

**YAPAY SİNİR AĞI, KARAR AĞAÇLARI VE AYIRMA
ANALİZİ YÖNTEMLERİ İLE PISA 2012 MATEMATİK
BAŞARILARININ SINIFLANDIRILMA
PERFORMANSLARININ KARŞILAŞTIRILMASI**

**COMPARISON OF CLASSIFICATION PERFORMANCES
OF MATHEMATICS ACHIEVEMENT AT PISA 2012 WITH
ARTIFICIAL NEURAL NETWORK, DECISION TREES AND
DISCRIMINANT ANALYSIS**

Emre TOPRAK

Hacettepe Üniversitesi

Eğitim Bilimleri Anabilim Dalı, Eğitimde Ölçme ve Değerlendirme Bilim Dalı

Doktora Tezi

olarak hazırlanmıştır.

2017

KABUL ve ONAY

Eđitim Bilimleri Enstitüsü M¼d¼rl¼đ¼'ne,

Emre TOPRAK'ın hazırladıđı "Yapay Sinir Ađı, Karar Ađaçları Ve Ayırma Analizi Y¼ntemleri İle PISA 2012 Matematik Bařarılarının Sınıflandırılma Performanslarının Karřılařtırılması" bařlıklı bu alıřma j¼rimiz tarafından **Eđitim Bilimleri Anabilim Dalı, Eđitimde Olme ve Deđerlendirme Bilim Dalı'nda Doktora Tezi** olarak kabul edilmiřtir.

Bařkan Prof. Dr. H¼lya KELECİOđLU

¼ye (Danıřman) Prof. Dr. Selahattin GELBAL

¼ye Do