontrol edilmiştir. Tek yönlü ANOVA testleri için varyansların homojenliği dışında diğer varsayımların sağlandığı görülmüştür. Bu varsayımın ise sağlandığı koşullar için Post Hoc testi olarak Tukey, sağlanmadığı durumlar için de Dunnett'in C testi kullanılmıştır. Tekrarlı ölçümler için ANOVA için küresellik dışında diğer varsayımların sağlandığı görülmüştür. Küreselliğin sağlanmadığı durumlarda ise bu varsayım için düzeltme işlemi uygulayan Greenhouse Geiser F değerleri kullanılmıştır. Son olarak, modellerin

farklı kořullarda nasıl performans gösterdiğini görsel hale getiren çizgi ve kutu grafiklere yer verilmiştir.



## Bölüm 4

### Bulgular ve Yorumlar

Bu bölümde, alt problem sırasına göre verilmiş araştırma bulguları ve bu bulgularla ilgili değerlendirmeler yer almaktadır.

#### Birinci Alt Probleme İlişkin Bulgular

500, 1000 ve 5000 kişilik örneklem büyüklükleri için Naive Bayes yönteminin test verisi oranı %11, %22, %33, %44 ve %55 olduğunda sınıflandırma doğruluk oranları ile standart sapma miktarları, Kappa uyum katsayıları ve ROC eğrisinin altında kalan alan değerleri nasıl farklılaşmaktadır?

Naive Bayes yöntemi için hesaplanan doğruluk oranları ortalamaları ve standart sapmaları, Kappa uyumu ve ROC eğrisinin altında kalan alan değerlerinin ortalamaları Tablo 13'te verilmiştir.

Tablo 13

*NB Yöntemi İçin Hesaplanan Performans Ölçüt Değerleri*


Örneklem Büyüklüğü	Test verisi oranı (%)	Doğruluk (%)	SS	Kappa	ROC
500	11	75.93	5.38	0.47	0.82
	22	75.87	3.64	0.46	0.82
	33	75.78	2.82	0.46	0.82
	44	75.66	2.33	0.46	0.81
	55	75.41	2.02	0.45	0.81
1000	11	76.35	3.76	0.47	0.82
	22	76.27	2.54	0.47	0.82
	33	76.16	1.98	0.47	0.82
	44	76.04	1.63	0.47	0.82
	55	75.94	1.41	0.46	0.82
5000	11	76.60	1.70	0.48	0.83
	22	76.60	1.13	0.48	0.83
	33	76.58	0.86	0.48	0.83
	44	76.53	0.72	0.48	0.83
	55	76.48	0.61	0.48	0.83

Not:

SS: Doğruluk oranları için ortalama standart sapma değerleridir.

Tablo 13'e göre, NB yöntemi için elde edilen doğru sınıflandırma oranları 75.41 ile 76.48 arasında değişmektedir. Buna göre, NB yöntemi ile öğrenciler yüksek düzeyde doğrulukla alt ve üst gruplara yerleştirilmişlerdir. Doğruluk oranlarının standart sapmalarının ise 0.61 ile 5.38 arasında değişmesi elde edilen


edilen doğru sınıflandırma oranlarının farklı koşullarda güvenilirlik düzeyinin değiştiğini göstermektedir. Hata matrisi için hesaplanan Kappa uyum değerleri 0.45 ile 0.48 arasında; ROC değerleri ise 0.81 ile 0.83 arasında değişmektedir. ROC eğrisi kullanarak modellerin değerlendirilmesinde alan değerinin 0,5'e yaklaşması model performansının düşük olduğunu, 1 veya 1'e yakın olması da performansın çok yüksek olduğunu gösterir (Han ve diğerleri, 2011). Kappa uyum değerlerinin 0-0.20 aralığında olması düşük, 0.21-0.40 aralığında olması kabul edilebilir, 0.41-0.60 arasında olması orta, 0.61-0.80 arasında olması oldukça iyi ve 0.81-1.00 arasında olması sınıflandırma tablosundaki mükemmel uyumu ifade eder (Landis ve Koch, 1977). Buna göre, elde edilen ROC eğrisinin altında kalan değerleri NB yöntemi ile yüksek düzeyde performans elde edildiğini, Kappa uyum değerleri ise hata matsindeki uyumun orta düzeyde olduğunu göstermiştir. Ayrıca, elde edilen ROC alan değerleri ile Kappa uyum değerleri, sınıflandırma sonuçlarının geçerliğinin yüksek olduğuna ilişkin kanıtlar sunmaktadır. Doğruluk oranlarının farklı koşullarda nasıl değişim gösterdiği Şekil 14'te görselleştirilmiştir.



Şekil 14. NB Yöntemi İçin Doğruluk Oranının Tüm Koşullara Göre Değişimi

Şekil 14 incelendiğinde, örneklem büyüdükçe doğru sınıflandırma oranı artmaktadır. Test verisi oranının artırılması doğruluk oranlarında düşüşe neden

olmuştur. Ancak, örneklem büyüdükçe test verisi oranının artırılmasının doğruluk oranları üzerindeki etkisi önemli ölçüde azalmaktadır. Doğruluk oranlarının standart sapma miktarlarının farklı koşullarda nasıl değişim gösterdiği ise Şekil 15'te görselleştirilmiştir.



Şekil 15. NB Yöntemi İçin Doğruluk Oranlarının Standart Sapma Miktarının Tüm Koşullara Göre Değişimi

Şekil 15'e göre, örneklem büyüdükçe doğru oranlarının standart sapma miktarları azalmaktadır. Bu sapma, test verisi oranı %33 olana kadar önemli düşüş göstermiş daha sonra ise önemli bir azalma göstermemiştir. Ancak, örneklem büyüdükçe test verisi oranının artırılmasının doğruluk oranlarının standart sapma miktarları üzerindeki etkisi önemli ölçüde azalmaktadır. Buna göre, büyük örneklerde ve orta büyüklükte test verisi oranı olduğunda makul düzeyde güvenilir doğruluk oranları elde edilmiştir.

Örneklem büyüklüğü arttıkça NB yönteminin doğruluk oranı ve hata oranlarının istatistiksel olarak anlamlı derecede değişip değişmediği tek yönlü varyans analizi ile incelenmiştir. Ön analizler sonucunda varyansların homojenliği dışında diğer varsayımların sağlandığı görülmüştür. Analizler sonucunda elde

edilen F değerleri, Dunnet's C Post-Hoc testi sonuçları ile birlikte Tablo 14'te verilmiştir.

Tablo 14

*NB Yönteminde Örneklem Büyüklüğü İçin F Değerleri*

Öçüt	Test verisi oranı									
	%11		%22		%33		%44		%55	
	F	Grup Farkı	F	Grup Farkı	F	Grup Farkı	F	Grup Farkı	F	Grup Farkı
Doğruluk	2.95*	I-II I-III* II-III	3.96*	I-II I-III* II-III	4.72*	I-II I-III* II-III	5.88*	I-II I-III* II-III*	8.04*	I-II I-III* II-III*
SS	1523.1*	I-II* I-III* II-III*	1516.8*	I-II* I-III* II-III*	1647.3*	I-II* I-III* II-III*	1402.1*	I-II* I-III* II-III*	1320.0*	I-II* I-III* II-III*

Not: I: örneklem büyüklüğü 500. II: örneklem büyüklüğü 1000. III: örneklem büyüklüğü 5000.

\*  $p < 0.05$

Tablo 13 ve Tablo 14 bir arada incelendiğinde, örneklem büyüklüğü 500'den 5000'e çıkarıldığında tüm test verisi oranları için doğruluk oranları anlamlı düzeyde artmaktadır ( $p < 0.05$ ). Test verisi oranı %44 ve %55 olduğunda, örneklem büyüklüğünün 1000'den 5000'e çıkarılması doğruluk oranlarında anlamlı bir artışa neden olmuştur ( $p < 0.05$ ). Tüm test verisi oranları için örneklem büyüklüğünün artırılması doğruluk oranlarının standart sapma miktarlarında anlamlı bir azalmaya neden olmuştur ( $p < 0.05$ ). Buna göre, örneklemin büyümesi güvenilirliği yüksek sonuçların elde edilmesini sağlamaktadır. Örneklem büyüdükçe doğruluk oranları artarken, standart sapma miktarının düşmesi modelin daha çok veriyle daha iyi eğitilebildiğini göstermektedir.

Test verisi oranı arttıkça NB yönteminin doğruluk oranı ve standart sapma oranlarının istatistiksel olarak anlamlı derecede değişip değişmediği tekrarlı ölçümler için varyans analizi ile incelenmiştir. Ön analizlerde küresellik varsayımı dışında analiz yönteminin varsayımlarının sağlandığı görülmüştür. Bu varsayımın sağlanmadığı durumda uygulanan Greenhouse-Geisser düzeltmesi ile elde edilen F değerleri, Bonferroni Post-Hoc testi sonuçları ile birlikte Tablo 15'te verilmiştir.

Tablo 15

## NB Yönteminde Test Verisi Oranı İçin F Değerleri

Ölçüt	Örneklem büyüklüğü					
	500		1000		5000	
	F	Grup Farkı	F	Grup Farkı	F	Grup Farkı
Doğruluk	3.23	I-II	1.89	I-II	0.28	I-II
		I-III		I-III		I-III
		I-IV		I-IV		I-IV
		I-V		I-V		I-V
		II-III		II-III		II-III
		II-IV		II-IV		II-IV
		II-V		II-V		II-V
		III-IV		III-IV		III-IV
		III-V		III-V		III-V
		IV-V		IV-V		IV-V
SS	3322.5*	I-II*	1329.0*	I-II*	1059.3*	I-II*
		I-III*		I-III*		I-III*
		I-IV*		I-IV*		I-IV*
		I-V*		I-V*		I-V*
		II-III*		II-III*		II-III*
		II-IV*		II-IV*		II-IV*
		II-V*		II-V*		II-V*
		III-IV*		III-IV*		III-IV*
		III-V*		III-V*		III-V*
		IV-V*		IV-V*		IV-V*

Not: I: %11. II: %22. III: %33. IV:%44. V: %55.

\*  $p < 0.05$

Tablo 13 ve Tablo 15 bir arada incelendiğinde, test verisi oranının arttıkça, tüm örneklem büyüklükleri için doğruluk oranları anlamlı bir değişim göstermemektedir ( $p > 0.05$ ). Ancak, test verisi oranının artırılması, tüm örneklem büyüklükleri için doğruluk oranlarının standart sapma miktarlarında anlamlı bir azalmaya neden olmaktadır ( $p < 0.05$ ). Bu azalma örneklem küçüldükçe daha belirgin hale gelmektedir. Bu sonuçlara göre, NB yöntemi modelin eğitilmesi için gerekli olan veri miktarı çok az olduğunda bile doğru sınıflandırma oranı ve güvenilirliği yüksek sonuçlar vermektedir.

### İkinci Alt Probleme İlişkin Bulgular

500, 1000 ve 5000 kişilik örneklem büyüklükleri için k- en yakın komşuluk yönteminin test verisi oranı %11, %22, %33, %44 ve %55 olduğunda sınıflandırma doğruluk oranları ile standart sapma miktarları, Kappa uyum katsayıları ve ROC eğrisinin altında kalan alan değerleri nasıl farklılaşmaktadır?

En yakın komşuluk yöntemi için hesaplanan doğruluk oranları ortalamaları ve standart sapmaları, Kappa uyumu ve ROC eğrisinin altında kalan alan değerlerinin ortalamaları Tablo 16'da verilmiştir.

Tablo 16

*KNN Yöntemi İçin Hesaplanan Performans Ölçüt Değerleri*

Örneklem Büyüklüğü	Test verisi oranı (%)	Doğruluk (%)	SS	Kappa	ROC
500	11	71.81	5.01	0.31	0.74
	22	71.44	3.42	0.30	0.74
	33	71.05	2.80	0.29	0.73
	44	70.55	2.46	0.28	0.72
	55	70.06	2.31	0.27	0.71
1000	11	72.11	3.46	0.32	0.76
	22	71.97	2.39	0.31	0.76
	33	71.78	1.96	0.31	0.75
	44	71.57	1.72	0.30	0.75
	55	71.18	1.62	0.29	0.74
5000	11	74.52	1.57	0.39	0.80
	22	74.34	1.09	0.39	0.79
	33	74.14	0.86	0.38	0.79
	44	73.83	0.74	0.37	0.79
	55	73.50	0.67	0.36	0.78


Not:

SS: Doğruluk oranları için ortalama standart sapma değerleridir.

Tablo 16 incelendiğinde, KNN yöntemi için elde edilen doğru sınıflandırma oranları 70.06 ile 74.52 arasında değişmektedir. Buna göre, KNN yöntemi ile öğrenciler orta düzeyin üzerinde bir doğrulukla alt ve üst gruplara yerleştirilmişlerdir. Doğruluk oranlarının standart sapmalarının ise 0.67 ile 5.01 arasında değişmesi elde edilen doğru sınıflandırma oranlarının farklı koşullarda güvenilirlik düzeyinin değiştiğini göstermektedir. Elde edilen doğru sınıflandırma performansı için geçerlik ölçütü olan Kappa uyum değerleri 0.27 ile 0.39 arasında; ROC değerleri ise 0.71 ile 0.80 arasında değişmektedir. ROC eğrisi kullanarak modellerin değerlendirilmesinde alan değerinin 0,5'e yaklaşması model performansının düşük olduğunu, 1 veya 1'e yakın olması da performansın çok yüksek olduğunu gösterir (Han ve diğerleri, 2011). Kappa uyum değerlerinin 0-0.20 aralığında olması düşük, 0.21-0.40 aralığında olması kabul edilebilir, 0.41-0.60 arasında olması orta, 0.61-0.80 arasında olması oldukça iyi ve 0.81-1.00 arasında olması sınıflandırma tablosundaki mükemmel uyumu ifade eder (Landis ve Koch, 1977). Buna göre, elde




edilen ROC eğrisinin altında kalan değerleri KNN yöntemi ile yüksek düzeyde performans elde edildiğini, Kappa uyum değerleri ise hata matsindeki uyumun kabul edilebilir düzeyde olduğunu göstermiştir. Ayrıca, elde edilen ROC alan değerleri ile Kappa uyum değerleri, sınıflandırma sonuçlarının geçerliğine yüksek olduğuna ilişkin kanıtlar sunmaktadır. Şekil 16’da doğruluk oranlarının farklı koşullar altındaki değişimleri grafiksel olarak verilmiştir.



Şekil 16. KNN Yöntemi İçin Doğruluk Oranının Tüm Koşullara Göre Değişimi

Şekil 16’ya göre, test verisi oranının artırılması doğruluk oranlarında düşüşe neden olmuştur. Farklı örneklem büyüklüklerinde test verisi oranının artırılması doğruluk oranları üzerinde benzer bir etki yaratmaktadır. Ancak, örneklem büyüdükçe doğru sınıflandırma oranları artmaktadır. Şekil 17’de ise doğruluk oranlarının standart sapma miktarlarının farklı koşullarda nasıl değişim gösterdiği verilmiştir.



Şekil 17. KNN Yöntemi İçin Doğruluk Oranlarının Standart Sapma Miktarının Tüm Koşullara Göre Değişimi

Şekil 17'ye göre, test verisi oranının artırılması, standart sapma miktarının test verisi oranı %33 olana kadar hızlı düşüş göstermesine daha sonra ise yatay bir eğilim göstermesine neden olmuştur. Örneklem büyüdükçe doğruluk oranlarının standart sapma miktarları önemli ölçüde azalmaktadır. Ancak, örneklem büyüdükçe test verisi oranının artırılmasının doğruluk oranlarının standart sapma miktarları üzerindeki etkisi önemli ölçüde azalmaktadır. Şekil 16 ve Şekil 17 bir arada değerlendirildiğinde, büyük örneklerde ve orta büyüklükte test verisi oranı olduğunda makul düzeyde güvenilir doğruluk oranları elde edilmiştir.

Örneklem büyüklüğü artırıldığında KNN yönteminin doğruluk oranı ve standart sapma miktarlarının istatistiksel olarak anlamlı derecede değişip değişmediği tek yönlü varyans analizi ile incelenmiştir. Öncesinde analizin varsayımlarının sağlandığı görülmüş ve analizler sonucunda elde edilen F değerleri, Bonferroni Post-hoc testi sonuçları ile birlikte Tablo 17'de verilmiştir.

Tablo 17

## KNN Yönteminde Örneklem Büyüklüğü İçin F Değerleri

Ölçüt	Test verisi oranı									
	%11		%22		%33		%44		%55	
	F	Grup Farkı	F	Grup Farkı	F	Grup Farkı	F	Grup Farkı	F	Grup Farkı
Doğruluk	33.82*	I-II I-III* II-III*	40.88*	I-II I-III* II-III*	45.81*	I-II* I-III* II-III*	52.66*	I-II* I-III* II-III*	61.68*	I-II* I-III* II-III*
SS	835.12*	I-II* I-III* II-III*	899.25*	I-II* I-III* II-III*	1174.4*	I-II* I-III* II-III*	804.45*	I-II* I-III* II-III*	747.16*	I-II* I-III* II-III*

Not: I: örneklem büyüklüğü 500. II: örneklem büyüklüğü 1000. III: örneklem büyüklüğü 5000.

\*  $p < 0.05$

Tablo 16 ve Tablo 17 bir arada incelendiğinde, test verisi oranı %11 ve %22 olduğunda örneklem büyüklüğünün 500'den 1000'e çıkarılması yöntemin doğruluk oranları üzerinde anlamlı bir etki yaratmamıştır ( $p > 0.05$ ). Diğer test verisi oranları için örneklem büyüklüğü artırıldığında KNN yönteminin doğruluk oranları anlamlı düzeyde artmıştır ( $p < 0.05$ ). Tüm test verisi oranları için örneklem büyüklüğü arttıkça doğruluk oranlarının standart sapmaları anlamlı düzeyde azalmıştır ( $p < 0.05$ ). Buna göre, örneklemin büyümesi güvenilirliği yüksek sonuçların elde edilmesini sağlamaktadır. Örneklem büyüdükçe doğruluk oranları artarken, standart sapma miktarının düşmesi modelin daha çok veriyle daha iyi eğitilebildiğini göstermektedir.

Test verisi oranı arttıkça KNN yönteminin doğruluk oranı ve standart sapma oranlarının istatistiksel olarak anlamlı derecede değişip değişmediği tekrarlı ölçümler için tek yönlü varyans analizi ile incelenmiştir. Analizin küresellik varsayımı dışında diğer varsayımlarının sağlandığı görülmüş ve bu nedenle Greenhouse-Geisser düzeltmesi uygulanarak elde edilen F değerleri, Bonferroni Post-hoc testi sonuçları ile birlikte Tablo 18'de verilmiştir.

Tablo 18

## KNN Yönteminde Test Verisi Oranı İçin F Değerleri

Ölçüt	Örneklem büyüklüğü					
	500		1000		5000	
	F	Grup Farkı	F	Grup Farkı	F	Grup Farkı
Doğruluk	267.00*	I-II*	72.50*	I-II	260.29*	I-II*
		I-III*		I-III*		I-III*
		I-IV		I-IV*		I-IV*
		I-V*		I-V*		I-V*
		II-III*		II-III*		II-III*
		II-IV*		II-IV*		II-IV*
		II-V*		II-V*		II-V*
		III-IV*		III-IV*		III-IV
		III-V*		III-V*		III-V*
		IV-V*		IV-V*		IV-V*
SS	1582.33*	I-II*	789.43*	I-II*	1002.86*	I-II*
		I-III*		I-III*		I-III*
		I-IV*		I-IV*		I-IV*
		I-V*		I-V*		I-V*
		II-III*		II-III*		II-III*
		II-IV*		II-IV*		II-IV*
		II-V*		II-V*		II-V*
		III-IV*		III-IV*		III-IV*
		III-V*		III-V*		III-V*
		IV-V*		IV-V*		IV-V*

Not: I: %11. II: %22. III: %33. IV:%44. V: %55.

\*  $p < 0.05$

Tablo 16 ve Tablo 18'e göre, tüm örneklem büyüklüklerinde neredeyse tüm test verisi oranları için elde edilen doğruluk oranları anlamlı bir değişim göstermektedir ( $p < 0.05$ ). Test verisi oranının artırılması doğruluk oranlarının anlamlı bir şekilde azalmasına neden olmaktadır ( $p < 0.05$ ). Bu sonuçlar, araştırmalarda genel geçer bir uygulama olan tüm verinin üçte biri oranındaki test verisi kullanımının verinin yapısına ve kullanılan yöntemle göre ideal bir uygulama olmayabileceğini göstermektedir.

KNN yönteminde küçük örneklerde doğruluk oranları test verisi miktarının artmasından daha fazla etkilenmektedir. Ancak, test verisi oranının artırılması, tüm örneklem büyüklükleri için doğruluk oranlarının standart sapma miktarlarında anlamlı bir azalmaya neden olmaktadır ( $p < 0.05$ ). Bu azalma örneklem küçüldükçe daha belirgin hale gelmektedir. Bu sonuçlara göre, KNN yöntemi modelin eğitilmesi için gerekli olan veri miktarı çok az olduğunda bile doğru sınıflandırma oranı ve güvenilirliği yüksek sonuçlar vermektedir.

### Üçüncü Alt Probleme İlişkin Bulgular

500, 1000 ve 5000 kişilik örneklem büyüklükleri için yapay sinir ağları çok katmanlı algılayıcı yönteminin test verisi oranı %11, %22, %33, %44 ve %55 olduğunda sınıflandırma doğruluk oranları ile standart sapma miktarları, Kappa uyum katsayıları ve ROC eğrisinin altında kalan alan değerleri nasıl farklılaşmaktadır?

Yapay sinir ağları çok katmanlı algılayıcı (Multilayer Preceptron - MLP) yöntemi için hesaplanan doğruluk oranları ortalamaları ve standart sapmaları, Kappa uyumu ve ROC eğrisinin altında kalan alan değerlerinin ortalamaları Tablo 19'da verilmiştir.

Tablo 19

MLP Yöntemi İçin Hesaplanan Performans Ölçüt Değerleri


Örneklem Büyüklüğü	Test verisi oranı (%)	Doğruluk (%)	SS	Kappa	ROC
500	11	72.80	5.66	0.39	0.78
	22	72.62	3.94	0.39	0.78
	33	72.27	3.25	0.38	0.77
	44	71.97	2.74	0.37	0.77
	55	71.56	2.54	0.37	0.76
1000	11	73.92	3.99	0.42	0.80
	22	73.65	2.84	0.41	0.79
	33	73.42	2.33	0.41	0.79
	44	73.07	2.05	0.40	0.78
	55	72.66	1.86	0.39	0.78
5000	11	76.36	1.79	0.47	0.83
	22	76.20	1.36	0.47	0.83
	33	76.04	1.14	0.46	0.83
	44	75.77	1.12	0.46	0.82
	55	75.53	1.06	0.45	0.82

Not:

SS: Doğruluk oranları için ortalama standart sapma (hata) değerleridir.

Tablo 19 incelendiğinde, MLP yöntemi için elde edilen doğru sınıflandırma oranları 71.56 ile 76.36 arasında değişmektedir. Buna göre, MLP yöntemi ile öğrenciler yüksek düzeyde doğrulukla alt ve üst gruplara yerleştirilmişlerdir. Doğruluk oranlarının standart sapmalarının ise 1.06 ile 5.66 arasında değişmesi elde edilen doğru sınıflandırma oranlarının farklı koşullarda güvenilirlik düzeyinin değiştiğini göstermektedir. Elde edilen doğru sınıflandırma performansı


için geçerlik ölçütü olan Kappa uyum değerleri 0.37 ile 0.47 arasında; ROC değerleri ise 0.76 ile 0.83 arasında değişmektedir. ROC eğrisi kullanarak modellerin değerlendirilmesinde alan değerinin 0,5'e yaklaşması model performansının düşük olduğunu, 1 veya 1'e yakın olması da performansın çok yüksek olduğunu gösterir (Han ve diğerleri, 2011). Kappa uyum değerlerinin 0-0.20 aralığında olması düşük, 0.21-0.40 aralığında olması kabul edilebilir, 0.41-0.60 arasında olması orta, 0.61-0.80 arasında olması oldukça iyi ve 0.81-1.00 arasında olması sınıflandırma tablosundaki mükemmel uyumu ifade eder (Landis ve Koch, 1977). Buna göre, elde edilen ROC eğrisinin altında kalan değerleri MLP yöntemi ile yüksek düzeyde performans elde edildiğini, Kappa uyum değerleri ise hata matrisindeki uyumun orta veya kabul edilebilir düzeyde olduğunu göstermiştir. Ayrıca, elde edilen ROC alan değerleri ile Kappa uyum değerleri, sınıflandırma sonuçlarının geçerliğine yüksek olduğuna ilişkin kanıtlar sunmaktadır. Doğruluk oranlarının farklı koşullarda nasıl değişim gösterdiği Şekil 18'de verilmiştir.



Şekil 18. MLP Yöntemi İçin Doğruluk Oranının Tüm Koşullara Göre Değişimi

Şekil 18 incelendiğinde, örneklem büyüdükçe doğru sınıflandırma oranı artmaktadır. Test verisi oranının artırılması doğruluk oranlarında düşüşe neden olmuştur. Ancak, örneklem büyüdükçe test verisi oranının artırılmasının doğruluk

oranları üzerindeki etkisi önemli ölçüde azalmaktadır. Doğruluk oranlarının standart sapma miktarlarının farklı koşullarda nasıl değişim gösterdiği ise Şekil 19'da verilmiştir.



Şekil 19. MLP Yöntemi İçin Doğruluk Oranlarının Standart Sapma Miktarının Tüm Koşullara Göre Değişimi

Şekil 19 incelendiğinde, örneklem büyüdükçe doğru oranlarının standart sapma miktarları önemli ölçüde azalmaktadır. Bu sapma, test verisi oranı %33 olana kadar önemli düşüş göstermiş daha sonra ise önemli bir azalma göstermemiştir. Ancak, örneklem büyüdükçe test verisi oranının artırılmasının doğruluk oranlarının standart sapma miktarları üzerindeki etkisi önemli ölçüde azalmaktadır. Buna göre, büyük örneklemelerde ve orta büyüklükte test verisi oranı olduğunda makul düzeyde güvenilir doğruluk oranları elde edilmiştir.

Örneklem büyüklüğü artırıldığında MLP yönteminin doğruluk oranı ve standart sapma oranlarının istatistiksel olarak anlamlı derecede değişip değişmediği tek yönlü varyans analizi ile incelenmiştir. Öncesinde analizin varsayımlarının sağlandığı görülmüş ve analizler sonucunda elde edilen F değerleri, Bonferroni Post-hoc testi sonuçları ile birlikte Tablo 20'de verilmiştir.

Tablo 20

## MLP Yönteminde Örneklem Büyüklüğü İçin F Değerleri

Ölçüt	Test verisi oranı									
	%11		%22		%33		%44		%55	
	F	Grup Farkı	F	Grup Farkı	F	Grup Farkı	F	Grup Farkı	F	Grup Farkı
Doğruluk	65.11*	I-II*	74.84*	I-II*	82.22*	I-II*	85.43*	I-II*	99.20*	I-II*
		I-III*		I-III*		I-III*		I-III*		I-III*
		II-III*		II-III*		II-III*		II-III*		II-III*
SS	1424.4*	I-II*	1316.4*	I-II*	1329.9*	I-II*	788.17*	I-II*	826.11*	I-II*
		I-III*		I-III*		I-III*		I-III*		I-III*
		II-III*		II-III*		II-III*		II-III*		II-III*

Not: I: örneklem büyüklüğü 500. II: örneklem büyüklüğü 1000. III: örneklem büyüklüğü 5000.

\*  $p < 0.05$

Tablo 19 ve Tablo 20 bir arada incelendiğinde, tüm test verisi oranları için örneklem büyüklüğü artırıldığında MLP yönteminin doğruluk oranları anlamlı düzeyde artmış ve standart sapmaları anlamlı düzeyde azalmıştır ( $p > 0.05$ ). Buna göre, örneklemin büyümesi daha dar güven aralığında yanlılığı düşük daha güvenilir sonuçların elde edilmesini sağlamaktadır.

Test verisi oranı arttıkça MLP yönteminin doğruluk oranı ve standart sapma oranlarının istatistiksel olarak anlamlı derecede değişip değişmediği tekrarlı ölçümler için tek yönlü varyans analizi ile incelenmiştir. Analizin küresellik varsayımı dışında diğer varsayımlarının sağlandığı görülmüş ve bu nedenle Greenhouse-Geisser düzeltmesi uygulanarak elde edilen F değerleri, Bonferroni Post-hoc testi sonuçları ile birlikte Tablo 21'de verilmiştir.



Tablo 21

## MLP Yönteminde Test Verisi Oranı İçin F Değerleri

Ölçüt	Örneklem büyüklüğü					
	500		1000		5000	
	F	Grup Farkı	F	Grup Farkı	F	Grup Farkı
Doğruluk	18.15*	I-II*	12.69*	I-II*	23.96*	I-II*
		I-III*		I-III*		I-III*
		I-IV*		I-IV*		I-IV*
		I-V*		I-V*		I-V*
		II-III*		II-III*		II-III*
		II-IV*		II-IV*		II-IV*
		II-V*		II-V*		II-V*
		III-IV		III-IV		III-IV
		III-V*		III-V		III-V*
		IV-V*		IV-V*		IV-V*
SH	2012.6*	I-II*	818.22*	I-II*	220.16*	I-II*
		I-III*		I-III*		I-III*
		I-IV*		I-IV*		I-IV*
		I-V*		I-V*		I-V*
		II-III*		II-III*		II-III*
		II-IV*		II-IV*		II-IV*
		II-V*		II-V*		II-V*
		III-IV*		III-IV*		III-IV*
		III-V*		III-V*		III-V*
		IV-V*		IV-V*		IV-V*

Not: I: %11. II: %22. III: %33. IV:%44. V: %55.

\* p<0.05

Tablo 19 ve Tablo 21 bir arada incelendiğinde, tüm örneklem büyüklükleri için %33 ile %44 test verisi oranları için elde edilen doğruluk oranları arasında anlamlı bir değişim görülmemektedir ( $p>0.05$ ). Diğer test verisi oranları için doğruluk oranları arasındaki azalma anlamlıdır ( $p<0.05$ ). Ayrıca, örneklem büyüdükçe doğruluk oranları test verisi miktarından benzer şekilde etkilenmektedir. Ancak, test verisi oranının artırılması, tüm örneklem büyüklükleri için doğruluk oranlarının standart sapma miktarlarında anlamlı bir azalmaya neden olmaktadır ( $p<0.05$ ). Buna göre, modelin öğrenme verisi az olduğunda doğruluk oranı ortalamaları düşmesine rağmen daha yüksek kesinlikte değerler elde edilmiştir.

## Dördüncü Alt Probleme İlişkin Bulgular

500, 1000 ve 5000 kişilik örneklem büyüklükleri için lojistik regresyon yönteminin test verisi oranı %11, %22, %33, %44 ve %55 olduğunda sınıflandırma doğruluk oranları ile standart sapma miktarları, Kappa uyum katsayıları ve ROC eğrisinin altında kalan alan değerleri nasıl farklılaşmaktadır?

Lojistik regresyon yöntemi için hesaplanan doğruluk oranları ortalamaları ve standart sapmaları, Kappa uyumu ve ROC eğrisinin altında kalan alan değerlerinin ortalamaları Tablo 22'de verilmiştir.

Tablo 22

### LR Yöntemi İçin Hesaplanan Performans Ölçüt Değerleri


Örneklem Büyüklüğü	Test verisi oranı (%)	Doğruluk (%)	SS	Kappa	ROC
500	11	75.30	5.32	0.44	0.80
	22	74.69	5.32	0.43	0.76
	33	73.94	2.97	0.41	0.77
	44	72.97	2.65	0.39	0.75
	55	71.62	2.51	0.36	0.73
1000	11	76.93	3.61	0.47	0.83
	22	76.70	2.47	0.47	0.83
	33	76.37	1.94	0.46	0.82
	44	75.88	1.66	0.45	0.81
	55	75.15	1.54	0.44	0.80
5000	11	78.30	1.56	0.51	0.85
	22	78.25	1.04	0.50	0.85
	33	78.19	0.81	0.50	0.85
	44	78.10	0.67	0.50	0.85
	55	77.96	0.57	0.50	0.85

Not:

SS: Doğruluk oranları için ortalama standart sapma (hata) değerleridir.

Tablo 22 incelendiğinde, LR yöntemi için elde edilen doğru sınıflandırma oranları 71.62 ile 78.30 arasında değişmektedir. Buna göre, LR yöntemi ile öğrenciler yüksek düzeyde doğrulukla alt ve üst gruplara yerleştirilmişlerdir. Doğruluk oranlarının standart sapmalarının ise 0.57 ile 5.32 arasında değişmesi elde edilen doğru sınıflandırma oranlarının farklı koşullarda güvenilirlik düzeyinin değiştiğini göstermektedir. Elde edilen doğru sınıflandırma performansı için geçerlik ölçütü olan Kappa uyum değerleri 0.36 ile 0.51 arasında; ROC değerleri


ise 0.73 ile 0.85 arasında değişmektedir. ROC eğrisi kullanarak modellerin değerlendirilmesinde alan değerinin 0,5'e yaklaşması model performansının düşük olduğunu, 1 veya 1'e yakın olması da performansın çok yüksek olduğunu gösterir (Han ve diğerleri, 2011). Kappa uyum değerlerinin 0-0.20 aralığında olması düşük, 0.21-0.40 aralığında olması kabul edilebilir, 0.41-0.60 arasında olması orta, 0.61-0.80 arasında olması oldukça iyi ve 0.81-1.00 arasında olması sınıflandırma tablosundaki mükemmel uyumu ifade eder (Landis ve Koch, 1977). Buna göre, elde edilen ROC eğrisinin altında kalan değerleri LR yöntemi ile yüksek düzeyde performans elde edildiğini, Kappa uyum değerleri ise hata matsindeki uyumun orta veya kabul edilebilir düzeyde olduğunu göstermiştir. Ayrıca, elde edilen ROC alan değerleri ile Kappa uyum değerleri, sınıflandırma sonuçlarının geçerliğine yüksek olduğuna ilişkin kanıtlar sunmaktadır. Doğruluk oranlarının farklı koşullarda nasıl değişim gösterdiği Şekil 20'de görselleştirilmiştir.



Şekil 20. LR Yöntemi İçin Doğruluk Oranının Tüm Koşullara Göre Değişimi

Şekil 20'ye göre, örneklem büyüdükçe doğru sınıflandırma oranı artmaktadır. 500 ve 1000 kişilik örneklerde test verisi oranının artırılması doğruluk oranlarında düşüşe neden olmuştur. Ancak, örneklem büyüdükçe test verisi oranının artırılmasının doğruluk oranları üzerindeki etkisi önemli ölçüde

azalmaktadır. Doğruluk oranlarının standart sapma miktarlarının farklı koşullarda nasıl değişim gösterdiği ise Şekil 21’de görselleştirilmiştir.



Şekil 21. LR Yöntemi İçin Doğruluk Oranlarının Standart Sapma Miktarının Tüm Koşullara Göre Değişimi

Şekil 21 incelendiğinde, örneklem büyüdükçe doğru oranlarının standart sapma miktarları önemli ölçüde azalmaktadır. Bu sapma, test verisi oranı %33 olana kadar önemli düşüş göstermiş daha sonra ise önemli bir azalma göstermemiştir. Ancak, örneklem büyüdükçe test verisi oranının artırılmasının doğruluk oranlarının standart sapma miktarları üzerindeki etkisi önemli ölçüde azalmaktadır. Buna göre, büyük örneklerde ve orta büyüklükte test verisi oranı olduğunda makul düzeyde güvenilir doğruluk oranları elde edilmiştir.

Örneklem büyüklüğü artırıldığında LR yönteminin doğruluk oranı ve standart sapma oranlarının istatistiksel olarak anlamlı derecede değişip değişmediği tek yönlü varyans analizi ile incelenmiştir. Öncesinde analizin varsayımlarının sağlandığı görülmüş ve analizler sonucunda elde edilen F değerleri, Bonferroni Post-hoc testi sonuçları ile birlikte Tablo 23’te verilmiştir.

Tablo 23

## LR Yönteminde Örneklem Büyüklüğü İçin F Değerleri

Ölçüt	Test verisi oranı									
	%11		%22		%33		%44		%55	
	F	Grup Farkı	F	Grup Farkı	F	Grup Farkı	F	Grup Farkı	F	Grup Farkı
Doğruluk	52.26*	I-II* I-III* II-III*	86.49*	I-II* I-III* II-III*	126.43*	I-II* I-III* II-III*	191.90*	I-II* I-III* II-III*	123.15*	I-II* I-III* II-III*
SS	1476.5*	I-II* I-III* II-III*	1879.4*	I-II* I-III* II-III*	1908.2*	I-II* I-III* II-III*	1990.0*	I-II* I-III* II-III*	2352.2*	I-II* I-III* II-III*

Not: I: örneklem büyüklüğü 500. II: örneklem büyüklüğü 1000. III: örneklem büyüklüğü 5000.

\*  $p < 0.05$

Tablo 22 ve Tablo 23 bir arada incelendiğinde, tüm test verisi oranları için örneklem büyüklüğü artırıldığında LR yönteminin doğruluk oranları anlamlı düzeyde artmış ve standart sapmaları anlamlı düzeyde azalmıştır ( $p < 0.05$ ). Buna göre, örneklemin büyümesi güvenilirliği yüksek sonuçların elde edilmesini sağlamaktadır. Örneklem büyüdükçe doğruluk oranları artarken, standart sapma miktarının düşmesi modelin daha çok veriyle daha iyi eğitilebildiğini göstermektedir.

Test verisi oranı arttıkça LR yönteminin doğruluk oranı ve standart sapma oranlarının istatistiksel olarak anlamlı derecede değişip değişmediği tekrarlı ölçümler için tek yönlü varyans analizi ile incelenmiştir. Analizin küresellik varsayımı dışında diğer varsayımlarının sağlandığı görülmüş ve bu nedenle Greenhouse-Geisser düzeltmesi uygulanarak elde edilen F değerleri, Bonferroni Post-hoc testi sonuçları ile birlikte Tablo 24'de verilmiştir.

Tablo 24

## LR Yönteminde Test Verisi Oranı İçin F Değerleri

Ölçüt	Örneklem büyüklüğü					
	500		1000		5000	
	F	Grup Farkı	F	Grup Farkı	F	Grup Farkı
Doğruluk	161.06*	I-II*	23.26*	I-II*	4.66*	I-II
		I-III*		I-III*		I-III*
		I-IV*		I-IV*		I-IV
		I-V*		I-V*		I-V
		II-III*		II-III*		II-III
		II-IV*		II-IV*		II-IV
		II-V*		II-V*		II-V
		III-IV*		III-IV		III-IV
		III-V*		III-V*		III-V
		IV-V*		IV-V*		IV-V*
SS	2228.9*	I-II*	1371.0*	I-II*	687.38*	I-II*
		I-III*		I-III*		I-III*
		I-IV*		I-IV*		I-IV*
		I-V*		I-V*		I-V*
		II-III*		II-III*		II-III*
		II-IV*		II-IV*		II-IV*
		II-V*		II-V*		II-V*
		III-IV*		III-IV*		III-IV*
		III-V*		III-V*		III-V*
		IV-V*		IV-V*		IV-V*

Not: I: %11. II: %22. III: %33. IV:%44. V: %55.

\*  $p < 0.05$

Tablo 22 ve Tablo 24 bir arada incelendiğinde, test verisi oranının arttıkça, 500 ve 1000 kişilik örneklem büyüklükleri için doğruluk oranları anlamlı bir azalma göstermektedir ( $p < 0.05$ ). 5000 kişilik örnekleme %11 ile %33 ve %44 ile %55 test verisi oranları arasındaki azalma anlamlıdır ( $p < 0.05$ ). Buna göre, örneklem büyüdükçe doğruluk oranları test verisi miktarından çok daha az etkilenmektedir. Örneklem çok küçük olduğunda karmaşık sayılabilecek bu modelin aşırı uyum sorununun yanında iyi eğitilememesi sorununu da ortaya çıkardığı görülmüştür. Ancak, test verisi oranının artırılması, tüm örneklem büyüklükleri için doğruluk oranlarının standart sapma miktarlarında anlamlı bir azalmaya neden olmaktadır ( $p < 0.05$ ). Bu azalma örneklem küçüldükçe daha belirgin hale gelmektedir. Bu sonuçlara göre, LR yöntemi modelin eğitilmesi için gerekli olan veri miktarı çok az olduğunda bile doğru sınıflandırma oranı ve güvenirliliği yüksek sonuçlar vermektedir.

## Beşinci Alt Probleme İlişkin Bulgular

*Naive Bayes, k-en yakın komşuluk, yapay sinir ağları çok katmanlı algılayıcı ve lojistik regresyon yöntemlerinin sınıflandırma doğruluk oranları ile standart sapma miktarları, analiz süreleri, Kappa uyum katsayıları ve ROC eğrisinin altında kalan alan değerleri farklı örneklem büyüklükleri ve test verisi oranlarına göre birbirinden nasıl farklılaşmaktadır?*

Tüm yöntemler için hesaplanan doğruluk oranları ortalamaları ve standart sapmaları, Kappa uyumu ve ROC eğrisinin altında kalan alan değerlerinin ortalamaları ve analiz işlem süreleri Tablo 25'te verilmiştir.

Tablo 25

### Tüm Yöntemler İçin Performans Ölçüt Değerleri

Örneklem büyüklüğü	Test verisi oranı (%)	NB			LR			MLP			KNN		
		Doğruluk (%)	SS	Süre (sn)	Doğruluk (%)	SS	Süre (sn)	Doğruluk (%)	SS	Süre (sn)	Doğruluk (%)	SS	Süre (sn)
500	11	75.93	5.38	0.00	75.30	5.32	0.04	72.80	5.66	0.72	71.81	5.01	0.03
	22	75.87	3.64	0.00	74.69	5.32	0.03	72.62	3.94	0.59	71.44	3.42	0.02
	33	75.78	2.82	0.00	73.94	2.97	0.03	72.27	3.25	0.50	71.05	2.80	0.02
	44	75.66	2.33	0.00	72.97	2.65	0.03	71.97	2.74	0.42	70.55	2.46	0.02
	55	75.41	2.02	0.00	71.62	2.51	0.02	71.56	2.54	0.35	70.06	2.31	0.01
1000	11	76.35	3.76	0.00	76.93	3.61	0.07	73.92	3.99	1.32	72.11	3.46	0.10
	22	76.27	2.54	0.00	76.70	2.47	0.06	73.65	2.84	1.16	71.97	2.39	0.09
	33	76.16	1.98	0.00	76.37	1.94	0.05	73.42	2.33	0.98	71.78	1.96	0.07
	44	76.04	1.63	0.00	75.88	1.66	0.04	73.07	2.05	0.82	71.57	1.72	0.06
	55	75.94	1.41	0.00	75.15	1.54	0.04	72.66	1.86	0.66	71.18	1.62	0.05
5000	11	76.60	1.70	0.00	78.30	1.56	0.36	76.36	1.79	6.54	74.52	1.57	2.05
	22	76.60	1.13	0.00	78.25	1.04	0.30	76.20	1.36	7.44	74.34	1.09	1.71
	33	76.58	0.86	0.00	78.19	0.81	0.25	76.04	1.14	4.93	74.14	0.86	1.50
	44	76.53	0.72	0.01	78.10	0.67	0.24	75.77	1.12	4.13	73.83	0.74	1.17
	55	76.48	0.61	0.01	77.96	0.57	0.25	75.53	1.06	0.35	73.50	0.67	1.03

Not:

SS: Doğruluk oranları için ortalama standart sapma değerleridir.

Tablo 25 incelendiğinde, tüm yöntemler için doğruluk oranlarının 70.06 ile 78.30 arasında değişmektedir. Buna göre, tüm yöntemler tüm koşullarda orta düzeyin üzerinde ve yüksek doğru sınıflandırma sonuçları vermiştir. 500 kişilik örneklemde NB yöntemi, 1000 ve 5000 kişilik örneklemde LR yöntemi en yüksek performansı göstermiştir. MLP yöntemi, tüm koşullarda NB ve LR yönteminden daha az ancak KNN yönteminden daha yüksek performans göstermiştir. Standart sapma oranlarına bakıldığında, örneklemin ve test verisi oranının büyümesi elde edilen sonuçların daha dar bir güven aralığında ve yüksek kesinlikte olmasını sağlamıştır.

KNN yönteminin doğruluk oranları diğer yöntemlere göre daha düşük olmakla birlikte tüm koşullarda en güvenilir sonuçları bu yöntem ile elde edilirken en az güvenilir sonuçlar MLP yöntemi ile elde edilmiştir. NB yönteminden elde edilen sonuçlar LR yöntemine göre daha geniş bir güven aralığına denk gelmektedir. Analiz sürelerine bakıldığında ise NB yöntemi tüm koşullarda neredeyse hiç zaman almadan işlemleri tamamlamıştır. KNN yöntemi, LR yönteminden biraz daha yavaş işlem yaparken MLP yöntemine göre daha hızlı bir şekilde analizleri gerçekleştirmiştir.

Tüm yöntemlerin doğruluk oranları ve standart sapmaları arasındaki ortalama farkın anlamlı olup olmadığı tekrarlı ölçümler için tek yönlü varyans analizi ile incelenmiştir. Analizin küresellik varsayımı dışında diğer varsayımlarının sağlandığı görülmüş ve bu nedenle Greenhouse-Geisser düzeltmesi uygulanarak elde edilen F değerleri, Bonferroni Post-hoc testi sonuçları ile birlikte Tablo 26'da verilmiştir.

Tablo 26

*Yöntem Karşılaştırması İçin F Değerleri*

Test verisi oranı	Ölçüt	Örneklem büyüklüğü		
		500	1000	5000
%11	Doğruluk	199.97*	238.30*	327.96*
	SS	39.50*	33.97*	32.55*
%22	Doğruluk	230.44*	288.64*	370.94*
	SS	53.85*	61.76*	99.85*
%33	Doğruluk	254.71*	309.79*	445.44*
	SS	81.82*	66.97*	171.33*
%44	Doğruluk	552.45*	715.57*	1467.67*
	SS	78.98*	100.67*	236.19*
%55	Doğruluk	671.88*	777.42*	1840.46*
	SS	157.29*	91.00*	485.57*

Notlar:

\*  $p < 0.05$

Tablo 26'ya göre, doğruluk oranları ve standart sapma miktarları açısından tüm koşullarda en az iki yöntem arasında anlamlı farklılık bulunmuştur ( $p < 0.05$ ). Ancak, doğruluk oranları arasındaki farkın büyüklüğü, tüm koşullar için standart sapmalarından daha büyüktür. Tablo 18'de elde edilen anlamlı farklılıkların hangi yöntemler arasında olduğunu görmek amacıyla 1. Tip hatayı önlemek için kullanılan güven aralığı düzeltmesi olan Bonferroni testi sonuçları incelenmiştir. Tablo 27'de yöntemlerin doğruluk oranları ve standart sapma miktarlarının tüm örneklem büyüklükleri ve test verisi oranları için ikili karşılaştırma sonuçları verilmiştir.



Tablo 27

## Farklı Koşullarda Yöntemler Arası Ortalama Fark Değerleri

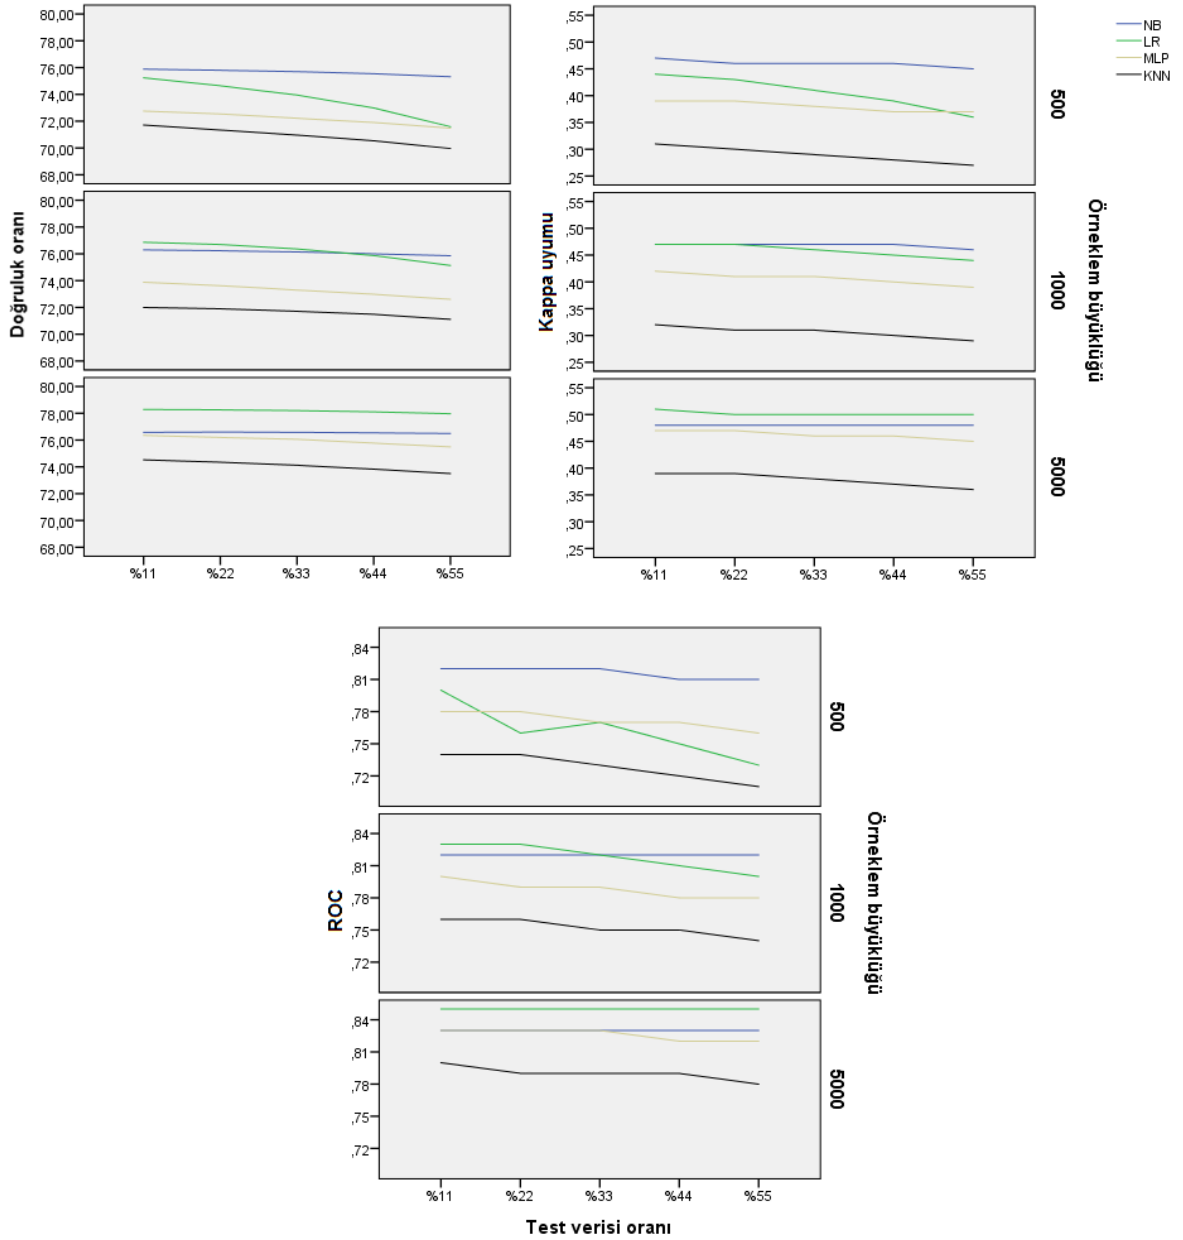
		Örneklem büyüklükleri											
		500				1000				5000			
		NB	LR	MLP	KNN	NB	LR	MLP	KNN	NB	LR	MLP	KNN
%11	NB		0.64*	3.13*	4.17*		-0.56*	2.41*	4.30*		-1.71*	0.23*	2.06*
	LR	0.06		2.48*	3.52*	-0.15*		2.97*	4.86*	0.14*		1.94*	3.76*
	MLP	-0.25*	-0.31*		1.04*	-0.23*	-0.38*		1.89*	-0.09*	-0.23*		1.83*
	KNN	-0.36*	-0.30*	-0.61*		-0.30*	-0.15	-0.53		-0.13*	0.01	-0.22*	
%22	NB		1.16*	3.26*	4.46*		-0.46*	2.61*	4.33*		-1.66*	0.40*	2.25*
	LR	-0.05		2.10*	3.31*	0.06		3.07*	4.80*	0.09*		2.06*	3.91*
	MLP	-0.26*	-0.21*		1.20*	-0.31*	-0.37*		1.72*	0.23*	-0.32*		1.84*
	KNN	-0.22*	-0.28*	-0.49*		-0.14*	-0.08	-0.45*		-0.04	0.05	-0.27*	
%33	NB		1.75*	3.48*	4.73*		-0.23	2.85*	4.43*		-1.63*	0.52*	2.45*
	LR	-0.15*		1.73*	2.98*	0.04		3.07*	4.66*	0.05*		2.15*	4.08*
	MLP	-0.39*	-0.25*		1.25*	-0.35*	-0.38*		1.59*	-0.28*	-0.33*		1.94*
	KNN	-0.02	-0.17*	-0.42*		-0.02	0.02	-0.37*		-0.01	0.05	-0.28*	
%44	NB		2.56*	3.64*	5.00*		0.13	3.02*	4.51*		-1.57*	0.77*	2.71*
	LR	-0.33*		1.08*	2.45*	-0.03		2.89*	4.39*	0.05*		2.34*	4.28*
	MLP	-0.41*	-0.09*		1.36*	-0.42*	-0.40*		1.50*	-0.41*	-0.45*		1.94*
	KNN	0.14*	-0.19*	-0.28*		0.09*	0.06	-0.34*		0.02	0.07*	-0.38*	
%55	NB		3.73*	3.84*	5.36*		0.72*	3.25*	4.74*		-1.47*	1.00*	2.99*
	LR	-0.49*		0.11	1.63*	-0.13*		2.53*	4.02*	0.04*		2.47*	4.46*
	MLP	-0.52*	-0.03		1.52*	-0.45*	-0.32*		1.49*	-0.45*	-0.49*		2.00*
	KNN	0.29*	-0.20*	-0.23*		0.21*	0.08	-0.24*		0.05	0.10*	-0.40*	

Notlar:

1. \* $p < 0.05$ 

2. Köşegenlerin üst kısmı (koyu renkte) doğruluk oranları için alt kısmı ise hata miktarları için hesaplanan ortalama fark değerlerini göstermektedir.

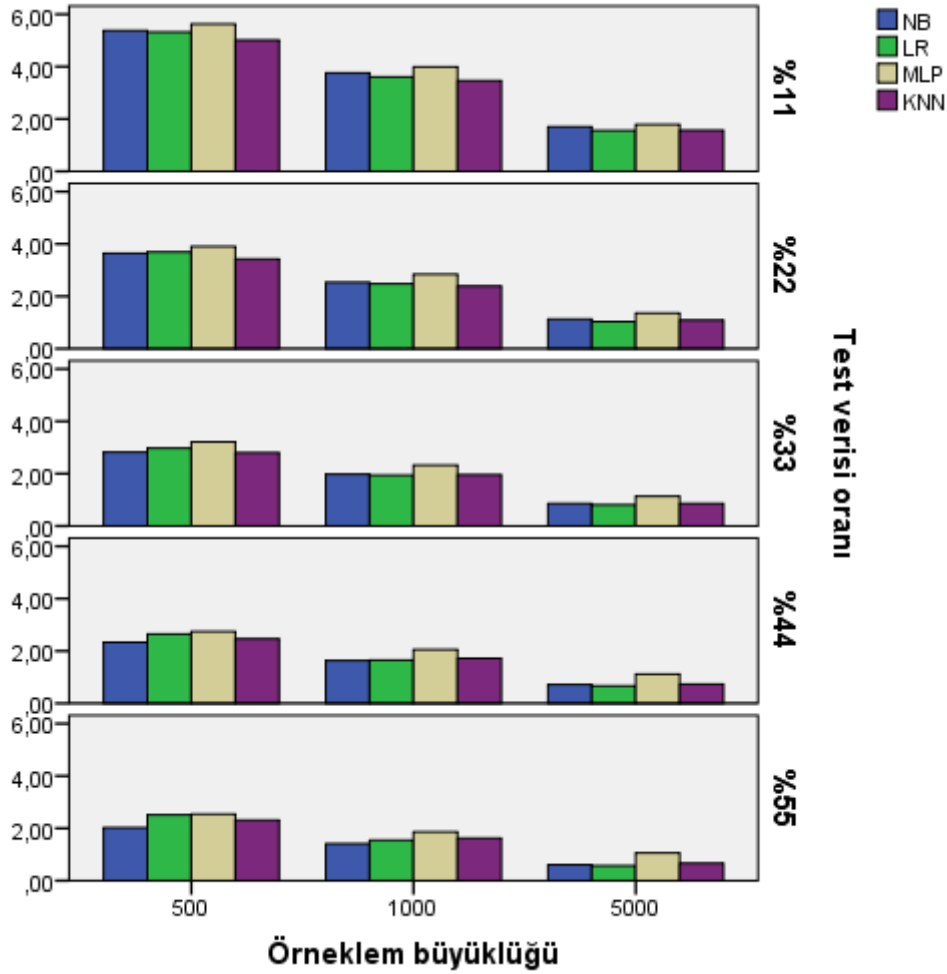
Tablo 27'ye göre, örneklem büyüklüğü 500 olduğunda test verisi oranı %55 için LR ve MLP yöntemleri arasında doğruluk oranları açısından anlamlı farklılık bulunamamıştır ( $p > 0.05$ ). Örneklem büyüklüğü 1000 olduğunda ise test verisi oranı %33 ve %44 için LR ve NB yöntemleri arasında doğruluk oranları açısından anlamlı farklılık bulunamamıştır ( $p > 0.05$ ). Diğer tüm koşullarda yöntemlerin doğruluk oranları anlamlı şekilde farklılaşmaktadır ( $p < 0.05$ ). Şekil 22'de yöntemlerin doğru sınıflandırma oranları arasındaki farklılıklar görsel hale getirilmiştir.



Şekil 22. Tüm Yöntemler İçin Doğruluk Oranlarının Farklı Koşullara Göre Değişimi

Şekil 22 incelendiğinde, örneklem büyüklüğünün artırılması NB yönteminde çok daha az olmakla birlikte tüm yöntemlerin sınıflandırma performanslarında artışa neden olmaktadır. Kappa ve ROC eğrisinin altında kalan değerleri doğruluk oranlarıyla genel olarak benzer bir seyir göstermektedir. 500 ve 1000 kişilik örneklerde test verisi oranının artırılması LR yönteminin performansında önemli bir azalmaya neden olurken, NB yöntemi bundan etkilenmemekte, diğer yöntemler ise LR yöntemine göre çok daha az etkilenmektedir. 5000 kişilik örnekte ise NB ve LR yöntemleri test verisi oranının artmasından etkilenmemekte, MLP ve KNN yöntemlerinin ise diğer örneklem büyüklüklerinde olduğu gibi az da olsa


performansları düşmektedir. Sonuç olarak, örneklem büyüklüğü artırıldığında LR yöntemi test verisi oranının değişiminden daha az etkilenirken, NB yöntemi bundan etkilenmemektedir. MLP ve KNN yöntemleri ise örneklem büyüklüğü artırıldığında bile doğruluk oranları açısından test verisi oranının artırılmasından benzer şekilde etkilenerek daha düşük performans göstermektedir. Şekil 23'te ise doğruluk oranlarının standart sapma miktarlarının karşılaştırılması verilmiştir.



Şekil 23. Tüm Yöntemler İçin Doğruluk Oranlarının Standart Sapma Miktarının Farklı Koşullara Göre Değişimi

Şekil 23'e göre, örneklemin büyümesi ve test verisi oranının artması, tüm yöntemlerin standart sapma miktarlarını önemli düzeyde azaltarak daha güvenilir ve yanlı olmayan sonuçların elde edilmesini sağlamaktadır. Hemen hemen tüm koşullarda MLP yöntemi diğer yöntemlerden daha yüksek standart sapmaya sahiptir. KNN yöntemi ile diğer yöntemlere göre çok daha düşük doğruluk oranları elde edilmesine rağmen bu yöntem standart sapma oranları açısından diğer yöntemlere göre benzer ya da daha düşük değerlere sahiptir. NB yöntemi küçük

örneklemelerde diğer yöntemlere göre daha az hatalı sonuçlar verirken örneklem büyüdükçe MLP yöntemi dışında diğer yöntemlerle benzer hata miktarlarına sahiptir. LR yöntemi ise küçük örneklemelerde NB ve KNN yöntemlerine göre daha fazla hata içeren sonuçlar verirken örneklem büyüdükçe diğer yöntemlerle benzer ya da daha az hata miktarları göstermektedir. Şekil 24'te ise yöntemlerin tüm koşullardaki analiz işlem süreleri verilmiştir.



Şekil 24. Yöntemlerin Analiz Sürelerinin Örneklem Büyüklüğü ve Test Verisi Oranına Göre Değişimi

Şekil 24 incelendiğinde, NB yöntemi tüm koşullarda neredeyse hiç zaman almadan analizleri gerçekleştirmektedir. 500 ve 1000 kişilik örneklemelerde LR ve KNN yöntemleri MLP yöntemine göre çok daha kısa sürede işlem yapmaktadır. Örneklem büyüklüğü 5000 olduğunda ise test verisi oranı %55 için KNN yöntemi diğer yöntemlerden daha fazla zaman almaktadır. MLP yöntemi test verisi oranı düşük olduğunda öğrenme verisi fazla olduğu için çok fazla zaman almaktadır. KNN yöntemi  $k$  değerinin seçilmesinde kullanılan  $k$ -katmanlı çapraz geçerlik yönteminden dolayı örneklemin büyümesi durumunda LR yönteminden daha fazla sürede işlemleri gerçekleştirmektedir.

## Bölüm 5

### Sonuç, Tartışma ve Öneriler

Bu bölümde araştırmanın bulgu ve yorumlarına dayalı olarak ulaşılan sonuçlar özetlenmiş, tartışılmış ve bu sonuçlardan yola çıkarak geliştirilen önerilere yer verilmiştir.

#### Sonuçlar

Araştırmanın bulgularına ve yorumlara yönelik ulaşılan sonuçlar alt problemlerin sırası gözetilerek sunulmuştur.

**Alt Problem 1.** *500, 1000 ve 5000 kişilik örneklem büyüklükleri için Naive Bayes yönteminin test verisi oranı %11, %22, %33, %44 ve %55 olduğunda sınıflandırma doğruluk oranları ile standart sapma miktarları, Kappa uyum katsayıları ve ROC eğrisinin altında kalan alan değerleri nasıl farklılaşmaktadır?*

1. Naive Bayes yöntemi, tüm örneklem büyüklükleri ve test verisi oranları için yüksek doğru sınıflandırma sonuçları vermiştir. Tüm koşullar için elde edilen Kappa ve ROC eğrisinin altında kalan alan değerleri, yapılan sınıflandırmanın şansa sınıflandırmanın ötesinde yüksek olasılıkla doğru olduğunu göstermektedir. Kappa ve ROC eğrisinin altında kalan alan değerleri, Naive Bayes yöntemi ile elde edilen yüksek doğru sınıflandırma oranlarının aynı zamanda geçerliğinin de yüksek olduğunu göstermiştir. Sonuç olarak, NB yöntemi öğrencileri PISA matematik performanslarına göre yüksek düzeyde doğrulukla alt ve üst gruplara yerleştirerek güvenilirliği ve geçerliği yüksek bir yordama işlemi gerçekleştirmiştir.

2. Küçük örneklerde ve orta büyüklükteki örneklerde, Naive Bayes yöntemi benzer doğru sınıflandırma oranları elde edilmiştir. Ancak, büyük örneklerde doğru sınıflandırma oranları diğer örneklem büyüklüklerine göre daha yüksektir. Örneklem önemli düzeyde artırdığında Naive Bayes yöntemi ile daha yüksek doğru sınıflandırma performansı elde edilmiştir. Doğru sınıflandırma oranlarının standart sapmaları, örneklem büyüdükçe daha güvenilir sonuçların elde edildiğini göstermektedir. Buna göre, örneklem büyüklüğünün artırılması Naive Bayes yöntemi ile aynı zamanda daha güvenilir sonuçların elde edilmesini sağlamaktadır. Bu sonuçlara göre, örneklem büyüklüğü arttığında alt ve üst gruplarda yer alan öğrenci sayılarının artmasıyla birlikte frekans tablolarındaki

hücrelere düşen birey sayıları da artmakta ve yöntem daha yüksek bir kararlılıkta doğru sınıflandırma işlemi gerçekleştirmektedir.

3. Test verisi oranının artırılması, Naive Bayes yönteminin doğruluk oranlarında önemli bir değişim yaratmamıştır. Ancak, test verisi oranı arttıkça daha yüksek kesinlikte doğru sınıflandırma oranları elde edilmiştir. Test verisinin artması, örneklem büyüklüğünde olduğu gibi frekans tablolarındaki öğrenci sayılarının artmasını sağlarken var olan modelin yeni gelen verileri hangi sınıfa atayacağını daha iyi seçilebildiğini göstermektedir. Sonuçta, Naive Bayes yöntemi, çok az veri ile eğitildiği zaman bile yüksek düzeyde güvenilir ve geçerli doğru sınıflandırma performansı göstermiştir.

4. Araştırma sonuçları, Naive Bayes yönteminin temel varsayımı olan koşullu bağımsızlık şartı sağlanmadığında bile yüksek doğru sınıflandırma oranları elde edilebildiğini göstermektedir. Değişkenler arası orta düzeyde ilişki olduğunda ve çoklu bağlantı problemi olmadığında bu yöntemin farklı yapıdaki değişkenlere göre yapılacak sınıflandırma işlemlerinde etkili bir şekilde kullanılabileceği görülmüştür. Ayrıca, yöntem, bağımlı değişkenin kategorilerine düşük düzeyde dengesiz dağılım gösteren veride geçerli ve güvenilir sonuçlar vermiştir.

**Alt Problem 2.** *500, 1000 ve 5000 kişilik örneklem büyüklükleri için k-en yakın komşuluk yönteminin test verisi oranı %11, %22, %33, %44 ve %55 olduğunda sınıflandırma doğruluk oranları ile standart sapma miktarları, Kappa uyum katsayıları ve ROC eğrisinin altında kalan alan değerleri nasıl farklılaşmaktadır?*

1. k-en yakın komşuluk yöntemi, tüm koşullar bir arada değerlendirildiğinde orta düzeyin üzerinde doğru sınıflandırma performansı göstermiştir. Kappa ve ROC eğrisinin altında kalan değerleri incelendiğinde, yapılan sınıflandırma işleminin şansa sınıflandırmanın ötesinde bir doğruluğa sahip olduğu görülmüştür. Buna göre, farklı kaynaklardan elde edilen performans ölçüt değerleri, en yakın komşuluk yöntemi ile elde edilen sonuçları doğrularak geçerliğinin yüksek olduğunu göstermiştir. Sonuç olarak, KNN yöntemi öğrencileri PISA matematik performanslarına göre orta düzeyin üzerinde veya yüksek düzeyde doğrulukla alt ve üst gruplara yerleştirerek güvenilirliği ve geçerliği yüksek bir yordama işlemi gerçekleştirmiştir.

2. Örneklem büyüklüğünün artırılması, en yakın komşuluk yönteminin doğru sınıflandırma performansını önemli düzeyde artırmıştır. Bu artış tüm test verisi oranları için benzer şekilde gerçekleşmiştir. Doğruluk oranlarının standart sapmaları, örneklem büyüdükçe önemli ölçüde azalmıştır. Buna göre örneklemin büyümesi, en yakın komşuluk yönteminin doğru sınıflandırma performansını artırarak daha güvenilir ve geçerli sonuçların elde edilmesini sağlamıştır. Bu sonuçlara göre, örneklem büyüklüğü arttığında alt ve üst grumlarda yer alan öğrenci sayılarının artmasıyla birlikte frekans tablolarındaki hücrelere düşen birey sayıları da artmakta ve yöntem daha yüksek bir kararlılıkta doğru sınıflandırma işlemi gerçekleştirmektedir.

3. Test verisi oranının artırılması, k-en yakın komşuluk yönteminin doğruluk oranlarında önemli bir azalmaya neden olmuştur. Ancak, test verisi oranı arttıkça doğruluk oranlarının standart sapmaları azalmış ve daha yüksek kesinlikte sınıflandırma sonuçları elde edilmiştir. Test verisinin artması, örneklem büyüklüğünde olduğu gibi frekans tablolarındaki öğrenci sayılarının artmasını sağlarken var olan modelin yeni gelen verileri hangi sınıfa atayacağını daha iyi seçilebildiğini göstermektedir. Sonuçta, en yakın komşuluk yöntemi öğrenme verisi az olduğunda daha düşük doğrulukta daha güvenilir sonuçlar vermiştir. Orta düzeydeki test verisi oranlarında makul düzeyde güvenilir ve yüksek doğru sınıflandırma performansı elde edilmiştir.

4. En yakın komşuluk yöntemi, seçilen k değerine çok duyarlı olduğundan, araştırmada bu değer seçilmesinde kullanılan k-katmanlı çapraz geçerlik yönteminin yüksek doğru sınıflandırma performansı elde edilmesinde etkili olduğu görülmüştür. Ayrıca, araştırmada analizlere geçmeden önce öğrencilerin matematik performanslarına göre sınıflandırılmasında katkısı olmayacak değişkenlerin ayrıştırılması, yöntemin yüksek performans göstermesinde etkili olmuştur.

**Alt Problem 3.** *500, 1000 ve 5000 kişilik örneklem büyüklükleri için yapay sinir ağıları çok katmanlı algılayıcı yönteminin test verisi oranı %11, %22, %33, %44 ve %55 olduğunda sınıflandırma doğruluk oranları ile standart sapma miktarları, Kappa uyum katsayıları ve ROC eğrisinin altında kalan alan değerleri nasıl farklılaşmaktadır?*

1. Yapay sinir ağıları için kullanılan çok katmanlı algılayıcı yöntemi hemen hemen tüm koşullarda yüksek düzeyde doğru sınıflandırma performansı göstermiştir. Kappa ve ROC eğrisinin altında kalan değerleri elde edilen doğru sınıflandırma performansının geçerliğine yönelik kanıtlar sunarak yapılan işlemin şansa sınıflandırmanın ötesinde yüksek olasılıkla doğru olduğunu göstermiştir. Buna göre, yapay sinir ağıları yöntemi ile elde edilen doğru sınıflandırma oranlarının yüksek düzeyde geçerliğe sahip olduğu görülmüştür. Sonuç olarak, MLP yöntemi öğrencileri PISA matematik performanslarına göre orta düzeyin üzerinde veya yüksek düzeyde doğrulukla alt ve üst gruplara yerleştirerek güvenilirliği ve geçerliği yüksek bir yordama işlemi gerçekleştirmiştir.

2. Örneklem büyüklüğünün artırılması, yöntemin doğru sınıflandırma oranlarında önemli bir artışa neden olmuştur. Bu artış, test verisi oranı fazla olduğunda daha belirgin hale gelmiştir. Buna göre, yapay sinir ağıları yöntemi örneklem büyüdükçe modelin eğitilmesi için gerekli olan veri miktarının artmasından dolayı performansı önemli ölçüde artmıştır. Büyük örneklerde, öğrenme verisi az olduğunda bile yüksek doğru sınıflandırma oranları elde edilmiştir. Bu sonuçlara göre, örneklem büyüklüğü arttığında alt ve üst gruplarda yer alan öğrenci sayılarının artmasıyla birlikte frekans tablolarındaki hücelere düşen birey sayıları da artmakta ve yöntem daha yüksek bir kararlılıkta doğru sınıflandırma işlemi gerçekleştirmektedir.

3. Doğruluk oranlarının standart sapma miktarları örneklemin büyümesinden önemli ölçüde etkilenmiştir. Buna göre, orta ve küçük örneklerde sınıflandırılan test verisi miktarı az olduğunda elde edilen doğruluk oranları düşük düzeyde güvenilirliğe sahiptir. Sonuç olarak, yapay sinir ağıları yöntemi, örneklem büyüdükçe test verisi oranı değişiminden daha az etkilenecek daha güvenilir sonuçlar vermiştir.

4. Test verisi oranının artırılması, yöntemin doğruluk oranlarında ve bu oranların standart sapma miktarlarında önemli düzeyde azalmaya neden olmuştur. Buna göre, test verisi oranı arttıkça daha az doğruluğa sahip daha güvenilir sonuçlar elde edilmiştir. Büyük örneklerde test verisi oranının yapay sinir ağılarının doğru sınıflandırma performansı üzerindeki etkisi küçük örneklemelere göre çok daha azdır. Test verisinin artması, örneklem büyüklüğünde olduğu gibi frekans tablolarındaki öğrenci sayılarının artmasını sağlarken var olan modelin yeni gelen verileri hangi sınıfa atayacağını daha iyi seçilebildiğini göstermektedir.



5. Yapay sinir ağırları yönteminde, katman sayısı, katmanlardaki düğüm sayısı, ağırlıklandırmalar gibi birçok parametre modellerin sınıflandırma performansını önemli ölçüde etkilemektedir. Araştırma sonuçları, çok fazla parametre içermesine rağmen yapay sinir ağırları yönteminin sınıflandırma problemlerinin çözümünde etkili olduğunu göstermiştir. Ayrıca, yöntem, kayıp, gürültü ve uç veriye karşı duyarlı olduğundan, bu değerlerin olmaması yüksek performans elde edilmesini sağlamıştır.

**Alt Problem 4.** *500, 1000 ve 5000 kişilik örneklem büyüklükleri için lojistik regresyon yönteminin test verisi oranı %11, %22, %33, %44 ve %55 olduğunda sınıflandırma doğruluk oranları ile standart sapma miktarları, Kappa uyum katsayıları ve ROC eğrisinin altında kalan alan değerleri nasıl farklılaşmaktadır?*

1. Lojistik regresyon yöntemi, tüm örneklem büyüklükleri ve test verisi oranları için yüksek düzeyde doğru sınıflandırma performansı göstermiştir. ROC eğrisinin altında kalan ve Kappa uyum istatistiği değerleri yapılan sınıflandırma işleminin şansa sınıflandırmanın ötesinde yüksek olasılıkla doğru olduğunu göstermiştir. Sınıflandırma tablosundan elde edilen yüksek doğruluk oranları, ROC ve Kappa değerleri lojistik regresyon yönteminden elde edilen sonuçların geçerliğinin de yüksek olduğunu göstermiştir. Sonuç olarak, LR yöntemi öğrencileri PISA matematik performanslarına göre orta düzeyin üzerinde veya yüksek düzeyde doğrulukla alt ve üst gruplara yerleştirerek güvenilirliği ve geçerliği yüksek bir yordama işlemi gerçekleştirmiştir.

2. Örneklem büyüklüğünün artırılması, yöntemin doğru sınıflandırma oranlarında önemli düzeyde artışa neden olmuştur. Doğruluk oranlarının standart sapma miktarları ise örneklem büyüdükçe azalarak daha yüksek kesinlikte sonuçların elde edilmesini sağlamıştır. Buna göre, lojistik regresyon yönteminde örneklemin büyümesiyle model hatalarının azalmasından dolayı daha yüksek doğrulukta ve daha güvenilir sonuçlar elde edilmiştir. Bu sonuçlara göre, örneklem büyüklüğü arttığında alt ve üst gruplarda yer alan öğrenci sayılarının artmasıyla birlikte frekans tablolarındaki hücrelere düşen birey sayıları da artmakta ve yöntem daha yüksek bir kararlılıkta doğru sınıflandırma işlemi gerçekleştirmektedir.

3. Test verisi oranının artırılması orta ve küçük örneklerde doğruluk oranlarında önemli ölçüde azalmaya neden olurken, büyük örneklerde test verisi

oranının artırılmasının doğruluk oranlarında bir deęişim yaratmadığı görülmüştür. Test verisi oranı az olduęunda, küçük örneklemlerde daha belirgin olmakla birlikte daha az güvenilir sonuçlar elde edilmesine neden olmuştur. Buna göre, lojistik regresyon yönteminde orta ve küçük örneklemlerde test verisi oranının orta düzeyin üzerinde olmasının yüksek doğrulukta ve güvenilir sonuçlar elde edilmesinde etkili olduęu görülmüştür. Lojistik regresyon analizi, büyük örneklemlerde test verisi oranı çok az ya da çok fazla olduęunda bile yüksek doğru sınıflandırma performansı göstermiştir.

4. Araştırmada kullanılan verinin varyans-kovaryans matrislerinin homojenliği varsayımı dışında kayıp, gürültü ve uç deęerler, normallik, doğrusallık ve çok bağlantı gibi varsayımları karşılaması, lojistik regresyon analizinin yüksek performans göstermesinde etkili olmuştur. Araştırma sonuçları, yöntemden genel olarak yüksek performans elde edilmesine karşın, lojistik regresyon analizinin küçük örneklemlere karşı hassas olduęunu ortaya koymuştur. Böyle bir durumun oluşmasında kullanılan deęişken sayısının da önemli bir faktör olduęu görülmektedir.

**Alt Problem 5.** *Naive Bayes, k-en yakın komşuluk, yapay sinir aęları çok katmanlı algılayıcı ve lojistik regresyon yöntemlerinin sınıflandırma doğruluk oranları ile standart sapma miktarları, analiz süreleri, Kappa uyum katsayıları ve ROC eğrisinin altında kalan alan deęerleri farklı örneklem büyüklükleri ve test verisi oranlarına göre birbirinden nasıl farklılaşmaktadır?*

Öğrencilerin PISA matematik başarılarına göre sınıflandırılmasında seçilen yöntemlerin deęişen koşullar altında genel olarak orta düzeyin üzerinde veya yüksek performans gösterdiği görülmüştür. Doğruluk oranı, Kappa uyumu ve ROC eğrisinin altında kalan alan deęerlerinin benzer seyir göstermesi yapılan sınıflandırma işlemlerinin geçerlięinin yüksek olduęunu göstermiştir. Yöntemlerin performansların karşılaştırılmasına yönelik sonuçlar örneklem büyüklüklerine göre ayrı ayrı sunulacaktır.

Buna göre, küçük örneklemler ( $n=500$ ) için sonuçlar şu şekildedir:

1. Küçük örneklemlerde Naive Bayes tüm test verisi oranları için en yüksek doğru sınıflandırma performansını göstermiştir. Daha sonra ise sınıflandırma

performansı açısından yüksekten düşüğe lojistik regresyon, yapay sinir ağları ve en yakın komşuluk yöntemi şeklinde sıralanmıştır.

2. Küçük örneklerde, lojistik regresyon analizi, diğer yöntemlere göre modelin eğitilmesi için gerekli olan veri miktarının azalması yöntemin performansını önemli ölçüde düşürmüştür. En yakın komşuluk yöntemi ve yapay sinir ağları bu değişimden daha az etkilenirken, test verisi oranının arttığında, Naive Bayes yönteminin doğruluk oranları değişmemiştir.

3. Analiz süresi açısından Naive Bayes yöntemi zaman almazken yapay sinir ağları yöntemi diğer yöntemlere göre daha uzun sürede işlem gerçekleştirmiştir. En yakın komşuluk ve lojistik regresyon yöntemleri benzer sürede analizleri gerçekleştirmişlerdir. Naive Bayes yöntemi hariç diğer yöntemler için test verisi oranının artması analiz süresini kısaltmıştır.

4. Doğruluk oranlarının standart sapma miktarlarına bakıldığında ise genel olarak en güvenilir sonuçlar yine Naive Bayes yöntemi ile elde edilmiştir. Daha sonra ise bu yöntemi sırasıyla en yakın komşuluk, lojistik regresyon ve yapay sinir ağları izlemiştir.

5. Tüm yöntemler için en güvenilir sonuçlar test verisi oranı yüksek olduğunda elde edilmiştir. Buna göre, doğruluk oranı yüksek olduğunda sonuçlar daha az güvenilirdir. Bu nedenle, küçük örneklerde Naive Bayes yöntemi hariç diğer yöntemler için düşük olmayan güvenilir doğruluk oranları orta büyüklükteki test verisi oranları için elde edilmiştir. Naive Bayes yönteminde ise en güvenilir doğruluk oranları test verisi oranı yüksek olduğunda elde edilmiştir.

Küçük örneklerle yönelik tüm sonuçlar bir arada değerlendirildiğinde Naive Bayes yöntemi diğer yöntemlere göre daha yüksek sınıflandırma performansı göstermiş, doğruluk oranları açısından test verisi oranı değişiminden etkilenmemiş, analizleri daha kısa sürede gerçekleştirerek geçerliği ve güvenilirliği yüksek sonuçlar vermiştir. Yapay sinir ağları yönteminin, en yakın komşuluk yöntemine göre daha yüksek doğru sınıflandırma performansı göstermesine karşın sonuçlarının güvenilirliğinin düşük olması ve çok zaman almasından dolayı küçük örneklerde diğer yöntemlere göre daha az kullanışlı olduğu görülmüştür.

Orta büyüklükteki örnekler ( $n=1000$ ) için sonuçlar şu şekildedir:

1. Orta büyüklükteki örneklerde test verisi oranı düşük olduğunda lojistik regresyon, yüksek olduğunda Naive Bayes yöntemi, orta büyüklükte olduğunda ise iki yöntem benzer performans göstermiştir. Yapay sinir ağları yöntemi, bu iki yöntemden daha düşük ancak en yakın komşuluk yönteminden daha yüksek doğru sınıflandırma performansı göstermiştir.

2. Test verisi oranının artırılması orta büyüklükteki örneklerde küçük örneklerdeki benzer bir etki yaratmıştır. Buna göre, test verisi oranının artması lojistik regresyon analizi yönteminin performansını önemli ölçüde düşürmüştür. En yakın komşuluk yöntemi ve yapay sinir ağları bu değişimden daha az etkilenirken, test verisi oranının arttığında, Naive Bayes yönteminin doğruluk oranları değişmemiştir.

3. Yöntemlerin analiz süreleri incelendiğinde küçük örneklerde olduğu gibi Naive Bayes yöntemi yine neredeyse hiç zaman almazken yapay sinir ağları en uzun sürede analizleri gerçekleştirmiştir. En yakın komşuluk yöntemi ise lojistik regresyon analizine göre daha uzun sürede işlemleri gerçekleştirmiştir. Naive Bayes yöntemi hariç diğer yöntemler için test verisi oranının artması analiz süresini kısaltmıştır.

4. Doğruluk oranlarının standart sapmaları, yapay sinir ağlarının tüm test verisi oranlarında diğer yöntemlere göre daha az güvenilir sonuçlar verdiğini göstermiştir. Naive Bayes ve lojistik regresyon analizi genel olarak benzer güvenilirlikte doğruluk oranlarına sahip iken test verisi oranı arttıkça iki yöntemden elde edilen doğru oranlarının güvenilirliği diğer yöntemlere göre daha yüksek bir artış göstermektedir. En yakın komşuluk yöntemi ise test verisi oranı düşük olduğunda bu iki yöntemden daha fazla güvenilir, yüksek olduğundan ise daha az güvenilir sonuçlar vermektedir.

5. Küçük örneklerde olduğu gibi orta büyüklükteki örneklerde de test verisi oranının artırılması tüm yöntemler için daha güvenilir doğruluk oranlarının elde edilmesini sağlamaktadır. Buna göre orta büyüklükte test verisi kullanımı Naive Bayes yöntemi hariç diğer yöntemler için orta güvenilirlikte ve doğrulukta sonuçların elde edilmesini sağlamaktadır. Naive Bayes yönteminde ise öğrenme verisi çok az olduğunda bile yüksek doğrulukta güvenilir sonuçlar elde edilebilmektedir.

Orta büyüklükteki örneklemelere yönelik tüm sonuçlar bir arada değerlendirildiğinde Naive Bayes yöntemi ile lojistik regresyon yöntemi benzer sonuçlar vermiştir. Ancak, test verisi oranının etkisi ve analizler için gerekli süre göz önünde bulundurulduğunda Naive Bayes yönteminin daha kullanışlı olduğu görülmüştür. En yakın komşuluk yöntemine diğer yöntemlere göre daha düşük doğru sınıflandırma performansı göstermiştir. Ancak, yapay sinir ağları yönteminde elde edilen sonuçlarının güvenilirliğinin düşük olması ve çok zaman almasından dolayı diğer yöntemlere göre daha az kullanışlı olduğu görülmüştür.

Büyük örneklemeler (n=5000) için sonuçlar şu şekildedir:

1. Büyük örneklemelerde lojistik regresyon analizi ile diğer yöntemlere göre tüm test verisi oranları için en yüksek doğruluk oranları elde edilmiştir. Test verisi oranı az olduğunda Naive Bayes ve yapay sinir ağları yöntemi benzer performans göstermesine karşın test verisi oranı arttıkça Naive Bayes yöntemi daha yüksek doğru sınıflandırma oranı vermiştir. En yakın komşuluk yöntemi ise tüm test verisi oranları için en düşük performans göstermiştir.

2. Test verisi oranının artırılması, lojistik regresyon ve yapay sinir ağlarının performansların önemli bir değişim yaratmazken diğer yöntemlerin doğruluk oranları benzer bir düşüş göstermiştir.

3. Yöntemlerin analiz süreleri incelendiğinde, test verisi oranı az olduğunda yapay sinir ağları analizi çok zaman alırken Naive Bayes yöntemi neredeyse hiç zaman almıştır. En yakın komşuluk analizi ise lojistik regresyon analizine göre daha uzun sürede işlem yapmıştır. Ancak test verisi oranı arttıkça tüm yöntemler işlem süresi düşerken yapay sinir ağları yöntemi yüksek büyüklükteki test verisi oranlarında en yakın komşuluk yönteminden daha kısa sürede ve lojistik regresyon ile neredeyse aynı sürede analizleri gerçekleştirmiştir. Buna göre test verisi oranının artması yapay sinir ağları yönteminin işlem süresini diğer yöntemlere göre çok daha fazla kısaltmıştır.

4. Büyük örneklemelerde tüm yöntemler güvenilir sonuçlar vermiştir. Yapay sinir ağları yöntemi diğer yöntemlere göre daha az güvenilir sonuçlar vermiştir. Test verisi oranı arttıkça tüm yöntemlerde birbirine yakın ve daha yüksek kesinlikte doğruluk oranları elde edilmiştir.

5. Test verisi oranının yüksek olması lojistik regresyon ve Naive Bayes yöntemlerinde düşük test verisi oranları ile aynı doğrulukta ancak daha güvenilir sonuçların elde edilmesini sağlamıştır. Orta büyüklükte test verisi kullanımı en yakın komşuluk ve sinir ağıları yöntemleri için orta güvenilirlikte ve doğrulukta sonuçların elde edilmesini sağlamaktadır.

Büyük örneklem için elde edilen tüm sonuçlar bir arada değerlendirildiğinde lojistik regresyon analizi diğer yöntemlere göre yüksek performans göstermiştir. Test verisi oranının etkisi ve analizler için gerekli süre göz önünde bulundurulduğunda Naive Bayes yöntemi ile benzerlik gösterirken diğer yöntemlere göre daha kullanışlı olduğu görülmüştür. Yapay sinir ağıları yöntemi, en yakın komşuluk yöntemine göre daha yüksek performans göstermesine karşın daha az güvenilir sonuçlar verdiği ve daha fazla zaman aldığından dolayı daha az kullanışlı olduğu görülmüştür.

Genel olarak, farklı örneklem büyüklüklerinin ve test verisi oranlarının yöntemlerin performansları üzerinde yarattığı etkiler şu şekildedir:

1. Örneklem büyüdükçe, tüm yöntemlerin doğru sınıflandırma performansları artmış geçerliliği ve güvenilirliği yüksek sonuçlar elde edilmiştir.

2. Örneklem büyüdükçe, Naive Bayes yönteminin analiz süresi değişmemekle birlikte diğer yöntemlerin analiz işlem süreleri uzamıştır.

3. Test verisi oranı örneklem büyüklüğüne göre yöntemlerin sınıflandırma performanslarında farklı etkiler yaratmıştır.

4. Örneklem büyüdükçe test verisi oranının artırılmasının yöntemlerin performansları üzerindeki etkisi azalmıştır.

5. Test verisi oranı tüm verinin üçte birinden az olduğunda da yüksek doğru sınıflandırma performansları elde edilmiştir.

6. Örneklem büyüdükçe test verisi oranı tüm verinin üçte birinden fazla olduğunda bile güvenilir sınıflandırma performansları elde edilebilmiştir.

7. Tüm örneklem büyüklükleri için test verisi oranının değişiminden en az etkilenen yöntem Naive Bayes yöntemidir.

8. Örneklem büyüklüğünün artmasından en fazla etkilenen yöntem lojistik regresyon analizidir.

9. Tüm koşullarda en düşük doğruluk oranları en yakın komşuluk yöntemi ile elde edilmiştir.

## Tartışma

Bu başlık altında araştırmanın bulgu ve yorumlarına dayalı olarak ulaşılan sonuçlar detaylı bir şekilde her bir alt problem için ayrı ayrı tartışılmıştır.

**Alt Problem 1.** *500, 1000 ve 5000 kişilik örneklem büyüklükleri için Naive Bayes yönteminin test verisi oranı %11, %22, %33, %44 ve %55 olduğunda sınıflandırma doğruluk oranları ile standart sapma miktarları, Kappa uyum katsayıları ve ROC eğrisinin altında kalan alan değerleri nasıl farklılaşmaktadır?*

NB yöntemi kullanılarak farklı koşullarda elde edilen doğru sınıflandırma oranlarının, Kappa ve ROC eğrisinin altında kalan alanlar ile birlikte değerlendirildiğinde yüksek düzey doğru ve geçerli olduğu söylenebilir. NB yöntemi küçük örneklemelerde bile yüksek doğru sınıflandırma oranları vermiştir. Bu sonuç, NB yönteminin basit istatistiksel yapısından ileri gelmektedir (Dunham, 2003; Hamalainen ve Vinni, 2011; Tan ve diğerleri, 2014). Hamalainen ve Vinni (2011), Naive Bayes yönteminde koşullu bağımsızlık varsayımının çoğunlukla sağlanmadığını ancak yine iyi sonuçlar elde edilebildiğini belirtmektedir. Araştırmada kullanılan değişkenlerin koşullu bağımsızlık varsayımını sağlamamasına rağmen NB yöntemi ile yine de iyi bulgular elde edilmesi bu sonucu destekler niteliktedir.

Araştırmada test verisi oranının artırılması, doğruluk oranlarında önemli bir değişim yaratmazken bu değerlerin güven aralığını daraltmaktadır. Brain ve Webb (1999) yaptıkları çalışmada test verisi oranının artırmanın yanlı sonuçlar elde edilmesine neden olduğunu söylemenin her zaman doğru olmadığını, bu etkinin test verisinin yapısıyla yakından ilişkili olduğunu belirtmişlerdir. Michie ve diğerleri (1994) ise test verisi oranı olarak verinin genellikle %20-30'luk bir kısmının kullanıldığını ifade etmişlerdir. Sonuç olarak, NB yöntemi için, alan yazından sıklıkla tercih edilen ve birçok yazılımda önceden ayarlanmış (default) şekilde yer alan tüm verinin üçte biri (%67) oranında öğrenme verisi kullanmanın diğer öğrenme verisi oranlarına göre önemli bir farklılık yaratmadığı görülmüştür. Ancak örneklem büyüklüğünün önemli ölçüde (500'den 5000'e) artırılması daha güvenilir ve genellenebilir sonuçların elde edilmesini sağlamaktadır.

Değişkenler arasındaki ilişkilerin orta düzeyde ve kabul edilebilir olması yüksek performans ölçüt değerlerinin elde edilmesini sağlamıştır. Tan ve diğerleri, (2014), Naive Bayes yönteminin yüksek düzeyde olmadığı sürece değişkenler arası basit ilişkilerde bile oldukça iyi sonuçlar verdiğini ifade etmişlerdir. Araştırmadan elde edilen bulgular yöntemin bu karakteristik özelliğini sergileyerek iyi sonuçlar verdiğini göstermektedir. Ayrıca, 6 sürekli ve 4 kategorik değişkenden oluşan karmaşık modellerde bile NB yönteminin etkili sonuçlar verdiği görülmektedir.

**Alt Problem 2.** *500, 1000 ve 5000 kişilik örneklem büyüklükleri için k-en yakın komşuluk yönteminin test verisi oranı %11, %22, %33, %44 ve %55 olduğunda sınıflandırma doğruluk oranları ile standart sapma miktarları, Kappa uyum katsayıları ve ROC eğrisinin altında kalan alan değerleri nasıl farklılaşmaktadır?*

KNN yöntemi kullanılarak farklı koşullarda elde edilen doğru sınıflandırma oranlarının, Kappa ve ROC eğrisinin altında kalan alanlar ile birlikte değerlendirildiğinde orta düzeyin üzerinde doğru ve geçerli olduğu görülmüştür. Bu sonuçların elde edilmesinde sınıflandırma hatasını minimize eden k değerinin seçilmesini ön gören k-katmanlı çapraz geçerlik yöntemi (Larose ve Larose, 2014) ve genel geçer bir kural olan öğrenme verisindeki birey ya da nesne sayısının karekökünü alınması (Dunham, 2003) yöntemlerinin kullanılması etkili olmuştur. Bu sonuca varılmasının en önemli nedeni, yöntemin seçilen k değerine aşırı duyarlı olmasından dolayı bu değerinin uygun seçilmemesi durumunda düşük performans değerlerinin elde edilmesidir (Larose ve Larose, 2014; Tan ve diğerleri, 2014).

Çalışmada, verilerin analizlere hazırlanırken sınıflandırmaya katkısı olmayan değişkenlerin analize alınmaması yüksek doğru sınıflandırma oranlarının elde edilmesinde etkili olmuştur. KNN yöntemi, sınıflandırmada önemsiz değişkenlerin ayıklanmadığında düşük performans göstermektedir (Tan ve diğerleri, 2014). Örneklem büyüklüğü arttıkça daha yüksek olmakla birlikte tüm örneklem büyüklüklerinde yüksek performans elde edilmesi yeterli örneklem büyüklüğüne ulaşıldığı anlamına gelmektedir. Çünkü KNN yöntemi yeterli büyüklükte örneklem olduğunda yüksek performans göstermektedir (Hamalainen ve Vinni, 2011; Larose ve Larose, 2014; Tan ve diğerleri, 2014). Küçük örneklemelerde bile yöntem geçerliği ve güvenilirliği yüksek sonuçlar vermiştir.



Tüm örneklem büyüklüklerinde, test verisi oranı az olduğunda en yakın komşuluğun belirlenmesi zorlaşmakta ve dolayısıyla doğruluk oranlarının standart sapma miktarları artmaktadır. Bu durumda doğruluk oranları yüksek olmakla birlikte daha düşük güvenilirliğe sahip sonuçlar elde edilmektedir. Ancak, test verisi fazla olduğunda ise daha güvenilir olmakla birlikte daha düşük doğruluk oranları elde edilmektedir. Bu sonuçlara göre, KNN yönteminde güvenilir ve geçerli sonuçlar elde edebilmenin başka bir yolu da ideal test verisi oranı kullanmaktır. Buna göre, test verisi oranı olarak tüm verinin %20-30'luk bir kısmının kullanılması (Michie ve diğerleri, 1994), KNN yöntemi için en uygun sonuçların elde edilmesini sağlamıştır.

**Alt Problem 3.** *500, 1000 ve 5000 kişilik örneklem büyüklükleri için yapay sinir ağları çok katmanlı algılayıcı yönteminin test verisi oranı %11, %22, %33, %44 ve %55 olduğunda sınıflandırma doğruluk oranları ile standart sapma miktarları, Kappa uyum katsayıları ve ROC eğrisinin altında kalan alan değerleri nasıl farklılaşmaktadır?*

MLP yöntemi kullanılarak farklı koşullarda elde edilen doğru sınıflandırma oranlarının, Kappa ve ROC eğrisinin altında kalan alanlar ile birlikte değerlendirildiğinde yüksek düzey doğru ve geçerli olduğu görülmektedir. Bu sonuçların elde edilmesinde, ağın uygun şekilde eğitildiğinde düşük hata oranları elde edilebilmesi (Dunham, 2003), sinir ağlarının diğer istatistiksel tekniklere göre bağımlı ve bağımsız değişkenler açısından daha esnek olması (Chattamvelli, 2009) ve uygun ağ mimarisi seçildiğinde etkili sonuçlar elde edilebilmesi (Tan ve diğerleri, 2014) gibi faktörlerin etkili olduğu görülmüştür. Ayrıca, araştırmada kullanılan gizli katman sayısı ve her bir katmanda bulunması gereken düğüm sayısının uygun seçildiği söylenebilir. Heaton (2008) bu faktörlerin, modellerin sınıflandırma performansını önemli ölçüde etkilediğini belirtmektedir.

MLP yöntemi parametrik analizlerin varsayımlarını gerektirmemekle birlikte varsayımların sağlanması yöntemin performansını artırmaktadır. Buna göre, araştırmada kullanılan değişkenlerin normallik ve çoklu bağlantı varsayımlarını önemli ölçüde sağlaması, kayıp ve uç değerlerin olmaması ve veri kalitesinin yüksek olması yöntemin yüksek performans göstermesinde etkili olmuştur. Tan ve diğerleri (2014) özellikle kayıp ve gürültülü verinin olmamasının kabul edilebilir sonuçlar elde edilmesini sağladığını ifade etmişlerdir.

Araştırmada kullanılan geri yayılım ağı öğrenme algoritmasının da yüksek sınıflandırma performansı elde edilmesinde etkili olduğu görülmüştür. Bunun nedeni, geri yayılım ağlarının yapay sinir ağına alınan her bir gözlemin çıktı düğümünde elde edilen değerinin gerçek değeri ile karşılaştırılması ve hatayı minimize eden modelin elde edilmesini temel almasından ileri gelmektedir (Larose ve Larose, 2014). Bu sayede, sürekli öğrenme gerçekleştirilerek sınıflandırma performansı artmış (Dunham, 2003), uyarlanabilir (adaptive) öğrenme gerçekleşmiş ve ağ kendi kendini organize ederek gerçek zamanlı işlemler yapabilmektedir (Chattamvelli, 2009).

Buna göre, test verisi oranı az olduğunda model aşırı doymuş hale gelmekte ve dolayısıyla doğruluk oranlarının standart sapma miktarları artmaktadır. Bu artış örneklem küçüldükçe daha belirgin hale gelmektedir. Bu sonuçlara göre, MLP yöntemi modelin eğitilmesi için gerekli olan veri miktarı çok az olduğunda bile doğru sınıflandırma oranı ve güvenilirliği yüksek sonuçlar vermektedir. Test verisi uygun seçildiğinde ve miktarı yeterli olduğunda bir sinir ağı modelinden etkili sonuçlar elde edilebilmektedir (Akpınar, 2014; Dunham, 2003). Dunham (2003), bir yapay sinir ağı uygun ve yeterli düzeyde eğitildiğinde düşük hata oranları elde edilebileceğini belirtmektedir. Çalışmada ağın öğrenme verisi azaltıldığında ağ yeterli düzeyde eğitilemediğinden hata oranları artmakta ancak örneklem büyüklüğü artırıldığında öğrenme verisi oranı az olsa bile gözlem sayısı arttığından hata oranı düşmektedir. Sonuç olarak, MLP yöntemi örneklem büyüklüğü yüksek olduğunda test verisi oranı düşük olsa bile yüksek sınıflandırma performansı göstermektedir.

**Alt Problem 4.** *500, 1000 ve 5000 kişilik örneklem büyüklükleri için lojistik regresyon yönteminin test verisi oranı %11, %22, %33, %44 ve %55 olduğunda sınıflandırma doğruluk oranları ile standart sapma miktarları, Kappa uyum katsayıları ve ROC eğrisinin altında kalan alan değerleri nasıl farklılaşmaktadır?*

LR yöntemi kullanılarak farklı koşullarda elde edilen doğru sınıflandırma oranlarının, Kappa ve ROC eğrisinin altında kalan alanlar ile birlikte değerlendirildiğinde orta düzeyin üzerinde veya yüksek düzey doğru ve geçerli olduğu görülmektedir. LR yönteminde, örneklem büyüdükçe doğruluk oranları test verisi miktarından çok daha az etkilenmektedir. Bu sonuç, kurulan modelin karmaşıklığı kadar test verisi çok az olduğunda modelin ağı daha yüksek kesinlikle ezberlemesi ve sonuçta yanlış genellemeler yapma olasılığının artmasıyla ilgilidir

(Tan ve diğeri, 2014). Aşırı uyum (over-fitting) olarak da adlandırılan bu durum araştırmacıları ideal test verisi kullanma konusunda ipuçları sağlamaktadır. Benzer şekilde, Michie ve diğeri (1994) test verisi oranı olarak verinin genellikle %20-30'luk bir kısmının kullanılmasının yeterli olacağını ifade etmişlerdir.

LR yöntemi parametrik analizlerin varsayımlarını gerektirmemekle birlikte varsayımların sağlanması yöntemin performansını artırmaktadır (Tabachnick ve Fidell, 2013). Buna göre, araştırmada kullanılan değişkenlerin normallik, çoklu bağlantı ve homojenlik varsayımlarını önemli ölçüde sağlanması yöntemin yüksek performans göstermesinde etkili olmuştur. Tüm örneklem büyüklüklerinde, test verisi oranı az olduğunda model aşırı doymuş hale gelmekte ve dolayısıyla doğruluk oranlarının standart sapma miktarları artmaktadır.

Örneklem büyüdükçe doğruluk oranları artarken, standart sapma miktarının düşmektedir. Bu durum, örneklem büyüdükçe modelin sınıflandırmada esas aldığı sıklık tablolarındaki hücrelerde daha fazla bireyin yer alması sonucunda model hatalarının azalmasıyla açıklanabilir. Lojistik regresyon analizi, bağımlı değişkenin kategorileri ve bağımsız değişkenler için veri matrisi gözlemlerinde yeterli düzeyde gözlem olduğunda etkili sonuçlar verir (Çokluk ve diğeri, 2014; Tabachnick ve Fidell, 2013; Tatlıdil, 2002).

**Alt Problem 5.** *Naive Bayes, k-en yakın komşuluk, yapay sinir ağları çok katmanlı algılayıcı ve lojistik regresyon yöntemlerinin sınıflandırma doğruluk oranları ile standart sapma miktarları, analiz süreleri, Kappa uyum katsayıları ve ROC eğrisinin altında kalan alan değerleri farklı örneklem büyüklükleri ve test verisi oranlarına göre birbirinden nasıl farklılaşmaktadır?*

NB yöntemi tüm koşullarda neredeyse hiç zaman almadan analizleri gerçekleştirmektedir. 500 ve 1000 kişilik örneklemelerde LR ve KNN yöntemleri MLP yöntemine göre çok daha kısa sürede işlem yapmaktadır. Örneklem büyüklüğü 5000 olduğunda ise test verisi oranı %55 için KNN yöntemi diğer yöntemlerden daha fazla zaman almaktadır. MLP yöntemi test verisi oranı düşük olduğunda öğrenme verisi fazla olduğu için çok fazla zaman almaktadır. Bu sonuçlarla benzer şekilde, Osmanbegović ve Suljić'in (2012) yaptığı çalışmada öğrenme kolaylığı açısından YSA yöntemi biraz zaman alırken NB yönteminin kullanılan değişkenlerle sınırlı olmak şartıyla neredeyse hiç zaman almadığı görülmüştür. KNN yöntemi k değerinin

seçilmesinde kullanılan k-katmanlı çapraz geçerlik yönteminden dolayı örneklemin büyümesi durumunda LR yönteminden daha fazla sürede işlemleri gerçekleştirmektedir.

Bulgular bir arada değerlendirildiğinde, 500 kişilik örneklemlerde tüm test verisi oranları için NB yöntemi diğer yöntemlerden daha yüksek performans göstermiştir. NB yönteminden sonra en iyi doğruluk oranı LR yöntemi ile elde edilmiş, daha sonra ise sırasıyla MLP ve KNN yöntemleri gelmektedir. NB yöntemi test verisi oranının değişiminden diğer yöntemlere göre daha az etkilenmiştir. LR yöntemi, test verisi oranından en çok etkilenen ve sınıflandırma doğruluğu bu oran arttıkça önemli azalma gösteren yöntemdir. Bu durum, LR yönteminin önemli bir varsayımı olan veri matrisindeki kişi sayısının küçük örneklemlerde yeterli olmamasından dolayı model hatalarının artmasından ileri gelmektedir. Sonuç olarak, NB yönteminin basit istatistiksel yapısından dolayı diğer yöntemlere göre küçük örneklemlerde daha etkili olduğu görülmüştür. Ayrıca, NB yöntemi ile küçük örneklemlerde diğer yöntemlerin standart sapma miktarlarına eşit veya daha az hata ile aynı zamanda yanlı olmayan ve güvenilir sonuçlar elde edilmiştir (Şekil 4.10). Alan yazında yapılan bazı çalışmalarda, küçük örneklemlerde NB yönteminin diğer yöntemlere göre daha iyi sonuçlar verdiği görülmüştür (Göker, 2012; Hamalainen ve Vinni, 2006; Hamalainen ve Vinni, 2011), Kotsiantis ve diğerleri, 2003; Osmanbegović ve Suljić, 2012). Yapılan bazı çalışmalarda ise LR yönteminin YSA yöntemine göre daha düşük performans gösterdiği görülmüştür (Bahadır, 2013; Çırac, 2012; Tepehan, 2011).

1000 kişilik örneklemlerde test verisi az olduğunda LR yöntemi ile diğer yöntemlerden daha yüksek doğruluk oranları elde edilirken test verisi oranı arttıkça NB yöntemi LR yönteminden daha yüksek performans göstermiştir. Doğruluk oranlarının standart sapmaları da test verisi artırıldıkça LR yönteminin NB yönteminin daha az güvenilir ve yanlı sonuçlar verdiğini göstermektedir. Bu sonuç, LR yönteminden orta büyüklükteki örneklemlerde yüksek performans elde edebilmek için daha az test verisi kullanılmasının etkili olacağını göstermektedir. Bu sayede, LR yönteminde model hatalarının önüne geçilerek model daha iyi eğitilmiş olacaktır. Dekker ve diğerleri (2009) tarafından yapılan çalışmada, benzer büyüklükte örnekleme LR yöntemi Bayes yöntemine göre daha iyi performans göstermiştir. NB ve LR yöntemlerinden sonra en yüksek doğruluk oranları sırasıyla

MLP ve KNN yöntemleri ile elde edilmiştir. Romero ve diğerlerinin (2013) yaptıkları çalışmada, numerik ve kategorik veri için KNN yönteminin diğer sınıflandırıcılara göre daha düşük performans göstermiştir. Ancak, KNN yöntemi MLP yönteminden daha az hatalı sonuçlar vermiştir. Bu sonuç, KNN yönteminin MLP yöntemine göre daha basit bir istatistiksel yapıya sahip olması ve seçilen k değerinin en yakın komşuluğu belirlemede daha kesin sonuçlar vermesiyle yakından ilişkilidir. MLP yönteminde ise katman sayısının 3 seçilmesi ağın eğitilmesinde etkili olmasına rağmen daha geniş aralıkta sonuçların elde edilmesine neden olmuştur.

5000 kişilik örneklemlerde ise LR yöntemi ile tüm test verisi oranlarında diğer yöntemlerden daha yüksek doğruluk oranları elde edilmiştir. LR yöntemi büyük örneklemlerde model hatalarının az olmasından dolayı farklı test verisi oranlarında bile yüksek performans göstermektedir. Benzer şekilde, Şekil 4.10 incelendiğinde doğruluk oranlarının güven aralığı da diğer yöntemlere göre daha fazla daralmış ve sonuçta daha güvenilir sonuçlar elde edilmiştir. Test verisi oranı az olduğunda NB ve MLP yöntemleri benzer performans gösterirken bu oran artırıldığında NB yöntemi daha yüksek sonuçlar vermiştir. Benzer şekilde, test verisi oranı az olduğunda iki yöntemden elde edilen sonuçlar benzer standart sapmaya sahip iken bu oran artırıldığında MLP yöntemi daha geniş güven aralığında sonuçlar verirken NB yöntemi daha az yanlı sonuçlar vermektedir. KNN yöntemi ise en düşük doğruluk oranlarına sahip iken test verisi oranı arttıkça MLP yönteminden daha dar, diğer yöntemler ile benzer güven aralığında sonuçlar vermektedir.

Bu çalışmada, KNN yöntemi diğer yöntemlere göre tüm koşullarda daha düşük doğru sınıflandırma performansı göstermiştir. Ancak, yapılan bazı araştırmalarda KNN yönteminin de en az YSA ve LR yöntemleri kadar performans gösterdiği görülmüştür (Minaei-Bidgoli, Kashy, Kortemeyer ve Punch, 2003; Yurdakul ve Topal, 2015). Benzer şekilde, Shahiri ve diğerleri(2015), 2002 ile 2015 yılları arasında uluslararası veri tabanlarında yayınlanan çalışmalarını karşılaştırmış ve ortalama performans açısından NB yönteminin KNN ve YSA yöntemlerine göre daha düşük performans gösterdiği görülmüştür. Ancak, bu çalışmada, NB yöntemi özellikle küçük ve orta büyüklükteki örneklemlerde daha yüksek sınıflandırma performansı göstermiştir. Sonuç olarak, farklı koşullar ve veriler için bir sınıflandırma yönteminin en iyi olduğunu söylemek doğru olmadığını ifade etmişlerdir (Romero ve diğerleri, 2013; Shahiri ve diğerleri, 2015). Barker ve diğerleri (2004) ise farklı

yıllarda mezun olan öğrencilerin mezun olma durumlarına göre yaptıkları sınıflandırmada farklı yıllarda verinin yapısına göre farklı yöntemlerin etkili olabileceğini göstermişlerdir. Bu nedenle, bu araştırmadan elde edilen bulgular, kullanılan verinin yapısı ve analiz koşulları çerçevesinde yorumlanmıştır.

## Öneriler

**Araştırmaya yönelik öneriler.** 1. Bu araştırmada kullanılan yapay sinir ağı yöntemi çok katmanlı algılayıcı modeli ile sınırlı olduğundan yapılacak uygulamalarda yapay sinir ağlarının diğer modelleri de kullanılarak sonuçları karşılaştırılabilir.

2. Araştırmada, Naive Bayes yöntemi için koşullu bağımsızlık varsayımının sağlanmadığı bir veri ile analizler gerçekleştirilmiştir. Başka bir araştırmada bu varsayımın sağlandığı koşullarda elde edilen sonuçlar geçerliği ve güvenilirliği incelenerek diğer yöntemlerin performansı ile karşılaştırılabilir.

3. Araştırmada, k-en yakın komşuluk yöntemi için seçilecek k değerinin sınıflandırma performansını etkilediği görülmüştür. Buna göre, diğer araştırmalarda k değerinin seçilmesinde farklı yöntemler kullanılabilir ya da yeni yöntemler geliştirilebilir.

4. Yapay sinir ağları yönteminde, katman sayısı, katmanlardaki düğüm sayısı, ağırlıklandırmalar gibi birçok parametre modellerin sınıflandırma performansını etkilediğinden yapılacak araştırmalarda bu parametrelerde yapılacak değişikliklerin yöntemin performansında yaratacağı etkiler incelenebilir.

5. Lojistik regresyon analizi ve yapay sinir ağları yöntemleri için elde edilen sonuçlar varyans-kovaryans matrislerinin homojenliğinin sağlanmadığı koşulda elde edilmiştir. Bu yöntemler bu varsayım sağlanmadığında bile etkili sonuçlar vermekle birlikte yapılacak araştırmalarda, varyans-kovaryans matrislerinin homojenliğinin sağlandığı koşullarda yöntemlerin sınıflandırma performansları değerlendirilip karşılaştırılabilir.

6. Araştırmada 2012 yılında yapılan PISA uygulaması öğrenci anketi verileri kullanılmıştır. PISA uygulamalarında kullanılan öğrenci anketleri ve her bir uygulamada temel alınan tema (matematik, okuma ve fen) farklılık göstermektedir. Bu çalışma, farklı yıllardaki uygulamalar için tekrarlanarak sonuçlar karşılaştırılabilir.

Böylece, hem istatistiksel hem de eğitimsel açısından daha kapsamlı çıktılar elde edilebilir.

7. Araştırmada tüm yöntemleri standart koşullar altında değerlendirebilmek ve karşılaştırabilmek amacıyla eksik veriden arındırılmış bir gerçek veri seti kullanılmıştır. Yapılacak araştırmalarda eksik veri olduğu durumlarda yöntemlerin performansları incelenebilir.

8. Bu araştırmada, öğrencilerin PISA matematik başarısına göre sınıflandırılmasında etkili olabilecek değişkenler, değişken seçme yöntemleri kullanılarak seçilmiştir. Sınıflandırmada en etkili olan ve çalışmaya dahil edilen değişkenler Matematik öz-yeterliği, Matematiksel benlik algısı, Matematik kaygısı, Ekonomik, sosyal ve kültürel statü indeksi, Problem çözmeye açık olma, Ülke, Babanın eğitim düzeyi (ISCED), Anne Eğitim düzeyi (ISCED), Öğretmen davranışı: Öğrenciyi yönlendirme ve Hesap makinesi kullanımınıdır. Yapılacak araştırmalarda, bu araştırmada kullanılan değişken seçme yöntemleri dışında başka yöntemler ve değişen sayılarda değişken kullanılarak sonuçları karşılaştırılabilir. Özellikle bilgi kazanımlarına göre değişkenler sıralandığında değişken sayısına karar verme sınırının ne olacağına ilişkin detaylı incelemeler yapılabilir.

9. Bu çalışmada, sınıflandırma işlemlerinde tercih edilen dört yöntemle elde edilen sonuçlar karşılaştırılmıştır. Ancak ilgili alan yazın incelendiğinde öğrencilerin performanslarına göre çeşitli değişkenler açısından sınıflandırılmasında kullanılacak çok çeşitli yöntemler mevcuttur. Yapılacak çalışmalarda, karar ağaçları, ayırma analizi veya destek vektör makineleri gibi farklı yöntemler kullanılarak benzer ya da farklı koşullar için yöntemlerin performansları karşılaştırılabilir.

**Uygulamaya yönelik öneriler.** 1. Naive Bayes yöntemi, küçük örneklemelerde diğer yöntemlere göre yüksek sınıflandırma performansı göstermiştir. Buna göre, benzer koşullarda yapılacak uygulamalarda bu yöntemin kullanılması zaman kaybı yaşanmadan geçerliliği ve güvenilirliği yüksek sonuçların elde edilmesini sağlayacaktır. Test verisi oranları çok düşük olduğunda bile bu yöntem kullanılarak yüksek sınıflandırma performansı elde edilebilir. Ayrıca, farklı örneklem büyüklükleri ve test verisi oranları için, Naive Bayes yöntemi ile koşullu

bağımsızlık varsayımı sağlanmadığında bile yüksek sınıflandırma performansı sağlanabilir.

2. k-en yakın komşuluk yöntemi, tüm örneklem büyüklüğü ve test verisi oranları için en düşük sınıflandırma performansı göstermiştir. Bu yöntemin sınıflandırma performansı artırmak amacıyla kullanılan k-katmanlı çaprazlı geçerlik yöntemi performansı artırmasına rağmen diğer yöntemlere göre k-en yakın komşuluk yönteminin performansının daha düşük olmasına engel olamamıştır. Buna göre, benzer koşullar için yapılacak uygulamalarda daha yüksek sınıflandırma performansı sağlayabilmek için diğer yöntemler, k-en yakın komşuluk yöntemine tercih edilebilir.

3. Yapay sinir ağları çok katmanlı algılayıcı yöntemi, lojistik regresyona analizine benzer şekilde örneklemin artırılmasından önemli ölçüde etkilediğinden, verinin yapısına bağlı olmakla birlikte bu yöntem orta ve yüksek büyüklükteki örneklerde kullanılarak yüksek performans elde edilebilir. Ancak, örneklem büyüklüğü fazla olduğunda Naive Bayes ve lojistik regresyon yöntemlerinin tercih edilmesi daha yüksek performans ve zaman tasarrufu sağlayacaktır.

4. Lojistik regresyon analizi, diğer yöntemlere göre örneklem büyüklüğü ve test verisi oranı değişiminden en fazla etkilenen yöntemdir. Benzer koşullarda, büyük örneklerde lojistik regresyon analizi ile diğer yöntemlere göre daha güvenilir ve geçerli sonuçlar elde edilebilir. Özellikle örneklemin küçük olması, lojistik regresyon analizinin hata oranlarını artırdığından bu gibi durumlarda Naive Bayes yöntemi gibi örneklemin küçülmesine daha fazla direnç gösterebilen yöntemler seçilebilir.

5. Test verisi oranı, kullanılan değişken sayısı, örneklem büyüklüğü, verinin yapısı ve yöntemin yapısı ile yakından ilişkili olduğundan her yöntem için genel geçer bir oran kullanmanın doğru olmayacağı görülmüştür. Ancak, genel olarak test verisi oranını artırmak yöntemlerin performansında artışa neden olmasına rağmen elde edilen sonuçların güvenilirliğini düşürmüştür. Buna göre, sözü edilen faktörler göz önünde bulundurulmak kaydıyla orta büyüklüklerde test verisi oranlarının kullanılması daha kabul edilebilir sonuçlar elde edilmesini sağlayacaktır. Ancak, örneklem büyüklüğünün artırılması hem sınıflandırma performansını hem de elde



edilen sonuçların güvenilirliğini artırdığından tüm yöntemlerden yüksek performans etmek için mümkün olduğunca yüksek örneklem büyüklükleri kullanılmalıdır.

6. Öğrencilerin PISA yetenek düzeylerine göre alt ve üst grupların, bağımsız değişkenlerin ve yöntem parametrelerinin seçilme yöntemleri öğrenci performanslarının yüksek oranda doğru bir şekilde yordanmasında etkili olmuştur. Buna göre, ileride yapılacak uygulamalarda yüksek yordama performansları elde edebilmek amacıyla alt ve üst grupların gerekli hassasiyette seçilmesi, değişken seçme işleminin titizlikle yapılması, seçilen yöntemlerinin parametrelerinin dikkatli seçilmesi ve mümkün olduğunca yeterli düzeyde performans değerlendirme ölçütünün bir arada kullanılması önerilmektedir.



## Kaynaklar

- Agresti, A. (1996). An introduction to categorical data analysis. New York: John Wiley and Sons.
- Aha, D. W., Kibler, D. ve Albert, M. K. (1991). Instance-based learning algorithms. *Machine Learning* 6, 37-66.
- Akpınar, H. (2014). *Veri madenciliği veri analizi*. Papatya Yayınları, İstanbul.
- Baker, R. S. (2007). Is gaming the system state-or-trait? Educational data mining through the multi-contextual application of a validated behavioral model. In Complete On-Line Proceedings of the Workshop on Data Mining for User Modeling at the 11th International Conference on User Modeling 2007 (pp. 76-80). Boston, MA: User Modeling Inc.
- Baker, R. S. J. (2010). Data mining for education. *International Encyclopedia of Education*, 7(3), 112-118.
- Baker, R.S.J. ve Yacef, K. (2009). The state of educational data mining in 2009: A review and future visions. *Journal of Educational Data Mining*, 1 (1), 3-17.
- Bahadır, E. (2013). *Yapay sinir ağları ve lojistik regresyon analizi yaklaşımları ile öğretmen adaylarının akademik başarılarının tahmini* (Yayımlanmamış Doktora Tezi). Marmara Üniversitesi, İstanbul.
- Barker, K., Trafalis, T. ve Rhoads, T. R. (2004). Learning from student data. In *Proceedings of the 2004 Systems and Information Engineering Design Symposium* (pp. 79-86). IEEE.
- Bhardwaj, B. K. ve Pal, S. (2011). Data mining: A prediction for performance improvement using classification. (*IJCSIS*) *International Journal of Computer Science and Information Security*, 9, (4), 136-140.
- Blum, A. L. ve Langley, P. (1997). Selection of relevant features and examples in machine learning. *Artificial Intelligence*, 97(1), 245–271.
- Bouckaert, R. R. (2008). Bayesian network classifiers in Weka for Version 3-5-7. *Artificial Intelligence Tools*, 11(3), 369-387.
- Branco, P., Torgo, L. ve Ribeiro, R. (2015). A survey of predictive modelling under imbalanced distributions. arXiv preprint arXiv:1505.01658.

- Brain, D. ve Webb, G. (1999). On the effect of data set size on bias and variance in classification learning. In *Proceedings of the Fourth Australian Knowledge Acquisition Workshop* (pp. 117-128). University of New South Wales.
- Bulut, F. (2010). *Madde bağımlısı olma riski altında olan öğrencilerin veri madenciliği sınıflandırma algoritmalarıyla tespit edilmesi* (Yayımlanmamış Yüksek Lisans Tezi). Fatih Üniversitesi, İstanbul.
- Büyüköztürk, Ş., Çakmak, E., Akgün, Ö., Karadeniz, Ş. ve Demirel, F. (2013). *Bilimsel araştırma yöntemleri*. Ankara: Pegem.
- Chattamvelli, R. (2009). *Data mining methods* U.K., Oxford: Alpha Science International Ltd.
- Chua, L. O. ve Yang, L. (1988). Cellular neural networks: Applications. *IEEE Transactions on circuits and systems*, 35(10), 1273-1290.
- Çırak, G. (2012). *Yükseköğretimde öğrenci başarılarının sınıflandırılmasında yapay sinir ağları ve lojistik regresyon yöntemlerinin kullanılması* (Yayımlanmamış Yüksek Lisans Tezi). Ankara Üniversitesi, Ankara.
- Cox, D. R. ve Snell, E. J. (1989). *The analysis of binary data* (2<sup>nd</sup> ed.). London: Chapman and Hall.
- Cohen J. (1960). A coefficient of agreement for nominal scales. *Educational and Psychological Measurement* 20, 37-46.
- Cramer, J.S. (2002). *The origins of logistic regression*. Tinbergen Institute Working Paper No. 2002-119/4. <http://dx.doi.org/10.2139/ssrn.360300>.
- Cüceloğlu, D. (1991). *İnsan ve davranışı*. İstanbul: Remzi Kitapevi.
- Çokluk, Ö., Şekercioğlu, G. ve Büyüköztürk, Ş. (2014). *Sosyal bilimler için çok değişkenli istatistik SPSS ve LISREL uygulamaları*. Ankara: Pegem Akademi.
- Cabrera, A. F. (1994). Logistic regression analysis in higher education: An applied perspective. *Higher Education: Handbook of Theory and Research*, 10, 225–256.
- Dekker, G. W., Pechenizkiy, M. ve Vleeshouwers, J. M. (2009). Predicting students drop out: A case study. In *Proceedings of 2<sup>nd</sup> International Conference on Educational Data Mining* (pp. 41-50). Spain, Cordoba.

- Dunham, M.H. (2003). *Data mining introductory and advanced topics*. Upper Saddle River, NJ: Pearson Education, Inc.
- Efron, B. (1983). Estimating the error rate of a prediction rule: Improvements on crossvalidation. *J. Amer. Stat. Ass.*, 78, 316–331.
- Egan, J. P. (1975). *Signal detection theory and ROC analysis*. New York: Academic Press.
- Field, A. (2005). *Discovering statistics using SPSS* (2<sup>nd</sup> ed.). London: Sage.
- Fraenkel, J. R. ve Wallen, N. E. (2011). *How to design and evaluate research in education* (6<sup>th</sup> ed.). New York: McGraw-Hill, Inc.
- Frank, E., Hall M. A. ve Witten, I. H. (2016). *The WEKA workbench: Online appendix for "Data mining: Practical machine learning tools and techniques"* (4<sup>th</sup> ed.). Morgan Kaufmann.
- Ghosh, A. K. (2006). On optimum choice of k in nearest neighbor classification. *Computational Statistics and Data Analysis*, 50(11), 3113-3123.
- Göker, H. (2012). *Üniversite giriş sınavında öğrencilerin başarılarının veri madenciliği yöntemleri ile tahmin edilmesi*. (Yayımlanmamış Yüksek Lisans Tezi). Gazi Üniversitesi, Ankara.
- Hall, M., Frank, E., Holmes, G., Pfahringer, B., Reutemann, P. ve Witten, I. H. (2009). The WEKA data mining software: An update. *ACM SIGKDD Explorations Newsletter*, 11(1), 10-18.
- Hall, P., Park, B. U. ve Samworth, R. J. (2008). Choice of neighbor order in nearest-neighbor classification. *The Annals of Statistics*, 36(5), 2135-2152.
- Han, J., Kamber, M. ve Pei, J. (2011). *Data mining: concepts and techniques* (3<sup>rd</sup> ed.). MA, USA: Elsevier.
- Hämäläinen, W. ve Vinni, M. (2006). Comparison of machine learning methods for intelligent tutoring systems. In *Proceedings of International Conference on Intelligent Tutoring Systems* (pp. 525-534). Springer Berlin/Heidelberg.

- Hämäläinen, W. ve Vinni, M. (2011). *Classifiers for educational technology*. In C. Romero, S. Ventura, M. Pechenizkiy, R.S.J.d. Baker (Eds.), *Handbook of educational data mining* (pp. 54-74). CRC Press.
- Heaton, J. (2008). *Introduction to neural networks with Java* (2<sup>nd</sup> ed.). St. Louis: Heaton Research, Inc..
- Hinneburg, A., Aggarwal, C.C. ve Kleim, D.A. (2000). What is the nearest neighbor in high dimensional spaces? In *Proceedings of 26th International Conference on Very Large Data Bases* (pp. 506–515). Egypt, Cairo.
- Huebner, R. A. (2013). A survey of educational data-mining research. *Research in Higher Education Journal*, 19, 1-13.
- Jalali-Heravi., M. (2008). *Neural networks in analytical chemistry*. In Livingstone, D. J. (Ed.), *Artificial neural networks*, (pp. 81-122). UK: Humana Press.
- John, G. H. ve Langley, P. (1995). Estimating continuous distributions in Bayesian classifiers. In *Proceedings of the Eleventh Conference on Uncertainty in artificial intelligence* (pp. 338-345). Morgan Kaufmann Publishers Inc..
- Karasar, N. (2005). *Bilimsel araştırma yöntemi*. Ankara: Nobel Yayın Dağıtım.
- Krenker, A., Bešter, J. ve Kos, A. (2011). *Introduction to the artificial neural networks artificial neural networks*. In Suzuki K. (Ed.), *Methodological advances and biomedical applications*, (pp. 3-18). Janeza Trdine, Croatia: InTech.
- Kotsiantis, S. B., Pierrakeas, C. J. ve Pintelas, P. E. (2003). Preventing student dropout in distance learning using machine learning techniques. In *Knowledge-Based Intelligent Information and Engineering Systems* (pp. 267-274). Springer Berlin/Heidelberg.
- Kubat, M., Holte, R. C. ve Matwin, S. (1998). Machine learning for the detection of oil spills in satellite radar images. *Machine Learning*, 30(2- 3), 195–215.
- Lachenbruch, P. A. ve Mickey, M. R. (1968). Estimation of error rates in discriminant analysis. *Technometrics*, 10(1), 1-11.
- Landis, J. R. ve Koch, G. G. (1977). The measurement of observer agreement for categorical data. *Biometrics* 33, 159-174.

- Larose, D. T. (2004). *K-nearest neighbor algorithm*. In Larose, D.T. and Larose, C.D. (Eds.), *Discovering knowledge in data: An introduction to data mining* (pp. 90-106). Hoboken, NJ, USA John Wiley and Sons, Inc.. doi: 10.1002/0471687545.ch5.
- Larose, D. T. ve Larose, C.D. (2014). *Discovering knowledge in data: An introduction to data mining*. John Wiley and Sons.
- Liu, H. ve Motoda, H. (2001). *Feature extraction, construction and selection: A data mining perspective*. Boston: Kluwer Academic Publishers.
- Liu, H., ve Yu, L. (2005). Toward integrating feature selection algorithms for classification and clustering. *IEEE Transactions on Knowledge and Data Engineering*, 17(4), 491-502.
- McCulloch, W. S. ve Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5(4), 115-133.
- Mertler, C. A. ve Vannatta, R. A. (2005). *Advanced and multivariate statistical methods: Practical application and interpretation* (3<sup>rd</sup> ed.). Glendale, CA: Pyczak Publishing.
- Michie, D., Spiegelhalter, D.J. ve Taylor, C.C. (1994). *Machine learning, neural and statistical classification*. Ellis Horwood Limited.
- Minsky, M. ve Papert, S. (1969). *Perceptrons: An introduction to computational geometry*. The MIT Press.
- Morgan, J., Daugherty, R., Hilchie, A. ve Carey, B. (2003) Sample size and modeling accuracy of decision tree based data mining tools. *Acad Inf Manage Sci J*. 6(2), 71–99.
- Minaei-Bidgoli, B., D.A. Kashy, G. Kortemeyer ve W. Punch (2003). Predicting student performance: An application of data mining methods with an educational web-based system. In *Proceedings of 33<sup>rd</sup> Frontiers in Education Conference*, (pp. 13-18). Westminster, CO..
- Nghe, N. T., Janecek, P. ve Haddawy, P. (2007). A comparative analysis of techniques for predicting academic performance. In *Frontiers in Education Conference-Global Engineering: Knowledge Without Borders, Opportunities Without Passports*, (pp. T2G-7). IEEE.

- Nisbet, R., Elder IV, J. ve Miner, G. (2009). *Handbook of statistical analysis and data mining applications*. Academic Press.
- OECD (2014a). *PISA 2012 results: What students know and can do - student performance in mathematics, reading and science* (Volume I, Revised edition). PISA, OECD Publishing.
- OECD (2014b). *PISA 2012 technical report*. PISA, OECD Publishing.
- Osmanbegović, E. ve Suljić, M. (2012). Data mining approach for predicting student performance. *Economic Review*, 10(1), 3-12.
- Peng, C.Y.J., Lee, K. L. ve Ingersoll, G. M. (2002) An introduction to logistic regression analysis and reporting. *The Journal of Educational Research*, 96(1), 3-14. DOI: 10.1080/00220670209598786.
- Peng, C. Y. J. ve So, T. S. H. (2002). Logistic regression analysis and reporting: A primer. *Understanding Statistics: Statistical Issues in Psychology, Education, and the Social Sciences*, 1(1), 31-70.
- Ranjan, J. ve Malik, K. (2007). Effective educational process: A data mining approach. *VINE*, 37(4), 502-515.
- Rijsbergen CV. (1979). *Information retrieval* (2<sup>nd</sup> ed.). Butterworth: Boston.
- Romero, C., Espejo, P. G., Zafra, A., Romero, J. R. ve Ventura, S. (2013). Web usage mining for predicting final marks of students that use Moodle courses. *Computer Applications in Engineering Education*, 21(1), 135-146.
- Romero, C., Ventura, S., Espejo, P. G. ve Hervás, C. (2008). Data mining algorithms to classify students. In *Proceedings of The 1st International Conference on Educational Data Mining* (pp. 8-17). Montréal, Québec, Canada.
- Romero, C. ve Ventura, S. (2007). Educational data mining: A survey from 1995 to 2005. *Expert Systems with Applications*, 33(1), 135-146.
- Romero, C. ve Ventura, S. (2013). Data mining in education. *WIREs Data Mining Knowledge Discovery* 3, 12-27.
- Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65, 386–407.

- Rosenblatt, F. (1961). *Principles of neurodynamics. perceptrons and the theory of brain mechanisms*. Buffalo NY: Cornell Aeronautical Lab Inc.
- Rumelhart, D. E., Hinton, G. E. ve Williams, R. J. (1985). *Learning internal representations by error propagation* (ICS Report 8506). San Diego: University of California.
- Shahiri, A. M., Husain, W. ve Rashid, N. A. (2015). A review on predicting student's performance using data mining techniques. *Procedia Computer Science*, 72, 414-422.
- Shao, L., Fan, X., Cheng, N., Wu, L. ve Cheng, Y. (2013) Determination of minimum training sample size for microarray-based cancer outcome prediction - An empirical assessment. *PLoS ONE* 8(7): e68579. doi:10.1371/journal.pone.0068579.
- Silahtaroglu, G. (2013). *Veri madenciliđi*. İstanbul: Papatya Yayınları.
- Şengür, D. (2013). *Öğrencilerin akademik başarılarının veri madenciliđi metotları ile tahmini* (Yayımlanmamış Yüksek Lisans Tezi). Fırat Üniversitesi, Elazığ.
- Tabachnick, B. G. ve Fidell, L. S. (2013). *Using multivariate statistics* (6<sup>th</sup> ed.). Boston: Pearson.
- Tan, P., Steinbach, M., Kumar, V. (2014). *Introduction to data mining*. Boston: Pearson Addison Wesley.
- Tatlıdil, H. (2002). *Uygulamalı çok deđişkenli istatistiksel analiz*. Ankara: Akademi matbaası.
- Tepehan, T. (2011). *Türk öğrencilerinin PISA başarılarının yordanmasında yapay sinir ađı ve lojistik regresyon modeli performanslarının karşılaştırılması* (Yayımlanmamış Doktora Tezi). Hacettepe Üniversitesi, Ankara.
- Tezbaşaran, E. (2016). *Temel bileşenler analizi ve yapay sinir ađı modellerinin ölçek geliştirme sürecinde kullanılabilirliğinin incelenmesi* (Yayımlanmamış Doktora Tezi). Mersin Üniversitesi, Mersin.
- Tosun, S. (2007). *Sınıflandırmada yapay sinir ađları ve karar ađaçları karşılaştırması: Öğrenci başarıları üzerine bir uygulama* (Yayımlanmamış Yüksek Lisans Tezi) İstanbul Teknik Üniversitesi, İstanbul.



Yurdakul, S. ve Topal, T. (2015). Veri madenciliđi ile lise öğrenci performanslarının değerlendirilmesi. *XVII. Akademik Bilişim Konferansında* sunulan bildiri. Anadolu Üniversitesi, Eskişehir.



## EK-A: 5000 Kişilik Örneklemde Test Verisi Oranı %11 için Elde Edilen Analiz Sonuçları

Analysing: Percent_correct (stddev)					Analysing: Kappa_statistic (stddev)					Analysing: Area_under_ROC (stddev)				
Datasets: 30					Datasets: 30					Datasets: 30				
Resultsets: 4					Resultsets: 4					Resultsets: 4				
Dataset	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk		
1. MATH2 (100)	76.63(1.63)	78.31(1.45)	76.45(1.75)	74.04(1.43)	0.49(0.04)	0.51(0.03)	0.48(0.04)	0.39(0.04)	0.83(0.02)	0.86(0.01)	0.84(0.02)	0.80(0.02)		
2. MATH2 (100)	76.59(1.84)	78.51(1.95)	76.50(2.05)	75.32(1.61)	0.48(0.04)	0.51(0.04)	0.47(0.05)	0.42(0.04)	0.82(0.02)	0.85(0.02)	0.83(0.02)	0.80(0.02)		
3. MATH2 (100)	76.06(1.76)	77.71(1.59)	75.95(2.16)	74.71(1.78)	0.47(0.04)	0.49(0.04)	0.46(0.05)	0.38(0.05)	0.82(0.02)	0.84(0.02)	0.83(0.02)	0.80(0.02)		
4. MATH2 (100)	76.57(1.86)	78.36(1.74)	76.34(1.90)	73.72(1.46)	0.48(0.04)	0.51(0.04)	0.47(0.05)	0.39(0.04)	0.82(0.02)	0.85(0.02)	0.83(0.02)	0.79(0.02)		
5. MATH2 (100)	76.35(1.75)	77.94(1.61)	76.12(1.68)	74.71(1.46)	0.47(0.04)	0.49(0.04)	0.46(0.04)	0.37(0.04)	0.82(0.02)	0.84(0.02)	0.82(0.02)	0.80(0.02)		
6. MATH2 (100)	76.46(1.55)	78.02(1.43)	76.28(1.81)	75.19(1.54)	0.48(0.03)	0.50(0.03)	0.47(0.04)	0.40(0.04)	0.83(0.01)	0.85(0.02)	0.83(0.02)	0.81(0.02)		
7. MATH2 (100)	76.82(1.71)	78.57(1.49)	76.70(1.74)	74.40(1.58)	0.49(0.04)	0.52(0.03)	0.49(0.04)	0.38(0.04)	0.83(0.02)	0.86(0.01)	0.84(0.02)	0.79(0.02)		
8. MATH2 (100)	76.43(1.68)	78.38(1.36)	76.55(1.63)	74.54(1.57)	0.48(0.04)	0.51(0.03)	0.48(0.04)	0.41(0.04)	0.82(0.02)	0.85(0.02)	0.83(0.02)	0.81(0.02)		
9. MATH2 (100)	75.00(1.94)	77.20(1.85)	75.16(1.93)	75.54(1.56)	0.45(0.04)	0.49(0.04)	0.45(0.04)	0.40(0.04)	0.82(0.02)	0.84(0.02)	0.82(0.02)	0.79(0.02)		
10. MATH2 (100)	76.87(1.57)	78.08(1.48)	76.35(2.00)	74.14(1.57)	0.49(0.03)	0.50(0.04)	0.48(0.05)	0.38(0.04)	0.83(0.02)	0.85(0.02)	0.83(0.02)	0.80(0.02)		
11. MATH2 (100)	77.69(1.66)	78.80(1.54)	76.90(1.72)	73.86(1.49)	0.50(0.04)	0.51(0.04)	0.48(0.04)	0.36(0.04)	0.83(0.02)	0.85(0.02)	0.83(0.02)	0.80(0.02)		
12. MATH2 (100)	76.29(1.71)	77.76(1.42)	75.87(1.77)	74.50(1.75)	0.48(0.04)	0.50(0.03)	0.47(0.05)	0.38(0.04)	0.83(0.02)	0.85(0.01)	0.83(0.02)	0.79(0.02)		
13. MATH2 (100)	76.81(1.52)	78.64(1.46)	76.40(1.79)	75.54(1.53)	0.48(0.03)	0.50(0.03)	0.46(0.06)	0.39(0.04)	0.83(0.02)	0.85(0.02)	0.83(0.02)	0.81(0.02)		
14. MATH2 (100)	76.42(1.75)	78.02(1.57)	76.58(1.66)	74.58(1.62)	0.48(0.04)	0.50(0.04)	0.48(0.04)	0.39(0.04)	0.83(0.02)	0.85(0.02)	0.84(0.02)	0.79(0.02)		
15. MATH2 (100)	77.04(1.83)	78.51(1.69)	76.42(1.91)	74.25(1.74)	0.49(0.04)	0.50(0.04)	0.47(0.05)	0.40(0.04)	0.83(0.02)	0.85(0.02)	0.83(0.02)	0.80(0.02)		
16. MATH2 (100)	77.00(1.56)	78.49(1.44)	76.47(1.68)	74.89(1.67)	0.50(0.03)	0.52(0.03)	0.48(0.04)	0.41(0.04)	0.83(0.02)	0.85(0.01)	0.84(0.01)	0.80(0.02)		
17. MATH2 (100)	75.93(1.74)	77.86(1.46)	76.00(1.65)	75.79(1.60)	0.46(0.04)	0.48(0.04)	0.45(0.05)	0.41(0.04)	0.82(0.02)	0.84(0.02)	0.82(0.02)	0.80(0.02)		
18. MATH2 (100)	76.92(1.57)	78.56(1.45)	76.60(1.63)	73.49(1.51)	0.49(0.04)	0.51(0.03)	0.47(0.04)	0.37(0.04)	0.83(0.02)	0.85(0.01)	0.83(0.02)	0.79(0.02)		
19. MATH2 (100)	76.12(1.73)	77.68(1.56)	75.80(1.77)	74.30(1.58)	0.47(0.04)	0.48(0.04)	0.45(0.05)	0.40(0.04)	0.82(0.02)	0.85(0.02)	0.83(0.02)	0.80(0.02)		
20. MATH2 (100)	77.92(1.66)	79.10(1.39)	77.41(1.91)	74.46(1.66)	0.50(0.04)	0.51(0.03)	0.48(0.04)	0.40(0.04)	0.84(0.02)	0.86(0.01)	0.84(0.02)	0.79(0.02)		
21. MATH2 (100)	76.74(1.79)	77.99(1.40)	75.91(1.69)	73.74(1.60)	0.49(0.04)	0.50(0.03)	0.46(0.04)	0.37(0.04)	0.82(0.02)	0.85(0.02)	0.83(0.02)	0.79(0.02)		
22. MATH2 (100)	76.76(1.69)	79.26(1.49)	76.90(1.76)	75.14(1.66)	0.49(0.04)	0.53(0.03)	0.49(0.05)	0.40(0.04)	0.83(0.02)	0.86(0.02)	0.84(0.02)	0.80(0.02)		
23. MATH2 (100)	76.58(1.82)	79.04(1.67)	76.83(1.63)	73.86(1.51)	0.48(0.04)	0.52(0.04)	0.48(0.04)	0.37(0.04)	0.83(0.02)	0.86(0.01)	0.84(0.02)	0.79(0.02)		
24. MATH2 (100)	77.44(1.82)	78.99(1.87)	76.92(1.99)	74.62(1.61)	0.49(0.04)	0.51(0.04)	0.48(0.05)	0.39(0.04)	0.83(0.02)	0.85(0.02)	0.84(0.02)	0.79(0.02)		
25. MATH2 (100)	76.27(1.87)	77.98(1.85)	75.70(1.74)	74.42(1.61)	0.48(0.04)	0.50(0.04)	0.45(0.05)	0.39(0.04)	0.82(0.02)	0.85(0.02)	0.83(0.02)	0.80(0.02)		
26. MATH2 (100)	75.84(1.58)	77.50(1.61)	75.65(1.82)	74.86(1.34)	0.48(0.03)	0.50(0.04)	0.46(0.04)	0.38(0.04)	0.82(0.02)	0.85(0.02)	0.83(0.02)	0.80(0.02)		
27. MATH2 (100)	76.33(1.69)	78.44(1.59)	76.40(1.59)	74.40(1.40)	0.48(0.04)	0.51(0.04)	0.47(0.04)	0.39(0.03)	0.82(0.02)	0.85(0.01)	0.83(0.02)	0.80(0.02)		
28. MATH2 (100)	76.18(1.61)	78.12(1.54)	75.86(1.80)	74.28(1.46)	0.47(0.04)	0.50(0.04)	0.46(0.05)	0.39(0.04)	0.82(0.02)	0.85(0.02)	0.82(0.02)	0.80(0.02)		
29. MATH2 (100)	76.82(1.58)	79.10(1.37)	77.53(1.71)	74.83(1.45)	0.48(0.03)	0.52(0.03)	0.49(0.04)	0.40(0.04)	0.83(0.02)	0.86(0.01)	0.84(0.02)	0.80(0.02)		
30. MATH2 (100)	76.54(1.54)	77.64(1.51)	75.92(1.79)	73.60(1.66)	0.48(0.03)	0.48(0.04)	0.46(0.05)	0.38(0.04)	0.82(0.02)	0.84(0.02)	0.82(0.02)	0.79(0.02)		

## EK-B: 5000 Kişilik Örneklemde Test Verisi Oranı %22 için Elde Edilen Analiz Sonuçları

Analysing: Percent_correct (stddev)				Analysing: Kappa_statistic (stddev)				Analysing: Area_under_ROC (stddev)				
Datasets: 30				Datasets: 30				Datasets: 30				
Resultsets: 4				Resultsets: 4				Resultsets: 4				
Dataset	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk
1. MATH2 (100)	76.51(1.13)	78.31(1.09)	76.42(1.24)	74.03(1.01)	0.48(0.02)	0.51(0.02)	0.48(0.03)	0.39(0.02)	0.83(0.01)	0.86(0.01)	0.84(0.01)	0.79(0.01)
2. MATH2 (100)	76.51(1.24)	78.47(1.15)	76.10(1.52)	74.98(1.12)	0.48(0.03)	0.51(0.03)	0.47(0.03)	0.41(0.03)	0.82(0.01)	0.85(0.01)	0.83(0.01)	0.80(0.01)
3. MATH2 (100)	76.18(1.22)	77.79(1.14)	75.81(1.30)	74.53(1.16)	0.47(0.03)	0.49(0.03)	0.46(0.03)	0.38(0.03)	0.82(0.01)	0.84(0.01)	0.82(0.01)	0.80(0.01)
4. MATH2 (100)	76.76(1.14)	78.45(1.14)	76.29(1.50)	73.71(1.06)	0.49(0.03)	0.51(0.03)	0.47(0.03)	0.39(0.03)	0.82(0.01)	0.85(0.01)	0.83(0.01)	0.79(0.01)
5. MATH2 (100)	76.39(1.25)	77.93(1.06)	75.94(1.33)	74.56(1.10)	0.47(0.03)	0.49(0.02)	0.46(0.03)	0.37(0.03)	0.82(0.01)	0.84(0.01)	0.82(0.01)	0.79(0.01)
6. MATH2 (100)	76.58(1.20)	78.21(0.97)	76.04(1.27)	74.87(1.04)	0.48(0.03)	0.50(0.02)	0.47(0.03)	0.39(0.03)	0.83(0.01)	0.85(0.01)	0.83(0.01)	0.81(0.01)
7. MATH2 (100)	76.81(1.13)	78.44(1.10)	76.51(1.37)	74.46(1.06)	0.49(0.02)	0.52(0.03)	0.48(0.03)	0.38(0.03)	0.83(0.01)	0.86(0.01)	0.84(0.01)	0.79(0.01)
8. MATH2 (100)	76.52(1.06)	78.49(0.80)	76.59(1.48)	74.38(1.10)	0.48(0.02)	0.52(0.02)	0.48(0.04)	0.40(0.03)	0.82(0.01)	0.85(0.01)	0.83(0.01)	0.80(0.01)
9. MATH2 (100)	75.34(1.18)	77.40(1.12)	75.07(1.49)	75.34(1.11)	0.46(0.03)	0.49(0.03)	0.45(0.04)	0.40(0.03)	0.82(0.01)	0.85(0.01)	0.82(0.01)	0.79(0.01)
10. MATH2 (100)	76.70(1.20)	78.09(1.06)	76.24(1.32)	73.98(1.07)	0.49(0.03)	0.50(0.02)	0.48(0.03)	0.37(0.03)	0.83(0.01)	0.85(0.01)	0.83(0.01)	0.80(0.01)
11. MATH2 (100)	77.52(1.14)	78.54(0.96)	76.68(1.32)	73.64(1.07)	0.50(0.03)	0.50(0.02)	0.48(0.03)	0.36(0.03)	0.82(0.01)	0.85(0.01)	0.83(0.01)	0.79(0.01)
12. MATH2 (100)	76.13(0.87)	77.66(0.95)	75.73(1.29)	74.33(1.13)	0.48(0.02)	0.50(0.02)	0.47(0.03)	0.38(0.03)	0.83(0.01)	0.85(0.01)	0.83(0.01)	0.79(0.01)
13. MATH2 (100)	76.73(1.08)	78.37(1.08)	76.14(1.37)	75.55(0.95)	0.47(0.02)	0.49(0.02)	0.46(0.04)	0.40(0.02)	0.82(0.01)	0.85(0.01)	0.82(0.01)	0.81(0.01)
14. MATH2 (100)	76.43(1.06)	78.06(1.07)	76.32(1.44)	74.15(1.05)	0.48(0.02)	0.50(0.02)	0.47(0.04)	0.37(0.03)	0.83(0.01)	0.86(0.01)	0.83(0.01)	0.79(0.01)
15. MATH2 (100)	76.99(0.93)	78.37(0.91)	76.13(1.31)	74.22(1.10)	0.49(0.02)	0.50(0.02)	0.46(0.03)	0.39(0.03)	0.83(0.01)	0.85(0.01)	0.83(0.01)	0.80(0.01)
16. MATH2 (100)	76.99(1.07)	78.33(0.98)	76.11(1.30)	74.35(1.06)	0.49(0.02)	0.51(0.02)	0.47(0.03)	0.40(0.03)	0.83(0.01)	0.85(0.01)	0.83(0.01)	0.80(0.01)
17. MATH2 (100)	76.06(1.16)	77.90(0.98)	76.06(1.21)	75.57(1.17)	0.46(0.03)	0.48(0.02)	0.46(0.03)	0.41(0.03)	0.82(0.01)	0.84(0.01)	0.82(0.01)	0.80(0.02)
18. MATH2 (100)	77.12(1.14)	78.61(1.02)	76.61(1.39)	73.35(1.04)	0.49(0.02)	0.51(0.02)	0.48(0.03)	0.36(0.03)	0.83(0.01)	0.85(0.01)	0.83(0.01)	0.79(0.01)
19. MATH2 (100)	75.96(1.04)	77.56(0.96)	75.35(1.32)	74.22(1.22)	0.46(0.02)	0.48(0.02)	0.44(0.04)	0.40(0.03)	0.82(0.01)	0.84(0.01)	0.82(0.01)	0.79(0.01)
20. MATH2 (100)	78.03(1.09)	79.07(1.04)	77.36(1.33)	74.14(1.17)	0.51(0.02)	0.51(0.02)	0.48(0.04)	0.39(0.03)	0.84(0.01)	0.86(0.01)	0.84(0.01)	0.79(0.01)
21. MATH2 (100)	76.78(1.04)	77.91(0.91)	75.72(1.23)	73.53(1.09)	0.49(0.02)	0.49(0.02)	0.46(0.03)	0.36(0.03)	0.82(0.01)	0.85(0.01)	0.82(0.01)	0.79(0.01)
22. MATH2 (100)	76.82(1.25)	79.06(0.92)	77.00(1.36)	74.87(1.13)	0.49(0.03)	0.53(0.02)	0.49(0.03)	0.39(0.03)	0.83(0.01)	0.86(0.01)	0.84(0.01)	0.80(0.01)
23. MATH2 (100)	76.62(1.13)	79.02(1.13)	76.70(1.13)	73.80(0.92)	0.48(0.03)	0.52(0.03)	0.48(0.03)	0.37(0.03)	0.83(0.01)	0.86(0.01)	0.83(0.01)	0.79(0.01)
24. MATH2 (100)	77.45(1.18)	79.02(1.19)	76.99(1.53)	74.22(1.12)	0.49(0.03)	0.51(0.03)	0.48(0.04)	0.38(0.03)	0.83(0.01)	0.85(0.01)	0.83(0.01)	0.78(0.01)
25. MATH2 (100)	76.35(1.19)	78.05(1.12)	75.91(1.36)	74.26(1.08)	0.48(0.03)	0.50(0.03)	0.46(0.03)	0.39(0.03)	0.82(0.01)	0.85(0.01)	0.83(0.01)	0.79(0.01)
26. MATH2 (100)	75.88(1.12)	77.51(1.10)	75.37(1.51)	74.73(1.05)	0.48(0.02)	0.50(0.02)	0.46(0.03)	0.38(0.03)	0.82(0.01)	0.85(0.01)	0.83(0.01)	0.79(0.01)
27. MATH2 (100)	76.19(1.13)	78.48(1.06)	75.97(1.34)	74.24(1.15)	0.48(0.03)	0.51(0.02)	0.46(0.03)	0.39(0.03)	0.82(0.01)	0.85(0.01)	0.83(0.01)	0.80(0.01)
28. MATH2 (100)	76.19(1.23)	77.95(1.07)	75.80(1.43)	74.32(1.16)	0.47(0.03)	0.49(0.02)	0.46(0.04)	0.39(0.03)	0.82(0.01)	0.84(0.01)	0.82(0.01)	0.80(0.01)
29. MATH2 (100)	76.70(1.07)	78.92(1.02)	77.13(1.29)	74.42(1.06)	0.48(0.02)	0.51(0.02)	0.49(0.03)	0.39(0.03)	0.83(0.01)	0.86(0.01)	0.84(0.01)	0.79(0.01)
30. MATH2 (100)	76.60(1.09)	77.68(0.95)	75.73(1.37)	73.74(1.05)	0.48(0.02)	0.48(0.02)	0.46(0.03)	0.39(0.03)	0.82(0.01)	0.84(0.01)	0.82(0.01)	0.79(0.01)

## EK-C: 5000 Kişilik Örneklemde Test Verisi Oranı %33 için Elde Edilen Analiz Sonuçları

Analysing: Percent_correct (stddev) Datasets: 30 Resultsets: 4				Analysing: Kappa_statistic (stddev) Datasets: 30 Resultsets: 4				Analysing: Area_under_ROC (stddev) Datasets: 30 Resultsets: 4				
Dataset	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk
1. MATH2 (100)	76.50(0.87)	78.18(0.91)	76.01(1.15)	73.87(0.76)	0.48(0.02)	0.51(0.02)	0.47(0.03)	0.38(0.02)	0.83(0.01)	0.85(0.01)	0.83(0.01)	0.79(0.01)
2. MATH2 (100)	76.46(0.93)	78.30(0.84)	76.11(1.14)	74.59(0.88)	0.48(0.02)	0.50(0.02)	0.46(0.03)	0.40(0.02)	0.82(0.01)	0.85(0.01)	0.83(0.01)	0.80(0.01)
3. MATH2 (100)	76.22(0.89)	77.79(0.81)	75.63(1.12)	74.46(0.80)	0.47(0.02)	0.49(0.02)	0.45(0.03)	0.37(0.02)	0.82(0.01)	0.84(0.01)	0.82(0.01)	0.79(0.01)
4. MATH2 (100)	76.63(0.93)	78.26(0.84)	76.09(1.16)	73.58(0.85)	0.48(0.02)	0.51(0.02)	0.47(0.03)	0.39(0.02)	0.82(0.01)	0.85(0.01)	0.82(0.01)	0.79(0.01)
5. MATH2 (100)	76.39(0.96)	77.91(0.86)	75.82(1.24)	74.25(0.87)	0.47(0.02)	0.49(0.02)	0.45(0.03)	0.36(0.02)	0.82(0.01)	0.84(0.01)	0.82(0.01)	0.79(0.01)
6. MATH2 (100)	76.61(0.85)	78.07(0.84)	76.13(1.19)	74.66(0.85)	0.48(0.02)	0.50(0.02)	0.47(0.03)	0.39(0.02)	0.83(0.01)	0.85(0.01)	0.83(0.01)	0.80(0.01)
7. MATH2 (100)	76.80(0.85)	78.45(0.90)	76.40(1.21)	74.07(0.95)	0.49(0.02)	0.52(0.02)	0.48(0.03)	0.38(0.02)	0.83(0.01)	0.86(0.01)	0.83(0.01)	0.78(0.01)
8. MATH2 (100)	76.64(0.84)	78.57(0.66)	76.28(1.16)	74.12(0.89)	0.49(0.02)	0.52(0.02)	0.48(0.03)	0.40(0.02)	0.82(0.01)	0.85(0.01)	0.83(0.01)	0.80(0.01)
9. MATH2 (100)	75.32(0.85)	77.35(0.86)	75.25(1.15)	75.01(0.88)	0.46(0.02)	0.49(0.02)	0.45(0.03)	0.39(0.02)	0.82(0.01)	0.85(0.01)	0.82(0.01)	0.79(0.01)
10. MATH2 (100)	76.73(0.89)	78.23(0.85)	75.94(1.04)	73.98(0.78)	0.49(0.02)	0.50(0.02)	0.46(0.03)	0.37(0.02)	0.83(0.01)	0.85(0.01)	0.83(0.01)	0.79(0.01)
11. MATH2 (100)	77.59(0.79)	78.66(0.78)	76.53(1.14)	73.64(0.83)	0.50(0.02)	0.51(0.02)	0.47(0.04)	0.36(0.02)	0.83(0.01)	0.85(0.01)	0.83(0.01)	0.79(0.01)
12. MATH2 (100)	76.17(0.73)	77.79(0.71)	75.61(0.99)	74.08(0.77)	0.48(0.02)	0.50(0.02)	0.46(0.03)	0.37(0.02)	0.83(0.01)	0.85(0.01)	0.83(0.01)	0.79(0.01)
13. MATH2 (100)	76.59(0.85)	78.19(0.84)	75.99(1.19)	75.56(0.76)	0.47(0.02)	0.49(0.02)	0.45(0.04)	0.40(0.02)	0.82(0.01)	0.84(0.01)	0.82(0.01)	0.80(0.01)
14. MATH2 (100)	76.35(0.87)	78.06(0.79)	76.20(1.01)	73.91(0.83)	0.48(0.02)	0.50(0.02)	0.47(0.03)	0.37(0.02)	0.83(0.01)	0.85(0.01)	0.83(0.01)	0.79(0.01)
15. MATH2 (100)	76.77(0.79)	78.28(0.78)	75.96(1.16)	74.02(0.76)	0.48(0.02)	0.50(0.02)	0.46(0.03)	0.39(0.02)	0.83(0.01)	0.85(0.01)	0.83(0.01)	0.80(0.01)
16. MATH2 (100)	77.00(0.81)	78.29(0.74)	76.02(1.11)	74.10(0.87)	0.50(0.02)	0.51(0.02)	0.47(0.03)	0.39(0.02)	0.83(0.01)	0.85(0.01)	0.83(0.01)	0.79(0.01)
17. MATH2 (100)	76.17(0.80)	77.90(0.80)	75.73(1.26)	75.09(0.88)	0.46(0.02)	0.48(0.02)	0.45(0.03)	0.40(0.02)	0.82(0.01)	0.84(0.01)	0.82(0.01)	0.79(0.01)
18. MATH2 (100)	77.16(0.88)	78.55(0.81)	76.41(0.95)	73.17(0.95)	0.49(0.02)	0.51(0.02)	0.47(0.03)	0.36(0.02)	0.83(0.01)	0.85(0.01)	0.83(0.01)	0.79(0.01)
19. MATH2 (100)	75.96(0.82)	77.55(0.75)	75.52(1.10)	73.84(1.02)	0.46(0.02)	0.48(0.02)	0.45(0.03)	0.39(0.02)	0.82(0.01)	0.84(0.01)	0.82(0.01)	0.79(0.01)
20. MATH2 (100)	78.10(0.86)	79.13(0.79)	77.02(1.26)	73.83(0.91)	0.51(0.02)	0.51(0.02)	0.48(0.03)	0.38(0.02)	0.84(0.01)	0.86(0.01)	0.84(0.01)	0.79(0.01)
21. MATH2 (100)	76.79(0.74)	77.77(0.73)	75.54(0.94)	73.28(0.90)	0.49(0.02)	0.49(0.02)	0.45(0.03)	0.35(0.02)	0.82(0.01)	0.85(0.01)	0.82(0.01)	0.78(0.01)
22. MATH2 (100)	76.76(0.95)	78.92(0.72)	76.64(1.18)	74.72(0.87)	0.49(0.02)	0.53(0.02)	0.49(0.03)	0.39(0.03)	0.83(0.01)	0.86(0.01)	0.84(0.01)	0.80(0.01)
23. MATH2 (100)	76.49(0.90)	78.81(0.91)	76.63(1.06)	73.60(0.81)	0.48(0.02)	0.52(0.02)	0.48(0.03)	0.36(0.02)	0.83(0.01)	0.86(0.01)	0.83(0.01)	0.78(0.01)
24. MATH2 (100)	77.29(0.88)	78.88(0.88)	76.77(1.24)	73.70(0.85)	0.49(0.02)	0.51(0.02)	0.47(0.03)	0.37(0.02)	0.83(0.01)	0.85(0.01)	0.83(0.01)	0.78(0.01)
25. MATH2 (100)	76.38(0.91)	77.97(0.78)	75.73(1.22)	74.01(0.87)	0.48(0.02)	0.50(0.02)	0.46(0.03)	0.38(0.02)	0.82(0.01)	0.85(0.01)	0.82(0.01)	0.79(0.01)
26. MATH2 (100)	75.91(0.88)	77.51(0.79)	75.50(1.15)	74.61(0.80)	0.48(0.02)	0.50(0.02)	0.46(0.03)	0.38(0.02)	0.82(0.01)	0.85(0.01)	0.82(0.01)	0.79(0.01)
27. MATH2 (100)	76.14(0.92)	78.24(0.82)	75.65(1.14)	74.11(0.86)	0.48(0.02)	0.50(0.02)	0.46(0.03)	0.38(0.02)	0.82(0.01)	0.85(0.01)	0.82(0.01)	0.79(0.01)
28. MATH2 (100)	75.96(0.95)	77.89(0.80)	75.77(1.21)	73.96(0.84)	0.47(0.02)	0.49(0.02)	0.45(0.03)	0.38(0.02)	0.82(0.01)	0.84(0.01)	0.82(0.01)	0.79(0.01)
29. MATH2 (100)	76.84(0.82)	78.99(0.90)	77.12(1.15)	74.26(0.89)	0.48(0.02)	0.52(0.02)	0.48(0.03)	0.39(0.02)	0.83(0.01)	0.85(0.01)	0.83(0.01)	0.79(0.01)
30. MATH2 (100)	76.49(0.80)	77.58(0.71)	75.67(1.13)	73.52(0.90)	0.48(0.02)	0.48(0.02)	0.45(0.03)	0.38(0.02)	0.82(0.01)	0.84(0.01)	0.82(0.01)	0.79(0.01)

## EK-D: 5000 Kişilik Örneklemde Test Verisi Oranı %44 için Elde Edilen Analiz Sonuçları

Analysing: Percent_correct (stddev)					Analysing: Kappa_statistic (stddev)					Analysing: Area_under_ROC (stddev)				
Datasets: 30					Datasets: 30					Datasets: 30				
Resultsets: 4					Resultsets: 4					Resultsets: 4				
Dataset	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk		
1. MATH2 (100)	76.43(0.75)	78.08(0.74)	75.94(1.24)	73.56(0.76)	0.48(0.02)	0.50(0.02)	0.47(0.03)	0.38(0.02)	0.83(0.01)	0.85(0.01)	0.83(0.01)	0.79(0.01)		
2. MATH2 (100)	76.65(0.73)	78.18(0.65)	75.97(0.92)	74.09(0.70)	0.49(0.02)	0.50(0.02)	0.46(0.03)	0.39(0.02)	0.83(0.01)	0.85(0.01)	0.83(0.01)	0.79(0.01)		
3. MATH2 (100)	77.53(0.80)	78.55(0.66)	76.13(1.07)	74.20(0.81)	0.50(0.02)	0.50(0.02)	0.46(0.03)	0.37(0.02)	0.82(0.01)	0.85(0.01)	0.82(0.01)	0.79(0.01)		
4. MATH2 (100)	76.18(0.66)	77.62(0.67)	75.35(1.18)	73.21(0.75)	0.48(0.01)	0.50(0.02)	0.46(0.03)	0.37(0.02)	0.83(0.01)	0.85(0.01)	0.82(0.01)	0.78(0.01)		
5. MATH2 (100)	76.48(0.70)	77.97(0.67)	75.41(1.11)	74.11(0.74)	0.47(0.02)	0.49(0.02)	0.43(0.04)	0.36(0.02)	0.82(0.01)	0.84(0.01)	0.82(0.01)	0.78(0.01)		
6. MATH2 (100)	76.39(0.69)	77.97(0.67)	76.06(1.09)	74.39(0.68)	0.48(0.02)	0.49(0.01)	0.46(0.03)	0.38(0.02)	0.83(0.01)	0.85(0.01)	0.83(0.01)	0.80(0.01)		
7. MATH2 (100)	76.77(0.67)	78.26(0.66)	75.70(1.10)	73.77(0.76)	0.48(0.02)	0.50(0.02)	0.45(0.02)	0.37(0.02)	0.83(0.01)	0.85(0.01)	0.82(0.01)	0.78(0.01)		
8. MATH2 (100)	76.88(0.67)	78.17(0.62)	75.75(0.95)	73.94(0.75)	0.49(0.01)	0.51(0.01)	0.47(0.02)	0.39(0.02)	0.83(0.01)	0.85(0.01)	0.83(0.01)	0.79(0.01)		
9. MATH2 (100)	76.19(0.76)	77.76(0.70)	75.67(1.17)	74.62(0.77)	0.46(0.02)	0.48(0.02)	0.46(0.03)	0.38(0.02)	0.82(0.01)	0.84(0.01)	0.82(0.01)	0.79(0.01)		
10. MATH2 (100)	77.09(0.70)	78.51(0.68)	76.16(1.10)	73.62(0.79)	0.49(0.02)	0.51(0.02)	0.47(0.03)	0.36(0.02)	0.83(0.01)	0.85(0.01)	0.83(0.01)	0.79(0.01)		
11. MATH2 (100)	75.92(0.66)	77.43(0.58)	75.13(1.14)	73.41(0.70)	0.46(0.01)	0.48(0.01)	0.44(0.03)	0.35(0.02)	0.82(0.01)	0.84(0.01)	0.82(0.01)	0.78(0.01)		
12. MATH2 (100)	76.43(0.79)	78.19(0.64)	75.63(1.54)	73.77(0.63)	0.48(0.02)	0.50(0.01)	0.45(0.03)	0.36(0.02)	0.82(0.01)	0.85(0.01)	0.82(0.01)	0.78(0.01)		
13. MATH2 (100)	77.93(0.71)	79.01(0.62)	76.77(1.26)	75.19(0.67)	0.50(0.02)	0.51(0.01)	0.47(0.03)	0.39(0.02)	0.84(0.01)	0.85(0.01)	0.83(0.01)	0.80(0.01)		
14. MATH2 (100)	76.75(0.65)	77.69(0.61)	75.32(1.09)	73.74(0.74)	0.49(0.01)	0.49(0.01)	0.45(0.03)	0.36(0.02)	0.82(0.01)	0.84(0.01)	0.82(0.01)	0.78(0.01)		
15. MATH2 (100)	76.85(0.81)	78.78(0.64)	76.26(1.12)	73.74(0.74)	0.49(0.02)	0.52(0.01)	0.48(0.02)	0.38(0.02)	0.83(0.01)	0.86(0.01)	0.83(0.01)	0.79(0.01)		
16. MATH2 (100)	76.41(0.67)	78.71(0.73)	76.29(1.33)	73.66(0.74)	0.48(0.02)	0.52(0.02)	0.48(0.03)	0.37(0.02)	0.82(0.01)	0.85(0.01)	0.83(0.01)	0.79(0.01)		
17. MATH2 (100)	77.15(0.76)	78.71(0.69)	76.65(1.05)	74.73(0.68)	0.49(0.02)	0.50(0.02)	0.47(0.03)	0.39(0.02)	0.83(0.01)	0.85(0.01)	0.83(0.01)	0.78(0.01)		
18. MATH2 (100)	76.36(0.73)	77.91(0.64)	75.31(1.23)	72.96(0.77)	0.48(0.02)	0.50(0.02)	0.46(0.03)	0.35(0.02)	0.82(0.01)	0.85(0.01)	0.82(0.01)	0.78(0.01)		
19. MATH2 (100)	75.85(0.69)	77.48(0.68)	75.01(1.11)	73.45(0.84)	0.47(0.01)	0.49(0.02)	0.44(0.03)	0.38(0.02)	0.82(0.01)	0.85(0.01)	0.82(0.01)	0.78(0.01)		
20. MATH2 (100)	76.13(0.64)	78.15(0.62)	75.41(1.17)	73.34(0.75)	0.47(0.01)	0.50(0.01)	0.46(0.02)	0.37(0.02)	0.82(0.01)	0.84(0.01)	0.82(0.01)	0.78(0.01)		
21. MATH2 (100)	75.95(0.75)	77.92(0.67)	75.30(1.11)	73.19(0.70)	0.47(0.02)	0.49(0.02)	0.45(0.03)	0.35(0.02)	0.82(0.01)	0.84(0.01)	0.82(0.01)	0.78(0.01)		
22. MATH2 (100)	76.95(0.66)	78.87(0.74)	76.79(1.14)	74.40(0.70)	0.49(0.02)	0.51(0.02)	0.48(0.03)	0.37(0.02)	0.83(0.01)	0.85(0.01)	0.83(0.01)	0.79(0.01)		
23. MATH2 (100)	76.18(0.72)	77.65(0.66)	75.37(0.98)	73.34(0.74)	0.47(0.02)	0.49(0.02)	0.45(0.03)	0.36(0.02)	0.82(0.01)	0.84(0.01)	0.82(0.01)	0.78(0.01)		
24. MATH2 (100)	76.53(0.67)	77.57(0.58)	75.46(0.89)	73.46(0.67)	0.48(0.02)	0.48(0.01)	0.45(0.03)	0.36(0.02)	0.82(0.01)	0.84(0.01)	0.82(0.01)	0.78(0.01)		
25. MATH2 (100)	76.57(0.83)	78.13(0.70)	75.80(1.12)	73.82(0.80)	0.48(0.02)	0.50(0.02)	0.46(0.03)	0.37(0.02)	0.82(0.01)	0.84(0.01)	0.82(0.01)	0.79(0.01)		
26. MATH2 (100)	76.35(0.68)	77.82(0.76)	75.67(1.15)	74.41(0.64)	0.47(0.01)	0.49(0.02)	0.45(0.03)	0.37(0.02)	0.82(0.01)	0.84(0.01)	0.82(0.01)	0.79(0.01)		
27. MATH2 (100)	76.49(0.71)	78.03(0.66)	75.70(1.04)	73.92(0.76)	0.48(0.02)	0.50(0.02)	0.46(0.03)	0.38(0.02)	0.83(0.01)	0.85(0.01)	0.82(0.01)	0.79(0.01)		
28. MATH2 (100)	76.80(0.71)	78.28(0.70)	76.03(1.03)	73.76(0.67)	0.49(0.02)	0.51(0.02)	0.47(0.03)	0.38(0.02)	0.83(0.01)	0.85(0.01)	0.83(0.01)	0.79(0.01)		
29. MATH2 (100)	76.66(0.79)	78.53(0.66)	76.02(1.03)	74.07(0.82)	0.49(0.02)	0.52(0.01)	0.47(0.02)	0.39(0.02)	0.83(0.01)	0.85(0.01)	0.82(0.01)	0.79(0.01)		
30. MATH2 (100)	75.36(0.72)	77.33(0.80)	75.04(1.16)	73.12(0.83)	0.46(0.02)	0.49(0.02)	0.45(0.03)	0.37(0.02)	0.82(0.01)	0.85(0.01)	0.82(0.01)	0.78(0.01)		

## EK-E: 5000 Kişilik Örneklemde Test Verisi Oranı %55 için Elde Edilen Analiz Sonuçları

Dataset	Analysing: Percent_correct ( stddev) Datasets: 30 Resultsets: 4					Analysing: Kappa_statistic ( stddev) Datasets: 30 Resultsets: 4					Analysing: Area_under_ROC ( stddev) Datasets: 30 Resultsets: 4			
	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk		(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk		(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk
1. MATH2 (100)	76.36(0.63)	78.01(0.59)	75.53(0.98)	73.28(0.68)		0.48(0.01)	0.50(0.01)	0.46(0.02)	0.37(0.02)		0.83(0.01)	0.85(0.01)	0.82(0.01)	0.78(0.01)
2. MATH2 (100)	76.69(0.57)	78.07(0.54)	75.54(1.08)	73.79(0.69)		0.49(0.01)	0.50(0.01)	0.46(0.03)	0.38(0.02)		0.83(0.01)	0.85(0.01)	0.82(0.01)	0.79(0.01)
3. MATH2 (100)	77.44(0.64)	78.30(0.53)	75.84(1.05)	73.94(0.71)		0.49(0.01)	0.50(0.01)	0.46(0.03)	0.36(0.02)		0.82(0.01)	0.85(0.01)	0.82(0.01)	0.78(0.01)
4. MATH2 (100)	76.11(0.56)	77.50(0.62)	75.01(1.04)	72.85(0.64)		0.48(0.01)	0.50(0.01)	0.45(0.03)	0.36(0.02)		0.83(0.01)	0.85(0.01)	0.82(0.01)	0.78(0.01)
5. MATH2 (100)	76.37(0.61)	77.72(0.58)	75.18(1.29)	73.83(0.69)		0.47(0.01)	0.48(0.01)	0.44(0.03)	0.35(0.02)		0.82(0.01)	0.84(0.01)	0.81(0.01)	0.78(0.01)
6. MATH2 (100)	76.31(0.61)	77.87(0.59)	75.54(1.08)	74.08(0.62)		0.48(0.01)	0.49(0.01)	0.45(0.03)	0.37(0.02)		0.83(0.01)	0.85(0.01)	0.82(0.01)	0.79(0.01)
7. MATH2 (100)	76.63(0.59)	78.06(0.62)	75.33(1.04)	73.15(0.78)		0.48(0.01)	0.50(0.01)	0.44(0.03)	0.35(0.02)		0.83(0.01)	0.85(0.01)	0.82(0.01)	0.77(0.01)
8. MATH2 (100)	76.77(0.64)	77.99(0.55)	75.62(1.01)	73.49(0.74)		0.49(0.01)	0.51(0.01)	0.46(0.02)	0.38(0.02)		0.83(0.01)	0.85(0.00)	0.82(0.01)	0.79(0.01)
9. MATH2 (100)	76.15(0.67)	77.62(0.54)	75.56(0.89)	74.23(0.60)		0.46(0.01)	0.48(0.01)	0.44(0.03)	0.37(0.02)		0.82(0.01)	0.84(0.01)	0.81(0.01)	0.78(0.01)
10. MATH2 (100)	77.05(0.60)	78.29(0.57)	75.88(1.24)	73.44(0.65)		0.49(0.01)	0.50(0.01)	0.46(0.03)	0.35(0.02)		0.83(0.01)	0.85(0.00)	0.82(0.01)	0.78(0.01)
11. MATH2 (100)	75.90(0.48)	77.32(0.50)	74.99(1.07)	73.19(0.59)		0.46(0.01)	0.48(0.01)	0.43(0.03)	0.34(0.02)		0.82(0.01)	0.84(0.01)	0.81(0.01)	0.78(0.01)
12. MATH2 (100)	76.40(0.66)	78.09(0.54)	75.41(1.05)	73.47(0.63)		0.47(0.01)	0.50(0.01)	0.45(0.02)	0.35(0.02)		0.82(0.01)	0.85(0.00)	0.82(0.01)	0.78(0.01)
13. MATH2 (100)	77.81(0.61)	78.84(0.56)	76.72(0.91)	74.85(0.66)		0.50(0.01)	0.51(0.01)	0.47(0.03)	0.38(0.02)		0.84(0.01)	0.85(0.01)	0.83(0.01)	0.79(0.01)
14. MATH2 (100)	76.55(0.54)	77.56(0.55)	75.09(1.10)	73.38(0.67)		0.48(0.01)	0.49(0.01)	0.44(0.03)	0.36(0.02)		0.82(0.01)	0.84(0.01)	0.81(0.01)	0.78(0.01)
15. MATH2 (100)	76.92(0.73)	78.75(0.57)	76.07(0.96)	73.57(0.63)		0.49(0.02)	0.52(0.01)	0.47(0.03)	0.37(0.02)		0.83(0.01)	0.86(0.01)	0.83(0.01)	0.79(0.01)
16. MATH2 (100)	76.46(0.66)	78.59(0.58)	75.92(1.12)	73.43(0.72)		0.48(0.02)	0.52(0.01)	0.46(0.03)	0.37(0.02)		0.82(0.01)	0.85(0.01)	0.82(0.01)	0.78(0.01)
17. MATH2 (100)	77.03(0.57)	78.55(0.60)	76.11(1.10)	74.16(0.65)		0.48(0.01)	0.50(0.01)	0.46(0.02)	0.37(0.02)		0.83(0.01)	0.85(0.01)	0.82(0.01)	0.78(0.01)
18. MATH2 (100)	76.37(0.68)	77.80(0.61)	75.19(1.01)	72.73(0.69)		0.48(0.01)	0.50(0.01)	0.44(0.03)	0.35(0.02)		0.82(0.01)	0.85(0.01)	0.82(0.01)	0.78(0.01)
19. MATH2 (100)	75.77(0.59)	77.35(0.59)	74.79(1.11)	72.99(0.72)		0.47(0.01)	0.49(0.01)	0.45(0.03)	0.37(0.02)		0.82(0.01)	0.84(0.01)	0.81(0.01)	0.78(0.01)
20. MATH2 (100)	76.10(0.57)	77.92(0.56)	75.25(1.10)	72.90(0.61)		0.47(0.01)	0.50(0.01)	0.45(0.02)	0.35(0.02)		0.82(0.01)	0.84(0.01)	0.82(0.01)	0.78(0.01)
21. MATH2 (100)	75.93(0.60)	77.70(0.52)	74.92(1.03)	72.89(0.62)		0.47(0.01)	0.49(0.01)	0.44(0.03)	0.34(0.02)		0.82(0.01)	0.84(0.01)	0.81(0.01)	0.77(0.01)
22. MATH2 (100)	76.93(0.58)	78.82(0.53)	76.51(0.92)	74.16(0.68)		0.49(0.01)	0.51(0.01)	0.47(0.03)	0.36(0.02)		0.83(0.01)	0.85(0.00)	0.83(0.01)	0.79(0.01)
23. MATH2 (100)	76.18(0.65)	77.50(0.56)	74.80(1.08)	73.02(0.62)		0.47(0.01)	0.49(0.01)	0.44(0.03)	0.35(0.02)		0.82(0.01)	0.84(0.01)	0.81(0.01)	0.78(0.01)
24. MATH2 (100)	76.49(0.58)	77.45(0.47)	75.20(1.10)	73.14(0.55)		0.48(0.01)	0.48(0.01)	0.44(0.03)	0.35(0.02)		0.82(0.01)	0.84(0.01)	0.81(0.01)	0.77(0.01)
25. MATH2 (100)	76.52(0.64)	78.00(0.58)	75.57(1.09)	73.43(0.69)		0.48(0.01)	0.50(0.01)	0.45(0.02)	0.36(0.02)		0.82(0.01)	0.84(0.01)	0.82(0.01)	0.78(0.01)
26. MATH2 (100)	76.36(0.56)	77.74(0.60)	75.48(1.11)	74.20(0.63)		0.47(0.01)	0.48(0.01)	0.45(0.02)	0.37(0.02)		0.82(0.01)	0.84(0.01)	0.81(0.01)	0.78(0.01)
27. MATH2 (100)	76.47(0.58)	77.85(0.60)	75.30(1.16)	73.56(0.69)		0.48(0.01)	0.50(0.01)	0.45(0.03)	0.37(0.02)		0.83(0.01)	0.85(0.01)	0.82(0.01)	0.78(0.01)
28. MATH2 (100)	76.68(0.63)	78.16(0.58)	75.84(1.03)	73.38(0.66)		0.49(0.01)	0.51(0.01)	0.47(0.02)	0.37(0.02)		0.83(0.01)	0.85(0.01)	0.83(0.01)	0.79(0.01)
29. MATH2 (100)	76.62(0.64)	78.32(0.58)	75.90(1.06)	73.70(0.71)		0.48(0.01)	0.51(0.01)	0.47(0.03)	0.38(0.02)		0.82(0.01)	0.85(0.01)	0.82(0.01)	0.78(0.01)
30. MATH2 (100)	75.40(0.67)	77.21(0.66)	74.80(1.05)	72.81(0.72)		0.46(0.01)	0.49(0.01)	0.44(0.04)	0.36(0.02)		0.82(0.01)	0.84(0.01)	0.82(0.01)	0.78(0.01)

## EK-F: 1000 Kişilik Örneklemde Test Verisi Oranı %11 için Elde Edilen Analiz Sonuçları

Dataset	Analysing: Percent_correct (stddev) Datasets: 50 Resultsets: 4					Analysing: Kappa_statistic (stddev) Datasets: 50 Resultsets: 4					Analysing: Area_under_ROC (stddev) Datasets: 50 Resultsets: 4			
	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk		(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk		(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk
1.MATH2 (100)	76.41(3.97)	76.68(3.46)	74.03(4.33)	71.82(3.02)		0.46(0.09)	0.44(0.08)	0.41(0.10)	0.29(0.09)		0.82(0.04)	0.83(0.04)	0.79(0.05)	0.75(0.04)
2.MATH2 (100)	77.00(3.85)	77.11(3.45)	74.74(3.82)	71.88(3.55)		0.50(0.09)	0.49(0.08)	0.44(0.08)	0.33(0.09)		0.83(0.04)	0.84(0.04)	0.81(0.04)	0.76(0.04)
3.MATH2 (100)	77.02(3.62)	80.43(3.71)	75.85(3.74)	70.69(3.48)		0.49(0.08)	0.56(0.08)	0.47(0.08)	0.31(0.08)		0.84(0.04)	0.86(0.04)	0.82(0.04)	0.73(0.05)
4.MATH2 (100)	75.98(3.78)	74.99(3.67)	72.20(3.67)	74.26(2.41)		0.48(0.08)	0.45(0.08)	0.40(0.08)	0.30(0.07)		0.82(0.04)	0.82(0.04)	0.78(0.04)	0.74(0.05)
5.MATH2 (100)	76.53(3.65)	76.61(3.78)	74.04(4.01)	69.62(3.89)		0.49(0.08)	0.49(0.08)	0.44(0.09)	0.27(0.10)		0.82(0.04)	0.83(0.04)	0.80(0.04)	0.73(0.05)
6.MATH2 (100)	75.61(4.19)	75.67(4.15)	72.30(3.89)	72.46(3.67)		0.45(0.09)	0.44(0.10)	0.38(0.09)	0.36(0.09)		0.80(0.05)	0.80(0.05)	0.77(0.05)	0.78(0.04)
7.MATH2 (100)	74.73(3.72)	75.31(3.73)	72.81(4.15)	72.42(3.47)		0.45(0.08)	0.44(0.08)	0.41(0.09)	0.30(0.09)		0.82(0.04)	0.82(0.04)	0.79(0.04)	0.77(0.04)
8.MATH2 (100)	75.60(4.35)	76.17(3.77)	73.08(4.25)	70.25(3.49)		0.44(0.10)	0.43(0.09)	0.38(0.09)	0.23(0.10)		0.81(0.05)	0.81(0.04)	0.76(0.05)	0.72(0.05)
9.MATH2 (100)	77.70(3.40)	79.30(3.42)	75.80(3.80)	71.01(3.15)		0.50(0.08)	0.52(0.08)	0.45(0.08)	0.25(0.08)		0.84(0.04)	0.84(0.04)	0.81(0.04)	0.73(0.05)
10.MATH2 (100)	77.13(3.69)	78.63(3.19)	74.72(3.82)	72.80(3.69)		0.51(0.08)	0.52(0.07)	0.44(0.08)	0.30(0.10)		0.83(0.03)	0.84(0.03)	0.80(0.04)	0.74(0.05)
11.MATH2 (100)	74.98(4.35)	75.49(3.93)	73.39(4.09)	71.37(3.37)		0.45(0.10)	0.45(0.09)	0.42(0.09)	0.34(0.08)		0.81(0.04)	0.81(0.04)	0.78(0.04)	0.77(0.04)
12.MATH2 (100)	77.41(3.69)	76.64(3.77)	74.00(4.27)	73.09(3.36)		0.47(0.09)	0.43(0.09)	0.39(0.10)	0.37(0.08)		0.81(0.04)	0.81(0.04)	0.78(0.05)	0.78(0.04)
13.MATH2 (100)	73.81(3.52)	74.40(3.91)	71.17(3.89)	72.54(3.37)		0.42(0.08)	0.43(0.09)	0.36(0.09)	0.36(0.08)		0.79(0.04)	0.81(0.04)	0.77(0.04)	0.75(0.04)
14.MATH2 (100)	76.41(3.66)	77.96(4.07)	74.92(3.92)	71.03(3.20)		0.49(0.08)	0.52(0.09)	0.46(0.09)	0.28(0.08)		0.83(0.04)	0.85(0.04)	0.82(0.04)	0.76(0.05)
15.MATH2 (100)	76.47(3.97)	78.51(3.87)	74.53(3.90)	70.60(3.76)		0.47(0.08)	0.51(0.09)	0.43(0.08)	0.26(0.10)		0.82(0.04)	0.83(0.04)	0.80(0.04)	0.75(0.06)
16.MATH2 (100)	75.69(4.03)	76.54(3.63)	73.72(3.98)	71.47(3.25)		0.45(0.09)	0.45(0.08)	0.40(0.09)	0.32(0.08)		0.83(0.04)	0.83(0.04)	0.79(0.04)	0.75(0.04)
17.MATH2 (100)	77.38(3.95)	78.45(3.54)	75.87(3.77)	72.00(3.69)		0.48(0.09)	0.49(0.08)	0.44(0.08)	0.35(0.09)		0.82(0.04)	0.84(0.04)	0.80(0.05)	0.78(0.04)
18.MATH2 (100)	75.65(3.68)	76.17(3.53)	73.44(4.05)	73.84(3.27)		0.44(0.08)	0.44(0.08)	0.39(0.09)	0.36(0.08)		0.81(0.04)	0.82(0.04)	0.78(0.04)	0.78(0.04)
19.MATH2 (100)	78.29(3.98)	77.96(3.62)	75.29(3.95)	73.39(3.24)		0.53(0.09)	0.52(0.08)	0.46(0.08)	0.32(0.09)		0.85(0.04)	0.85(0.03)	0.82(0.03)	0.77(0.04)
20.MATH2 (100)	76.91(4.08)	76.56(4.00)	73.62(4.22)	72.30(3.46)		0.50(0.09)	0.48(0.09)	0.42(0.09)	0.29(0.09)		0.83(0.04)	0.82(0.04)	0.79(0.04)	0.73(0.05)
21.MATH2 (100)	75.76(3.41)	76.86(3.44)	72.96(3.74)	73.46(3.12)		0.46(0.08)	0.47(0.08)	0.40(0.08)	0.32(0.09)		0.81(0.04)	0.82(0.04)	0.79(0.04)	0.76(0.05)
22.MATH2 (100)	77.28(3.83)	77.15(3.97)	74.35(4.04)	73.30(3.74)		0.50(0.08)	0.47(0.09)	0.42(0.09)	0.37(0.09)		0.83(0.04)	0.84(0.04)	0.80(0.05)	0.79(0.04)
23.MATH2 (100)	75.88(3.91)	77.78(3.40)	73.86(4.09)	72.11(3.60)		0.46(0.09)	0.50(0.08)	0.43(0.08)	0.33(0.08)		0.82(0.04)	0.83(0.04)	0.80(0.04)	0.77(0.05)
24.MATH2 (100)	77.26(3.84)	78.17(3.73)	75.21(4.01)	71.31(3.78)		0.51(0.08)	0.51(0.08)	0.46(0.09)	0.33(0.09)		0.83(0.04)	0.85(0.04)	0.82(0.04)	0.74(0.04)
25.MATH2 (100)	78.49(3.42)	79.00(3.20)	76.18(3.98)	72.96(3.13)		0.52(0.08)	0.51(0.08)	0.47(0.09)	0.31(0.08)		0.84(0.04)	0.84(0.04)	0.82(0.04)	0.77(0.04)
26.MATH2 (100)	78.40(3.41)	75.96(3.44)	73.63(4.38)	72.34(2.78)		0.51(0.08)	0.43(0.08)	0.40(0.10)	0.27(0.08)		0.83(0.04)	0.82(0.04)	0.79(0.05)	0.73(0.05)
27.MATH2 (100)	76.21(3.36)	76.75(3.49)	73.48(3.93)	73.64(3.57)		0.46(0.07)	0.45(0.08)	0.39(0.08)	0.33(0.10)		0.81(0.04)	0.81(0.04)	0.78(0.04)	0.78(0.05)
28.MATH2 (100)	74.52(3.82)	75.87(3.70)	72.73(4.49)	70.77(3.63)		0.44(0.08)	0.44(0.09)	0.38(0.09)	0.30(0.09)		0.81(0.04)	0.81(0.04)	0.77(0.05)	0.75(0.05)
29.MATH2 (100)	78.04(3.20)	78.49(3.22)	75.59(3.82)	72.21(3.06)		0.52(0.07)	0.52(0.07)	0.47(0.08)	0.34(0.07)		0.85(0.03)	0.85(0.03)	0.82(0.04)	0.77(0.04)
30.MATH2 (100)	74.91(3.45)	74.96(3.93)	73.16(4.11)	70.52(3.56)		0.44(0.08)	0.43(0.09)	0.41(0.09)	0.28(0.09)		0.81(0.04)	0.81(0.04)	0.78(0.04)	0.75(0.04)
31.MATH2 (100)	76.67(3.92)	78.22(3.35)	74.91(3.86)	69.66(3.47)		0.47(0.09)	0.49(0.08)	0.43(0.08)	0.24(0.09)		0.83(0.04)	0.84(0.04)	0.80(0.04)	0.71(0.05)
32.MATH2 (100)	77.05(3.10)	78.53(3.24)	75.49(3.40)	73.15(4.09)		0.46(0.07)	0.49(0.08)	0.43(0.08)	0.38(0.09)		0.82(0.04)	0.83(0.04)	0.80(0.04)	0.77(0.05)
33.MATH2 (100)	77.02(4.00)	77.07(3.44)	74.24(3.80)	72.80(4.06)		0.48(0.09)	0.47(0.08)	0.41(0.08)	0.36(0.10)		0.82(0.04)	0.83(0.04)	0.79(0.04)	0.77(0.05)
34.MATH2 (100)	75.04(4.19)	73.36(3.31)	70.37(3.81)	70.82(3.57)		0.45(0.09)	0.39(0.08)	0.34(0.08)	0.32(0.09)		0.81(0.04)	0.80(0.04)	0.76(0.04)	0.76(0.04)
35.MATH2 (100)	77.28(3.53)	77.59(3.79)	75.19(4.22)	73.93(3.99)		0.50(0.08)	0.49(0.08)	0.44(0.10)	0.38(0.10)		0.83(0.04)	0.83(0.04)	0.80(0.04)	0.78(0.05)
36.MATH2 (100)	75.17(3.40)	76.17(3.48)	73.84(3.79)	70.94(3.58)		0.45(0.08)	0.46(0.08)	0.42(0.08)	0.25(0.09)		0.82(0.03)	0.84(0.04)	0.81(0.04)	0.74(0.05)
37.MATH2 (100)	71.91(4.18)	73.58(4.20)	70.48(3.76)	73.06(3.05)		0.38(0.09)	0.39(0.10)	0.33(0.09)	0.34(0.08)		0.78(0.04)	0.79(0.04)	0.77(0.04)	0.77(0.04)
38.MATH2 (100)	77.01(3.54)	77.56(3.66)	75.30(4.36)	70.79(3.34)		0.49(0.08)	0.49(0.09)	0.46(0.09)	0.32(0.08)		0.82(0.04)	0.84(0.04)	0.81(0.05)	0.74(0.04)
39.MATH2 (100)	75.85(3.93)	78.02(3.58)	75.10(3.37)	71.10(3.86)		0.47(0.09)	0.51(0.08)	0.46(0.07)	0.34(0.09)		0.83(0.04)	0.84(0.04)	0.81(0.04)	0.76(0.05)
40.MATH2 (100)	77.06(3.99)	76.44(3.79)	73.08(4.85)	70.09(4.09)		0.50(0.09)	0.48(0.08)	0.41(0.10)	0.32(0.09)		0.83(0.04)	0.83(0.04)	0.79(0.05)	0.75(0.05)
41.MATH2 (100)	74.63(3.62)	75.55(3.40)	72.37(4.65)	73.28(3.34)		0.43(0.08)	0.43(0.08)	0.38(0.10)	0.36(0.09)		0.80(0.04)	0.80(0.04)	0.77(0.05)	0.78(0.04)
42.MATH2 (100)	77.29(3.30)	78.65(3.17)	74.84(3.96)	72.62(3.09)		0.49(0.08)	0.51(0.07)	0.44(0.08)	0.33(0.08)		0.83(0.04)	0.84(0.03)	0.80(0.04)	0.77(0.04)
43.MATH2 (100)	76.23(3.57)	76.51(3.75)	74.02(3.88)	72.22(3.19)		0.48(0.08)	0.48(0.08)	0.44(0.08)	0.29(0.09)		0.83(0.04)	0.84(0.04)	0.81(0.04)	0.73(0.04)
44.MATH2 (100)	75.64(4.25)	76.05(4.13)	73.03(3.88)	73.24(3.54)		0.48(0.09)	0.48(0.09)	0.42(0.08)	0.34(0.09)		0.82(0.04)	0.83(0.04)	0.80(0.04)	0.77(0.04)
45.MATH2 (100)	76.49(4.15)	74.55(3.57)	71.51(4.40)	71.43(3.55)		0.49(0.09)	0.45(0.08)	0.39(0.09)	0.34(0.09)		0.82(0.04)	0.82(0.04)	0.78(0.05)	0.75(0.04)
46.MATH2 (100)	75.64(3.30)	77.26(2.99)	74.46(3.69)	73.22(3.06)		0.47(0.07)	0.50(0.07)	0.44(0.08)	0.31(0.08)		0.83(0.03)	0.84(0.03)	0.81(0.03)	0.76(0.04)
47.MATH2 (100)	76.62(3.92)	77.98(3.50)	74.81(3.91)	69.91(3.96)		0.48(0.09)	0.50(0.08)	0.44(0.09)	0.25(0.10)		0.81(0.04)	0.84(0.03)	0.80(0.04)	0.74(0.05)
48.MATH2 (100)	74.70(3.86)	75.51(3.37)	72.75(3.90)	70.44(3.94)		0.43(0.09)	0.42(0.08)	0.38(0.08)	0.30(0.09)		0.80(0.04)	0.81(0.04)	0.77(0.05)	0.76(0.05)
49.MATH2 (100)	76.70(3.88)	76.08(3.37)	73.26(3.61)	72.64(3.12)		0.47(0.08)	0.45(0.08)	0.40(0.08)	0.30(0.08)		0.81(0.04)	0.81(0.04)	0.79(0.05)	0.76(0.05)
50.MATH2 (100)	77.24(4.22)	77.59(3.76)	74.46(4.28)	73.06(3.30)		0.49(0.09)	0.47(0.09)	0.42(0.10)	0.33(0.09)		0.83(0.04)	0.84(0.04)	0.79(0.05)	0.76(0.04)

## EK-G: 1000 Kişilik Örneklemde Test Verisi Oranı %22 için Elde Edilen Analiz Sonuçları

Analysing: Percent_correct (stddev) Datasets: 50 Resultsets: 4				Analysing: Kappa_statistic (stddev) Datasets: 50 Resultsets: 4				Analysing: Area_under_ROC (stddev) Datasets: 50 Resultsets: 4				
Dataset	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk
1.MATH2 (100)	76.28(2.99)	76.52(2.51)	73.77(2.74)	71.24(2.45)	0.45(0.07)	0.44(0.06)	0.40(0.06)	0.26(0.06)	0.81(0.03)	0.82(0.03)	0.79(0.03)	0.74(0.04)
2.MATH2 (100)	76.94(2.39)	76.90(2.48)	74.13(2.59)	71.90(2.32)	0.50(0.05)	0.49(0.06)	0.43(0.06)	0.33(0.06)	0.83(0.03)	0.84(0.02)	0.80(0.03)	0.77(0.03)
3.MATH2 (100)	77.47(2.52)	80.05(2.56)	76.28(2.93)	71.27(2.29)	0.50(0.06)	0.55(0.06)	0.47(0.06)	0.32(0.06)	0.84(0.03)	0.85(0.03)	0.82(0.03)	0.74(0.03)
4.MATH2 (100)	76.00(2.54)	75.26(2.34)	72.24(2.77)	73.89(1.90)	0.48(0.05)	0.45(0.05)	0.40(0.06)	0.29(0.05)	0.82(0.02)	0.82(0.02)	0.78(0.03)	0.74(0.03)
5.MATH2 (100)	76.30(2.48)	76.24(2.70)	73.65(2.82)	69.60(2.37)	0.49(0.05)	0.48(0.06)	0.43(0.06)	0.27(0.06)	0.82(0.03)	0.82(0.03)	0.80(0.03)	0.73(0.03)
6.MATH2 (100)	75.04(2.92)	75.69(2.72)	72.08(3.37)	72.38(2.29)	0.44(0.06)	0.44(0.06)	0.37(0.07)	0.36(0.06)	0.79(0.03)	0.80(0.03)	0.77(0.04)	0.77(0.03)
7.MATH2 (100)	74.61(2.40)	75.29(2.44)	71.98(2.44)	72.14(1.95)	0.45(0.05)	0.44(0.05)	0.39(0.06)	0.30(0.05)	0.82(0.02)	0.82(0.02)	0.78(0.03)	0.77(0.03)
8.MATH2 (100)	75.50(2.86)	76.16(2.67)	72.46(3.15)	70.25(2.29)	0.44(0.06)	0.43(0.06)	0.37(0.06)	0.23(0.06)	0.80(0.03)	0.80(0.03)	0.76(0.03)	0.71(0.05)
9.MATH2 (100)	77.07(2.54)	78.58(2.49)	74.62(2.87)	71.16(2.26)	0.48(0.06)	0.51(0.06)	0.43(0.07)	0.25(0.06)	0.83(0.03)	0.84(0.03)	0.80(0.03)	0.73(0.04)
10.MATH2 (100)	77.36(2.22)	78.31(2.08)	74.86(2.72)	72.55(2.17)	0.51(0.05)	0.51(0.05)	0.45(0.06)	0.29(0.06)	0.84(0.02)	0.84(0.02)	0.80(0.03)	0.73(0.03)
11.MATH2 (100)	74.99(2.70)	75.62(2.48)	72.49(2.98)	71.65(2.88)	0.45(0.06)	0.46(0.06)	0.40(0.06)	0.34(0.07)	0.81(0.03)	0.81(0.03)	0.78(0.03)	0.77(0.03)
12.MATH2 (100)	76.67(2.55)	76.56(2.52)	73.92(2.70)	72.77(2.27)	0.46(0.06)	0.43(0.06)	0.39(0.06)	0.36(0.05)	0.81(0.03)	0.81(0.03)	0.77(0.03)	0.77(0.03)
13.MATH2 (100)	73.76(2.56)	74.56(2.45)	70.92(2.96)	72.47(2.69)	0.42(0.06)	0.43(0.05)	0.36(0.06)	0.36(0.06)	0.79(0.03)	0.81(0.03)	0.77(0.03)	0.75(0.03)
14.MATH2 (100)	76.39(2.47)	77.89(2.53)	74.76(2.76)	71.09(2.21)	0.49(0.05)	0.52(0.06)	0.46(0.06)	0.28(0.06)	0.83(0.02)	0.84(0.02)	0.81(0.03)	0.76(0.03)
15.MATH2 (100)	76.58(2.70)	78.08(2.61)	74.36(3.24)	71.19(2.40)	0.48(0.06)	0.50(0.06)	0.43(0.07)	0.28(0.06)	0.81(0.03)	0.83(0.03)	0.80(0.03)	0.75(0.04)
16.MATH2 (100)	76.03(2.85)	76.44(2.32)	73.74(2.78)	70.85(2.12)	0.46(0.06)	0.45(0.05)	0.40(0.06)	0.30(0.06)	0.83(0.03)	0.83(0.03)	0.79(0.03)	0.75(0.03)
17.MATH2 (100)	77.44(2.50)	78.18(2.57)	74.90(2.75)	72.48(2.52)	0.48(0.06)	0.49(0.06)	0.42(0.06)	0.36(0.06)	0.82(0.03)	0.83(0.03)	0.80(0.03)	0.78(0.03)
18.MATH2 (100)	75.79(2.47)	76.53(2.48)	73.27(2.64)	73.71(2.38)	0.44(0.06)	0.45(0.06)	0.39(0.06)	0.36(0.06)	0.81(0.03)	0.82(0.03)	0.78(0.03)	0.78(0.03)
19.MATH2 (100)	78.32(2.33)	78.01(2.40)	75.06(2.39)	73.54(2.12)	0.53(0.05)	0.52(0.05)	0.46(0.05)	0.32(0.06)	0.85(0.02)	0.85(0.02)	0.82(0.02)	0.77(0.03)
20.MATH2 (100)	76.65(2.76)	76.43(2.80)	73.39(2.76)	72.17(2.54)	0.49(0.06)	0.47(0.06)	0.42(0.06)	0.28(0.07)	0.82(0.03)	0.82(0.03)	0.79(0.03)	0.74(0.04)
21.MATH2 (100)	75.56(2.31)	76.60(2.16)	73.10(2.80)	73.34(2.13)	0.46(0.05)	0.47(0.05)	0.41(0.06)	0.32(0.06)	0.81(0.02)	0.82(0.02)	0.79(0.03)	0.76(0.03)
22.MATH2 (100)	77.04(2.33)	77.03(2.54)	74.21(3.10)	72.80(2.57)	0.49(0.05)	0.47(0.06)	0.42(0.07)	0.36(0.06)	0.83(0.03)	0.83(0.03)	0.80(0.03)	0.79(0.03)
23.MATH2 (100)	75.41(2.34)	77.67(2.52)	73.63(2.95)	72.28(2.52)	0.45(0.05)	0.50(0.06)	0.42(0.07)	0.33(0.06)	0.82(0.02)	0.83(0.02)	0.79(0.03)	0.78(0.03)
24.MATH2 (100)	77.39(2.48)	78.01(2.40)	75.04(2.72)	70.84(2.83)	0.51(0.05)	0.51(0.05)	0.45(0.06)	0.32(0.06)	0.84(0.02)	0.84(0.02)	0.81(0.03)	0.74(0.03)
25.MATH2 (100)	78.29(2.55)	78.69(2.52)	75.52(2.92)	73.07(2.29)	0.52(0.06)	0.51(0.06)	0.45(0.06)	0.31(0.06)	0.84(0.03)	0.84(0.03)	0.82(0.03)	0.77(0.03)
26.MATH2 (100)	78.07(2.33)	75.88(2.26)	73.37(2.94)	72.71(2.02)	0.50(0.05)	0.43(0.05)	0.39(0.07)	0.28(0.07)	0.82(0.03)	0.82(0.03)	0.78(0.03)	0.73(0.05)
27.MATH2 (100)	76.19(2.51)	76.22(2.44)	73.41(2.73)	73.46(2.21)	0.45(0.06)	0.44(0.06)	0.38(0.06)	0.33(0.06)	0.81(0.03)	0.80(0.03)	0.77(0.03)	0.77(0.03)
28.MATH2 (100)	74.69(2.70)	75.68(2.47)	72.73(2.85)	70.50(2.38)	0.44(0.06)	0.44(0.06)	0.38(0.06)	0.29(0.06)	0.81(0.03)	0.81(0.03)	0.77(0.03)	0.74(0.03)
29.MATH2 (100)	77.63(2.55)	78.52(2.26)	75.76(2.73)	72.35(2.28)	0.51(0.06)	0.52(0.05)	0.47(0.06)	0.33(0.06)	0.84(0.02)	0.85(0.02)	0.82(0.03)	0.77(0.03)
30.MATH2 (100)	74.66(2.26)	74.89(2.39)	72.44(2.55)	70.55(2.31)	0.44(0.05)	0.43(0.05)	0.39(0.05)	0.28(0.06)	0.81(0.03)	0.81(0.03)	0.77(0.03)	0.75(0.03)
31.MATH2 (100)	76.67(2.46)	77.76(2.19)	74.33(2.85)	69.66(2.54)	0.47(0.05)	0.48(0.05)	0.41(0.06)	0.24(0.06)	0.83(0.03)	0.83(0.02)	0.80(0.03)	0.72(0.03)
32.MATH2 (100)	77.09(2.23)	78.29(2.55)	74.90(2.75)	72.66(2.80)	0.46(0.05)	0.48(0.06)	0.41(0.07)	0.36(0.07)	0.82(0.03)	0.83(0.03)	0.79(0.03)	0.76(0.03)
33.MATH2 (100)	77.16(2.35)	77.34(2.29)	73.97(2.77)	72.21(2.74)	0.48(0.05)	0.47(0.05)	0.41(0.06)	0.35(0.06)	0.82(0.02)	0.83(0.02)	0.79(0.03)	0.77(0.04)
34.MATH2 (100)	74.88(2.64)	73.44(2.16)	71.08(2.83)	71.25(2.78)	0.45(0.06)	0.39(0.05)	0.36(0.06)	0.33(0.06)	0.81(0.03)	0.80(0.02)	0.76(0.03)	0.76(0.03)
35.MATH2 (100)	77.40(2.76)	76.97(2.61)	74.04(3.23)	73.00(2.54)	0.50(0.06)	0.47(0.06)	0.42(0.07)	0.36(0.06)	0.82(0.03)	0.83(0.03)	0.79(0.03)	0.77(0.03)
36.MATH2 (100)	75.60(2.48)	76.24(2.44)	73.71(2.99)	70.75(2.45)	0.46(0.06)	0.46(0.05)	0.42(0.07)	0.25(0.06)	0.83(0.02)	0.84(0.02)	0.80(0.03)	0.74(0.04)
37.MATH2 (100)	72.12(2.69)	73.29(2.78)	69.93(3.08)	73.05(2.35)	0.39(0.06)	0.39(0.06)	0.33(0.06)	0.33(0.06)	0.78(0.03)	0.78(0.03)	0.75(0.03)	0.77(0.03)
38.MATH2 (100)	76.23(2.63)	77.09(2.43)	74.51(2.94)	70.85(2.55)	0.47(0.06)	0.48(0.06)	0.44(0.06)	0.32(0.06)	0.82(0.03)	0.83(0.03)	0.80(0.03)	0.74(0.03)
39.MATH2 (100)	76.13(2.53)	77.64(2.72)	74.14(3.01)	70.97(2.64)	0.48(0.06)	0.50(0.06)	0.44(0.07)	0.34(0.06)	0.83(0.03)	0.83(0.03)	0.80(0.03)	0.76(0.03)
40.MATH2 (100)	76.87(2.73)	75.99(2.36)	73.51(2.72)	69.59(2.57)	0.50(0.06)	0.47(0.05)	0.42(0.06)	0.31(0.06)	0.82(0.03)	0.82(0.02)	0.79(0.03)	0.74(0.03)
41.MATH2 (100)	74.15(2.43)	75.03(2.33)	72.11(2.65)	73.08(2.38)	0.42(0.06)	0.42(0.06)	0.37(0.06)	0.35(0.06)	0.79(0.03)	0.79(0.03)	0.76(0.03)	0.78(0.03)
42.MATH2 (100)	77.34(2.64)	77.95(2.62)	74.42(3.09)	72.29(2.05)	0.49(0.06)	0.50(0.06)	0.43(0.06)	0.32(0.05)	0.83(0.03)	0.83(0.03)	0.80(0.03)	0.76(0.03)
43.MATH2 (100)	76.12(2.54)	76.64(2.36)	73.53(2.90)	71.79(2.22)	0.47(0.06)	0.48(0.05)	0.42(0.06)	0.27(0.06)	0.83(0.03)	0.83(0.02)	0.80(0.03)	0.73(0.03)
44.MATH2 (100)	75.79(2.80)	76.10(2.71)	73.48(2.94)	73.76(2.09)	0.48(0.06)	0.48(0.06)	0.43(0.06)	0.35(0.05)	0.82(0.03)	0.83(0.03)	0.80(0.03)	0.77(0.03)
45.MATH2 (100)	76.21(2.32)	74.10(2.69)	71.80(2.74)	71.12(2.62)	0.49(0.05)	0.44(0.06)	0.39(0.05)	0.33(0.06)	0.81(0.03)	0.81(0.03)	0.78(0.03)	0.75(0.03)
46.MATH2 (100)	76.12(2.23)	77.74(2.38)	74.69(2.59)	73.14(2.39)	0.48(0.05)	0.51(0.05)	0.44(0.05)	0.31(0.06)	0.84(0.02)	0.84(0.02)	0.81(0.03)	0.76(0.03)
47.MATH2 (100)	76.48(2.39)	77.85(2.68)	74.50(2.54)	70.24(2.65)	0.47(0.05)	0.50(0.06)	0.43(0.06)	0.26(0.07)	0.82(0.03)	0.84(0.03)	0.80(0.03)	0.73(0.04)
48.MATH2 (100)	74.81(2.73)	75.59(2.53)	72.69(2.95)	70.57(2.15)	0.43(0.06)	0.42(0.06)	0.37(0.07)	0.30(0.05)	0.81(0.03)	0.81(0.03)	0.77(0.03)	0.76(0.03)
49.MATH2 (100)	77.44(2.62)	76.61(2.26)	73.97(3.08)	72.31(2.62)	0.49(0.06)	0.46(0.05)	0.42(0.06)	0.29(0.07)	0.82(0.03)	0.82(0.03)	0.79(0.03)	0.75(0.04)
50.MATH2 (100)	76.90(2.44)	76.67(2.54)	73.82(2.85)	72.58(2.48)	0.48(0.05)	0.46(0.06)	0.40(0.07)	0.32(0.06)	0.83(0.02)	0.83(0.03)	0.79(0.03)	0.76(0.04)



## EK-H: 1000 Kişilik Örneklemde Test Verisi Oranı %33 için Elde Edilen Analiz Sonuçları

Analysing: Percent_correct (stddev) Datasets: 50 Resultsets: 4				Analysing: Kappa_statistic (stddev) Datasets: 50 Resultsets: 4				Analysing: Area_under_ROC (stddev) Datasets: 50 Resultsets: 4				
Dataset	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk
1.MATH2 (100)	76.34(2.01)	76.26(2.02)	73.49(2.44)	71.31(2.29)	0.45(0.05)	0.44(0.05)	0.39(0.05)	0.26(0.06)	0.81(0.02)	0.81(0.02)	0.78(0.02)	0.74(0.03)
2.MATH2 (100)	76.84(1.93)	76.65(1.98)	73.79(2.26)	71.72(2.10)	0.50(0.04)	0.48(0.04)	0.43(0.04)	0.33(0.05)	0.83(0.02)	0.83(0.02)	0.80(0.02)	0.76(0.03)
3.MATH2 (100)	77.14(2.05)	79.39(1.99)	75.06(2.21)	71.25(1.96)	0.50(0.04)	0.54(0.04)	0.45(0.05)	0.32(0.05)	0.84(0.02)	0.84(0.02)	0.81(0.02)	0.74(0.03)
4.MATH2 (100)	75.93(2.21)	75.02(2.00)	71.80(2.57)	73.48(1.76)	0.48(0.05)	0.45(0.04)	0.39(0.05)	0.28(0.05)	0.81(0.02)	0.82(0.02)	0.78(0.02)	0.73(0.03)
5.MATH2 (100)	76.10(1.91)	75.82(2.06)	73.39(2.24)	69.68(2.05)	0.48(0.04)	0.47(0.04)	0.42(0.05)	0.27(0.05)	0.82(0.02)	0.82(0.02)	0.79(0.02)	0.72(0.03)
6.MATH2 (100)	74.83(2.19)	75.10(2.00)	71.31(2.22)	72.08(2.02)	0.44(0.05)	0.43(0.05)	0.36(0.05)	0.36(0.05)	0.79(0.02)	0.79(0.02)	0.76(0.02)	0.77(0.02)
7.MATH2 (100)	74.75(1.74)	75.01(1.96)	71.86(2.60)	71.72(2.04)	0.45(0.04)	0.44(0.04)	0.38(0.06)	0.29(0.05)	0.82(0.02)	0.81(0.02)	0.78(0.02)	0.76(0.03)
8.MATH2 (100)	75.19(2.03)	75.39(2.10)	72.39(2.61)	70.09(1.64)	0.43(0.04)	0.42(0.05)	0.36(0.06)	0.23(0.05)	0.80(0.02)	0.80(0.02)	0.76(0.03)	0.71(0.04)
9.MATH2 (100)	77.10(2.13)	77.94(2.22)	74.54(2.33)	71.13(2.23)	0.48(0.05)	0.49(0.05)	0.42(0.05)	0.24(0.06)	0.83(0.02)	0.83(0.02)	0.80(0.02)	0.73(0.04)
10.MATH2 (100)	77.16(1.96)	77.79(1.89)	74.53(2.23)	72.30(1.58)	0.51(0.04)	0.50(0.04)	0.44(0.05)	0.29(0.04)	0.83(0.02)	0.84(0.02)	0.80(0.03)	0.73(0.03)
11.MATH2 (100)	75.25(2.00)	75.52(2.09)	72.53(2.50)	71.94(2.12)	0.46(0.04)	0.45(0.05)	0.40(0.05)	0.35(0.05)	0.81(0.02)	0.81(0.02)	0.77(0.02)	0.77(0.03)
12.MATH2 (100)	76.58(2.11)	76.37(1.97)	73.87(2.16)	72.68(2.00)	0.46(0.05)	0.43(0.05)	0.39(0.05)	0.36(0.05)	0.81(0.02)	0.80(0.02)	0.77(0.03)	0.77(0.02)
13.MATH2 (100)	73.87(1.94)	74.54(2.01)	71.08(2.33)	71.80(1.98)	0.42(0.04)	0.43(0.05)	0.36(0.05)	0.34(0.05)	0.79(0.02)	0.80(0.02)	0.77(0.02)	0.74(0.03)
14.MATH2 (100)	76.10(2.03)	77.25(1.94)	73.74(2.44)	71.32(1.77)	0.48(0.04)	0.50(0.04)	0.44(0.05)	0.29(0.04)	0.82(0.02)	0.84(0.02)	0.80(0.03)	0.76(0.03)
15.MATH2 (100)	75.97(2.20)	77.21(2.05)	73.73(2.43)	71.06(2.14)	0.46(0.05)	0.48(0.05)	0.41(0.06)	0.28(0.05)	0.81(0.02)	0.82(0.03)	0.78(0.03)	0.75(0.03)
16.MATH2 (100)	75.98(2.21)	76.41(1.86)	73.57(2.26)	70.75(1.81)	0.46(0.05)	0.45(0.04)	0.40(0.06)	0.29(0.05)	0.83(0.02)	0.82(0.02)	0.78(0.02)	0.75(0.03)
17.MATH2 (100)	76.94(1.93)	77.59(1.72)	74.38(2.18)	71.86(2.01)	0.47(0.04)	0.48(0.04)	0.41(0.05)	0.34(0.05)	0.82(0.02)	0.83(0.02)	0.79(0.02)	0.77(0.03)
18.MATH2 (100)	75.45(1.99)	76.13(1.84)	72.43(2.73)	73.52(1.92)	0.44(0.05)	0.44(0.04)	0.38(0.05)	0.36(0.05)	0.81(0.02)	0.81(0.02)	0.78(0.03)	0.77(0.03)
19.MATH2 (100)	78.25(1.87)	77.80(1.90)	74.52(2.22)	73.39(1.74)	0.53(0.04)	0.51(0.04)	0.45(0.05)	0.33(0.05)	0.85(0.02)	0.84(0.02)	0.81(0.03)	0.76(0.03)
20.MATH2 (100)	76.40(2.02)	76.13(2.11)	72.91(2.43)	71.98(2.18)	0.49(0.04)	0.47(0.05)	0.41(0.05)	0.28(0.06)	0.82(0.02)	0.82(0.02)	0.78(0.03)	0.74(0.03)
21.MATH2 (100)	75.45(1.83)	75.99(1.60)	72.13(2.55)	73.05(1.78)	0.46(0.04)	0.46(0.04)	0.38(0.05)	0.31(0.05)	0.81(0.02)	0.82(0.02)	0.78(0.02)	0.76(0.03)
22.MATH2 (100)	76.75(1.89)	76.76(1.79)	73.91(2.02)	72.50(2.00)	0.49(0.04)	0.47(0.04)	0.41(0.04)	0.35(0.05)	0.83(0.02)	0.82(0.02)	0.79(0.02)	0.78(0.02)
23.MATH2 (100)	75.26(2.05)	76.95(2.19)	73.41(2.16)	72.17(2.08)	0.45(0.04)	0.48(0.05)	0.41(0.05)	0.33(0.05)	0.82(0.02)	0.82(0.02)	0.79(0.03)	0.77(0.03)
24.MATH2 (100)	77.41(1.94)	77.83(1.89)	74.68(2.16)	70.23(1.98)	0.51(0.04)	0.50(0.04)	0.44(0.05)	0.30(0.05)	0.84(0.02)	0.84(0.02)	0.81(0.02)	0.73(0.03)
25.MATH2 (100)	78.36(1.89)	78.27(1.86)	75.96(2.18)	72.79(1.76)	0.52(0.04)	0.50(0.04)	0.46(0.04)	0.31(0.05)	0.84(0.02)	0.84(0.02)	0.81(0.02)	0.76(0.03)
26.MATH2 (100)	77.59(1.89)	75.62(1.92)	73.20(2.45)	72.74(1.86)	0.49(0.04)	0.42(0.05)	0.38(0.05)	0.27(0.06)	0.82(0.02)	0.81(0.02)	0.78(0.03)	0.74(0.04)
27.MATH2 (100)	76.02(2.02)	75.86(1.94)	72.78(2.35)	73.28(1.89)	0.45(0.05)	0.43(0.05)	0.38(0.05)	0.32(0.05)	0.80(0.02)	0.80(0.02)	0.77(0.03)	0.76(0.03)
28.MATH2 (100)	74.84(2.06)	75.56(1.97)	72.33(2.55)	69.70(1.91)	0.44(0.04)	0.44(0.05)	0.37(0.05)	0.27(0.05)	0.81(0.02)	0.80(0.02)	0.77(0.03)	0.73(0.03)
29.MATH2 (100)	77.55(1.73)	77.99(2.13)	75.36(1.96)	72.07(2.15)	0.51(0.04)	0.51(0.05)	0.46(0.04)	0.33(0.05)	0.84(0.02)	0.84(0.02)	0.81(0.02)	0.76(0.03)
30.MATH2 (100)	74.98(1.90)	74.63(1.91)	72.05(2.28)	70.83(2.03)	0.45(0.04)	0.43(0.04)	0.38(0.05)	0.28(0.05)	0.81(0.02)	0.80(0.02)	0.77(0.02)	0.75(0.02)
31.MATH2 (100)	76.27(1.90)	77.18(1.51)	74.43(2.05)	69.61(1.96)	0.46(0.04)	0.47(0.03)	0.42(0.04)	0.24(0.05)	0.83(0.02)	0.82(0.02)	0.79(0.02)	0.71(0.03)
32.MATH2 (100)	77.38(1.81)	78.20(1.86)	74.88(2.18)	72.53(2.03)	0.47(0.04)	0.48(0.04)	0.41(0.05)	0.36(0.05)	0.82(0.02)	0.82(0.02)	0.78(0.03)	0.76(0.02)
33.MATH2 (100)	76.95(1.84)	76.81(1.65)	73.91(2.25)	72.17(2.41)	0.48(0.04)	0.46(0.04)	0.40(0.05)	0.35(0.06)	0.82(0.02)	0.82(0.02)	0.78(0.03)	0.77(0.03)
34.MATH2 (100)	74.33(1.84)	73.02(1.85)	70.22(2.46)	71.24(2.10)	0.44(0.04)	0.38(0.04)	0.34(0.06)	0.33(0.05)	0.80(0.02)	0.79(0.02)	0.75(0.03)	0.76(0.03)
35.MATH2 (100)	77.05(2.26)	76.71(1.89)	73.85(2.23)	72.58(1.99)	0.49(0.05)	0.47(0.04)	0.41(0.04)	0.35(0.05)	0.82(0.02)	0.82(0.02)	0.79(0.02)	0.76(0.02)
36.MATH2 (100)	76.07(1.88)	76.49(1.93)	74.13(2.18)	70.91(2.11)	0.47(0.04)	0.47(0.04)	0.43(0.05)	0.25(0.05)	0.83(0.02)	0.84(0.02)	0.80(0.02)	0.74(0.04)
37.MATH2 (100)	72.21(2.01)	73.21(1.89)	69.53(2.79)	72.65(1.87)	0.39(0.04)	0.39(0.04)	0.32(0.05)	0.32(0.05)	0.78(0.02)	0.78(0.02)	0.74(0.03)	0.77(0.03)
38.MATH2 (100)	76.05(1.99)	76.87(2.03)	74.46(2.23)	70.35(1.88)	0.47(0.04)	0.48(0.04)	0.44(0.05)	0.31(0.05)	0.82(0.02)	0.82(0.02)	0.80(0.02)	0.74(0.03)
39.MATH2 (100)	76.35(2.01)	77.15(2.03)	73.76(2.41)	70.80(2.09)	0.48(0.04)	0.49(0.05)	0.43(0.05)	0.34(0.05)	0.83(0.02)	0.83(0.02)	0.79(0.02)	0.76(0.03)
40.MATH2 (100)	76.95(1.99)	75.75(1.75)	72.79(2.31)	69.46(2.17)	0.50(0.04)	0.46(0.04)	0.41(0.05)	0.30(0.05)	0.82(0.02)	0.82(0.02)	0.78(0.02)	0.74(0.03)
41.MATH2 (100)	74.09(2.08)	74.52(1.93)	71.43(2.23)	72.35(1.76)	0.42(0.05)	0.40(0.05)	0.35(0.04)	0.34(0.05)	0.79(0.02)	0.78(0.02)	0.75(0.02)	0.77(0.03)
42.MATH2 (100)	77.42(2.11)	77.63(2.12)	74.28(2.30)	72.36(1.74)	0.49(0.05)	0.49(0.05)	0.43(0.05)	0.32(0.04)	0.83(0.02)	0.83(0.02)	0.80(0.02)	0.76(0.02)
43.MATH2 (100)	76.24(1.96)	76.35(1.85)	73.26(2.15)	71.49(1.87)	0.48(0.04)	0.47(0.04)	0.42(0.05)	0.26(0.05)	0.83(0.02)	0.83(0.02)	0.80(0.02)	0.73(0.03)
44.MATH2 (100)	75.72(2.29)	75.79(1.98)	73.09(2.33)	73.50(1.61)	0.48(0.05)	0.47(0.04)	0.42(0.05)	0.34(0.04)	0.82(0.02)	0.83(0.02)	0.79(0.02)	0.77(0.02)
45.MATH2 (100)	75.90(1.82)	74.17(2.07)	71.39(2.38)	70.92(2.05)	0.48(0.04)	0.44(0.04)	0.39(0.05)	0.32(0.05)	0.81(0.02)	0.81(0.02)	0.78(0.02)	0.75(0.03)
46.MATH2 (100)	75.85(1.81)	77.25(1.90)	74.34(2.29)	73.21(1.78)	0.47(0.04)	0.50(0.04)	0.44(0.05)	0.31(0.05)	0.84(0.02)	0.83(0.02)	0.80(0.02)	0.76(0.03)
47.MATH2 (100)	76.64(1.79)	78.00(2.13)	74.28(2.07)	69.76(2.11)	0.48(0.04)	0.50(0.05)	0.42(0.04)	0.25(0.05)	0.82(0.02)	0.83(0.02)	0.80(0.02)	0.73(0.03)
48.MATH2 (100)	74.82(1.93)	75.59(2.02)	72.41(2.66)	70.53(2.03)	0.43(0.04)	0.43(0.05)	0.37(0.06)	0.30(0.05)	0.81(0.02)	0.81(0.02)	0.76(0.03)	0.76(0.02)
49.MATH2 (100)	77.48(1.99)	76.30(1.82)	73.87(2.48)	72.26(1.80)	0.49(0.04)	0.45(0.04)	0.41(0.06)	0.29(0.05)	0.82(0.02)	0.81(0.02)	0.79(0.02)	0.74(0.03)
50.MATH2 (100)	76.89(2.04)	76.59(2.06)	73.74(2.31)	72.44(1.89)	0.48(0.05)	0.45(0.05)	0.40(0.05)	0.31(0.05)	0.83(0.02)	0.82(0.02)	0.78(0.02)	0.75(0.03)

## EK-I: 1000 Kişilik Örneklemde Test Verisi Oranı %44 için Elde Edilen Analiz Sonuçları

Analysing: Percent_correct (stddev) Datasets: 50 Resultsets: 4				Analysing: Kappa_statistic (stddev) Datasets: 50 Resultsets: 4				Analysing: Area_under_ROC (stddev) Datasets: 50 Resultsets: 4				
Dataset	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk
1.MATH2 (100)	76.23(1.51)	75.60(1.49)	73.00(2.11)	71.28(1.91)	0.45(0.03)	0.42(0.03)	0.38(0.04)	0.26(0.05)	0.81(0.02)	0.80(0.02)	0.78(0.02)	0.74(0.03)
2.MATH2 (100)	76.97(1.54)	77.01(1.58)	74.36(2.06)	71.63(1.59)	0.50(0.03)	0.49(0.04)	0.44(0.04)	0.32(0.04)	0.83(0.01)	0.83(0.02)	0.80(0.02)	0.76(0.03)
3.MATH2 (100)	75.16(1.46)	75.19(1.60)	72.39(2.25)	71.01(1.68)	0.46(0.03)	0.45(0.03)	0.40(0.04)	0.31(0.04)	0.81(0.02)	0.80(0.02)	0.77(0.02)	0.74(0.02)
4.MATH2 (100)	76.44(1.81)	76.33(1.78)	73.67(2.21)	73.06(1.72)	0.45(0.04)	0.43(0.04)	0.38(0.05)	0.27(0.05)	0.81(0.02)	0.80(0.02)	0.77(0.02)	0.73(0.03)
5.MATH2 (100)	73.77(1.57)	74.35(1.78)	70.75(2.09)	69.28(1.85)	0.42(0.03)	0.43(0.04)	0.36(0.05)	0.26(0.04)	0.79(0.02)	0.80(0.02)	0.76(0.02)	0.72(0.03)
6.MATH2 (100)	75.98(1.50)	76.92(1.83)	73.84(2.05)	72.04(1.83)	0.48(0.03)	0.50(0.04)	0.44(0.04)	0.36(0.04)	0.82(0.02)	0.83(0.02)	0.80(0.02)	0.76(0.02)
7.MATH2 (100)	75.83(1.92)	76.68(1.58)	73.36(2.14)	71.52(1.94)	0.46(0.04)	0.47(0.03)	0.40(0.04)	0.29(0.05)	0.81(0.02)	0.81(0.02)	0.78(0.02)	0.76(0.03)
8.MATH2 (100)	75.84(1.85)	75.83(1.59)	73.04(1.94)	70.06(1.52)	0.45(0.04)	0.43(0.04)	0.39(0.04)	0.23(0.04)	0.82(0.02)	0.81(0.02)	0.78(0.02)	0.72(0.03)
9.MATH2 (100)	76.73(1.77)	76.92(1.74)	74.21(1.84)	71.22(1.86)	0.47(0.04)	0.46(0.04)	0.41(0.04)	0.24(0.05)	0.82(0.02)	0.81(0.02)	0.79(0.02)	0.73(0.03)
10.MATH2 (100)	75.37(1.59)	75.66(1.69)	72.21(2.42)	71.91(1.59)	0.44(0.04)	0.43(0.04)	0.37(0.05)	0.28(0.05)	0.81(0.02)	0.80(0.02)	0.77(0.02)	0.72(0.03)
11.MATH2 (100)	78.09(1.41)	77.04(1.55)	74.50(1.79)	71.69(2.04)	0.53(0.03)	0.50(0.03)	0.45(0.04)	0.34(0.05)	0.84(0.01)	0.83(0.02)	0.81(0.02)	0.77(0.03)
12.MATH2 (100)	76.80(1.57)	76.28(1.80)	73.55(1.97)	72.58(1.68)	0.50(0.04)	0.48(0.04)	0.42(0.04)	0.36(0.04)	0.83(0.02)	0.83(0.02)	0.80(0.02)	0.77(0.02)
13.MATH2 (100)	76.52(1.76)	75.94(1.82)	72.50(2.36)	71.55(1.91)	0.49(0.04)	0.47(0.04)	0.40(0.04)	0.34(0.05)	0.82(0.02)	0.81(0.02)	0.78(0.02)	0.74(0.02)
14.MATH2 (100)	75.27(1.62)	75.60(1.59)	71.85(1.92)	71.05(1.71)	0.45(0.04)	0.45(0.04)	0.38(0.04)	0.28(0.04)	0.81(0.02)	0.81(0.02)	0.78(0.02)	0.75(0.02)
15.MATH2 (100)	76.73(1.68)	76.10(1.47)	73.60(1.92)	71.09(1.70)	0.49(0.04)	0.45(0.03)	0.40(0.04)	0.28(0.05)	0.83(0.02)	0.81(0.02)	0.79(0.02)	0.74(0.03)
16.MATH2 (100)	75.36(1.85)	76.54(1.80)	72.93(2.04)	71.01(2.01)	0.45(0.04)	0.48(0.04)	0.40(0.05)	0.30(0.05)	0.82(0.02)	0.81(0.02)	0.78(0.02)	0.74(0.03)
17.MATH2 (100)	77.35(1.60)	77.43(1.85)	74.21(1.92)	71.76(2.04)	0.51(0.03)	0.50(0.04)	0.44(0.04)	0.34(0.05)	0.84(0.02)	0.83(0.02)	0.81(0.02)	0.77(0.03)
18.MATH2 (100)	78.10(1.66)	77.54(1.70)	75.16(1.77)	72.67(1.82)	0.52(0.04)	0.49(0.04)	0.45(0.04)	0.34(0.05)	0.84(0.02)	0.83(0.02)	0.81(0.02)	0.76(0.02)
19.MATH2 (100)	77.53(1.56)	75.51(1.59)	73.21(1.73)	73.39(1.42)	0.49(0.03)	0.42(0.04)	0.38(0.04)	0.32(0.04)	0.82(0.02)	0.80(0.02)	0.78(0.02)	0.76(0.02)
20.MATH2 (100)	75.72(1.64)	75.15(1.77)	72.12(2.30)	71.87(1.68)	0.44(0.04)	0.42(0.04)	0.36(0.05)	0.28(0.04)	0.80(0.02)	0.79(0.02)	0.76(0.02)	0.73(0.03)
21.MATH2 (100)	74.65(1.67)	75.23(1.73)	71.84(2.26)	73.05(1.44)	0.44(0.03)	0.43(0.04)	0.36(0.04)	0.31(0.04)	0.81(0.02)	0.80(0.02)	0.76(0.02)	0.76(0.02)
22.MATH2 (100)	77.51(1.38)	77.80(1.70)	75.09(2.32)	72.34(1.71)	0.51(0.03)	0.51(0.04)	0.45(0.05)	0.35(0.04)	0.84(0.01)	0.84(0.02)	0.81(0.02)	0.77(0.02)
23.MATH2 (100)	77.17(1.71)	78.66(1.67)	74.98(2.00)	72.25(1.80)	0.50(0.04)	0.52(0.04)	0.45(0.04)	0.33(0.04)	0.84(0.02)	0.83(0.02)	0.81(0.02)	0.77(0.03)
24.MATH2 (100)	74.78(1.52)	74.30(1.52)	72.14(2.21)	69.64(1.75)	0.44(0.03)	0.42(0.04)	0.38(0.05)	0.28(0.04)	0.81(0.02)	0.79(0.02)	0.77(0.02)	0.72(0.03)
25.MATH2 (100)	75.89(1.62)	76.64(1.54)	73.78(1.97)	72.63(1.48)	0.46(0.03)	0.45(0.04)	0.40(0.04)	0.31(0.04)	0.82(0.02)	0.82(0.02)	0.79(0.02)	0.76(0.03)
26.MATH2 (100)	77.43(1.53)	77.67(1.57)	74.76(1.90)	72.48(1.49)	0.47(0.04)	0.47(0.03)	0.41(0.05)	0.27(0.04)	0.82(0.02)	0.82(0.02)	0.79(0.02)	0.74(0.04)
27.MATH2 (100)	76.82(1.53)	76.19(1.62)	73.56(2.19)	72.64(1.45)	0.48(0.03)	0.45(0.04)	0.40(0.05)	0.30(0.04)	0.82(0.02)	0.81(0.02)	0.78(0.02)	0.76(0.02)
28.MATH2 (100)	73.87(1.61)	72.41(1.54)	70.45(2.11)	69.19(1.73)	0.43(0.04)	0.37(0.04)	0.34(0.05)	0.26(0.04)	0.80(0.02)	0.78(0.02)	0.75(0.02)	0.73(0.02)
29.MATH2 (100)	77.17(1.77)	76.24(1.63)	73.40(1.94)	71.75(1.82)	0.49(0.04)	0.46(0.04)	0.40(0.04)	0.31(0.04)	0.82(0.02)	0.81(0.02)	0.78(0.02)	0.75(0.02)
30.MATH2 (100)	76.17(1.37)	76.45(1.71)	73.83(1.82)	70.84(1.84)	0.47(0.03)	0.47(0.04)	0.42(0.05)	0.29(0.05)	0.83(0.01)	0.83(0.02)	0.80(0.02)	0.75(0.02)
31.MATH2 (100)	71.95(1.73)	72.67(1.82)	69.36(2.33)	69.77(1.68)	0.38(0.04)	0.38(0.04)	0.31(0.05)	0.25(0.04)	0.78(0.02)	0.77(0.02)	0.74(0.02)	0.71(0.02)
32.MATH2 (100)	76.09(1.66)	76.00(1.68)	73.70(2.24)	72.13(1.82)	0.47(0.04)	0.46(0.04)	0.42(0.05)	0.35(0.04)	0.82(0.02)	0.81(0.02)	0.79(0.02)	0.75(0.02)
33.MATH2 (100)	75.93(1.56)	76.44(1.65)	73.57(1.83)	71.98(1.56)	0.47(0.03)	0.48(0.04)	0.42(0.04)	0.34(0.04)	0.83(0.02)	0.82(0.02)	0.79(0.02)	0.76(0.02)
34.MATH2 (100)	75.41(1.81)	74.23(1.68)	71.76(1.87)	70.74(1.88)	0.47(0.04)	0.43(0.04)	0.39(0.04)	0.32(0.04)	0.81(0.02)	0.81(0.02)	0.78(0.02)	0.75(0.02)
35.MATH2 (100)	76.49(1.73)	75.19(1.57)	72.22(2.13)	71.64(1.70)	0.49(0.04)	0.45(0.03)	0.39(0.04)	0.33(0.04)	0.82(0.02)	0.80(0.02)	0.77(0.02)	0.75(0.02)
36.MATH2 (100)	74.04(1.68)	74.13(1.85)	71.49(2.10)	70.95(1.70)	0.42(0.04)	0.40(0.04)	0.35(0.04)	0.25(0.04)	0.79(0.02)	0.78(0.02)	0.75(0.02)	0.74(0.03)
37.MATH2 (100)	77.45(1.60)	77.23(1.54)	74.47(2.04)	72.23(1.58)	0.49(0.04)	0.48(0.03)	0.43(0.04)	0.31(0.04)	0.83(0.02)	0.82(0.02)	0.80(0.02)	0.76(0.03)
38.MATH2 (100)	75.97(1.59)	75.88(1.68)	72.82(1.92)	70.28(1.78)	0.47(0.03)	0.47(0.04)	0.41(0.04)	0.31(0.05)	0.83(0.01)	0.82(0.02)	0.79(0.02)	0.74(0.03)
39.MATH2 (100)	75.67(1.76)	75.44(1.74)	71.97(2.29)	70.58(1.69)	0.48(0.04)	0.47(0.04)	0.40(0.05)	0.33(0.04)	0.81(0.02)	0.82(0.02)	0.78(0.02)	0.75(0.02)
40.MATH2 (100)	75.72(1.60)	73.93(1.68)	70.88(2.05)	69.69(2.05)	0.48(0.03)	0.43(0.04)	0.37(0.04)	0.31(0.04)	0.81(0.02)	0.80(0.02)	0.77(0.02)	0.74(0.03)
41.MATH2 (100)	75.54(1.46)	76.50(1.54)	73.94(2.02)	71.99(1.67)	0.47(0.03)	0.48(0.03)	0.43(0.04)	0.33(0.04)	0.83(0.01)	0.82(0.02)	0.80(0.02)	0.76(0.02)
42.MATH2 (100)	76.46(1.66)	77.40(1.61)	73.95(1.79)	71.91(1.73)	0.47(0.04)	0.49(0.04)	0.42(0.04)	0.31(0.05)	0.82(0.02)	0.82(0.02)	0.79(0.02)	0.75(0.02)
43.MATH2 (100)	74.84(1.63)	75.00(1.60)	72.09(2.06)	71.47(1.59)	0.43(0.04)	0.42(0.04)	0.36(0.04)	0.26(0.04)	0.81(0.02)	0.80(0.02)	0.76(0.02)	0.72(0.03)
44.MATH2 (100)	77.32(1.38)	75.93(1.47)	73.27(1.86)	73.11(1.53)	0.49(0.03)	0.45(0.04)	0.40(0.04)	0.33(0.04)	0.82(0.02)	0.80(0.02)	0.78(0.02)	0.76(0.03)
45.MATH2 (100)	75.93(1.66)	75.23(1.69)	72.69(1.86)	70.63(1.94)	0.48(0.03)	0.46(0.04)	0.41(0.04)	0.32(0.04)	0.82(0.02)	0.81(0.02)	0.79(0.02)	0.74(0.03)
46.MATH2 (100)	76.75(1.70)	76.04(1.63)	73.66(2.12)	72.94(1.61)	0.48(0.04)	0.44(0.04)	0.40(0.04)	0.30(0.04)	0.83(0.02)	0.81(0.02)	0.78(0.02)	0.75(0.02)
47.MATH2 (100)	74.64(1.75)	74.37(1.65)	71.00(2.21)	69.82(1.64)	0.43(0.04)	0.41(0.04)	0.35(0.05)	0.25(0.04)	0.79(0.02)	0.78(0.02)	0.75(0.02)	0.73(0.02)
48.MATH2 (100)	74.70(1.43)	74.64(1.52)	71.63(2.00)	69.98(1.66)	0.45(0.03)	0.43(0.03)	0.38(0.05)	0.29(0.05)	0.82(0.01)	0.81(0.02)	0.78(0.02)	0.75(0.02)
49.MATH2 (100)	74.84(1.73)	74.85(1.84)	72.04(2.25)	72.06(1.44)	0.43(0.04)	0.42(0.04)	0.35(0.04)	0.28(0.04)	0.80(0.02)	0.78(0.02)	0.75(0.02)	0.74(0.02)
50.MATH2 (100)	76.99(1.76)	77.22(1.53)	74.24(2.13)	71.91(1.54)	0.48(0.04)	0.48(0.03)	0.42(0.04)	0.30(0.04)	0.83(0.02)	0.82(0.02)	0.79(0.02)	0.75(0.03)

## EK-İ: 1000 Kişilik Örneklemde Test Verisi Oranı %55 için Elde Edilen Analiz Sonuçları

Analysing: Percent_correct (stddev) Datasets: 50 Resultsets: 4				Analysing: Kappa_statistic (stddev) Datasets: 50 Resultsets: 4				Analysing: Area_under_ROC (stddev) Datasets: 50 Resultsets: 4				
Dataset	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk
1.MATH2 (100)	76.03(1.27)	74.94(1.51)	72.83(1.67)	70.84(1.68)	0.45(0.03)	0.41(0.04)	0.38(0.04)	0.25(0.04)	0.81(0.02)	0.78(0.02)	0.77(0.02)	0.73(0.03)
2.MATH2 (100)	76.74(1.51)	76.63(1.47)	73.71(1.80)	71.48(1.87)	0.50(0.03)	0.48(0.03)	0.42(0.04)	0.32(0.04)	0.83(0.01)	0.82(0.02)	0.79(0.02)	0.75(0.02)
3.MATH2 (100)	75.06(1.45)	74.44(1.65)	72.23(1.96)	70.51(1.62)	0.45(0.03)	0.43(0.04)	0.39(0.04)	0.31(0.04)	0.81(0.01)	0.79(0.02)	0.77(0.02)	0.73(0.02)
4.MATH2 (100)	76.21(1.57)	75.46(1.55)	73.09(2.02)	72.56(1.62)	0.45(0.04)	0.41(0.04)	0.37(0.04)	0.26(0.04)	0.80(0.02)	0.78(0.02)	0.76(0.02)	0.72(0.03)
5.MATH2 (100)	73.76(1.37)	73.87(1.51)	70.31(1.94)	68.77(1.72)	0.42(0.03)	0.42(0.03)	0.35(0.04)	0.25(0.04)	0.79(0.02)	0.79(0.02)	0.75(0.02)	0.71(0.03)
6.MATH2 (100)	75.99(1.22)	76.30(1.61)	73.37(1.79)	71.43(1.55)	0.48(0.03)	0.48(0.03)	0.43(0.04)	0.34(0.04)	0.82(0.01)	0.81(0.02)	0.79(0.02)	0.76(0.02)
7.MATH2 (100)	75.57(1.69)	75.60(1.63)	73.03(1.94)	70.65(1.55)	0.45(0.03)	0.45(0.04)	0.39(0.04)	0.27(0.04)	0.81(0.02)	0.79(0.02)	0.78(0.02)	0.74(0.03)
8.MATH2 (100)	75.83(1.48)	75.34(1.47)	72.93(1.96)	69.74(1.33)	0.45(0.03)	0.42(0.03)	0.38(0.04)	0.22(0.04)	0.82(0.01)	0.79(0.02)	0.78(0.02)	0.71(0.03)
9.MATH2 (100)	76.47(1.61)	76.18(1.61)	73.70(1.93)	70.66(1.76)	0.46(0.04)	0.45(0.04)	0.39(0.04)	0.23(0.04)	0.81(0.02)	0.80(0.02)	0.78(0.02)	0.72(0.04)
10.MATH2 (100)	75.47(1.38)	75.05(1.62)	72.00(2.04)	71.50(1.39)	0.44(0.03)	0.42(0.04)	0.36(0.05)	0.26(0.04)	0.81(0.01)	0.79(0.02)	0.76(0.02)	0.71(0.03)
11.MATH2 (100)	77.89(1.30)	76.16(1.65)	73.73(1.62)	71.40(1.82)	0.52(0.03)	0.48(0.04)	0.43(0.04)	0.34(0.04)	0.84(0.01)	0.82(0.02)	0.80(0.02)	0.76(0.03)
12.MATH2 (100)	76.69(1.39)	75.74(1.85)	73.20(2.02)	72.34(1.55)	0.50(0.03)	0.47(0.04)	0.42(0.04)	0.36(0.03)	0.83(0.01)	0.81(0.02)	0.79(0.02)	0.77(0.02)
13.MATH2 (100)	76.36(1.49)	75.13(1.71)	72.17(1.92)	71.15(1.62)	0.49(0.03)	0.45(0.04)	0.39(0.04)	0.33(0.04)	0.82(0.01)	0.80(0.02)	0.78(0.02)	0.74(0.02)
14.MATH2 (100)	75.01(1.48)	74.60(1.40)	71.64(2.00)	70.45(1.98)	0.45(0.03)	0.43(0.03)	0.37(0.04)	0.28(0.05)	0.81(0.01)	0.79(0.02)	0.77(0.02)	0.74(0.03)
15.MATH2 (100)	76.62(1.28)	75.19(1.59)	73.08(1.73)	70.77(1.68)	0.48(0.03)	0.43(0.04)	0.40(0.04)	0.28(0.05)	0.83(0.01)	0.80(0.02)	0.78(0.02)	0.74(0.03)
16.MATH2 (100)	75.21(1.40)	76.01(1.53)	72.75(1.67)	71.21(1.34)	0.45(0.03)	0.47(0.03)	0.40(0.04)	0.30(0.03)	0.82(0.01)	0.80(0.02)	0.78(0.02)	0.74(0.02)
17.MATH2 (100)	77.18(1.33)	76.38(1.56)	73.88(1.91)	71.64(1.88)	0.50(0.03)	0.47(0.04)	0.43(0.05)	0.34(0.05)	0.84(0.01)	0.82(0.02)	0.80(0.02)	0.76(0.03)
18.MATH2 (100)	77.90(1.25)	76.80(1.56)	74.91(1.90)	72.34(1.62)	0.51(0.03)	0.47(0.04)	0.44(0.04)	0.33(0.04)	0.84(0.01)	0.81(0.02)	0.81(0.02)	0.76(0.02)
19.MATH2 (100)	77.12(1.32)	74.65(1.51)	72.87(1.63)	73.01(1.40)	0.48(0.03)	0.40(0.04)	0.37(0.04)	0.31(0.04)	0.82(0.01)	0.78(0.02)	0.77(0.02)	0.75(0.02)
20.MATH2 (100)	75.49(1.36)	74.21(1.55)	71.64(2.16)	71.79(1.69)	0.44(0.03)	0.40(0.03)	0.35(0.04)	0.28(0.04)	0.80(0.01)	0.77(0.02)	0.75(0.02)	0.73(0.03)
21.MATH2 (100)	74.65(1.61)	74.45(1.56)	72.08(2.17)	72.34(1.49)	0.44(0.03)	0.41(0.03)	0.36(0.04)	0.30(0.04)	0.81(0.01)	0.78(0.02)	0.76(0.02)	0.75(0.02)
22.MATH2 (100)	77.44(1.16)	76.98(1.48)	74.58(1.90)	72.01(1.44)	0.51(0.02)	0.49(0.03)	0.44(0.04)	0.34(0.03)	0.84(0.01)	0.82(0.02)	0.81(0.02)	0.77(0.02)
23.MATH2 (100)	76.91(1.31)	77.29(1.54)	74.05(1.96)	72.00(1.66)	0.49(0.03)	0.49(0.04)	0.43(0.04)	0.33(0.04)	0.83(0.01)	0.82(0.02)	0.80(0.02)	0.76(0.02)
24.MATH2 (100)	74.64(1.38)	73.44(1.42)	71.91(1.71)	69.30(1.64)	0.44(0.03)	0.41(0.03)	0.38(0.04)	0.27(0.04)	0.81(0.01)	0.78(0.02)	0.76(0.02)	0.71(0.03)
25.MATH2 (100)	75.69(1.33)	75.93(1.30)	73.63(1.72)	72.12(1.64)	0.45(0.03)	0.44(0.03)	0.39(0.04)	0.29(0.04)	0.82(0.01)	0.80(0.02)	0.78(0.02)	0.75(0.03)
26.MATH2 (100)	77.32(1.35)	76.93(1.28)	74.13(1.78)	72.44(1.52)	0.47(0.03)	0.45(0.03)	0.40(0.04)	0.27(0.04)	0.82(0.01)	0.80(0.02)	0.78(0.02)	0.75(0.03)
27.MATH2 (100)	76.72(1.29)	75.89(1.65)	73.12(1.91)	72.44(1.60)	0.47(0.03)	0.44(0.04)	0.39(0.04)	0.30(0.05)	0.82(0.01)	0.80(0.02)	0.78(0.02)	0.75(0.02)
28.MATH2 (100)	73.88(1.56)	72.05(1.62)	69.50(1.91)	68.98(1.61)	0.43(0.03)	0.37(0.04)	0.32(0.04)	0.25(0.04)	0.80(0.02)	0.77(0.02)	0.74(0.02)	0.72(0.02)
29.MATH2 (100)	77.04(1.51)	75.66(1.56)	73.09(1.95)	71.42(1.47)	0.49(0.03)	0.44(0.03)	0.39(0.04)	0.30(0.04)	0.82(0.02)	0.80(0.02)	0.78(0.02)	0.74(0.02)
30.MATH2 (100)	76.19(1.44)	76.03(1.59)	73.39(1.59)	70.60(1.82)	0.47(0.03)	0.46(0.04)	0.41(0.04)	0.28(0.04)	0.83(0.02)	0.82(0.02)	0.80(0.02)	0.74(0.03)
31.MATH2 (100)	71.92(1.54)	71.75(1.52)	69.09(2.01)	69.30(1.52)	0.38(0.03)	0.36(0.04)	0.31(0.04)	0.24(0.04)	0.77(0.02)	0.76(0.02)	0.73(0.02)	0.71(0.02)
32.MATH2 (100)	75.90(1.53)	75.30(1.75)	73.37(1.76)	71.61(1.51)	0.46(0.03)	0.44(0.04)	0.41(0.04)	0.33(0.04)	0.82(0.01)	0.79(0.02)	0.78(0.02)	0.74(0.02)
33.MATH2 (100)	75.89(1.26)	75.82(1.59)	73.19(1.77)	71.61(1.80)	0.47(0.03)	0.47(0.04)	0.41(0.04)	0.34(0.04)	0.82(0.01)	0.81(0.02)	0.79(0.02)	0.76(0.02)
34.MATH2 (100)	75.16(1.64)	73.53(1.55)	71.17(1.99)	70.27(1.84)	0.47(0.03)	0.42(0.03)	0.38(0.04)	0.31(0.04)	0.81(0.01)	0.79(0.02)	0.77(0.02)	0.74(0.03)
35.MATH2 (100)	76.43(1.57)	74.46(1.57)	71.77(2.11)	70.93(1.82)	0.49(0.03)	0.44(0.03)	0.38(0.04)	0.32(0.04)	0.82(0.02)	0.79(0.02)	0.77(0.02)	0.74(0.02)
36.MATH2 (100)	73.93(1.43)	73.44(1.52)	71.24(2.11)	70.74(1.66)	0.42(0.03)	0.38(0.04)	0.35(0.04)	0.25(0.04)	0.79(0.01)	0.76(0.02)	0.75(0.02)	0.73(0.03)
37.MATH2 (100)	77.33(1.26)	76.20(1.34)	73.73(1.68)	72.20(1.46)	0.49(0.03)	0.46(0.03)	0.41(0.04)	0.31(0.04)	0.83(0.01)	0.81(0.02)	0.79(0.02)	0.75(0.02)
38.MATH2 (100)	75.87(1.62)	75.27(1.48)	72.41(1.73)	70.03(1.86)	0.47(0.03)	0.45(0.03)	0.40(0.04)	0.30(0.05)	0.83(0.01)	0.81(0.02)	0.78(0.02)	0.74(0.03)
39.MATH2 (100)	75.77(1.36)	74.98(1.58)	71.94(1.78)	70.39(1.70)	0.48(0.03)	0.46(0.03)	0.40(0.04)	0.32(0.04)	0.81(0.01)	0.81(0.02)	0.78(0.02)	0.74(0.02)
40.MATH2 (100)	75.68(1.41)	73.42(1.39)	70.82(1.76)	69.43(1.81)	0.48(0.03)	0.42(0.03)	0.37(0.03)	0.30(0.04)	0.81(0.01)	0.79(0.02)	0.77(0.02)	0.74(0.03)
41.MATH2 (100)	75.31(1.36)	75.83(1.58)	73.19(1.82)	71.15(2.04)	0.46(0.03)	0.47(0.03)	0.41(0.04)	0.31(0.05)	0.83(0.01)	0.81(0.02)	0.79(0.02)	0.75(0.03)
42.MATH2 (100)	76.23(1.43)	76.56(1.49)	73.72(1.82)	71.44(1.47)	0.47(0.03)	0.47(0.03)	0.42(0.04)	0.30(0.04)	0.81(0.01)	0.81(0.02)	0.79(0.02)	0.74(0.02)
43.MATH2 (100)	74.64(1.42)	74.61(1.37)	71.94(2.32)	71.12(1.61)	0.42(0.03)	0.41(0.03)	0.36(0.04)	0.25(0.04)	0.81(0.01)	0.78(0.02)	0.76(0.02)	0.72(0.02)
44.MATH2 (100)	77.18(1.20)	75.14(1.64)	72.81(1.87)	72.72(1.30)	0.49(0.03)	0.43(0.04)	0.39(0.04)	0.32(0.03)	0.82(0.01)	0.79(0.02)	0.77(0.02)	0.75(0.02)
45.MATH2 (100)	75.65(1.46)	74.69(1.57)	72.30(1.71)	70.63(1.55)	0.47(0.03)	0.45(0.03)	0.40(0.04)	0.32(0.04)	0.82(0.01)	0.80(0.02)	0.78(0.02)	0.74(0.02)
46.MATH2 (100)	76.61(1.38)	75.38(1.51)	73.23(1.75)	72.26(1.47)	0.47(0.03)	0.43(0.03)	0.39(0.04)	0.29(0.04)	0.82(0.01)	0.80(0.02)	0.78(0.02)	0.74(0.03)
47.MATH2 (100)	74.39(1.50)	73.24(1.62)	70.69(1.79)	69.21(1.50)	0.43(0.03)	0.39(0.04)	0.34(0.04)	0.24(0.04)	0.79(0.02)	0.76(0.02)	0.75(0.02)	0.72(0.02)
48.MATH2 (100)	74.45(1.37)	73.75(1.53)	71.56(1.43)	69.65(1.68)	0.44(0.03)	0.41(0.03)	0.37(0.04)	0.28(0.04)	0.81(0.01)	0.79(0.02)	0.77(0.02)	0.74(0.03)
49.MATH2 (100)	74.59(1.46)	73.80(1.62)	71.57(2.11)	71.70(1.35)	0.42(0.03)	0.39(0.04)	0.35(0.04)	0.27(0.04)	0.80(0.02)	0.77(0.02)	0.75(0.02)	0.73(0.02)
50.MATH2 (100)	76.66(1.39)	76.13(1.37)	73.78(1.65)	71.33(1.55)	0.47(0.03)	0.45(0.03)	0.41(0.04)	0.28(0.04)	0.83(0.01)	0.80(0.02)	0.79(0.02)	0.73(0.03)

## EK-J: 500 Kişilik Örneklemde Test Verisi Oranı %11 için Elde Edilen Analiz Sonuçları

Analysing: Percent_correct (stddev) Datasets: 100 Resultsets: 4				Analysing: Kappa_statistic (stddev) Datasets: 100 Resultsets: 4				Analysing: Area_under_ROC (stddev) Datasets: 100 Resultsets: 4				
Dataset	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk
1.MATH2 (100)	74.93(5.44)	74.11(4.91)	73.21(5.31)	72.93(5.44)	0.45(0.12)	0.42(0.11)	0.40(0.12)	0.34(0.14)	0.80(0.06)	0.78(0.06)	0.76(0.07)	0.74(0.07)
2.MATH2 (100)	77.63(4.82)	77.05(4.75)	75.69(4.84)	74.11(4.72)	0.50(0.11)	0.48(0.11)	0.45(0.11)	0.36(0.13)	0.85(0.05)	0.83(0.06)	0.82(0.05)	0.77(0.07)
3.MATH2 (100)	74.91(5.39)	75.74(5.38)	73.16(6.16)	68.68(5.18)	0.43(0.13)	0.44(0.13)	0.39(0.14)	0.25(0.12)	0.81(0.06)	0.77(0.07)	0.76(0.07)	0.72(0.07)
4.MATH2 (100)	73.34(5.76)	75.85(5.49)	72.87(6.33)	74.65(4.84)	0.39(0.13)	0.43(0.13)	0.38(0.14)	0.37(0.12)	0.81(0.06)	0.79(0.07)	0.77(0.07)	0.79(0.06)
5.MATH2 (100)	73.89(5.95)	71.78(5.46)	71.11(5.66)	72.35(5.13)	0.44(0.12)	0.37(0.12)	0.37(0.12)	0.31(0.14)	0.80(0.06)	0.78(0.06)	0.76(0.06)	0.75(0.07)
6.MATH2 (100)	74.72(5.06)	76.37(4.78)	71.50(6.10)	72.87(5.05)	0.42(0.12)	0.45(0.11)	0.33(0.14)	0.36(0.12)	0.78(0.06)	0.77(0.06)	0.73(0.07)	0.75(0.07)
7.MATH2 (100)	75.61(5.42)	76.55(4.70)	72.48(5.65)	73.96(4.57)	0.45(0.12)	0.45(0.11)	0.37(0.14)	0.30(0.13)	0.82(0.05)	0.81(0.06)	0.77(0.07)	0.74(0.07)
8.MATH2 (100)	77.13(5.14)	75.03(5.28)	73.13(4.87)	74.38(4.62)	0.49(0.12)	0.44(0.12)	0.40(0.11)	0.33(0.13)	0.83(0.06)	0.80(0.06)	0.78(0.06)	0.73(0.08)
9.MATH2 (100)	73.55(5.18)	74.72(5.11)	73.94(5.61)	73.00(5.17)	0.42(0.11)	0.43(0.11)	0.42(0.12)	0.32(0.14)	0.82(0.05)	0.80(0.06)	0.79(0.06)	0.71(0.07)
10.MATH2 (100)	78.52(5.39)	79.46(5.41)	75.96(5.89)	70.55(5.71)	0.52(0.12)	0.53(0.12)	0.46(0.13)	0.29(0.14)	0.85(0.05)	0.84(0.06)	0.82(0.05)	0.75(0.06)
11.MATH2 (100)	74.87(5.42)	74.45(5.66)	72.84(5.21)	71.63(5.09)	0.43(0.12)	0.41(0.13)	0.38(0.12)	0.35(0.12)	0.82(0.06)	0.81(0.06)	0.78(0.06)	0.78(0.06)
12.MATH2 (100)	75.02(5.49)	74.24(5.88)	72.02(6.60)	68.66(5.16)	0.45(0.12)	0.42(0.13)	0.38(0.14)	0.24(0.13)	0.81(0.06)	0.78(0.07)	0.76(0.07)	0.69(0.07)
13.MATH2 (100)	76.77(5.18)	75.36(4.81)	72.06(5.59)	72.98(5.43)	0.49(0.11)	0.45(0.11)	0.38(0.13)	0.34(0.13)	0.82(0.06)	0.80(0.06)	0.78(0.06)	0.75(0.07)
14.MATH2 (100)	76.50(5.04)	75.41(5.02)	74.20(5.59)	72.25(4.53)	0.46(0.11)	0.41(0.12)	0.39(0.13)	0.27(0.13)	0.82(0.06)	0.76(0.07)	0.77(0.07)	0.73(0.07)
15.MATH2 (100)	75.23(5.78)	75.01(5.18)	71.95(5.66)	73.48(5.17)	0.43(0.14)	0.40(0.13)	0.35(0.13)	0.34(0.13)	0.80(0.06)	0.76(0.07)	0.74(0.07)	0.76(0.07)
16.MATH2 (100)	75.52(6.04)	75.05(5.14)	72.46(5.68)	70.35(4.09)	0.44(0.14)	0.42(0.13)	0.37(0.13)	0.21(0.11)	0.81(0.07)	0.78(0.07)	0.76(0.07)	0.71(0.07)
17.MATH2 (100)	71.50(5.40)	71.84(5.85)	69.26(5.78)	72.14(5.27)	0.38(0.12)	0.37(0.13)	0.33(0.12)	0.34(0.13)	0.78(0.06)	0.78(0.06)	0.76(0.06)	0.76(0.06)
18.MATH2 (100)	76.52(5.68)	74.34(5.43)	71.70(5.71)	70.59(5.54)	0.49(0.12)	0.44(0.12)	0.39(0.12)	0.31(0.13)	0.83(0.05)	0.79(0.06)	0.78(0.06)	0.72(0.07)
19.MATH2 (100)	74.17(5.30)	73.47(5.52)	71.10(5.74)	72.19(4.79)	0.43(0.11)	0.41(0.12)	0.37(0.12)	0.27(0.13)	0.80(0.06)	0.80(0.06)	0.77(0.06)	0.73(0.06)
20.MATH2 (100)	77.94(5.35)	76.27(4.66)	74.10(5.38)	68.69(4.46)	0.48(0.13)	0.41(0.12)	0.38(0.12)	0.25(0.11)	0.83(0.05)	0.78(0.07)	0.77(0.06)	0.70(0.06)
21.MATH2 (100)	76.39(5.58)	75.35(5.84)	72.00(5.49)	71.76(4.87)	0.46(0.13)	0.43(0.13)	0.37(0.12)	0.28(0.13)	0.82(0.06)	0.80(0.06)	0.76(0.07)	0.74(0.06)
22.MATH2 (100)	76.56(5.03)	73.38(4.84)	72.14(6.42)	71.13(4.48)	0.45(0.12)	0.36(0.12)	0.35(0.14)	0.25(0.11)	0.83(0.06)	0.76(0.07)	0.77(0.07)	0.72(0.07)
23.MATH2 (100)	75.75(5.60)	76.31(5.33)	72.38(5.85)	71.94(5.32)	0.46(0.13)	0.47(0.12)	0.39(0.13)	0.35(0.13)	0.83(0.06)	0.81(0.06)	0.78(0.06)	0.77(0.06)
24.MATH2 (100)	74.49(5.31)	71.25(5.51)	69.31(5.17)	73.35(4.66)	0.45(0.11)	0.36(0.13)	0.32(0.11)	0.32(0.13)	0.80(0.05)	0.77(0.06)	0.74(0.06)	0.71(0.07)
25.MATH2 (100)	73.77(5.30)	78.62(5.07)	74.63(5.77)	70.08(5.60)	0.39(0.12)	0.50(0.12)	0.42(0.13)	0.27(0.14)	0.80(0.05)	0.83(0.06)	0.79(0.06)	0.72(0.07)
26.MATH2 (100)	74.79(5.23)	75.55(4.98)	73.44(5.07)	73.09(3.76)	0.45(0.11)	0.47(0.11)	0.42(0.11)	0.24(0.11)	0.80(0.06)	0.81(0.05)	0.79(0.06)	0.74(0.06)
27.MATH2 (100)	74.17(5.30)	75.44(5.85)	71.72(5.51)	74.04(6.40)	0.41(0.13)	0.44(0.13)	0.37(0.13)	0.38(0.16)	0.81(0.06)	0.80(0.06)	0.77(0.06)	0.78(0.08)
28.MATH2 (100)	73.61(5.46)	72.85(5.05)	69.86(5.78)	71.03(5.36)	0.41(0.12)	0.36(0.12)	0.31(0.13)	0.23(0.14)	0.80(0.06)	0.75(0.07)	0.73(0.07)	0.71(0.08)
29.MATH2 (100)	76.02(4.87)	76.58(5.21)	74.52(5.65)	73.15(4.78)	0.47(0.11)	0.49(0.11)	0.45(0.12)	0.32(0.12)	0.83(0.05)	0.83(0.06)	0.81(0.06)	0.77(0.07)
30.MATH2 (100)	75.89(4.92)	74.38(5.26)	72.26(4.99)	71.58(5.26)	0.46(0.11)	0.41(0.12)	0.38(0.12)	0.26(0.14)	0.83(0.05)	0.79(0.06)	0.78(0.05)	0.71(0.07)
31.MATH2 (100)	78.29(5.85)	75.07(6.20)	71.96(6.18)	69.59(5.19)	0.49(0.13)	0.38(0.15)	0.33(0.14)	0.26(0.13)	0.82(0.07)	0.78(0.06)	0.75(0.07)	0.71(0.08)
32.MATH2 (100)	77.78(5.15)	77.66(5.19)	75.39(5.14)	72.57(4.78)	0.51(0.11)	0.50(0.12)	0.45(0.12)	0.33(0.12)	0.83(0.06)	0.83(0.06)	0.80(0.06)	0.73(0.07)
33.MATH2 (100)	74.03(5.19)	73.80(5.05)	70.93(5.50)	71.88(5.17)	0.40(0.12)	0.38(0.12)	0.32(0.12)	0.31(0.13)	0.78(0.06)	0.77(0.07)	0.74(0.06)	0.73(0.07)
34.MATH2 (100)	77.06(5.37)	76.66(5.73)	73.26(5.59)	71.97(5.44)	0.48(0.12)	0.46(0.13)	0.39(0.12)	0.34(0.13)	0.83(0.05)	0.82(0.06)	0.77(0.06)	0.75(0.07)
35.MATH2 (100)	75.25(5.06)	75.06(4.65)	71.26(5.53)	72.31(4.79)	0.43(0.12)	0.41(0.11)	0.34(0.12)	0.28(0.12)	0.79(0.05)	0.76(0.07)	0.74(0.07)	0.74(0.07)
36.MATH2 (100)	75.18(4.77)	71.42(5.30)	69.70(6.03)	73.75(4.89)	0.45(0.11)	0.36(0.12)	0.34(0.13)	0.34(0.13)	0.80(0.06)	0.77(0.06)	0.75(0.07)	0.79(0.06)
37.MATH2 (100)	76.75(5.25)	74.86(5.17)	71.84(5.58)	68.63(5.56)	0.48(0.12)	0.42(0.12)	0.38(0.12)	0.29(0.13)	0.82(0.05)	0.78(0.07)	0.77(0.06)	0.71(0.07)
38.MATH2 (100)	79.18(5.48)	77.38(5.09)	75.29(5.86)	71.77(5.00)	0.53(0.12)	0.49(0.12)	0.45(0.13)	0.28(0.14)	0.84(0.05)	0.83(0.05)	0.81(0.06)	0.70(0.07)
39.MATH2 (100)	74.11(5.80)	74.53(5.86)	71.77(5.65)	69.56(5.05)	0.44(0.12)	0.44(0.13)	0.38(0.12)	0.27(0.12)	0.81(0.06)	0.79(0.07)	0.77(0.07)	0.73(0.06)
40.MATH2 (100)	74.89(5.60)	76.00(5.47)	73.77(5.30)	70.49(5.74)	0.43(0.13)	0.45(0.12)	0.41(0.12)	0.32(0.13)	0.83(0.06)	0.82(0.06)	0.80(0.06)	0.75(0.07)
41.MATH2 (100)	74.18(5.08)	72.43(4.69)	69.63(5.84)	68.78(5.66)	0.45(0.11)	0.40(0.10)	0.35(0.13)	0.30(0.13)	0.80(0.05)	0.77(0.06)	0.75(0.06)	0.73(0.07)
42.MATH2 (100)	75.71(5.34)	75.43(5.33)	73.16(6.18)	69.80(5.65)	0.43(0.13)	0.42(0.13)	0.38(0.14)	0.29(0.13)	0.79(0.07)	0.78(0.07)	0.77(0.07)	0.73(0.06)
43.MATH2 (100)	76.72(4.62)	76.49(5.25)	73.33(5.14)	70.31(4.64)	0.49(0.10)	0.47(0.12)	0.42(0.11)	0.24(0.12)	0.82(0.05)	0.80(0.06)	0.79(0.06)	0.70(0.08)
44.MATH2 (100)	73.59(4.47)	72.94(4.84)	69.90(5.68)	70.26(4.49)	0.43(0.10)	0.41(0.11)	0.36(0.13)	0.26(0.11)	0.81(0.05)	0.78(0.06)	0.76(0.06)	0.73(0.06)
45.MATH2 (100)	75.80(5.82)	74.98(5.93)	72.94(5.95)	70.43(5.13)	0.49(0.12)	0.47(0.13)	0.43(0.13)	0.30(0.13)	0.81(0.06)	0.82(0.06)	0.79(0.06)	0.75(0.06)
46.MATH2 (100)	77.00(5.49)	74.56(5.55)	71.32(5.56)	68.16(6.13)	0.50(0.12)	0.44(0.12)	0.37(0.12)	0.26(0.14)	0.83(0.06)	0.81(0.06)	0.78(0.06)	0.70(0.07)
47.MATH2 (100)	74.84(5.65)	73.23(5.36)	70.40(6.06)	66.14(6.46)	0.43(0.13)	0.38(0.12)	0.34(0.13)	0.24(0.15)	0.79(0.07)	0.76(0.07)	0.74(0.07)	0.67(0.08)
48.MATH2 (100)	73.89(5.64)	73.17(6.17)	71.00(5.23)	76.07(5.05)	0.42(0.12)	0.39(0.14)	0.36(0.12)	0.39(0.13)	0.78(0.07)	0.77(0.07)	0.76(0.06)	0.80(0.06)
49.MATH2 (100)	73.71(4.86)	71.01(5.06)	69.69(5.89)	66.21(6.15)	0.43(0.10)	0.36(0.11)	0.34(0.13)	0.24(0.14)	0.80(0.05)	0.77(0.06)	0.76(0.06)	0.70(0.07)
50.MATH2 (100)	70.93(5.77)	70.69(6.22)	67.40(6.22)	70.75(5.11)	0.37(0.13)	0.37(0.13)	0.31(0.13)	0.32(0.12)	0.76(0.06)	0.75(0.07)	0.72(0.07)	0.76(0.07)

Analysing: Percent_correct (stddev) Datasets: 100 Resultsets: 4				Analysing: Kappa_statistic (stddev) Datasets: 100 Resultsets: 4				Analysing: Area_under_ROC (stddev) Datasets: 100 Resultsets: 4				
Dataset	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk
51. MATH2 (100)	78.78 (4.52)	77.25 (4.95)	75.09 (5.91)	73.37 (4.86)	0.52 (0.10)	0.47 (0.11)	0.43 (0.13)	0.35 (0.12)	0.85 (0.05)	0.81 (0.06)	0.80 (0.06)	0.77 (0.07)
52. MATH2 (100)	73.69 (5.84)	76.79 (5.01)	71.70 (5.60)	72.91 (4.95)	0.43 (0.13)	0.50 (0.11)	0.39 (0.12)	0.35 (0.13)	0.80 (0.05)	0.81 (0.06)	0.78 (0.06)	0.73 (0.07)
53. MATH2 (100)	73.79 (6.21)	73.13 (5.63)	72.10 (5.93)	68.86 (4.42)	0.44 (0.13)	0.42 (0.12)	0.40 (0.12)	0.25 (0.11)	0.82 (0.06)	0.79 (0.06)	0.78 (0.06)	0.73 (0.06)
54. MATH2 (100)	78.53 (5.82)	77.66 (5.41)	75.78 (4.86)	73.58 (5.18)	0.52 (0.13)	0.50 (0.12)	0.46 (0.11)	0.37 (0.13)	0.87 (0.05)	0.84 (0.06)	0.83 (0.05)	0.79 (0.06)
55. MATH2 (100)	76.20 (5.53)	73.77 (5.74)	70.93 (5.33)	70.14 (5.12)	0.47 (0.12)	0.40 (0.13)	0.35 (0.12)	0.28 (0.13)	0.80 (0.06)	0.76 (0.08)	0.75 (0.07)	0.73 (0.07)
56. MATH2 (100)	74.97 (5.45)	75.61 (5.47)	72.70 (6.55)	73.75 (4.07)	0.46 (0.12)	0.46 (0.12)	0.40 (0.14)	0.31 (0.11)	0.81 (0.06)	0.80 (0.06)	0.78 (0.06)	0.75 (0.07)
57. MATH2 (100)	76.68 (5.47)	75.14 (5.04)	73.57 (5.14)	68.88 (4.62)	0.49 (0.12)	0.44 (0.12)	0.42 (0.11)	0.17 (0.13)	0.85 (0.05)	0.80 (0.07)	0.80 (0.05)	0.66 (0.08)
58. MATH2 (100)	75.49 (5.77)	76.76 (5.76)	73.87 (5.68)	70.60 (4.76)	0.47 (0.12)	0.48 (0.13)	0.42 (0.13)	0.23 (0.12)	0.82 (0.06)	0.79 (0.07)	0.80 (0.06)	0.72 (0.07)
59. MATH2 (100)	77.91 (4.99)	76.64 (5.02)	75.53 (5.39)	73.63 (5.19)	0.49 (0.12)	0.45 (0.12)	0.44 (0.12)	0.34 (0.14)	0.82 (0.05)	0.81 (0.07)	0.82 (0.05)	0.76 (0.06)
60. MATH2 (100)	74.56 (5.87)	76.21 (5.24)	72.21 (5.33)	72.49 (4.97)	0.43 (0.13)	0.45 (0.12)	0.36 (0.12)	0.32 (0.13)	0.80 (0.06)	0.79 (0.06)	0.76 (0.06)	0.75 (0.07)
61. MATH2 (100)	75.60 (5.76)	76.78 (5.08)	74.80 (5.47)	71.57 (5.33)	0.45 (0.13)	0.46 (0.12)	0.43 (0.12)	0.33 (0.13)	0.83 (0.06)	0.80 (0.06)	0.79 (0.06)	0.74 (0.06)
62. MATH2 (100)	78.36 (6.04)	76.16 (5.73)	72.88 (6.36)	74.28 (5.08)	0.52 (0.13)	0.46 (0.13)	0.40 (0.13)	0.38 (0.13)	0.84 (0.06)	0.79 (0.07)	0.79 (0.07)	0.78 (0.06)
63. MATH2 (100)	75.54 (5.51)	73.80 (5.66)	71.08 (5.72)	69.93 (5.33)	0.47 (0.12)	0.43 (0.12)	0.37 (0.12)	0.25 (0.14)	0.81 (0.06)	0.77 (0.06)	0.76 (0.06)	0.72 (0.06)
64. MATH2 (100)	78.38 (4.28)	78.76 (4.91)	74.55 (4.63)	72.23 (4.29)	0.51 (0.09)	0.51 (0.11)	0.43 (0.10)	0.29 (0.11)	0.85 (0.04)	0.84 (0.06)	0.80 (0.05)	0.73 (0.06)
65. MATH2 (100)	75.59 (5.43)	75.75 (5.17)	72.37 (5.84)	71.75 (5.16)	0.46 (0.12)	0.44 (0.12)	0.38 (0.13)	0.31 (0.12)	0.83 (0.06)	0.82 (0.06)	0.78 (0.07)	0.76 (0.07)
66. MATH2 (100)	77.15 (6.07)	75.93 (5.36)	75.46 (5.48)	73.95 (4.52)	0.49 (0.14)	0.46 (0.12)	0.45 (0.12)	0.36 (0.11)	0.82 (0.06)	0.79 (0.07)	0.80 (0.06)	0.79 (0.06)
67. MATH2 (100)	75.94 (5.69)	75.31 (5.76)	73.94 (5.13)	70.92 (5.60)	0.47 (0.12)	0.45 (0.13)	0.42 (0.12)	0.32 (0.14)	0.82 (0.06)	0.81 (0.06)	0.79 (0.06)	0.73 (0.07)
68. MATH2 (100)	77.77 (5.48)	77.67 (5.53)	75.54 (5.52)	70.41 (4.87)	0.51 (0.12)	0.50 (0.12)	0.46 (0.12)	0.26 (0.13)	0.85 (0.05)	0.82 (0.07)	0.82 (0.06)	0.73 (0.07)
69. MATH2 (100)	73.93 (5.66)	74.87 (5.36)	73.34 (5.17)	73.65 (5.42)	0.42 (0.12)	0.43 (0.12)	0.41 (0.12)	0.39 (0.13)	0.81 (0.06)	0.78 (0.07)	0.78 (0.07)	0.79 (0.06)
70. MATH2 (100)	77.51 (5.55)	75.37 (5.63)	72.95 (5.82)	71.03 (4.84)	0.52 (0.12)	0.46 (0.12)	0.42 (0.13)	0.25 (0.13)	0.84 (0.05)	0.83 (0.06)	0.80 (0.06)	0.76 (0.07)
71. MATH2 (100)	77.16 (5.00)	74.12 (4.84)	72.06 (5.79)	71.50 (4.80)	0.47 (0.11)	0.37 (0.12)	0.34 (0.13)	0.30 (0.13)	0.82 (0.06)	0.76 (0.06)	0.76 (0.07)	0.72 (0.07)
72. MATH2 (100)	75.90 (5.75)	75.00 (5.10)	71.45 (5.29)	72.07 (5.29)	0.47 (0.12)	0.44 (0.11)	0.38 (0.13)	0.31 (0.14)	0.81 (0.06)	0.80 (0.06)	0.77 (0.06)	0.74 (0.07)
73. MATH2 (100)	75.00 (5.12)	74.17 (6.10)	71.47 (5.55)	76.43 (5.05)	0.44 (0.11)	0.41 (0.14)	0.36 (0.12)	0.41 (0.13)	0.80 (0.06)	0.78 (0.06)	0.76 (0.06)	0.78 (0.06)
74. MATH2 (100)	79.17 (4.98)	77.62 (5.02)	75.77 (5.70)	71.17 (5.60)	0.53 (0.11)	0.49 (0.12)	0.45 (0.12)	0.30 (0.14)	0.85 (0.05)	0.81 (0.06)	0.81 (0.06)	0.71 (0.07)
75. MATH2 (100)	73.32 (5.86)	71.98 (5.66)	71.08 (5.79)	74.46 (4.81)	0.42 (0.13)	0.37 (0.13)	0.35 (0.12)	0.36 (0.13)	0.77 (0.06)	0.76 (0.07)	0.74 (0.07)	0.77 (0.06)
76. MATH2 (100)	76.36 (5.11)	74.32 (6.11)	73.63 (4.82)	68.26 (4.51)	0.46 (0.12)	0.41 (0.14)	0.40 (0.11)	0.23 (0.11)	0.83 (0.05)	0.80 (0.07)	0.78 (0.06)	0.72 (0.07)
77. MATH2 (100)	73.40 (5.14)	74.14 (5.69)	71.70 (5.00)	73.56 (5.19)	0.42 (0.11)	0.43 (0.12)	0.37 (0.11)	0.37 (0.13)	0.81 (0.05)	0.78 (0.06)	0.75 (0.06)	0.78 (0.06)
78. MATH2 (100)	77.86 (5.07)	78.13 (5.00)	76.26 (5.16)	71.52 (4.56)	0.52 (0.11)	0.52 (0.11)	0.48 (0.11)	0.25 (0.12)	0.84 (0.05)	0.84 (0.05)	0.82 (0.05)	0.69 (0.08)
79. MATH2 (100)	74.56 (5.38)	75.48 (4.56)	73.88 (5.42)	72.08 (4.80)	0.40 (0.12)	0.42 (0.11)	0.40 (0.12)	0.31 (0.12)	0.79 (0.06)	0.80 (0.06)	0.77 (0.06)	0.76 (0.06)
80. MATH2 (100)	77.85 (5.31)	76.06 (5.82)	75.00 (5.58)	74.08 (5.26)	0.53 (0.11)	0.49 (0.12)	0.47 (0.12)	0.43 (0.12)	0.86 (0.05)	0.83 (0.06)	0.83 (0.05)	0.80 (0.06)
81. MATH2 (100)	79.39 (5.66)	75.38 (5.33)	72.29 (5.32)	71.39 (4.77)	0.54 (0.12)	0.43 (0.12)	0.39 (0.11)	0.28 (0.12)	0.83 (0.06)	0.80 (0.06)	0.78 (0.06)	0.75 (0.06)
82. MATH2 (100)	76.91 (5.33)	76.33 (4.84)	73.00 (6.53)	72.74 (5.12)	0.50 (0.11)	0.49 (0.10)	0.42 (0.13)	0.37 (0.12)	0.83 (0.06)	0.80 (0.06)	0.79 (0.06)	0.78 (0.07)
83. MATH2 (100)	74.58 (5.23)	74.42 (4.57)	71.09 (5.78)	70.67 (4.75)	0.43 (0.12)	0.43 (0.10)	0.36 (0.12)	0.29 (0.12)	0.79 (0.06)	0.78 (0.06)	0.75 (0.06)	0.72 (0.07)
84. MATH2 (100)	77.07 (4.92)	75.92 (4.93)	74.21 (5.17)	73.79 (4.46)	0.46 (0.11)	0.42 (0.12)	0.39 (0.12)	0.30 (0.13)	0.83 (0.05)	0.78 (0.06)	0.78 (0.06)	0.74 (0.07)
85. MATH2 (100)	73.47 (5.23)	74.59 (5.57)	71.04 (5.61)	67.31 (5.13)	0.42 (0.11)	0.44 (0.12)	0.37 (0.13)	0.24 (0.12)	0.82 (0.05)	0.79 (0.07)	0.77 (0.06)	0.70 (0.07)
86. MATH2 (100)	73.81 (5.72)	75.37 (5.53)	72.64 (6.67)	72.63 (3.78)	0.39 (0.13)	0.41 (0.13)	0.36 (0.16)	0.24 (0.12)	0.78 (0.07)	0.77 (0.07)	0.75 (0.08)	0.71 (0.07)
87. MATH2 (100)	77.41 (5.25)	75.97 (5.47)	72.86 (5.29)	71.07 (5.19)	0.49 (0.12)	0.45 (0.12)	0.40 (0.11)	0.27 (0.14)	0.83 (0.06)	0.80 (0.06)	0.79 (0.06)	0.73 (0.07)
88. MATH2 (100)	76.53 (4.50)	76.68 (4.76)	73.15 (5.69)	73.79 (5.07)	0.46 (0.10)	0.45 (0.12)	0.38 (0.13)	0.33 (0.14)	0.82 (0.05)	0.81 (0.05)	0.77 (0.07)	0.77 (0.06)
89. MATH2 (100)	76.93 (5.68)	78.13 (4.96)	76.66 (5.49)	73.77 (4.65)	0.48 (0.13)	0.51 (0.11)	0.48 (0.13)	0.34 (0.12)	0.82 (0.06)	0.83 (0.06)	0.81 (0.06)	0.75 (0.07)
90. MATH2 (100)	78.89 (5.50)	77.39 (5.15)	74.11 (6.29)	72.66 (5.01)	0.53 (0.11)	0.46 (0.13)	0.34 (0.12)	0.34 (0.12)	0.86 (0.05)	0.84 (0.05)	0.82 (0.05)	0.76 (0.06)
91. MATH2 (100)	79.08 (5.03)	74.58 (5.90)	72.68 (5.28)	70.30 (5.44)	0.53 (0.12)	0.42 (0.13)	0.39 (0.12)	0.36 (0.12)	0.83 (0.05)	0.79 (0.07)	0.77 (0.06)	0.79 (0.06)
92. MATH2 (100)	77.79 (5.65)	76.35 (5.08)	74.67 (5.94)	72.98 (5.45)	0.49 (0.13)	0.44 (0.12)	0.41 (0.14)	0.34 (0.13)	0.83 (0.06)	0.80 (0.07)	0.80 (0.06)	0.77 (0.07)
93. MATH2 (100)	78.77 (5.14)	76.46 (5.19)	75.06 (5.93)	74.22 (3.84)	0.54 (0.11)	0.48 (0.11)	0.46 (0.13)	0.31 (0.11)	0.85 (0.05)	0.83 (0.06)	0.82 (0.06)	0.77 (0.07)
94. MATH2 (100)	76.39 (5.06)	76.49 (5.10)	73.86 (6.07)	74.47 (5.70)	0.49 (0.11)	0.49 (0.11)	0.44 (0.13)	0.42 (0.13)	0.82 (0.06)	0.82 (0.06)	0.80 (0.06)	0.79 (0.06)
95. MATH2 (100)	74.10 (5.11)	74.84 (5.39)	71.88 (5.85)	71.74 (4.02)	0.42 (0.12)	0.43 (0.12)	0.37 (0.12)	0.34 (0.09)	0.80 (0.06)	0.77 (0.07)	0.75 (0.07)	0.77 (0.05)
96. MATH2 (100)	76.57 (5.59)	75.06 (6.08)	72.81 (5.76)	72.70 (4.43)	0.48 (0.12)	0.44 (0.14)	0.40 (0.13)	0.31 (0.12)	0.82 (0.06)	0.80 (0.06)	0.77 (0.07)	0.74 (0.06)
97. MATH2 (100)	76.54 (5.06)	74.23 (4.68)	72.29 (5.67)	70.56 (5.10)	0.49 (0.11)	0.42 (0.10)	0.39 (0.12)	0.28 (0.13)	0.82 (0.05)	0.78 (0.06)	0.77 (0.07)	0.75 (0.06)
98. MATH2 (100)	78.34 (5.55)	76.44 (5.77)	74.05 (5.51)	68.47 (4.61)	0.52 (0.12)	0.46 (0.13)	0.42 (0.12)	0.23 (0.12)	0.83 (0.06)	0.80 (0.07)	0.79 (0.06)	0.73 (0.07)
99. MATH2 (100)	75.39 (5.82)	76.28 (4.97)	72.79 (4.69)	72.79 (4.93)	0.47 (0.12)	0.48 (0.11)	0.41 (0.10)	0.32 (0.13)	0.80 (0.06)	0.81 (0.06)	0.78 (0.06)	0.75 (0.07)
100. MATH2 (100)	74.88 (5.76)	73.24 (5.70)	70.84 (5.19)	69.30 (4.99)	0.45 (0.13)	0.40 (0.13)	0.35 (0.12)	0.29 (0.12)	0.80 (0.06)	0.77 (0.07)	0.76 (0.06)	0.74 (0.07)

## EK-K: 500 Kişilik Örneklemde Test Verisi Oranı %22 için Elde Edilen Analiz Sonuçları

Dataset	Analysing: Percent_correct (stddev) Datasets: 100 Resultsets: 4					Analysing: Kappa_statistic (stddev) Datasets: 100 Resultsets: 4					Analysing: Area_under_ROC (stddev) Datasets: 100 Resultsets: 4			
	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk		(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk		(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk
1.MATH2 (100)	74.23(3.18)	73.07(3.54)	71.77(4.48)	72.09(2.96)		0.43(0.07)	0.40(0.08)	0.37(0.10)	0.32(0.08)		0.79(0.04)	0.76(0.04)	0.75(0.05)	0.74(0.04)
2.MATH2 (100)	77.72(3.38)	76.77(3.49)	75.88(3.87)	73.62(3.66)		0.50(0.08)	0.47(0.08)	0.46(0.09)	0.35(0.09)		0.85(0.03)	0.82(0.04)	0.82(0.04)	0.76(0.05)
3.MATH2 (100)	74.60(3.75)	74.15(3.91)	72.80(4.02)	69.31(3.64)		0.43(0.08)	0.40(0.09)	0.38(0.09)	0.26(0.08)		0.80(0.04)	0.75(0.05)	0.76(0.05)	0.72(0.05)
4.MATH2 (100)	73.40(3.43)	74.92(3.48)	73.15(3.89)	74.05(2.87)		0.39(0.08)	0.41(0.08)	0.38(0.08)	0.36(0.07)		0.80(0.03)	0.77(0.05)	0.77(0.04)	0.78(0.04)
5.MATH2 (100)	73.68(4.24)	71.94(3.48)	70.12(4.28)	71.58(3.26)		0.44(0.09)	0.38(0.08)	0.34(0.09)	0.30(0.08)		0.80(0.04)	0.78(0.04)	0.75(0.05)	0.74(0.05)
6.MATH2 (100)	74.89(3.41)	75.64(3.48)	71.40(3.92)	72.91(3.55)		0.43(0.08)	0.43(0.08)	0.33(0.09)	0.36(0.09)		0.78(0.04)	0.76(0.04)	0.73(0.05)	0.75(0.04)
7.MATH2 (100)	75.40(3.87)	76.02(3.25)	73.04(3.86)	73.33(2.89)		0.44(0.09)	0.44(0.08)	0.38(0.09)	0.28(0.09)		0.82(0.04)	0.80(0.04)	0.78(0.04)	0.73(0.05)
8.MATH2 (100)	76.73(3.52)	74.65(3.85)	73.03(3.60)	73.75(2.85)		0.49(0.08)	0.43(0.09)	0.39(0.08)	0.31(0.08)		0.82(0.04)	0.79(0.04)	0.78(0.04)	0.73(0.05)
9.MATH2 (100)	73.20(3.88)	74.00(3.33)	72.24(3.93)	71.30(3.13)		0.42(0.08)	0.42(0.07)	0.38(0.08)	0.27(0.08)		0.82(0.04)	0.79(0.04)	0.78(0.04)	0.70(0.05)
10.MATH2 (100)	77.55(3.78)	78.19(3.53)	75.59(3.42)	70.03(4.04)		0.50(0.08)	0.50(0.08)	0.45(0.08)	0.29(0.10)		0.84(0.04)	0.82(0.04)	0.81(0.04)	0.75(0.05)
11.MATH2 (100)	75.52(3.13)	73.63(3.38)	72.18(3.76)	71.29(3.86)		0.45(0.07)	0.39(0.08)	0.36(0.08)	0.34(0.09)		0.82(0.03)	0.79(0.04)	0.77(0.04)	0.78(0.05)
12.MATH2 (100)	75.19(4.02)	73.78(4.01)	71.56(3.99)	68.24(3.52)		0.45(0.09)	0.41(0.09)	0.37(0.08)	0.23(0.09)		0.81(0.04)	0.78(0.04)	0.76(0.04)	0.68(0.05)
13.MATH2 (100)	76.56(3.79)	75.32(4.07)	72.59(3.62)	72.72(3.87)		0.48(0.08)	0.45(0.09)	0.39(0.08)	0.34(0.10)		0.82(0.04)	0.79(0.05)	0.79(0.04)	0.75(0.05)
14.MATH2 (100)	76.19(3.89)	74.37(3.79)	73.86(3.97)	72.17(3.23)		0.45(0.09)	0.38(0.09)	0.38(0.09)	0.26(0.09)		0.82(0.04)	0.75(0.05)	0.77(0.05)	0.72(0.06)
15.MATH2 (100)	75.47(4.06)	74.67(3.60)	71.87(3.60)	72.79(3.48)		0.43(0.09)	0.39(0.09)	0.34(0.08)	0.32(0.09)		0.80(0.04)	0.75(0.05)	0.74(0.05)	0.75(0.05)
16.MATH2 (100)	74.79(4.14)	73.25(3.64)	71.31(4.38)	70.21(3.07)		0.42(0.10)	0.38(0.09)	0.34(0.10)	0.20(0.09)		0.80(0.05)	0.76(0.05)	0.74(0.04)	0.72(0.06)
17.MATH2 (100)	71.91(4.18)	71.95(3.90)	69.50(4.36)	71.41(3.83)		0.39(0.09)	0.38(0.08)	0.33(0.09)	0.32(0.09)		0.78(0.04)	0.77(0.04)	0.75(0.05)	0.74(0.04)
18.MATH2 (100)	76.27(3.70)	73.52(4.05)	72.07(3.52)	69.71(3.22)		0.49(0.08)	0.42(0.09)	0.40(0.08)	0.29(0.08)		0.83(0.04)	0.78(0.05)	0.78(0.04)	0.71(0.04)
19.MATH2 (100)	74.40(3.84)	72.86(3.66)	70.16(3.82)	71.03(3.07)		0.43(0.09)	0.40(0.08)	0.35(0.09)	0.24(0.09)		0.80(0.04)	0.78(0.04)	0.76(0.05)	0.72(0.05)
20.MATH2 (100)	78.27(3.35)	76.06(3.36)	73.88(3.89)	68.46(3.34)		0.49(0.08)	0.41(0.08)	0.37(0.09)	0.25(0.08)		0.83(0.04)	0.77(0.05)	0.77(0.04)	0.69(0.05)
21.MATH2 (100)	76.03(3.57)	75.39(4.09)	72.59(3.64)	70.74(3.58)		0.45(0.08)	0.43(0.09)	0.38(0.09)	0.26(0.09)		0.82(0.04)	0.80(0.05)	0.77(0.04)	0.72(0.05)
22.MATH2 (100)	76.58(3.61)	73.19(3.54)	73.34(3.53)	71.40(3.31)		0.45(0.09)	0.35(0.09)	0.38(0.08)	0.26(0.09)		0.82(0.04)	0.75(0.05)	0.77(0.04)	0.72(0.05)
23.MATH2 (100)	75.91(3.52)	75.67(3.76)	72.86(3.96)	71.40(3.24)		0.47(0.08)	0.46(0.08)	0.40(0.09)	0.34(0.07)		0.82(0.04)	0.80(0.04)	0.78(0.04)	0.76(0.04)
24.MATH2 (100)	74.60(3.72)	71.76(3.72)	69.70(4.13)	73.06(3.34)		0.45(0.08)	0.37(0.08)	0.34(0.09)	0.32(0.07)		0.80(0.04)	0.76(0.04)	0.74(0.05)	0.71(0.05)
25.MATH2 (100)	74.87(3.63)	77.98(3.54)	74.75(3.81)	69.23(3.41)		0.41(0.08)	0.49(0.08)	0.42(0.08)	0.24(0.08)		0.81(0.04)	0.82(0.04)	0.79(0.04)	0.72(0.05)
26.MATH2 (100)	74.53(4.03)	75.46(4.15)	73.25(3.95)	72.38(2.69)		0.45(0.09)	0.47(0.09)	0.42(0.09)	0.23(0.08)		0.80(0.04)	0.80(0.04)	0.78(0.05)	0.72(0.05)
27.MATH2 (100)	74.58(3.46)	74.88(3.99)	72.01(4.13)	73.89(3.65)		0.42(0.08)	0.43(0.09)	0.37(0.09)	0.38(0.09)		0.80(0.04)	0.79(0.05)	0.76(0.04)	0.78(0.05)
28.MATH2 (100)	73.49(3.79)	72.28(3.74)	69.91(3.90)	70.94(3.14)		0.40(0.08)	0.35(0.08)	0.31(0.09)	0.24(0.08)		0.80(0.04)	0.74(0.05)	0.73(0.05)	0.70(0.06)
29.MATH2 (100)	75.88(3.47)	75.73(4.00)	74.03(3.87)	72.92(3.41)		0.47(0.08)	0.47(0.09)	0.44(0.08)	0.32(0.08)		0.83(0.03)	0.80(0.04)	0.80(0.04)	0.77(0.05)
30.MATH2 (100)	75.53(3.67)	73.72(3.82)	72.04(3.84)	71.04(3.11)		0.46(0.08)	0.39(0.09)	0.37(0.09)	0.24(0.08)		0.82(0.04)	0.78(0.04)	0.77(0.04)	0.70(0.04)
31.MATH2 (100)	77.24(3.52)	74.61(3.71)	72.36(3.54)	70.18(3.25)		0.47(0.08)	0.38(0.09)	0.34(0.08)	0.27(0.08)		0.81(0.04)	0.76(0.05)	0.76(0.04)	0.72(0.05)
32.MATH2 (100)	77.94(3.49)	77.08(3.81)	74.87(3.69)	71.34(3.75)		0.52(0.08)	0.49(0.09)	0.45(0.08)	0.30(0.09)		0.83(0.04)	0.82(0.05)	0.80(0.04)	0.72(0.04)
33.MATH2 (100)	73.91(3.35)	73.74(3.45)	70.00(4.17)	72.06(3.34)		0.40(0.08)	0.38(0.08)	0.30(0.09)	0.31(0.09)		0.78(0.04)	0.76(0.05)	0.73(0.05)	0.74(0.04)
34.MATH2 (100)	77.03(3.75)	77.04(3.45)	73.96(3.75)	72.02(3.28)		0.48(0.08)	0.47(0.08)	0.40(0.09)	0.34(0.08)		0.83(0.04)	0.81(0.04)	0.79(0.04)	0.75(0.04)
35.MATH2 (100)	75.20(3.28)	74.70(3.66)	72.59(4.67)	72.40(3.51)		0.42(0.07)	0.40(0.09)	0.36(0.10)	0.29(0.09)		0.79(0.04)	0.76(0.05)	0.74(0.05)	0.74(0.04)
36.MATH2 (100)	75.69(3.80)	72.17(3.73)	69.86(3.65)	73.58(3.10)		0.46(0.08)	0.38(0.09)	0.34(0.08)	0.34(0.08)		0.81(0.04)	0.77(0.05)	0.75(0.05)	0.78(0.04)
37.MATH2 (100)	76.33(3.40)	74.09(3.88)	71.52(3.86)	68.51(3.95)		0.48(0.07)	0.40(0.09)	0.36(0.08)	0.28(0.09)		0.81(0.04)	0.77(0.05)	0.76(0.04)	0.71(0.05)
38.MATH2 (100)	79.25(3.49)	76.77(3.37)	74.71(3.88)	70.57(3.37)		0.53(0.08)	0.47(0.08)	0.44(0.09)	0.24(0.10)		0.84(0.04)	0.82(0.04)	0.81(0.04)	0.69(0.06)
39.MATH2 (100)	74.65(3.44)	74.44(3.70)	71.60(3.83)	69.67(3.37)		0.45(0.08)	0.44(0.08)	0.38(0.08)	0.28(0.08)		0.81(0.04)	0.79(0.04)	0.78(0.04)	0.72(0.04)
40.MATH2 (100)	75.08(3.43)	75.26(3.55)	73.40(4.11)	69.71(3.61)		0.44(0.08)	0.43(0.08)	0.40(0.09)	0.30(0.08)		0.82(0.03)	0.80(0.04)	0.79(0.04)	0.73(0.04)
41.MATH2 (100)	75.18(3.45)	72.76(3.61)	70.19(4.14)	67.54(3.80)		0.47(0.07)	0.41(0.08)	0.36(0.09)	0.27(0.08)		0.81(0.04)	0.77(0.04)	0.75(0.05)	0.71(0.04)
42.MATH2 (100)	75.50(3.50)	74.51(3.23)	72.25(3.92)	69.41(3.54)		0.43(0.08)	0.40(0.08)	0.37(0.09)	0.28(0.08)		0.79(0.04)	0.77(0.04)	0.76(0.04)	0.72(0.05)
43.MATH2 (100)	76.60(3.60)	75.62(3.53)	73.71(3.54)	69.79(2.88)		0.49(0.08)	0.45(0.08)	0.42(0.08)	0.23(0.08)		0.82(0.04)	0.79(0.04)	0.79(0.04)	0.70(0.04)
44.MATH2 (100)	73.05(3.14)	72.51(3.33)	70.08(4.58)	70.63(3.22)		0.41(0.07)	0.40(0.07)	0.36(0.09)	0.27(0.08)		0.80(0.03)	0.77(0.04)	0.76(0.04)	0.73(0.05)
45.MATH2 (100)	74.31(4.34)	73.67(3.94)	71.77(4.54)	70.69(3.55)		0.46(0.09)	0.44(0.09)	0.40(0.09)	0.31(0.08)		0.81(0.04)	0.80(0.04)	0.78(0.05)	0.75(0.05)
46.MATH2 (100)	76.82(3.46)	74.43(3.66)	72.22(4.33)	67.50(4.28)		0.50(0.07)	0.44(0.08)	0.39(0.09)	0.24(0.10)		0.83(0.03)	0.81(0.04)	0.79(0.04)	0.69(0.05)
47.MATH2 (100)	75.95(3.99)	73.19(3.83)	71.08(4.20)	65.59(3.57)		0.45(0.09)	0.39(0.09)	0.35(0.09)	0.24(0.08)		0.80(0.04)	0.77(0.05)	0.75(0.05)	0.67(0.04)
48.MATH2 (100)	74.04(3.73)	73.23(4.29)	71.02(3.83)	75.18(3.06)		0.42(0.08)	0.40(0.10)	0.36(0.09)	0.37(0.08)		0.78(0.04)	0.76(0.05)	0.76(0.05)	0.79(0.04)
49.MATH2 (100)	73.96(3.72)	71.43(3.79)	70.06(4.20)	66.26(4.02)		0.43(0.08)	0.37(0.08)	0.35(0.09)	0.24(0.09)		0.80(0.04)	0.77(0.05)	0.75(0.05)	0.69(0.05)
50.MATH2 (100)	70.06(4.06)	70.04(3.63)	66.64(3.81)	70.29(3.79)		0.36(0.09)	0.36(0.08)	0.30(0.08)	0.32(0.09)		0.75(0.04)	0.74(0.04)	0.72(0.04)	0.76(0.05)

Analysing: Percent_correct (stddev) Datasets: 100 Resultsets: 4				Analysing: Kappa_statistic (stddev) Datasets: 100 Resultsets: 4				Analysing: Area_under_ROC (stddev) Datasets: 100 Resultsets: 4				
Dataset	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk
51. MATH2 (100)	78.36(3.10)	76.43(3.84)	74.40(3.70)	72.62(3.63)	0.51(0.07)	0.45(0.09)	0.41(0.09)	0.33(0.09)	0.85(0.03)	0.80(0.05)	0.79(0.05)	0.76(0.04)
52. MATH2 (100)	74.03(3.59)	76.71(2.89)	71.98(3.93)	72.71(3.06)	0.44(0.08)	0.50(0.06)	0.40(0.08)	0.34(0.08)	0.81(0.03)	0.80(0.04)	0.78(0.04)	0.73(0.04)
53. MATH2 (100)	73.57(3.37)	72.41(3.90)	72.39(3.64)	68.94(3.69)	0.43(0.07)	0.40(0.08)	0.40(0.08)	0.25(0.09)	0.81(0.04)	0.77(0.05)	0.77(0.04)	0.72(0.05)
54. MATH2 (100)	77.82(3.69)	76.49(3.87)	74.76(4.07)	72.01(3.64)	0.51(0.08)	0.48(0.09)	0.45(0.09)	0.33(0.08)	0.86(0.03)	0.82(0.04)	0.81(0.04)	0.76(0.05)
55. MATH2 (100)	76.27(3.75)	73.45(3.94)	71.37(3.79)	71.15(2.97)	0.48(0.08)	0.40(0.08)	0.36(0.08)	0.30(0.07)	0.81(0.04)	0.76(0.04)	0.75(0.04)	0.74(0.04)
56. MATH2 (100)	75.14(4.11)	74.25(3.69)	72.79(3.73)	73.55(3.06)	0.46(0.09)	0.43(0.08)	0.40(0.08)	0.31(0.08)	0.81(0.04)	0.79(0.04)	0.78(0.04)	0.74(0.05)
57. MATH2 (100)	75.68(3.67)	73.10(3.50)	71.09(4.01)	68.37(2.99)	0.47(0.08)	0.40(0.08)	0.37(0.09)	0.16(0.08)	0.83(0.03)	0.77(0.05)	0.77(0.04)	0.66(0.05)
58. MATH2 (100)	75.99(3.76)	75.90(3.42)	73.77(3.78)	69.76(3.09)	0.48(0.08)	0.46(0.07)	0.42(0.08)	0.21(0.08)	0.83(0.04)	0.79(0.05)	0.80(0.04)	0.71(0.05)
59. MATH2 (100)	77.32(3.29)	76.27(3.51)	75.41(3.60)	72.88(3.90)	0.48(0.08)	0.45(0.08)	0.44(0.08)	0.32(0.10)	0.82(0.04)	0.80(0.05)	0.82(0.04)	0.75(0.05)
60. MATH2 (100)	74.28(3.86)	74.94(3.96)	72.60(3.88)	72.38(2.94)	0.42(0.09)	0.42(0.09)	0.38(0.08)	0.32(0.07)	0.80(0.04)	0.78(0.05)	0.77(0.04)	0.75(0.05)
61. MATH2 (100)	76.02(3.49)	75.42(3.48)	73.89(3.93)	71.76(4.07)	0.46(0.08)	0.44(0.08)	0.41(0.09)	0.34(0.10)	0.83(0.04)	0.79(0.05)	0.79(0.04)	0.75(0.05)
62. MATH2 (100)	78.45(3.92)	74.87(3.87)	73.01(3.99)	74.55(3.50)	0.52(0.08)	0.43(0.09)	0.39(0.09)	0.39(0.09)	0.84(0.04)	0.78(0.05)	0.78(0.05)	0.79(0.04)
63. MATH2 (100)	75.75(3.94)	73.04(3.90)	70.39(4.10)	70.47(3.72)	0.48(0.09)	0.41(0.09)	0.36(0.09)	0.26(0.10)	0.81(0.04)	0.76(0.04)	0.75(0.05)	0.72(0.05)
64. MATH2 (100)	78.02(3.09)	78.11(3.29)	75.27(3.27)	71.96(3.05)	0.51(0.07)	0.50(0.08)	0.44(0.08)	0.29(0.08)	0.85(0.03)	0.82(0.04)	0.81(0.04)	0.72(0.05)
65. MATH2 (100)	75.64(3.62)	76.15(3.68)	72.44(3.95)	71.72(3.33)	0.46(0.08)	0.45(0.09)	0.38(0.09)	0.31(0.08)	0.83(0.03)	0.80(0.04)	0.78(0.04)	0.76(0.04)
66. MATH2 (100)	77.82(3.66)	75.10(3.30)	73.67(3.87)	73.76(3.17)	0.51(0.08)	0.44(0.08)	0.41(0.08)	0.36(0.08)	0.83(0.04)	0.79(0.04)	0.79(0.04)	0.78(0.04)
67. MATH2 (100)	76.25(3.44)	74.97(3.84)	73.31(3.52)	69.99(3.29)	0.48(0.08)	0.44(0.08)	0.40(0.08)	0.29(0.08)	0.83(0.04)	0.80(0.04)	0.79(0.04)	0.72(0.04)
68. MATH2 (100)	78.13(3.64)	77.27(3.75)	75.21(4.08)	70.27(3.44)	0.52(0.08)	0.49(0.08)	0.44(0.09)	0.25(0.09)	0.85(0.03)	0.81(0.05)	0.81(0.04)	0.73(0.05)
69. MATH2 (100)	73.17(3.66)	73.78(3.68)	73.04(4.14)	72.83(3.66)	0.41(0.08)	0.41(0.09)	0.40(0.09)	0.38(0.09)	0.80(0.04)	0.77(0.05)	0.77(0.04)	0.78(0.04)
70. MATH2 (100)	76.77(3.42)	75.05(3.56)	73.16(3.81)	70.61(3.26)	0.50(0.07)	0.46(0.08)	0.42(0.08)	0.23(0.09)	0.84(0.04)	0.82(0.04)	0.80(0.04)	0.74(0.05)
71. MATH2 (100)	76.10(3.69)	73.45(3.95)	71.77(3.96)	70.57(3.46)	0.44(0.09)	0.36(0.09)	0.34(0.10)	0.28(0.09)	0.81(0.04)	0.74(0.05)	0.75(0.05)	0.71(0.05)
72. MATH2 (100)	75.59(3.57)	73.94(3.37)	71.88(3.92)	71.18(3.36)	0.46(0.08)	0.42(0.07)	0.38(0.09)	0.29(0.09)	0.81(0.04)	0.79(0.04)	0.77(0.04)	0.74(0.04)
73. MATH2 (100)	75.01(3.83)	74.43(3.78)	71.51(3.89)	75.63(3.53)	0.44(0.08)	0.42(0.08)	0.36(0.08)	0.40(0.09)	0.80(0.04)	0.77(0.05)	0.76(0.04)	0.78(0.04)
74. MATH2 (100)	79.09(3.23)	76.95(3.82)	75.31(3.62)	70.89(3.52)	0.53(0.07)	0.47(0.09)	0.45(0.08)	0.29(0.09)	0.85(0.03)	0.81(0.04)	0.81(0.04)	0.71(0.05)
75. MATH2 (100)	73.57(4.06)	71.18(4.16)	70.12(4.17)	73.74(3.37)	0.42(0.09)	0.35(0.09)	0.33(0.09)	0.34(0.09)	0.78(0.04)	0.75(0.05)	0.74(0.05)	0.76(0.04)
76. MATH2 (100)	75.33(3.26)	72.94(3.37)	72.29(3.53)	68.52(3.31)	0.44(0.08)	0.38(0.08)	0.37(0.08)	0.23(0.08)	0.82(0.03)	0.77(0.05)	0.77(0.04)	0.71(0.05)
77. MATH2 (100)	73.53(3.97)	73.22(3.93)	71.40(3.85)	72.87(3.28)	0.42(0.09)	0.41(0.09)	0.36(0.08)	0.35(0.08)	0.81(0.04)	0.77(0.04)	0.76(0.04)	0.77(0.04)
78. MATH2 (100)	77.25(4.21)	76.77(3.77)	74.66(4.42)	71.36(2.69)	0.51(0.09)	0.49(0.08)	0.45(0.10)	0.24(0.07)	0.83(0.04)	0.82(0.04)	0.81(0.05)	0.69(0.05)
79. MATH2 (100)	74.99(3.51)	74.57(3.41)	73.25(3.95)	71.99(3.47)	0.42(0.08)	0.40(0.08)	0.38(0.08)	0.31(0.09)	0.79(0.04)	0.78(0.05)	0.76(0.05)	0.75(0.05)
80. MATH2 (100)	77.35(3.52)	74.96(4.26)	74.00(4.80)	72.95(3.52)	0.52(0.07)	0.47(0.09)	0.45(0.10)	0.40(0.08)	0.85(0.03)	0.81(0.04)	0.81(0.04)	0.79(0.04)
81. MATH2 (100)	78.96(3.76)	74.98(3.70)	73.06(4.21)	70.88(3.47)	0.53(0.09)	0.43(0.09)	0.40(0.09)	0.27(0.09)	0.83(0.04)	0.79(0.04)	0.78(0.05)	0.73(0.05)
82. MATH2 (100)	77.18(3.66)	75.21(3.59)	73.59(3.86)	73.10(3.80)	0.51(0.08)	0.46(0.08)	0.43(0.08)	0.38(0.09)	0.83(0.04)	0.79(0.04)	0.79(0.04)	0.77(0.04)
83. MATH2 (100)	74.64(3.55)	73.46(3.37)	70.16(3.57)	69.70(3.71)	0.44(0.08)	0.41(0.07)	0.34(0.07)	0.27(0.09)	0.79(0.04)	0.77(0.04)	0.74(0.04)	0.70(0.05)
84. MATH2 (100)	77.60(3.33)	75.62(3.56)	73.60(3.36)	73.46(3.18)	0.47(0.08)	0.41(0.09)	0.37(0.08)	0.28(0.09)	0.83(0.04)	0.78(0.04)	0.77(0.04)	0.75(0.05)
85. MATH2 (100)	73.41(3.51)	73.49(3.79)	71.29(3.76)	66.68(3.94)	0.42(0.08)	0.42(0.08)	0.38(0.08)	0.22(0.10)	0.81(0.04)	0.78(0.04)	0.77(0.04)	0.69(0.05)
86. MATH2 (100)	74.05(3.76)	74.94(4.25)	72.52(4.04)	70.95(3.17)	0.39(0.09)	0.40(0.10)	0.35(0.09)	0.19(0.09)	0.78(0.04)	0.76(0.05)	0.75(0.05)	0.70(0.05)
87. MATH2 (100)	77.31(3.61)	75.14(4.03)	72.64(3.90)	71.08(3.67)	0.49(0.08)	0.44(0.09)	0.39(0.08)	0.27(0.10)	0.82(0.04)	0.79(0.05)	0.78(0.05)	0.73(0.05)
88. MATH2 (100)	76.41(3.46)	75.56(3.26)	73.38(3.54)	73.80(3.17)	0.46(0.08)	0.42(0.08)	0.38(0.09)	0.33(0.08)	0.82(0.04)	0.78(0.05)	0.77(0.04)	0.77(0.04)
89. MATH2 (100)	76.36(3.87)	78.19(3.46)	76.10(3.62)	73.52(3.40)	0.46(0.09)	0.51(0.08)	0.46(0.08)	0.34(0.09)	0.81(0.04)	0.82(0.04)	0.81(0.04)	0.74(0.05)
90. MATH2 (100)	78.88(3.47)	76.32(3.92)	73.85(3.93)	71.74(3.49)	0.56(0.07)	0.51(0.08)	0.46(0.08)	0.33(0.09)	0.86(0.03)	0.83(0.04)	0.81(0.04)	0.75(0.05)
91. MATH2 (100)	78.64(3.40)	74.15(3.82)	72.39(3.82)	70.26(3.50)	0.52(0.08)	0.42(0.09)	0.38(0.09)	0.37(0.08)	0.82(0.04)	0.78(0.05)	0.76(0.04)	0.78(0.04)
92. MATH2 (100)	77.50(3.39)	76.34(3.84)	73.98(3.52)	73.53(3.69)	0.49(0.08)	0.44(0.09)	0.39(0.09)	0.36(0.09)	0.83(0.04)	0.80(0.05)	0.79(0.04)	0.77(0.04)
93. MATH2 (100)	79.17(3.53)	76.16(3.69)	75.66(3.73)	73.08(3.32)	0.55(0.08)	0.48(0.08)	0.47(0.08)	0.29(0.09)	0.86(0.03)	0.82(0.04)	0.82(0.04)	0.76(0.04)
94. MATH2 (100)	76.06(3.64)	75.35(3.81)	73.71(3.68)	74.42(3.53)	0.48(0.08)	0.46(0.08)	0.43(0.08)	0.42(0.08)	0.82(0.04)	0.80(0.04)	0.79(0.04)	0.80(0.04)
95. MATH2 (100)	74.72(4.01)	74.29(3.77)	71.54(4.12)	71.69(3.38)	0.44(0.09)	0.41(0.09)	0.36(0.09)	0.34(0.08)	0.80(0.04)	0.76(0.05)	0.76(0.04)	0.77(0.04)
96. MATH2 (100)	75.78(3.55)	74.76(4.04)	70.86(3.90)	72.89(3.25)	0.46(0.08)	0.44(0.09)	0.35(0.09)	0.32(0.09)	0.82(0.04)	0.79(0.04)	0.75(0.04)	0.74(0.05)
97. MATH2 (100)	76.01(3.49)	73.48(3.47)	71.58(3.69)	70.10(3.51)	0.48(0.07)	0.41(0.08)	0.37(0.08)	0.27(0.08)	0.82(0.04)	0.77(0.04)	0.77(0.04)	0.73(0.05)
98. MATH2 (100)	78.59(3.96)	76.30(3.95)	74.31(3.90)	68.31(3.63)	0.52(0.08)	0.46(0.09)	0.42(0.08)	0.23(0.09)	0.83(0.04)	0.79(0.04)	0.79(0.04)	0.72(0.06)
99. MATH2 (100)	75.85(3.88)	75.22(3.52)	71.79(4.68)	72.77(3.84)	0.48(0.08)	0.46(0.07)	0.39(0.10)	0.33(0.10)	0.81(0.04)	0.79(0.04)	0.78(0.05)	0.75(0.05)
100. MATH2 (100)	74.81(3.61)	72.98(3.88)	71.45(3.84)	69.75(4.09)	0.44(0.08)	0.39(0.08)	0.37(0.08)	0.30(0.09)	0.80(0.04)	0.76(0.05)	0.77(0.04)	0.74(0.05)

## EK-L: 500 Kişilik Örneklemde Test Verisi Oranı %33 için Elde Edilen Analiz Sonuçları

Analysing: Percent_correct (stddev) Datasets: 100 Resultsets: 4				Analysing: Kappa_statistic (stddev) Datasets: 100 Resultsets: 4				Analysing: Area_under_ROC (stddev) Datasets: 100 Resultsets: 4				
Dataset	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk
1.MATH2 (100)	74.40(2.45)	72.57(3.12)	72.06(3.67)	72.21(2.81)	0.44(0.05)	0.39(0.07)	0.38(0.08)	0.33(0.07)	0.80(0.03)	0.75(0.04)	0.76(0.04)	0.74(0.04)
2.MATH2 (100)	77.36(2.97)	75.90(3.02)	75.11(3.38)	72.78(2.88)	0.50(0.07)	0.45(0.07)	0.44(0.08)	0.32(0.07)	0.85(0.02)	0.80(0.04)	0.81(0.03)	0.76(0.04)
3.MATH2 (100)	74.98(2.89)	73.63(2.93)	72.18(3.39)	68.70(2.84)	0.43(0.06)	0.39(0.07)	0.37(0.08)	0.25(0.07)	0.81(0.03)	0.74(0.04)	0.75(0.04)	0.71(0.04)
4.MATH2 (100)	73.06(2.61)	74.29(2.76)	72.74(3.62)	73.67(2.62)	0.38(0.06)	0.39(0.06)	0.37(0.08)	0.35(0.06)	0.80(0.03)	0.76(0.04)	0.76(0.04)	0.77(0.03)
5.MATH2 (100)	73.02(3.18)	71.36(2.98)	68.90(3.23)	71.09(2.79)	0.42(0.07)	0.36(0.06)	0.32(0.07)	0.29(0.07)	0.79(0.03)	0.76(0.04)	0.74(0.04)	0.74(0.04)
6.MATH2 (100)	74.32(2.69)	74.22(3.03)	70.57(3.18)	72.35(3.02)	0.42(0.06)	0.40(0.07)	0.32(0.07)	0.34(0.07)	0.77(0.03)	0.75(0.04)	0.73(0.04)	0.74(0.04)
7.MATH2 (100)	75.48(2.83)	75.49(2.68)	72.26(3.40)	73.27(2.47)	0.45(0.06)	0.43(0.06)	0.37(0.08)	0.28(0.07)	0.82(0.03)	0.78(0.04)	0.77(0.03)	0.74(0.04)
8.MATH2 (100)	76.44(2.63)	73.92(3.04)	72.68(3.10)	72.60(2.38)	0.48(0.06)	0.41(0.07)	0.39(0.07)	0.28(0.07)	0.82(0.03)	0.78(0.04)	0.78(0.03)	0.71(0.04)
9.MATH2 (100)	73.69(2.98)	74.00(2.86)	72.50(3.61)	70.37(3.19)	0.43(0.06)	0.42(0.06)	0.39(0.07)	0.25(0.08)	0.82(0.03)	0.78(0.03)	0.78(0.04)	0.69(0.04)
10.MATH2 (100)	77.33(2.53)	77.04(3.02)	74.71(3.05)	69.45(2.64)	0.49(0.06)	0.48(0.07)	0.43(0.06)	0.27(0.06)	0.84(0.03)	0.81(0.04)	0.80(0.03)	0.74(0.04)
11.MATH2 (100)	75.40(3.08)	73.04(2.91)	72.37(3.19)	71.22(3.26)	0.45(0.07)	0.38(0.06)	0.37(0.07)	0.35(0.08)	0.82(0.03)	0.77(0.04)	0.77(0.03)	0.76(0.04)
12.MATH2 (100)	75.27(3.09)	73.18(3.05)	71.27(3.23)	68.48(2.54)	0.45(0.07)	0.40(0.07)	0.37(0.07)	0.23(0.06)	0.81(0.03)	0.76(0.04)	0.76(0.04)	0.68(0.04)
13.MATH2 (100)	76.60(3.12)	74.86(3.27)	72.52(3.12)	72.51(3.16)	0.48(0.07)	0.44(0.07)	0.39(0.07)	0.33(0.08)	0.82(0.03)	0.78(0.04)	0.78(0.03)	0.75(0.04)
14.MATH2 (100)	76.88(2.77)	74.32(3.21)	74.35(2.96)	71.97(3.03)	0.47(0.06)	0.39(0.08)	0.39(0.07)	0.25(0.09)	0.82(0.03)	0.74(0.04)	0.77(0.03)	0.71(0.05)
15.MATH2 (100)	75.55(2.71)	73.60(3.02)	71.91(3.47)	72.57(2.55)	0.43(0.06)	0.37(0.07)	0.34(0.08)	0.31(0.07)	0.80(0.03)	0.73(0.04)	0.73(0.04)	0.74(0.05)
16.MATH2 (100)	74.39(2.84)	72.71(2.89)	71.17(3.06)	70.12(2.97)	0.42(0.07)	0.37(0.07)	0.34(0.06)	0.20(0.07)	0.80(0.03)	0.75(0.04)	0.74(0.03)	0.73(0.06)
17.MATH2 (100)	71.71(3.06)	71.43(3.07)	69.36(3.45)	70.83(2.83)	0.38(0.07)	0.37(0.07)	0.33(0.08)	0.31(0.06)	0.78(0.03)	0.76(0.04)	0.74(0.04)	0.74(0.03)
18.MATH2 (100)	75.76(2.73)	72.65(3.04)	71.20(3.11)	68.98(2.72)	0.48(0.06)	0.41(0.07)	0.38(0.07)	0.27(0.06)	0.82(0.03)	0.77(0.03)	0.77(0.03)	0.70(0.04)
19.MATH2 (100)	73.96(3.16)	73.10(2.78)	69.77(3.49)	71.00(2.77)	0.42(0.07)	0.40(0.06)	0.34(0.07)	0.24(0.07)	0.80(0.03)	0.78(0.03)	0.75(0.03)	0.71(0.04)
20.MATH2 (100)	77.55(2.35)	75.41(2.92)	73.61(3.45)	68.23(2.79)	0.47(0.06)	0.40(0.07)	0.37(0.08)	0.25(0.07)	0.82(0.03)	0.76(0.04)	0.77(0.04)	0.68(0.04)
21.MATH2 (100)	76.47(2.81)	74.84(3.18)	72.70(3.22)	70.18(3.05)	0.46(0.06)	0.42(0.07)	0.38(0.07)	0.25(0.08)	0.82(0.03)	0.79(0.04)	0.77(0.03)	0.71(0.04)
22.MATH2 (100)	76.34(2.81)	72.96(2.99)	72.38(3.16)	71.00(2.67)	0.45(0.07)	0.35(0.08)	0.36(0.07)	0.25(0.07)	0.82(0.03)	0.74(0.04)	0.77(0.03)	0.71(0.04)
23.MATH2 (100)	75.99(2.79)	74.84(2.62)	72.59(2.95)	70.96(2.41)	0.47(0.06)	0.44(0.06)	0.39(0.07)	0.33(0.06)	0.82(0.03)	0.79(0.04)	0.78(0.03)	0.75(0.03)
24.MATH2 (100)	74.79(2.78)	71.37(2.65)	69.72(3.50)	72.85(2.26)	0.45(0.06)	0.37(0.06)	0.34(0.07)	0.31(0.06)	0.80(0.03)	0.75(0.04)	0.74(0.03)	0.71(0.04)
25.MATH2 (100)	74.90(2.68)	77.32(2.37)	73.84(3.16)	69.21(2.78)	0.42(0.06)	0.48(0.05)	0.40(0.07)	0.24(0.07)	0.81(0.03)	0.81(0.03)	0.78(0.03)	0.72(0.04)
26.MATH2 (100)	74.67(2.64)	75.27(3.05)	72.51(2.99)	71.95(2.37)	0.45(0.06)	0.46(0.06)	0.40(0.06)	0.22(0.07)	0.80(0.03)	0.79(0.03)	0.78(0.03)	0.72(0.04)
27.MATH2 (100)	74.74(2.95)	73.78(3.18)	71.42(3.35)	73.79(2.73)	0.42(0.07)	0.41(0.07)	0.36(0.07)	0.38(0.06)	0.80(0.03)	0.76(0.04)	0.77(0.03)	0.78(0.04)
28.MATH2 (100)	73.43(2.97)	71.51(2.91)	69.82(3.01)	70.65(2.44)	0.40(0.07)	0.34(0.06)	0.31(0.06)	0.23(0.07)	0.79(0.03)	0.73(0.04)	0.73(0.04)	0.70(0.04)
29.MATH2 (100)	75.84(2.67)	74.75(2.92)	73.57(2.82)	72.89(2.89)	0.47(0.06)	0.45(0.06)	0.43(0.06)	0.32(0.08)	0.83(0.02)	0.79(0.03)	0.80(0.03)	0.77(0.04)
30.MATH2 (100)	75.51(2.92)	73.09(2.87)	71.58(3.27)	71.03(2.72)	0.46(0.06)	0.39(0.06)	0.36(0.07)	0.25(0.07)	0.82(0.03)	0.77(0.03)	0.76(0.04)	0.70(0.04)
31.MATH2 (100)	76.87(2.82)	73.78(2.53)	72.08(3.04)	70.10(2.83)	0.46(0.06)	0.36(0.06)	0.33(0.08)	0.27(0.07)	0.82(0.03)	0.75(0.04)	0.75(0.03)	0.71(0.04)
32.MATH2 (100)	77.81(2.68)	75.79(3.58)	74.84(2.91)	71.17(2.52)	0.51(0.06)	0.47(0.08)	0.45(0.06)	0.28(0.07)	0.83(0.03)	0.80(0.04)	0.80(0.03)	0.71(0.04)
33.MATH2 (100)	73.70(2.76)	72.86(2.58)	70.05(2.76)	71.62(2.84)	0.39(0.07)	0.36(0.06)	0.31(0.06)	0.30(0.07)	0.78(0.03)	0.74(0.04)	0.73(0.04)	0.73(0.04)
34.MATH2 (100)	77.18(2.89)	76.31(2.92)	74.04(3.06)	71.36(2.76)	0.49(0.06)	0.45(0.07)	0.41(0.07)	0.33(0.07)	0.83(0.03)	0.80(0.04)	0.79(0.03)	0.74(0.04)
35.MATH2 (100)	74.99(2.45)	74.08(2.91)	72.03(3.62)	72.39(3.08)	0.42(0.06)	0.39(0.07)	0.35(0.08)	0.29(0.07)	0.79(0.03)	0.74(0.04)	0.74(0.04)	0.73(0.04)
36.MATH2 (100)	75.54(2.90)	71.45(3.07)	69.96(3.74)	72.72(3.05)	0.46(0.06)	0.36(0.07)	0.34(0.08)	0.33(0.07)	0.81(0.03)	0.75(0.04)	0.75(0.04)	0.77(0.04)
37.MATH2 (100)	76.02(2.63)	73.14(3.08)	70.49(3.65)	68.24(3.34)	0.47(0.06)	0.38(0.07)	0.34(0.08)	0.28(0.07)	0.81(0.03)	0.76(0.03)	0.75(0.04)	0.71(0.04)
38.MATH2 (100)	78.91(2.82)	75.91(3.14)	74.41(3.03)	70.26(2.51)	0.53(0.06)	0.45(0.07)	0.43(0.07)	0.23(0.07)	0.84(0.03)	0.80(0.04)	0.80(0.03)	0.69(0.04)
39.MATH2 (100)	74.60(2.45)	73.51(3.28)	72.00(2.91)	69.72(2.89)	0.44(0.05)	0.42(0.07)	0.39(0.07)	0.27(0.07)	0.81(0.03)	0.77(0.04)	0.77(0.03)	0.72(0.04)
40.MATH2 (100)	75.20(3.03)	74.54(2.78)	73.92(2.85)	69.12(2.95)	0.44(0.07)	0.42(0.06)	0.41(0.06)	0.29(0.07)	0.82(0.03)	0.79(0.04)	0.79(0.03)	0.73(0.03)
41.MATH2 (100)	74.88(2.71)	72.36(3.01)	69.89(3.51)	67.59(2.88)	0.47(0.06)	0.40(0.06)	0.35(0.07)	0.28(0.07)	0.81(0.03)	0.76(0.03)	0.75(0.04)	0.71(0.04)
42.MATH2 (100)	75.45(2.89)	74.68(2.60)	72.27(3.54)	68.85(3.11)	0.43(0.07)	0.41(0.06)	0.37(0.08)	0.26(0.07)	0.79(0.03)	0.76(0.03)	0.76(0.04)	0.72(0.04)
43.MATH2 (100)	76.83(2.98)	75.12(3.17)	73.71(3.10)	69.03(2.59)	0.49(0.06)	0.44(0.07)	0.42(0.07)	0.21(0.07)	0.82(0.03)	0.78(0.04)	0.79(0.03)	0.69(0.04)
44.MATH2 (100)	73.25(2.73)	71.70(2.63)	69.89(3.32)	69.80(2.79)	0.42(0.06)	0.39(0.05)	0.36(0.07)	0.25(0.07)	0.80(0.03)	0.75(0.03)	0.75(0.03)	0.71(0.03)
45.MATH2 (100)	74.14(3.38)	72.38(3.47)	70.65(3.48)	70.70(2.97)	0.45(0.07)	0.41(0.08)	0.38(0.07)	0.32(0.07)	0.80(0.03)	0.78(0.04)	0.77(0.04)	0.74(0.04)
46.MATH2 (100)	76.44(2.54)	73.81(3.01)	71.87(3.21)	66.87(2.92)	0.49(0.05)	0.42(0.06)	0.38(0.07)	0.23(0.07)	0.83(0.02)	0.79(0.03)	0.78(0.03)	0.68(0.04)
47.MATH2 (100)	75.63(3.18)	72.05(3.09)	71.00(3.32)	65.48(3.00)	0.44(0.07)	0.36(0.07)	0.35(0.08)	0.23(0.07)	0.80(0.03)	0.74(0.04)	0.75(0.04)	0.66(0.03)
48.MATH2 (100)	74.24(2.88)	72.90(2.95)	71.27(3.40)	75.01(2.64)	0.43(0.06)	0.39(0.07)	0.36(0.08)	0.37(0.07)	0.78(0.03)	0.75(0.04)	0.76(0.04)	0.79(0.04)
49.MATH2 (100)	74.02(2.76)	70.98(2.98)	69.67(3.42)	65.63(2.87)	0.43(0.06)	0.37(0.07)	0.34(0.07)	0.22(0.07)	0.79(0.03)	0.75(0.04)	0.75(0.04)	0.69(0.03)
50.MATH2 (100)	69.44(3.14)	68.73(2.63)	66.87(2.85)	69.73(3.04)	0.34(0.07)	0.33(0.06)	0.30(0.06)	0.30(0.07)	0.75(0.03)	0.72(0.04)	0.72(0.03)	0.75(0.04)



Analysing: Percent_correct (stddev) Datasets: 100 Resultsets: 4					Analysing: Kappa_statistic (stddev) Datasets: 100 Resultsets: 4					Analysing: Area_under_ROC (stddev) Datasets: 100 Resultsets: 4				
Dataset	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk		
51. MATH2 (100)	78.63(2.66)	75.97(2.91)	74.50(3.66)	71.86(2.93)	0.51(0.06)	0.44(0.07)	0.41(0.08)	0.31(0.07)	0.85(0.03)	0.79(0.03)	0.79(0.04)	0.76(0.04)		
52. MATH2 (100)	74.38(3.03)	75.82(2.92)	71.82(3.36)	71.46(2.73)	0.45(0.07)	0.48(0.06)	0.40(0.07)	0.30(0.07)	0.81(0.03)	0.79(0.04)	0.78(0.03)	0.72(0.04)		
53. MATH2 (100)	73.64(3.07)	71.90(3.12)	71.46(3.05)	68.48(2.90)	0.44(0.06)	0.39(0.07)	0.39(0.06)	0.25(0.07)	0.81(0.03)	0.76(0.04)	0.76(0.03)	0.71(0.04)		
54. MATH2 (100)	77.61(2.85)	76.34(2.87)	73.96(3.20)	72.22(2.80)	0.50(0.07)	0.47(0.07)	0.42(0.07)	0.34(0.07)	0.85(0.03)	0.81(0.03)	0.80(0.03)	0.76(0.04)		
55. MATH2 (100)	75.90(2.89)	72.59(2.79)	71.44(3.15)	70.44(2.77)	0.47(0.06)	0.38(0.06)	0.36(0.06)	0.29(0.07)	0.80(0.03)	0.75(0.04)	0.75(0.03)	0.74(0.04)		
56. MATH2 (100)	74.79(2.70)	73.48(3.21)	72.27(3.15)	72.62(2.61)	0.45(0.06)	0.42(0.07)	0.39(0.07)	0.29(0.07)	0.81(0.03)	0.77(0.04)	0.78(0.03)	0.73(0.04)		
57. MATH2 (100)	75.59(2.59)	72.78(2.67)	71.60(3.37)	68.66(2.48)	0.47(0.05)	0.39(0.06)	0.37(0.07)	0.16(0.07)	0.83(0.02)	0.76(0.03)	0.77(0.04)	0.66(0.05)		
58. MATH2 (100)	75.75(2.82)	75.03(3.26)	73.00(2.88)	69.22(2.65)	0.48(0.06)	0.44(0.07)	0.40(0.06)	0.20(0.07)	0.82(0.03)	0.78(0.04)	0.79(0.03)	0.69(0.05)		
59. MATH2 (100)	77.07(2.68)	75.50(2.93)	74.88(3.32)	72.40(3.04)	0.48(0.06)	0.43(0.07)	0.43(0.08)	0.31(0.08)	0.82(0.03)	0.79(0.04)	0.80(0.04)	0.74(0.04)		
60. MATH2 (100)	74.00(2.78)	74.09(3.02)	71.56(3.60)	71.68(2.59)	0.42(0.06)	0.40(0.07)	0.35(0.07)	0.30(0.06)	0.79(0.03)	0.76(0.04)	0.75(0.03)	0.74(0.03)		
61. MATH2 (100)	75.90(2.70)	74.95(2.95)	73.58(3.29)	71.82(2.86)	0.46(0.06)	0.43(0.06)	0.40(0.07)	0.34(0.07)	0.83(0.03)	0.78(0.04)	0.79(0.03)	0.75(0.03)		
62. MATH2 (100)	78.19(2.72)	73.86(2.96)	71.84(3.15)	74.24(3.04)	0.52(0.06)	0.41(0.07)	0.37(0.07)	0.38(0.08)	0.84(0.03)	0.76(0.04)	0.77(0.03)	0.79(0.04)		
63. MATH2 (100)	75.73(3.04)	72.20(3.14)	70.85(3.58)	69.47(3.40)	0.48(0.07)	0.39(0.07)	0.37(0.08)	0.25(0.08)	0.81(0.03)	0.75(0.04)	0.76(0.04)	0.71(0.04)		
64. MATH2 (100)	78.06(2.51)	77.16(2.80)	74.82(3.12)	71.56(2.68)	0.51(0.06)	0.48(0.06)	0.44(0.07)	0.28(0.07)	0.85(0.03)	0.81(0.04)	0.81(0.04)	0.72(0.04)		
65. MATH2 (100)	75.05(2.93)	74.69(3.05)	72.64(3.10)	71.51(2.71)	0.44(0.06)	0.42(0.07)	0.38(0.07)	0.31(0.06)	0.82(0.03)	0.79(0.04)	0.78(0.04)	0.75(0.03)		
66. MATH2 (100)	77.54(2.62)	74.32(2.88)	74.20(3.29)	73.60(2.68)	0.50(0.06)	0.42(0.07)	0.42(0.07)	0.36(0.07)	0.83(0.03)	0.78(0.04)	0.78(0.04)	0.78(0.03)		
67. MATH2 (100)	75.66(2.90)	74.77(2.99)	73.71(3.29)	69.59(2.74)	0.47(0.06)	0.44(0.06)	0.42(0.07)	0.27(0.07)	0.82(0.03)	0.79(0.03)	0.79(0.03)	0.72(0.04)		
68. MATH2 (100)	78.41(2.67)	76.93(2.84)	75.20(3.11)	70.23(3.02)	0.52(0.06)	0.48(0.06)	0.44(0.07)	0.25(0.08)	0.85(0.02)	0.80(0.04)	0.81(0.03)	0.73(0.04)		
69. MATH2 (100)	73.28(2.97)	72.52(3.26)	72.16(3.07)	72.28(2.66)	0.40(0.06)	0.38(0.07)	0.38(0.07)	0.37(0.06)	0.80(0.03)	0.75(0.04)	0.76(0.03)	0.78(0.03)		
70. MATH2 (100)	76.78(2.74)	74.67(2.87)	72.47(2.87)	70.76(2.78)	0.50(0.06)	0.45(0.06)	0.41(0.06)	0.24(0.07)	0.84(0.03)	0.80(0.03)	0.80(0.03)	0.78(0.04)		
71. MATH2 (100)	75.83(2.84)	72.88(3.15)	70.26(3.25)	69.72(3.18)	0.44(0.07)	0.35(0.07)	0.31(0.07)	0.27(0.08)	0.81(0.03)	0.73(0.04)	0.74(0.04)	0.71(0.04)		
72. MATH2 (100)	75.40(3.05)	73.49(2.70)	71.42(3.25)	70.77(2.61)	0.46(0.07)	0.41(0.06)	0.37(0.07)	0.28(0.07)	0.81(0.03)	0.78(0.04)	0.76(0.03)	0.73(0.03)		
73. MATH2 (100)	75.41(2.60)	74.26(2.86)	71.23(3.19)	74.87(2.65)	0.45(0.06)	0.42(0.06)	0.36(0.07)	0.38(0.06)	0.80(0.03)	0.76(0.04)	0.76(0.03)	0.77(0.03)		
74. MATH2 (100)	78.80(2.79)	75.90(3.59)	74.83(3.12)	70.23(2.81)	0.52(0.06)	0.45(0.08)	0.44(0.07)	0.28(0.07)	0.85(0.03)	0.79(0.04)	0.80(0.04)	0.70(0.04)		
75. MATH2 (100)	73.05(2.91)	70.34(3.09)	69.31(3.58)	72.53(2.78)	0.41(0.06)	0.34(0.07)	0.31(0.08)	0.23(0.07)	0.78(0.03)	0.73(0.04)	0.72(0.04)	0.75(0.04)		
76. MATH2 (100)	75.05(2.72)	72.56(2.82)	71.30(2.88)	68.60(2.62)	0.43(0.06)	0.37(0.06)	0.35(0.06)	0.31(0.07)	0.82(0.03)	0.76(0.04)	0.76(0.03)	0.71(0.05)		
77. MATH2 (100)	73.00(3.00)	72.23(2.87)	70.46(3.55)	72.41(2.57)	0.41(0.07)	0.38(0.06)	0.34(0.07)	0.34(0.06)	0.80(0.03)	0.76(0.04)	0.74(0.03)	0.76(0.04)		
78. MATH2 (100)	76.97(3.16)	76.22(3.22)	75.00(3.03)	70.58(2.64)	0.50(0.07)	0.47(0.07)	0.45(0.07)	0.23(0.06)	0.83(0.03)	0.81(0.04)	0.81(0.03)	0.68(0.04)		
79. MATH2 (100)	75.26(2.82)	74.17(2.79)	73.22(3.37)	72.16(2.70)	0.42(0.06)	0.39(0.07)	0.38(0.08)	0.31(0.08)	0.79(0.03)	0.77(0.04)	0.76(0.04)	0.75(0.04)		
80. MATH2 (100)	77.05(2.87)	74.23(3.01)	73.37(3.24)	71.86(3.21)	0.51(0.06)	0.45(0.06)	0.44(0.07)	0.38(0.07)	0.85(0.03)	0.80(0.03)	0.81(0.03)	0.78(0.04)		
81. MATH2 (100)	78.96(2.81)	74.31(3.10)	72.53(3.27)	70.60(2.68)	0.53(0.06)	0.41(0.07)	0.39(0.07)	0.26(0.07)	0.83(0.03)	0.78(0.04)	0.78(0.03)	0.73(0.04)		
82. MATH2 (100)	76.96(2.99)	74.12(2.80)	73.34(3.38)	71.81(3.04)	0.50(0.06)	0.44(0.06)	0.43(0.07)	0.36(0.07)	0.83(0.03)	0.78(0.04)	0.78(0.03)	0.76(0.03)		
83. MATH2 (100)	74.45(3.17)	72.39(2.96)	69.86(2.84)	69.43(3.05)	0.43(0.07)	0.39(0.07)	0.33(0.06)	0.27(0.08)	0.79(0.03)	0.76(0.04)	0.74(0.04)	0.70(0.04)		
84. MATH2 (100)	77.80(2.27)	75.30(2.91)	73.75(2.97)	73.65(2.71)	0.47(0.06)	0.40(0.07)	0.37(0.07)	0.29(0.08)	0.83(0.03)	0.77(0.04)	0.77(0.04)	0.75(0.04)		
85. MATH2 (100)	73.71(2.93)	72.82(3.37)	70.62(3.20)	66.71(3.06)	0.43(0.07)	0.41(0.07)	0.36(0.07)	0.22(0.07)	0.81(0.03)	0.77(0.04)	0.76(0.04)	0.68(0.05)		
86. MATH2 (100)	73.78(2.94)	73.91(2.82)	71.54(3.06)	70.02(2.67)	0.39(0.07)	0.38(0.06)	0.33(0.07)	0.17(0.07)	0.78(0.03)	0.75(0.04)	0.74(0.04)	0.69(0.05)		
87. MATH2 (100)	77.37(2.86)	74.20(3.05)	72.00(3.14)	71.10(2.44)	0.49(0.06)	0.42(0.07)	0.37(0.07)	0.27(0.06)	0.82(0.03)	0.78(0.04)	0.77(0.04)	0.73(0.04)		
88. MATH2 (100)	76.42(3.15)	74.60(2.76)	73.31(3.12)	73.74(2.45)	0.46(0.07)	0.40(0.06)	0.38(0.06)	0.33(0.06)	0.81(0.03)	0.77(0.04)	0.77(0.04)	0.76(0.04)		
89. MATH2 (100)	76.56(2.87)	76.91(3.17)	75.22(2.79)	73.51(2.43)	0.47(0.06)	0.48(0.07)	0.44(0.06)	0.34(0.06)	0.81(0.03)	0.80(0.04)	0.80(0.03)	0.74(0.03)		
90. MATH2 (100)	78.76(2.83)	75.49(3.05)	73.92(3.02)	71.93(3.04)	0.56(0.06)	0.49(0.06)	0.46(0.06)	0.33(0.07)	0.86(0.03)	0.81(0.04)	0.81(0.03)	0.76(0.04)		
91. MATH2 (100)	78.63(2.42)	73.61(2.97)	71.92(3.02)	70.31(3.03)	0.52(0.06)	0.41(0.07)	0.38(0.07)	0.37(0.07)	0.82(0.03)	0.76(0.04)	0.76(0.04)	0.78(0.04)		
92. MATH2 (100)	77.44(2.57)	75.64(3.11)	73.85(3.11)	73.34(2.63)	0.48(0.06)	0.43(0.07)	0.39(0.07)	0.36(0.07)	0.83(0.03)	0.78(0.04)	0.78(0.04)	0.76(0.03)		
93. MATH2 (100)	79.20(2.87)	75.89(2.74)	75.25(3.26)	72.26(2.88)	0.55(0.06)	0.47(0.06)	0.47(0.07)	0.27(0.07)	0.86(0.03)	0.80(0.04)	0.82(0.03)	0.74(0.05)		
94. MATH2 (100)	75.53(2.73)	74.22(3.04)	73.02(3.36)	74.62(2.97)	0.47(0.06)	0.44(0.06)	0.42(0.07)	0.42(0.07)	0.81(0.03)	0.78(0.04)	0.79(0.03)	0.80(0.04)		
95. MATH2 (100)	74.40(2.95)	73.28(2.99)	71.62(3.15)	70.97(2.96)	0.43(0.06)	0.39(0.07)	0.36(0.06)	0.33(0.06)	0.80(0.03)	0.74(0.04)	0.75(0.03)	0.76(0.03)		
96. MATH2 (100)	75.56(3.12)	74.26(3.00)	71.46(2.88)	72.67(2.54)	0.46(0.07)	0.43(0.06)	0.36(0.06)	0.32(0.06)	0.81(0.03)	0.78(0.03)	0.76(0.03)	0.73(0.04)		
97. MATH2 (100)	76.02(2.73)	73.10(2.67)	71.51(3.14)	69.53(2.79)	0.48(0.06)	0.40(0.06)	0.37(0.07)	0.26(0.07)	0.82(0.03)	0.76(0.03)	0.77(0.03)	0.72(0.04)		
98. MATH2 (100)	78.42(2.60)	75.71(2.97)	73.44(3.11)	67.83(3.24)	0.52(0.06)	0.45(0.07)	0.40(0.07)	0.21(0.08)	0.83(0.03)	0.78(0.04)	0.79(0.03)	0.71(0.05)		
99. MATH2 (100)	75.82(2.72)	74.13(3.00)	71.79(3.17)	72.94(2.63)	0.48(0.06)	0.43(0.07)	0.39(0.07)	0.33(0.07)	0.81(0.03)	0.77(0.04)	0.77(0.04)	0.75(0.04)		
100. MATH2 (100)	74.76(2.88)	72.41(3.18)	71.24(3.31)	69.45(2.95)	0.44(0.06)	0.38(0.07)	0.36(0.07)	0.29(0.07)	0.80(0.03)	0.75(0.04)	0.76(0.04)	0.73(0.04)		

## EK-M: 500 Kişilik Örneklemde Test Verisi Oranı %44 için Elde Edilen Analiz Sonuçları

Analysing: Percent_correct (stddev) Datasets: 100 Resultsets: 4				Analysing: Kappa_statistic (stddev) Datasets: 100 Resultsets: 4				Analysing: Area_under_ROC (stddev) Datasets: 100 Resultsets: 4				
Dataset	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk
1.MATH2 (100)	74.50(2.31)	71.74(3.13)	71.45(3.24)	71.49(2.39)	0.44(0.05)	0.37(0.07)	0.36(0.07)	0.31(0.06)	0.80(0.02)	0.74(0.04)	0.75(0.03)	0.72(0.03)
2.MATH2 (100)	76.87(2.22)	75.81(2.95)	74.05(2.87)	72.86(2.47)	0.48(0.05)	0.45(0.07)	0.42(0.06)	0.42(0.07)	0.84(0.03)	0.78(0.04)	0.80(0.03)	0.75(0.04)
3.MATH2 (100)	74.60(2.25)	71.32(2.52)	70.71(2.76)	68.91(2.22)	0.44(0.05)	0.36(0.05)	0.35(0.06)	0.25(0.05)	0.80(0.02)	0.74(0.03)	0.76(0.03)	0.71(0.04)
4.MATH2 (100)	75.61(2.50)	72.19(2.61)	72.27(2.65)	73.43(2.38)	0.45(0.05)	0.37(0.06)	0.36(0.06)	0.35(0.06)	0.82(0.02)	0.75(0.04)	0.77(0.03)	0.76(0.03)
5.MATH2 (100)	75.53(2.38)	72.56(2.95)	71.13(2.77)	70.07(2.56)	0.46(0.05)	0.39(0.06)	0.36(0.06)	0.27(0.06)	0.81(0.02)	0.75(0.03)	0.76(0.03)	0.72(0.03)
6.MATH2 (100)	76.31(2.46)	73.56(2.68)	72.29(3.13)	71.73(2.66)	0.48(0.05)	0.41(0.06)	0.39(0.07)	0.33(0.07)	0.82(0.03)	0.75(0.03)	0.78(0.03)	0.73(0.03)
7.MATH2 (100)	77.05(2.14)	73.34(2.67)	73.72(2.61)	72.85(2.24)	0.47(0.05)	0.36(0.06)	0.38(0.06)	0.27(0.06)	0.82(0.02)	0.73(0.03)	0.77(0.03)	0.73(0.03)
8.MATH2 (100)	75.39(2.43)	72.58(2.76)	71.43(2.54)	72.08(2.13)	0.43(0.05)	0.35(0.06)	0.33(0.06)	0.26(0.06)	0.80(0.02)	0.72(0.04)	0.73(0.03)	0.70(0.03)
9.MATH2 (100)	74.45(2.25)	71.75(2.86)	70.39(3.10)	69.56(2.45)	0.42(0.05)	0.35(0.06)	0.33(0.07)	0.23(0.06)	0.79(0.02)	0.73(0.03)	0.74(0.03)	0.69(0.04)
10.MATH2 (100)	71.90(2.66)	70.75(2.52)	69.17(2.72)	69.20(2.60)	0.39(0.06)	0.35(0.06)	0.32(0.06)	0.27(0.07)	0.78(0.02)	0.74(0.03)	0.74(0.03)	0.73(0.03)
11.MATH2 (100)	75.42(2.48)	72.46(2.61)	71.76(2.55)	70.21(2.71)	0.47(0.05)	0.40(0.05)	0.39(0.05)	0.33(0.07)	0.82(0.02)	0.76(0.03)	0.77(0.03)	0.75(0.04)
12.MATH2 (100)	73.50(2.90)	72.60(2.84)	69.82(2.93)	67.95(2.16)	0.41(0.06)	0.40(0.06)	0.34(0.06)	0.22(0.06)	0.79(0.03)	0.76(0.03)	0.75(0.03)	0.68(0.03)
13.MATH2 (100)	77.00(2.34)	75.06(2.63)	74.23(2.67)	71.83(2.59)	0.49(0.05)	0.44(0.06)	0.42(0.06)	0.31(0.07)	0.84(0.02)	0.78(0.03)	0.80(0.03)	0.73(0.03)
14.MATH2 (100)	77.61(2.38)	74.65(2.60)	73.53(2.59)	71.78(2.46)	0.47(0.06)	0.39(0.06)	0.37(0.06)	0.25(0.07)	0.82(0.02)	0.75(0.03)	0.76(0.03)	0.71(0.05)
15.MATH2 (100)	76.45(2.24)	74.03(2.81)	72.10(2.89)	72.50(2.14)	0.46(0.05)	0.40(0.06)	0.37(0.07)	0.31(0.06)	0.82(0.02)	0.77(0.04)	0.77(0.03)	0.74(0.03)
16.MATH2 (100)	75.92(2.20)	71.96(2.55)	72.21(2.61)	70.37(2.27)	0.44(0.05)	0.33(0.06)	0.36(0.06)	0.21(0.06)	0.82(0.02)	0.72(0.04)	0.76(0.03)	0.72(0.05)
17.MATH2 (100)	75.87(2.42)	73.46(2.70)	71.91(2.54)	70.14(2.53)	0.47(0.05)	0.41(0.06)	0.38(0.06)	0.30(0.06)	0.82(0.02)	0.76(0.04)	0.78(0.03)	0.72(0.04)
18.MATH2 (100)	74.51(2.08)	70.39(2.65)	69.59(3.01)	68.65(2.53)	0.45(0.04)	0.35(0.06)	0.34(0.06)	0.27(0.06)	0.80(0.02)	0.73(0.04)	0.74(0.03)	0.70(0.03)
19.MATH2 (100)	74.56(2.24)	76.28(2.61)	73.69(2.89)	70.78(2.29)	0.41(0.06)	0.46(0.06)	0.40(0.06)	0.24(0.06)	0.80(0.02)	0.79(0.04)	0.78(0.03)	0.71(0.03)
20.MATH2 (100)	74.23(2.27)	74.16(2.63)	71.93(2.69)	68.00(2.86)	0.44(0.05)	0.44(0.05)	0.39(0.05)	0.24(0.07)	0.79(0.02)	0.77(0.03)	0.77(0.03)	0.68(0.04)
21.MATH2 (100)	74.29(2.55)	72.92(2.68)	70.91(3.11)	69.79(2.27)	0.41(0.06)	0.39(0.06)	0.35(0.07)	0.24(0.06)	0.80(0.03)	0.75(0.04)	0.75(0.03)	0.71(0.03)
22.MATH2 (100)	73.44(2.44)	69.86(2.61)	69.21(2.77)	70.49(2.52)	0.40(0.05)	0.31(0.06)	0.30(0.06)	0.24(0.06)	0.79(0.03)	0.70(0.04)	0.72(0.03)	0.70(0.03)
23.MATH2 (100)	75.66(2.32)	73.41(2.56)	72.90(2.78)	70.32(1.97)	0.47(0.05)	0.43(0.06)	0.42(0.06)	0.32(0.05)	0.83(0.02)	0.76(0.03)	0.79(0.03)	0.74(0.03)
24.MATH2 (100)	74.91(2.27)	72.49(2.51)	71.69(2.67)	72.06(2.30)	0.43(0.05)	0.37(0.05)	0.36(0.06)	0.30(0.06)	0.80(0.02)	0.72(0.03)	0.76(0.03)	0.70(0.03)
25.MATH2 (100)	75.57(2.38)	73.01(2.38)	71.62(2.60)	69.29(2.28)	0.46(0.05)	0.39(0.05)	0.36(0.06)	0.24(0.06)	0.83(0.02)	0.76(0.03)	0.77(0.03)	0.72(0.03)
26.MATH2 (100)	76.58(2.54)	73.02(2.48)	71.82(2.84)	71.73(2.04)	0.46(0.06)	0.34(0.06)	0.33(0.06)	0.22(0.06)	0.81(0.02)	0.73(0.04)	0.76(0.03)	0.71(0.04)
27.MATH2 (100)	77.71(2.42)	74.55(3.03)	74.74(2.19)	73.72(2.40)	0.51(0.05)	0.44(0.06)	0.44(0.05)	0.38(0.06)	0.83(0.02)	0.77(0.04)	0.79(0.02)	0.77(0.03)
28.MATH2 (100)	73.55(2.12)	72.01(2.16)	70.13(2.94)	70.61(2.30)	0.39(0.05)	0.34(0.05)	0.31(0.06)	0.23(0.06)	0.78(0.02)	0.73(0.03)	0.73(0.03)	0.69(0.04)
29.MATH2 (100)	76.81(2.07)	75.62(2.69)	73.92(2.47)	72.43(2.66)	0.48(0.04)	0.44(0.06)	0.40(0.06)	0.31(0.07)	0.83(0.02)	0.79(0.03)	0.79(0.03)	0.76(0.04)
30.MATH2 (100)	74.83(2.30)	72.91(2.70)	71.40(2.73)	70.43(2.16)	0.42(0.05)	0.36(0.06)	0.34(0.06)	0.23(0.06)	0.79(0.02)	0.72(0.04)	0.74(0.03)	0.69(0.03)
31.MATH2 (100)	74.88(2.32)	70.24(2.79)	69.91(2.30)	69.64(2.65)	0.44(0.05)	0.34(0.06)	0.33(0.05)	0.27(0.06)	0.80(0.02)	0.73(0.04)	0.74(0.03)	0.70(0.04)
32.MATH2 (100)	75.73(2.28)	72.04(2.78)	70.11(2.92)	70.09(2.46)	0.46(0.05)	0.36(0.06)	0.33(0.06)	0.26(0.06)	0.80(0.02)	0.74(0.04)	0.75(0.03)	0.70(0.03)
33.MATH2 (100)	78.67(2.26)	75.05(2.49)	73.93(2.76)	71.36(2.43)	0.52(0.05)	0.44(0.06)	0.42(0.06)	0.30(0.06)	0.84(0.02)	0.78(0.03)	0.80(0.03)	0.73(0.04)
34.MATH2 (100)	75.09(2.09)	72.63(2.87)	71.67(2.42)	70.99(2.36)	0.46(0.04)	0.40(0.06)	0.38(0.05)	0.32(0.06)	0.82(0.02)	0.75(0.03)	0.77(0.03)	0.74(0.03)
35.MATH2 (100)	72.97(2.54)	72.79(2.74)	71.98(2.72)	71.89(2.31)	0.38(0.06)	0.36(0.06)	0.35(0.06)	0.28(0.06)	0.79(0.03)	0.73(0.04)	0.76(0.03)	0.72(0.03)
36.MATH2 (100)	75.03(2.26)	73.89(2.45)	73.73(2.77)	72.26(2.75)	0.44(0.05)	0.41(0.05)	0.41(0.06)	0.32(0.07)	0.82(0.02)	0.77(0.04)	0.79(0.02)	0.76(0.04)
37.MATH2 (100)	74.96(2.43)	71.28(2.68)	69.93(2.87)	67.83(2.57)	0.47(0.05)	0.38(0.06)	0.35(0.06)	0.27(0.06)	0.81(0.03)	0.74(0.03)	0.75(0.03)	0.70(0.03)
38.MATH2 (100)	75.53(2.22)	73.44(2.43)	72.19(2.45)	69.58(2.35)	0.43(0.05)	0.38(0.06)	0.36(0.05)	0.21(0.06)	0.79(0.03)	0.74(0.03)	0.76(0.03)	0.68(0.04)
39.MATH2 (100)	76.81(2.31)	73.67(2.45)	73.31(2.72)	69.43(2.45)	0.49(0.05)	0.41(0.06)	0.41(0.07)	0.27(0.06)	0.82(0.02)	0.75(0.03)	0.78(0.03)	0.71(0.03)
40.MATH2 (100)	73.49(2.44)	70.43(2.34)	69.55(2.60)	68.65(2.36)	0.43(0.05)	0.36(0.05)	0.35(0.06)	0.28(0.06)	0.80(0.02)	0.73(0.04)	0.75(0.03)	0.72(0.03)
41.MATH2 (100)	73.87(2.59)	71.82(2.90)	70.40(3.03)	66.77(2.36)	0.45(0.05)	0.40(0.06)	0.37(0.06)	0.25(0.06)	0.80(0.03)	0.76(0.04)	0.76(0.03)	0.70(0.04)
42.MATH2 (100)	76.38(2.04)	72.78(2.46)	71.50(2.61)	68.76(2.59)	0.49(0.04)	0.40(0.06)	0.37(0.06)	0.26(0.06)	0.83(0.02)	0.77(0.03)	0.78(0.03)	0.71(0.03)
43.MATH2 (100)	75.32(2.41)	71.56(2.77)	70.70(2.63)	68.59(2.13)	0.44(0.06)	0.35(0.06)	0.34(0.06)	0.20(0.05)	0.80(0.02)	0.73(0.04)	0.74(0.03)	0.68(0.04)
44.MATH2 (100)	73.94(2.51)	71.65(2.47)	70.21(2.87)	69.51(2.11)	0.42(0.05)	0.36(0.05)	0.34(0.06)	0.25(0.05)	0.78(0.03)	0.72(0.04)	0.75(0.03)	0.71(0.03)
45.MATH2 (100)	73.78(2.22)	69.99(2.41)	70.09(2.98)	70.33(2.54)	0.43(0.05)	0.35(0.05)	0.35(0.06)	0.30(0.06)	0.79(0.02)	0.73(0.04)	0.75(0.03)	0.73(0.03)
46.MATH2 (100)	72.66(2.44)	70.23(2.89)	69.17(2.86)	66.46(2.28)	0.42(0.05)	0.34(0.06)	0.33(0.06)	0.22(0.06)	0.79(0.03)	0.74(0.04)	0.74(0.03)	0.69(0.04)
47.MATH2 (100)	69.31(2.45)	67.59(2.67)	65.89(2.65)	64.91(2.64)	0.34(0.05)	0.31(0.06)	0.28(0.06)	0.22(0.05)	0.74(0.03)	0.70(0.03)	0.70(0.03)	0.66(0.03)
48.MATH2 (100)	78.36(2.04)	75.26(2.67)	74.22(2.53)	74.80(2.59)	0.51(0.05)	0.43(0.06)	0.41(0.06)	0.36(0.07)	0.85(0.02)	0.78(0.03)	0.79(0.03)	0.78(0.04)
49.MATH2 (100)	73.83(2.59)	74.26(2.34)	71.04(2.70)	65.56(2.61)	0.44(0.06)	0.45(0.05)	0.38(0.06)	0.22(0.07)	0.81(0.02)	0.77(0.03)	0.77(0.03)	0.68(0.03)
50.MATH2 (100)	73.70(2.31)	71.21(2.51)	71.38(2.84)	69.35(2.83)	0.44(0.05)	0.38(0.05)	0.38(0.06)	0.30(0.06)	0.81(0.02)	0.74(0.03)	0.77(0.03)	0.74(0.03)

Analysing: Percent_correct (stddev) Datasets: 100 Resultsets: 4					Analysing: Kappa_statistic (stddev) Datasets: 100 Resultsets: 4					Analysing: Area_under_ROC (stddev) Datasets: 100 Resultsets: 4				
Dataset	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk		
51. MATH2 (100)	77.61(2.33)	75.54(2.64)	74.00(2.98)	71.43(2.70)	0.51(0.05)	0.46(0.06)	0.42(0.06)	0.31(0.07)	0.85(0.02)	0.79(0.03)	0.81(0.03)	0.74(0.03)		
52. MATH2 (100)	75.56(2.27)	71.90(2.47)	70.97(2.72)	70.86(2.50)	0.46(0.05)	0.36(0.05)	0.35(0.06)	0.28(0.06)	0.80(0.02)	0.73(0.03)	0.75(0.03)	0.71(0.04)		
53. MATH2 (100)	74.39(2.46)	72.50(2.39)	71.75(2.60)	68.24(2.41)	0.44(0.05)	0.39(0.05)	0.38(0.06)	0.25(0.05)	0.81(0.02)	0.75(0.04)	0.77(0.03)	0.70(0.03)		
54. MATH2 (100)	75.33(2.43)	72.20(2.91)	71.24(3.32)	71.04(3.07)	0.47(0.05)	0.38(0.06)	0.37(0.07)	0.31(0.07)	0.83(0.02)	0.74(0.04)	0.77(0.03)	0.74(0.04)		
55. MATH2 (100)	75.75(2.50)	74.19(2.83)	72.59(2.52)	70.68(2.80)	0.48(0.05)	0.42(0.06)	0.39(0.06)	0.30(0.07)	0.82(0.02)	0.76(0.04)	0.78(0.03)	0.74(0.04)		
56. MATH2 (100)	76.82(1.98)	74.88(2.61)	74.37(2.63)	71.98(2.36)	0.47(0.04)	0.42(0.06)	0.41(0.06)	0.27(0.06)	0.81(0.02)	0.77(0.03)	0.80(0.03)	0.71(0.03)		
57. MATH2 (100)	73.80(2.26)	73.21(2.60)	70.58(3.02)	68.67(2.12)	0.41(0.05)	0.38(0.06)	0.32(0.06)	0.16(0.06)	0.77(0.03)	0.73(0.03)	0.73(0.03)	0.67(0.04)		
58. MATH2 (100)	73.77(2.44)	72.99(2.96)	71.58(2.77)	68.82(2.48)	0.41(0.05)	0.38(0.06)	0.35(0.06)	0.19(0.06)	0.79(0.02)	0.74(0.03)	0.75(0.03)	0.69(0.04)		
59. MATH2 (100)	75.85(2.36)	74.15(2.71)	73.27(2.87)	72.27(2.29)	0.46(0.05)	0.41(0.06)	0.39(0.06)	0.30(0.06)	0.82(0.02)	0.76(0.04)	0.78(0.03)	0.74(0.03)		
60. MATH2 (100)	78.08(1.96)	73.07(2.58)	72.28(2.37)	71.42(2.18)	0.52(0.04)	0.39(0.06)	0.38(0.05)	0.30(0.06)	0.84(0.02)	0.74(0.03)	0.77(0.03)	0.74(0.03)		
61. MATH2 (100)	76.01(2.59)	71.43(2.79)	70.48(3.01)	71.56(2.71)	0.48(0.06)	0.38(0.06)	0.36(0.06)	0.34(0.06)	0.81(0.03)	0.73(0.04)	0.76(0.03)	0.74(0.03)		
62. MATH2 (100)	77.92(2.03)	75.85(2.53)	74.54(3.02)	73.82(2.66)	0.51(0.05)	0.45(0.06)	0.43(0.07)	0.37(0.07)	0.85(0.02)	0.79(0.03)	0.80(0.03)	0.77(0.04)		
63. MATH2 (100)	74.74(2.46)	73.28(2.75)	71.21(2.65)	69.07(2.78)	0.43(0.05)	0.39(0.06)	0.35(0.06)	0.23(0.07)	0.82(0.02)	0.76(0.04)	0.76(0.03)	0.70(0.04)		
64. MATH2 (100)	77.38(2.08)	73.98(2.56)	73.98(2.70)	71.30(2.40)	0.50(0.04)	0.42(0.06)	0.41(0.06)	0.28(0.06)	0.82(0.02)	0.77(0.03)	0.78(0.03)	0.71(0.04)		
65. MATH2 (100)	75.56(2.42)	74.10(2.26)	73.01(2.73)	71.08(2.44)	0.46(0.05)	0.42(0.05)	0.40(0.06)	0.30(0.06)	0.82(0.02)	0.78(0.03)	0.79(0.03)	0.74(0.03)		
66. MATH2 (100)	78.06(2.08)	75.41(2.92)	74.52(2.65)	72.95(2.53)	0.51(0.05)	0.45(0.06)	0.43(0.06)	0.35(0.07)	0.85(0.02)	0.78(0.04)	0.81(0.03)	0.77(0.03)		
67. MATH2 (100)	73.02(2.43)	71.58(2.50)	71.54(2.68)	69.00(2.56)	0.40(0.06)	0.36(0.06)	0.37(0.06)	0.26(0.06)	0.79(0.03)	0.73(0.03)	0.76(0.03)	0.71(0.03)		
68. MATH2 (100)	74.98(2.41)	73.79(2.52)	71.67(2.60)	70.36(2.35)	0.44(0.05)	0.40(0.06)	0.36(0.06)	0.25(0.06)	0.81(0.02)	0.76(0.03)	0.77(0.03)	0.72(0.04)		
69. MATH2 (100)	76.55(2.44)	73.69(3.04)	72.36(2.28)	71.74(2.18)	0.50(0.05)	0.43(0.07)	0.40(0.05)	0.36(0.05)	0.84(0.02)	0.78(0.04)	0.79(0.03)	0.77(0.03)		
70. MATH2 (100)	75.91(2.40)	72.26(2.64)	70.81(3.01)	70.16(2.11)	0.44(0.05)	0.34(0.06)	0.32(0.07)	0.22(0.06)	0.81(0.02)	0.72(0.03)	0.74(0.03)	0.72(0.03)		
71. MATH2 (100)	75.56(2.25)	72.38(2.44)	71.00(3.19)	69.25(2.68)	0.46(0.05)	0.38(0.05)	0.36(0.07)	0.25(0.06)	0.81(0.02)	0.75(0.03)	0.76(0.03)	0.71(0.04)		
72. MATH2 (100)	75.52(2.10)	73.22(2.77)	71.17(2.62)	70.09(2.10)	0.45(0.05)	0.40(0.06)	0.36(0.05)	0.27(0.06)	0.80(0.02)	0.75(0.03)	0.75(0.03)	0.72(0.03)		
73. MATH2 (100)	78.86(2.38)	75.06(2.67)	74.56(2.68)	73.81(2.66)	0.52(0.05)	0.44(0.06)	0.43(0.06)	0.36(0.06)	0.85(0.02)	0.77(0.04)	0.80(0.03)	0.76(0.03)		
74. MATH2 (100)	73.00(2.56)	69.81(2.81)	69.14(3.00)	69.69(2.55)	0.41(0.06)	0.32(0.06)	0.31(0.06)	0.26(0.07)	0.78(0.02)	0.71(0.04)	0.72(0.04)	0.70(0.03)		
75. MATH2 (100)	75.23(2.32)	71.85(2.90)	72.01(2.58)	71.75(2.50)	0.44(0.05)	0.36(0.06)	0.37(0.06)	0.29(0.06)	0.82(0.02)	0.74(0.04)	0.76(0.03)	0.73(0.04)		
76. MATH2 (100)	72.64(2.34)	71.62(2.86)	70.01(2.81)	68.32(2.47)	0.40(0.05)	0.37(0.06)	0.34(0.06)	0.22(0.06)	0.80(0.03)	0.75(0.03)	0.74(0.03)	0.70(0.04)		
77. MATH2 (100)	76.86(2.30)	75.16(2.52)	74.83(2.45)	72.08(2.25)	0.50(0.05)	0.45(0.05)	0.45(0.06)	0.33(0.06)	0.83(0.02)	0.78(0.03)	0.80(0.03)	0.75(0.03)		
78. MATH2 (100)	75.12(2.49)	73.20(2.53)	73.51(2.76)	70.67(2.16)	0.42(0.06)	0.37(0.06)	0.38(0.06)	0.22(0.05)	0.79(0.03)	0.74(0.04)	0.76(0.03)	0.67(0.03)		
79. MATH2 (100)	75.86(2.08)	73.10(2.43)	71.64(2.87)	71.40(2.52)	0.47(0.05)	0.39(0.06)	0.36(0.06)	0.29(0.07)	0.82(0.02)	0.75(0.03)	0.76(0.03)	0.74(0.04)		
80. MATH2 (100)	77.01(2.54)	73.63(2.76)	73.27(2.57)	70.96(3.27)	0.51(0.05)	0.44(0.06)	0.44(0.05)	0.36(0.07)	0.85(0.02)	0.78(0.03)	0.80(0.03)	0.76(0.04)		
81. MATH2 (100)	78.64(2.30)	73.14(2.84)	72.31(2.36)	69.99(3.26)	0.52(0.05)	0.39(0.06)	0.38(0.05)	0.25(0.08)	0.83(0.02)	0.75(0.04)	0.77(0.03)	0.71(0.05)		
82. MATH2 (100)	76.90(2.45)	73.10(2.52)	72.95(2.75)	70.64(3.11)	0.50(0.05)	0.42(0.05)	0.42(0.06)	0.33(0.07)	0.83(0.03)	0.75(0.03)	0.79(0.03)	0.74(0.04)		
83. MATH2 (100)	74.49(2.51)	71.75(2.26)	69.60(2.31)	69.26(2.31)	0.44(0.05)	0.37(0.05)	0.33(0.05)	0.27(0.06)	0.79(0.03)	0.74(0.03)	0.73(0.03)	0.70(0.03)		
84. MATH2 (100)	78.07(2.04)	74.39(2.62)	73.18(2.57)	73.12(2.32)	0.48(0.05)	0.39(0.06)	0.36(0.06)	0.27(0.07)	0.83(0.02)	0.75(0.04)	0.77(0.03)	0.74(0.04)		
85. MATH2 (100)	73.53(2.20)	71.57(3.09)	70.96(3.10)	66.43(2.65)	0.43(0.05)	0.38(0.07)	0.37(0.07)	0.21(0.06)	0.81(0.02)	0.75(0.04)	0.76(0.03)	0.68(0.04)		
86. MATH2 (100)	73.67(2.38)	72.65(2.49)	70.77(2.37)	69.88(2.05)	0.38(0.05)	0.35(0.06)	0.31(0.05)	0.17(0.06)	0.77(0.03)	0.73(0.03)	0.72(0.03)	0.68(0.04)		
87. MATH2 (100)	77.07(2.35)	73.38(2.71)	71.90(3.23)	69.65(2.33)	0.48(0.05)	0.40(0.06)	0.37(0.07)	0.24(0.06)	0.82(0.03)	0.76(0.03)	0.77(0.03)	0.70(0.04)		
88. MATH2 (100)	75.94(2.55)	73.32(2.60)	72.37(2.54)	72.93(2.56)	0.45(0.06)	0.38(0.06)	0.36(0.06)	0.31(0.06)	0.81(0.03)	0.74(0.04)	0.76(0.03)	0.74(0.04)		
89. MATH2 (100)	76.71(2.14)	75.69(3.06)	75.16(2.67)	73.29(2.25)	0.47(0.05)	0.46(0.07)	0.44(0.06)	0.33(0.06)	0.81(0.02)	0.77(0.04)	0.80(0.03)	0.73(0.03)		
90. MATH2 (100)	73.92(2.10)	73.30(2.31)	71.95(3.07)	71.29(2.75)	0.43(0.05)	0.41(0.05)	0.38(0.06)	0.32(0.06)	0.82(0.02)	0.77(0.03)	0.77(0.03)	0.75(0.04)		
91. MATH2 (100)	78.39(2.31)	74.38(2.77)	73.20(2.35)	69.28(2.55)	0.55(0.05)	0.47(0.06)	0.45(0.05)	0.35(0.05)	0.86(0.02)	0.79(0.03)	0.81(0.02)	0.76(0.03)		
92. MATH2 (100)	78.70(1.97)	72.82(2.56)	72.62(2.56)	72.63(2.06)	0.53(0.04)	0.39(0.06)	0.39(0.06)	0.34(0.05)	0.82(0.02)	0.75(0.03)	0.77(0.03)	0.75(0.03)		
93. MATH2 (100)	77.29(2.00)	74.59(2.81)	73.51(2.68)	72.70(2.40)	0.48(0.05)	0.40(0.06)	0.39(0.06)	0.29(0.07)	0.83(0.02)	0.76(0.04)	0.78(0.03)	0.74(0.04)		
94. MATH2 (100)	79.17(2.20)	74.97(2.59)	75.29(2.67)	74.70(2.89)	0.55(0.05)	0.45(0.06)	0.47(0.06)	0.42(0.07)	0.86(0.02)	0.79(0.04)	0.82(0.03)	0.79(0.04)		
95. MATH2 (100)	75.15(2.51)	73.28(2.67)	73.06(2.90)	70.86(2.53)	0.46(0.05)	0.42(0.06)	0.42(0.06)	0.33(0.06)	0.81(0.02)	0.77(0.03)	0.79(0.03)	0.75(0.03)		
96. MATH2 (100)	74.14(2.55)	72.06(2.50)	70.30(3.10)	71.90(2.44)	0.43(0.05)	0.37(0.06)	0.34(0.06)	0.30(0.06)	0.80(0.02)	0.72(0.03)	0.74(0.03)	0.72(0.04)		
97. MATH2 (100)	75.43(2.55)	73.35(2.83)	71.20(2.69)	69.29(2.95)	0.46(0.05)	0.41(0.06)	0.36(0.06)	0.26(0.07)	0.81(0.03)	0.77(0.03)	0.76(0.03)	0.71(0.04)		
98. MATH2 (100)	75.57(2.27)	71.72(2.37)	70.77(2.75)	67.86(2.26)	0.47(0.05)	0.37(0.05)	0.36(0.06)	0.22(0.06)	0.81(0.02)	0.74(0.03)	0.76(0.03)	0.71(0.04)		
99. MATH2 (100)	77.99(2.11)	74.85(2.61)	73.36(2.65)	72.53(2.28)	0.51(0.05)	0.43(0.06)	0.40(0.06)	0.33(0.06)	0.83(0.02)	0.76(0.03)	0.79(0.03)	0.75(0.04)		
100. MATH2 (100)	75.33(2.22)	72.73(2.90)	71.02(2.92)	68.94(2.69)	0.47(0.05)	0.40(0.06)	0.37(0.06)	0.28(0.06)	0.81(0.02)	0.75(0.03)	0.76(0.03)	0.72(0.04)		

## EK-N: 500 Kişilik Örneklemde Test Verisi Oranı %55 için Elde Edilen Analiz Sonuçları

Analysing: Percent_correct (stddev) Datasets: 100 Resultsets: 4				Analysing: Kappa_statistic (stddev) Datasets: 100 Resultsets: 4				Analysing: Area_under_ROC (stddev) Datasets: 100 Resultsets: 4				
Dataset	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk
1.MATH2 (100)	74.26(2.08)	70.70(2.83)	71.28(2.91)	70.47(2.53)	0.43(0.04)	0.35(0.06)	0.36(0.06)	0.28(0.06)	0.79(0.02)	0.72(0.03)	0.75(0.03)	0.71(0.03)
2.MATH2 (100)	76.52(1.91)	74.22(2.44)	73.69(2.39)	72.56(1.90)	0.47(0.04)	0.41(0.06)	0.40(0.05)	0.31(0.06)	0.83(0.02)	0.76(0.03)	0.79(0.03)	0.74(0.03)
3.MATH2 (100)	74.30(2.09)	69.98(2.48)	70.11(2.31)	68.39(2.22)	0.43(0.04)	0.34(0.05)	0.34(0.05)	0.24(0.06)	0.80(0.02)	0.71(0.03)	0.75(0.03)	0.70(0.04)
4.MATH2 (100)	75.08(2.10)	70.51(2.72)	71.66(2.79)	73.27(2.40)	0.44(0.04)	0.33(0.06)	0.35(0.06)	0.35(0.06)	0.82(0.02)	0.72(0.04)	0.76(0.03)	0.75(0.03)
5.MATH2 (100)	74.98(2.18)	70.79(2.68)	70.60(2.65)	69.32(2.73)	0.45(0.05)	0.35(0.06)	0.35(0.06)	0.25(0.06)	0.80(0.02)	0.72(0.04)	0.75(0.03)	0.71(0.04)
6.MATH2 (100)	75.78(2.05)	71.84(2.71)	71.78(2.47)	70.31(2.57)	0.46(0.05)	0.37(0.06)	0.38(0.05)	0.30(0.06)	0.82(0.02)	0.73(0.03)	0.77(0.03)	0.71(0.04)
7.MATH2 (100)	76.57(1.77)	72.32(2.45)	72.92(2.24)	72.25(2.29)	0.46(0.04)	0.34(0.06)	0.36(0.05)	0.27(0.06)	0.82(0.02)	0.71(0.03)	0.76(0.03)	0.72(0.04)
8.MATH2 (100)	75.21(2.02)	70.90(2.42)	70.68(2.74)	71.46(2.05)	0.43(0.04)	0.32(0.05)	0.32(0.05)	0.24(0.06)	0.79(0.02)	0.70(0.03)	0.72(0.03)	0.69(0.03)
9.MATH2 (100)	74.41(2.10)	70.70(2.85)	70.25(2.36)	69.35(2.28)	0.42(0.05)	0.33(0.06)	0.32(0.05)	0.23(0.05)	0.79(0.02)	0.71(0.04)	0.74(0.03)	0.68(0.04)
10.MATH2 (100)	71.57(2.13)	69.91(2.19)	68.84(2.44)	68.64(2.45)	0.38(0.05)	0.34(0.05)	0.31(0.05)	0.25(0.07)	0.78(0.02)	0.72(0.03)	0.74(0.03)	0.71(0.04)
11.MATH2 (100)	75.11(2.16)	71.34(2.57)	70.72(2.29)	69.98(2.59)	0.46(0.05)	0.38(0.05)	0.37(0.05)	0.32(0.06)	0.82(0.02)	0.74(0.03)	0.76(0.03)	0.74(0.04)
12.MATH2 (100)	73.26(2.49)	71.57(2.73)	69.85(2.79)	67.08(1.93)	0.41(0.06)	0.37(0.06)	0.34(0.06)	0.20(0.05)	0.79(0.03)	0.74(0.03)	0.75(0.03)	0.67(0.04)
13.MATH2 (100)	76.68(2.10)	73.55(2.28)	73.80(2.55)	71.03(2.12)	0.48(0.05)	0.40(0.05)	0.41(0.05)	0.29(0.06)	0.84(0.02)	0.75(0.03)	0.80(0.03)	0.72(0.03)
14.MATH2 (100)	77.24(2.19)	73.42(2.37)	72.32(2.96)	71.58(2.37)	0.46(0.05)	0.37(0.05)	0.35(0.06)	0.24(0.07)	0.82(0.02)	0.72(0.03)	0.75(0.03)	0.70(0.04)
15.MATH2 (100)	76.34(1.93)	72.89(2.46)	72.15(2.20)	71.59(1.96)	0.46(0.05)	0.38(0.05)	0.37(0.05)	0.29(0.06)	0.82(0.02)	0.74(0.04)	0.76(0.03)	0.73(0.03)
16.MATH2 (100)	75.92(1.91)	70.49(2.34)	71.54(2.39)	70.23(2.01)	0.44(0.04)	0.31(0.05)	0.34(0.05)	0.21(0.06)	0.82(0.02)	0.70(0.03)	0.76(0.03)	0.72(0.04)
17.MATH2 (100)	75.70(1.84)	72.17(2.51)	71.90(2.43)	69.77(2.37)	0.46(0.04)	0.38(0.05)	0.38(0.05)	0.29(0.06)	0.82(0.02)	0.74(0.03)	0.77(0.02)	0.72(0.04)
18.MATH2 (100)	74.25(1.89)	69.03(2.79)	68.93(2.64)	67.92(2.47)	0.44(0.04)	0.32(0.06)	0.32(0.05)	0.25(0.06)	0.80(0.02)	0.70(0.03)	0.73(0.03)	0.69(0.03)
19.MATH2 (100)	74.84(2.04)	74.67(2.55)	72.86(2.45)	69.74(2.37)	0.42(0.05)	0.42(0.05)	0.38(0.05)	0.21(0.06)	0.80(0.02)	0.76(0.04)	0.77(0.03)	0.69(0.04)
20.MATH2 (100)	74.05(1.84)	72.63(2.70)	71.64(2.60)	67.91(2.41)	0.44(0.04)	0.41(0.06)	0.39(0.05)	0.24(0.05)	0.79(0.02)	0.75(0.03)	0.77(0.03)	0.68(0.03)
21.MATH2 (100)	74.37(2.10)	71.74(2.07)	70.86(2.67)	68.86(2.19)	0.42(0.05)	0.37(0.05)	0.35(0.06)	0.22(0.05)	0.80(0.02)	0.73(0.03)	0.75(0.03)	0.69(0.04)
22.MATH2 (100)	73.26(2.09)	68.77(2.47)	68.81(2.63)	69.78(2.47)	0.40(0.04)	0.29(0.05)	0.30(0.05)	0.22(0.06)	0.79(0.02)	0.68(0.03)	0.72(0.02)	0.69(0.03)
23.MATH2 (100)	75.40(1.85)	71.79(2.58)	72.45(2.44)	69.60(2.07)	0.46(0.04)	0.39(0.06)	0.41(0.05)	0.30(0.05)	0.82(0.02)	0.73(0.04)	0.78(0.02)	0.72(0.03)
24.MATH2 (100)	74.87(1.97)	70.92(2.87)	71.44(2.63)	71.52(2.44)	0.43(0.04)	0.34(0.06)	0.35(0.05)	0.30(0.05)	0.80(0.02)	0.70(0.04)	0.75(0.03)	0.70(0.03)
25.MATH2 (100)	75.79(1.82)	71.99(2.35)	71.94(2.18)	69.40(1.79)	0.46(0.04)	0.36(0.05)	0.37(0.05)	0.24(0.06)	0.82(0.02)	0.73(0.03)	0.77(0.02)	0.71(0.03)
26.MATH2 (100)	76.37(2.23)	71.47(2.14)	71.36(2.55)	70.92(2.30)	0.45(0.05)	0.31(0.05)	0.32(0.07)	0.20(0.06)	0.81(0.02)	0.70(0.03)	0.75(0.03)	0.69(0.04)
27.MATH2 (100)	77.40(1.97)	73.10(2.58)	73.78(2.47)	72.77(2.25)	0.50(0.05)	0.40(0.06)	0.42(0.06)	0.35(0.06)	0.83(0.02)	0.74(0.03)	0.78(0.03)	0.76(0.03)
28.MATH2 (100)	73.39(2.23)	70.58(2.51)	69.58(2.57)	69.99(1.86)	0.38(0.05)	0.31(0.06)	0.30(0.05)	0.22(0.05)	0.78(0.02)	0.70(0.03)	0.72(0.03)	0.68(0.03)
29.MATH2 (100)	76.75(1.83)	74.22(2.54)	73.63(2.49)	72.23(2.08)	0.48(0.04)	0.41(0.06)	0.40(0.05)	0.31(0.06)	0.83(0.02)	0.76(0.04)	0.78(0.02)	0.75(0.04)
30.MATH2 (100)	74.53(2.15)	70.71(2.54)	70.79(2.60)	69.46(2.13)	0.41(0.05)	0.32(0.06)	0.33(0.06)	0.20(0.07)	0.78(0.02)	0.69(0.04)	0.73(0.03)	0.68(0.03)
31.MATH2 (100)	74.50(1.88)	69.11(2.63)	69.46(2.24)	69.54(2.60)	0.44(0.04)	0.32(0.06)	0.33(0.05)	0.27(0.06)	0.80(0.02)	0.70(0.04)	0.74(0.02)	0.70(0.03)
32.MATH2 (100)	75.39(1.90)	70.57(2.44)	70.07(2.53)	69.43(2.19)	0.45(0.04)	0.33(0.06)	0.33(0.06)	0.25(0.05)	0.80(0.02)	0.72(0.03)	0.74(0.03)	0.69(0.03)
33.MATH2 (100)	78.55(2.06)	73.44(2.34)	73.85(2.40)	71.01(2.05)	0.52(0.05)	0.40(0.05)	0.41(0.05)	0.28(0.05)	0.84(0.02)	0.75(0.04)	0.79(0.03)	0.73(0.04)
34.MATH2 (100)	74.97(1.81)	71.42(2.39)	71.67(2.70)	70.16(2.32)	0.46(0.04)	0.38(0.05)	0.38(0.06)	0.30(0.05)	0.82(0.02)	0.73(0.03)	0.77(0.03)	0.73(0.03)
35.MATH2 (100)	73.15(2.21)	71.19(2.66)	71.64(2.66)	71.65(2.27)	0.38(0.05)	0.33(0.06)	0.35(0.06)	0.28(0.06)	0.80(0.02)	0.71(0.04)	0.75(0.03)	0.71(0.03)
36.MATH2 (100)	74.91(2.04)	72.45(2.40)	73.19(2.55)	71.21(2.68)	0.43(0.04)	0.38(0.05)	0.40(0.06)	0.29(0.06)	0.82(0.02)	0.75(0.03)	0.78(0.03)	0.75(0.04)
37.MATH2 (100)	74.56(2.17)	69.99(2.65)	69.39(2.52)	67.04(2.71)	0.46(0.04)	0.35(0.05)	0.34(0.05)	0.25(0.06)	0.80(0.02)	0.72(0.03)	0.75(0.03)	0.69(0.03)
38.MATH2 (100)	75.11(2.01)	71.76(2.36)	71.77(2.27)	69.13(1.96)	0.42(0.04)	0.35(0.05)	0.35(0.05)	0.20(0.06)	0.78(0.02)	0.72(0.03)	0.75(0.02)	0.67(0.04)
39.MATH2 (100)	77.00(1.90)	71.78(2.55)	72.20(2.82)	69.20(2.70)	0.50(0.04)	0.38(0.06)	0.39(0.06)	0.26(0.07)	0.82(0.02)	0.72(0.03)	0.77(0.03)	0.70(0.04)
40.MATH2 (100)	73.34(1.91)	69.44(2.32)	68.95(2.53)	67.99(2.39)	0.42(0.04)	0.34(0.05)	0.34(0.05)	0.26(0.06)	0.80(0.02)	0.71(0.03)	0.74(0.03)	0.71(0.04)
41.MATH2 (100)	73.78(2.40)	70.41(2.69)	69.84(2.88)	65.84(2.44)	0.45(0.05)	0.37(0.06)	0.36(0.06)	0.23(0.05)	0.80(0.02)	0.73(0.04)	0.76(0.03)	0.68(0.03)
42.MATH2 (100)	75.93(1.84)	71.54(2.39)	71.34(2.60)	68.27(2.06)	0.48(0.04)	0.37(0.05)	0.37(0.06)	0.25(0.05)	0.82(0.02)	0.75(0.03)	0.77(0.03)	0.70(0.03)
43.MATH2 (100)	75.00(2.06)	70.21(2.87)	70.17(2.35)	68.17(2.26)	0.43(0.04)	0.33(0.06)	0.33(0.05)	0.19(0.05)	0.80(0.02)	0.70(0.04)	0.74(0.02)	0.67(0.03)
44.MATH2 (100)	73.48(2.07)	70.48(2.48)	70.69(2.75)	69.32(1.90)	0.41(0.04)	0.34(0.06)	0.35(0.06)	0.25(0.05)	0.78(0.02)	0.70(0.03)	0.75(0.02)	0.70(0.03)
45.MATH2 (100)	73.67(2.08)	69.04(2.67)	69.54(2.54)	69.20(2.67)	0.43(0.05)	0.33(0.06)	0.34(0.05)	0.28(0.06)	0.79(0.02)	0.71(0.04)	0.74(0.03)	0.71(0.04)
46.MATH2 (100)	72.34(1.99)	69.34(2.62)	68.92(2.56)	66.22(2.15)	0.41(0.04)	0.33(0.05)	0.32(0.06)	0.21(0.05)	0.78(0.02)	0.72(0.03)	0.73(0.03)	0.67(0.04)
47.MATH2 (100)	68.93(1.79)	65.98(2.59)	65.73(2.58)	64.56(2.67)	0.33(0.04)	0.28(0.05)	0.27(0.06)	0.21(0.06)	0.74(0.02)	0.68(0.03)	0.70(0.03)	0.65(0.03)
48.MATH2 (100)	78.48(1.71)	73.66(2.39)	74.32(2.25)	74.53(2.27)	0.51(0.04)	0.39(0.05)	0.41(0.05)	0.36(0.07)	0.85(0.02)	0.75(0.03)	0.79(0.02)	0.77(0.04)
49.MATH2 (100)	73.69(2.18)	72.42(2.23)	70.45(2.59)	64.99(2.66)	0.44(0.04)	0.41(0.05)	0.37(0.05)	0.21(0.06)	0.80(0.02)	0.74(0.03)	0.76(0.03)	0.67(0.04)
50.MATH2 (100)	73.85(2.13)	70.16(2.44)	70.68(2.32)	69.09(2.48)	0.44(0.04)	0.36(0.05)	0.37(0.05)	0.29(0.06)	0.81(0.02)	0.72(0.03)	0.76(0.02)	0.73(0.03)

Analysing: Percent_correct (stddev) Datasets: 100 Resultsets: 4				Analysing: Kappa_statistic (stddev) Datasets: 100 Resultsets: 4				Analysing: Area_under_ROC (stddev) Datasets: 100 Resultsets: 4				
Dataset	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk	(1) bayes. NaiveBay	(2) functions. L	(3) functions. M	(4) lazy. IBk
51. MATH2 (100)	77.24(1.98)	74.08(2.52)	73.73(2.11)	70.79(2.39)	0.50(0.04)	0.43(0.06)	0.42(0.05)	0.30(0.05)	0.85(0.02)	0.77(0.03)	0.80(0.02)	0.73(0.04)
52. MATH2 (100)	75.40(1.95)	71.16(2.59)	70.69(2.86)	70.00(2.36)	0.46(0.04)	0.35(0.05)	0.35(0.06)	0.25(0.06)	0.80(0.02)	0.71(0.04)	0.74(0.03)	0.70(0.03)
53. MATH2 (100)	74.23(2.07)	71.10(2.50)	71.60(2.43)	67.61(2.23)	0.44(0.04)	0.37(0.05)	0.38(0.05)	0.23(0.05)	0.81(0.02)	0.73(0.03)	0.77(0.02)	0.70(0.03)
54. MATH2 (100)	75.04(2.07)	70.60(2.54)	71.00(2.57)	70.61(2.42)	0.46(0.04)	0.35(0.06)	0.36(0.06)	0.30(0.06)	0.82(0.02)	0.72(0.04)	0.77(0.03)	0.73(0.04)
55. MATH2 (100)	75.60(2.03)	72.76(2.55)	72.15(2.68)	69.78(2.87)	0.47(0.04)	0.39(0.06)	0.38(0.05)	0.28(0.07)	0.82(0.02)	0.74(0.04)	0.78(0.02)	0.73(0.04)
56. MATH2 (100)	76.34(1.83)	73.61(2.49)	73.43(2.49)	70.79(2.30)	0.46(0.04)	0.39(0.05)	0.39(0.06)	0.24(0.06)	0.81(0.02)	0.75(0.03)	0.79(0.03)	0.70(0.03)
57. MATH2 (100)	73.37(2.01)	71.59(2.54)	69.93(2.73)	68.33(2.07)	0.40(0.04)	0.35(0.05)	0.31(0.05)	0.16(0.05)	0.77(0.02)	0.71(0.03)	0.72(0.03)	0.66(0.04)
58. MATH2 (100)	73.06(2.27)	71.33(2.74)	71.06(2.46)	67.90(2.29)	0.40(0.05)	0.34(0.06)	0.34(0.05)	0.17(0.06)	0.79(0.02)	0.71(0.04)	0.74(0.03)	0.67(0.04)
59. MATH2 (100)	75.64(2.12)	73.03(2.51)	73.12(2.42)	71.58(2.38)	0.45(0.05)	0.39(0.05)	0.39(0.05)	0.29(0.06)	0.82(0.02)	0.74(0.03)	0.78(0.02)	0.72(0.04)
60. MATH2 (100)	77.98(1.67)	71.81(2.70)	72.20(2.74)	70.97(1.97)	0.51(0.03)	0.36(0.06)	0.37(0.07)	0.29(0.05)	0.84(0.02)	0.73(0.03)	0.77(0.03)	0.73(0.03)
61. MATH2 (100)	75.83(1.98)	69.54(2.55)	70.49(2.53)	70.94(2.25)	0.48(0.04)	0.34(0.06)	0.36(0.05)	0.32(0.06)	0.81(0.02)	0.70(0.04)	0.75(0.03)	0.74(0.03)
62. MATH2 (100)	77.67(1.80)	73.83(2.43)	73.89(2.41)	73.49(2.24)	0.50(0.04)	0.41(0.05)	0.41(0.05)	0.36(0.06)	0.84(0.02)	0.75(0.04)	0.79(0.03)	0.76(0.04)
63. MATH2 (100)	74.39(2.25)	71.94(2.38)	71.57(2.38)	68.70(2.57)	0.43(0.05)	0.36(0.05)	0.35(0.06)	0.22(0.07)	0.82(0.02)	0.73(0.03)	0.77(0.03)	0.70(0.04)
64. MATH2 (100)	77.45(1.96)	72.72(2.44)	73.18(2.62)	70.69(2.27)	0.50(0.04)	0.39(0.05)	0.40(0.05)	0.27(0.06)	0.82(0.02)	0.75(0.03)	0.78(0.03)	0.71(0.04)
65. MATH2 (100)	75.51(1.68)	72.67(2.34)	72.76(2.58)	71.19(2.18)	0.46(0.03)	0.39(0.05)	0.39(0.05)	0.30(0.05)	0.82(0.02)	0.76(0.03)	0.78(0.03)	0.74(0.03)
66. MATH2 (100)	78.14(1.83)	74.19(2.69)	74.59(2.39)	72.48(2.30)	0.52(0.04)	0.42(0.06)	0.43(0.05)	0.34(0.06)	0.85(0.02)	0.75(0.04)	0.80(0.02)	0.76(0.03)
67. MATH2 (100)	72.99(1.92)	70.71(2.52)	71.08(2.80)	68.37(2.22)	0.40(0.05)	0.34(0.06)	0.36(0.06)	0.24(0.05)	0.79(0.02)	0.72(0.04)	0.75(0.03)	0.69(0.03)
68. MATH2 (100)	74.63(2.38)	72.44(2.48)	71.51(2.67)	69.59(2.59)	0.43(0.05)	0.37(0.06)	0.35(0.07)	0.23(0.07)	0.81(0.02)	0.73(0.03)	0.76(0.03)	0.71(0.04)
69. MATH2 (100)	76.06(2.15)	71.74(2.72)	71.87(2.13)	71.03(2.21)	0.49(0.05)	0.39(0.06)	0.39(0.05)	0.34(0.05)	0.83(0.02)	0.75(0.04)	0.78(0.02)	0.76(0.02)
70. MATH2 (100)	75.70(1.88)	70.68(2.50)	70.32(2.48)	69.56(2.20)	0.44(0.04)	0.31(0.05)	0.30(0.06)	0.21(0.06)	0.80(0.02)	0.70(0.03)	0.74(0.03)	0.71(0.04)
71. MATH2 (100)	75.06(1.87)	70.86(2.18)	70.95(2.33)	67.87(2.67)	0.45(0.04)	0.35(0.05)	0.36(0.05)	0.23(0.06)	0.80(0.02)	0.73(0.03)	0.76(0.02)	0.69(0.04)
72. MATH2 (100)	75.27(1.97)	71.86(2.41)	70.71(2.60)	69.44(2.22)	0.44(0.04)	0.37(0.05)	0.35(0.06)	0.25(0.06)	0.80(0.02)	0.73(0.03)	0.75(0.03)	0.71(0.03)
73. MATH2 (100)	78.98(2.18)	73.19(2.30)	74.12(2.42)	73.36(2.15)	0.53(0.05)	0.40(0.05)	0.42(0.05)	0.35(0.06)	0.85(0.02)	0.74(0.03)	0.79(0.02)	0.75(0.03)
74. MATH2 (100)	72.82(2.17)	68.46(2.53)	68.85(3.06)	69.20(1.92)	0.40(0.05)	0.30(0.06)	0.30(0.07)	0.25(0.05)	0.78(0.02)	0.69(0.04)	0.72(0.03)	0.69(0.03)
75. MATH2 (100)	74.95(1.93)	70.79(2.49)	71.56(2.56)	70.88(1.87)	0.43(0.04)	0.34(0.05)	0.35(0.06)	0.27(0.05)	0.81(0.02)	0.71(0.04)	0.76(0.03)	0.72(0.03)
76. MATH2 (100)	72.64(2.30)	70.47(2.39)	69.56(2.43)	68.53(2.45)	0.40(0.05)	0.35(0.05)	0.32(0.05)	0.23(0.06)	0.80(0.02)	0.72(0.03)	0.74(0.02)	0.69(0.04)
77. MATH2 (100)	76.65(2.05)	73.38(2.86)	73.88(2.77)	71.17(2.24)	0.49(0.04)	0.42(0.06)	0.43(0.06)	0.31(0.05)	0.83(0.02)	0.75(0.04)	0.79(0.03)	0.73(0.03)
78. MATH2 (100)	74.87(2.17)	72.06(2.55)	72.35(2.51)	70.46(2.09)	0.41(0.05)	0.35(0.06)	0.36(0.06)	0.22(0.05)	0.79(0.02)	0.72(0.04)	0.75(0.02)	0.67(0.03)
79. MATH2 (100)	75.68(1.95)	71.55(2.36)	71.64(3.11)	70.63(2.09)	0.46(0.04)	0.36(0.05)	0.37(0.07)	0.28(0.05)	0.81(0.02)	0.73(0.03)	0.76(0.03)	0.72(0.04)
80. MATH2 (100)	76.75(1.92)	72.14(2.59)	72.74(2.41)	70.17(3.06)	0.51(0.04)	0.41(0.06)	0.42(0.05)	0.34(0.06)	0.84(0.02)	0.76(0.04)	0.80(0.03)	0.75(0.04)
81. MATH2 (100)	78.01(2.01)	71.58(2.40)	71.65(2.77)	69.18(2.63)	0.51(0.05)	0.36(0.05)	0.37(0.06)	0.23(0.07)	0.82(0.02)	0.73(0.04)	0.76(0.03)	0.69(0.05)
82. MATH2 (100)	76.76(2.08)	71.48(2.38)	71.98(2.56)	69.83(2.56)	0.50(0.05)	0.39(0.05)	0.40(0.05)	0.31(0.07)	0.83(0.02)	0.73(0.03)	0.78(0.02)	0.74(0.04)
83. MATH2 (100)	74.12(2.09)	70.17(2.56)	68.89(2.94)	68.62(2.56)	0.43(0.05)	0.34(0.05)	0.32(0.06)	0.25(0.07)	0.78(0.02)	0.72(0.04)	0.73(0.03)	0.69(0.04)
84. MATH2 (100)	78.05(1.77)	72.50(2.28)	72.72(2.26)	72.52(1.90)	0.48(0.04)	0.34(0.05)	0.35(0.05)	0.25(0.06)	0.83(0.02)	0.71(0.04)	0.76(0.02)	0.73(0.04)
85. MATH2 (100)	73.27(2.02)	70.23(2.75)	70.25(2.50)	66.27(2.57)	0.42(0.05)	0.35(0.06)	0.36(0.06)	0.21(0.06)	0.80(0.02)	0.72(0.04)	0.75(0.03)	0.67(0.04)
86. MATH2 (100)	73.52(2.16)	71.79(2.46)	70.16(3.09)	69.51(1.91)	0.38(0.05)	0.34(0.05)	0.30(0.06)	0.16(0.06)	0.77(0.02)	0.72(0.03)	0.72(0.03)	0.67(0.04)
87. MATH2 (100)	76.49(2.04)	72.39(2.66)	70.85(2.58)	69.20(2.22)	0.47(0.05)	0.38(0.06)	0.35(0.06)	0.22(0.06)	0.81(0.02)	0.73(0.04)	0.76(0.03)	0.69(0.04)
88. MATH2 (100)	75.97(2.02)	72.09(2.42)	72.39(2.47)	72.92(2.60)	0.45(0.05)	0.35(0.06)	0.36(0.06)	0.31(0.06)	0.81(0.02)	0.72(0.04)	0.76(0.03)	0.73(0.04)
89. MATH2 (100)	76.62(2.25)	73.87(3.08)	74.21(2.33)	72.08(2.26)	0.47(0.05)	0.42(0.06)	0.42(0.05)	0.31(0.05)	0.81(0.02)	0.75(0.04)	0.79(0.02)	0.72(0.03)
90. MATH2 (100)	73.86(1.94)	72.15(2.28)	71.49(2.81)	70.66(2.52)	0.43(0.04)	0.38(0.05)	0.37(0.06)	0.30(0.06)	0.82(0.02)	0.75(0.03)	0.77(0.03)	0.73(0.04)
91. MATH2 (100)	78.03(1.91)	72.24(2.39)	72.48(2.36)	68.24(2.60)	0.54(0.04)	0.42(0.05)	0.43(0.05)	0.32(0.06)	0.85(0.02)	0.76(0.03)	0.80(0.02)	0.75(0.04)
92. MATH2 (100)	78.39(1.77)	71.80(2.58)	71.99(2.54)	72.04(1.94)	0.52(0.04)	0.37(0.06)	0.38(0.06)	0.32(0.05)	0.82(0.02)	0.73(0.03)	0.76(0.03)	0.74(0.03)
93. MATH2 (100)	76.89(2.08)	73.23(2.57)	73.16(2.42)	72.14(2.08)	0.47(0.05)	0.37(0.05)	0.37(0.05)	0.27(0.06)	0.82(0.02)	0.73(0.04)	0.78(0.03)	0.73(0.03)
94. MATH2 (100)	78.93(2.17)	73.74(2.46)	74.73(2.51)	74.46(2.38)	0.55(0.05)	0.43(0.05)	0.45(0.05)	0.42(0.06)	0.86(0.02)	0.77(0.03)	0.81(0.02)	0.79(0.03)
95. MATH2 (100)	74.70(2.14)	71.94(2.43)	72.35(2.73)	70.11(2.41)	0.45(0.04)	0.39(0.05)	0.40(0.05)	0.31(0.06)	0.81(0.02)	0.74(0.03)	0.77(0.03)	0.73(0.03)
96. MATH2 (100)	74.04(2.03)	70.54(2.34)	70.88(2.66)	71.23(2.21)	0.43(0.04)	0.34(0.05)	0.35(0.06)	0.28(0.06)	0.80(0.02)	0.69(0.04)	0.74(0.03)	0.71(0.03)
97. MATH2 (100)	75.25(2.18)	72.06(2.69)	70.85(2.47)	68.48(2.40)	0.45(0.05)	0.38(0.06)	0.36(0.05)	0.24(0.06)	0.81(0.02)	0.75(0.03)	0.76(0.03)	0.70(0.03)
98. MATH2 (100)	75.27(1.98)	70.32(2.36)	70.64(2.49)	67.66(2.50)	0.46(0.04)	0.34(0.05)	0.35(0.05)	0.21(0.06)	0.81(0.02)	0.71(0.04)	0.75(0.03)	0.70(0.04)
99. MATH2 (100)	77.79(1.92)	73.73(2.26)	73.59(2.22)	72.22(2.35)	0.51(0.04)	0.41(0.05)	0.41(0.05)	0.33(0.06)	0.83(0.02)	0.75(0.03)	0.79(0.02)	0.74(0.04)
100. MATH2 (100)	75.42(1.98)	71.51(2.46)	70.51(2.49)	69.02(2.66)	0.47(0.04)	0.38(0.05)	0.36(0.05)	0.28(0.06)	0.80(0.02)	0.73(0.03)	0.76(0.03)	0.71(0.04)

# EK-O: Etik Komisyonu Onay Bildirimi

Form: 40

## Tez Çalışması Etik Kurul İzin Muafiyeti Formu

20 / 05 / 2016

Hacettepe Üniversitesi  
Eğitim Bilimleri Enstitüsü  
Eğitim Bilimleri Anabilim Dalı Başkanlığı'na

<b>Tez Başlığı / Konusu:</b>	EĞİTİMSEL VERİ MADENCİLİĞİ: ÖĞRENCİLERİN MATEMATİK PERFORMANSLARININ YORDANMASI
------------------------------	---

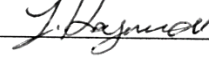
Yukarıda başlığı/konusu gösterilen tez çalışmam:

1. İnsan ve hayvan üzerinde deney niteliği taşımamaktadır,
2. Biyolojik materyal (kan, idrar vb. biyolojik sıvılar ve numuneler) kullanılmasını gerektirmemektedir.
3. Beden bütünlüğüne müdahale içermemektedir.
4. Gözlemsel ve betimsel araştırma (anket, ölçek/skala çalışmaları, dosya taramaları, veri kaynakları taraması, sistem-model geliştirme çalışmaları) niteliğinde değildir.

Hacettepe Üniversitesi Etik Kurullar ve Komisyonlarının Yönergelerini inceledim ve bunlara göre tez çalışmamın yürütülebilmesi için herhangi bir Etik Kuruldan izin alınmasına gerek olmadığını; aksi durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Gereğini saygılarımla arz ederim.

İlhan KOYUNCU  
(Öğrencinin Adı Soyadı, İmzası)




### Öğrenci Bilgileri

<b>Adı Soyadı</b>	İlhan KOYUNCU
<b>Öğrenci No</b>	N12246678
<b>Anabilim Dalı</b>	EĞİTİM BİLİMLERİ
<b>Programı</b>	EĞİTİMDE ÖLÇME VE DEĞERLENDİRME
<b>Statüsü</b>	<input type="checkbox"/> Yüksek Lisans <input checked="" type="checkbox"/> Doktora <input type="checkbox"/> Bütünleşik Dr.

### Danışman Görüşü ve Onayı

Bu çalışmada OECD tarafından gerçekleştirilen PISA (2012) uygulamasından elde edilen ve paylaşımına açık olan veri kullanılacaktır. Herhangi bir uygulama yapılmayıp araştırma amaçlı paylaşılan gerçek veri kullanılacağından Etik Kurul izin muafiyeti uygun görülmüştür.

  
Prof. Dr. Selahattin GELBAL  
(İmza)  
(Danışmanın ünvanı, Adı ve Soyadı)

## EK-P: 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.

25/01/2018

  
İlhan KOYUNCU

## EK-R: Doktora Tez Çalışması Orijinallik Raporu

25/01/2018

HACETTEPE ÜNİVERSİTESİ

Eğitim Bilimleri Enstitüsü

Eğitim Bilimleri Ana Bilim Dalı Başkanlığına,

Tez Başlığı: Öğrencilerin PISA Matematik Başarılarının Yordanmasında Veri Madenciliği Yöntemlerinin Karşılaştırılması

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
25/01/2018	119	194192	22/01/2018	%4	906634873

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 olduğunu beyan eder, gereğini saygılarımla arz ederim.

Ad Soyadı: İlhan KOYUNCU

Öğrenci No.: N12246678

Ana Bilim Dalı: Eğitim Bilimleri

Programı: Eğitimde Ölçme ve Değerlendirme

Statüsü:  Y.Lisans  Doktora  Bütünleşik Dr.



DANIŞMAN ONAYI



UYGUNDUR.

Prof. Dr. Selahattin GELBAL



## EK-S: Dissertation Originality Report

25/01/2018

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

Thesis Title: Comparison of Data Mining Methods in Predicting PISA Mathematical Achievements of Students

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 Defence	Similarity Index	Submission ID
25/01/2018	119	194192	22/01/2018	%4	906634873

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: İlhan KOYUNCU  
Student No.: N12246678  
Department: Educational Sciences  
Program: Measurement and Evaluation in Education  
Status:  Masters  Ph.D.  Integrated Ph.D.



ADVISOR APPROVAL

  
APPROVED  
Prof. Dr. Selahattin GELBAL

## EK-T: Yayınlama 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 Üniversite'ye verilen kullanım hakları dışındaki bütün fikrî mülkiyet haklarım bende kalacak, tezimin tamamının veya 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 metinleri yazılı izin alarak kullandığımı ve istenildiğinde suretlerini Üniversite'ye teslim etmeyi taahhüt ederim.

Tezimin/Raporumun tamamı dünya çapında erişime açılabilir ve bir kısmı veya tamamının fotokopisi alınabilir.

(Bu seçenekle teziniz arama motorlarında indekslenebilecek, daha sonra tezinizin erişim statüsünün değiştirilmesini talep etmeniz ve kütüphane bu talebinizi yerine getirse bile, teziniz arama motorlarının ön belleklerinde kalmaya devam edebilecektir)

Tezimin/Raporumun 22/01/2021 tarihine kadar erişime açılmasını ve fotokopi alınmasını (İç Kapak, Özet, İçindekiler ve Kaynakça hariç) istemiyorum.

(Bu sürenin sonunda uzatma için başvuruda bulunmadığım takdirde, tezimin/raporumun tamamı her yerden erişime açılabilir, kaynak gösterilmek şartıyla bir kısmı veya tamamının fotokopisi alınabilir).

Tezimin/Raporumun ..... tarihine kadar erişime açılmasını istemiyorum ancak kaynak gösterilmek şartıyla bir kısmı veya tamamının fotokopisinin alınmasını onaylıyorum.

Serbest Seçenek/Yazarın Seçimi:

.....  
.....  
.....  
.....

25/01/2018

  
İlhan KOYUNCU

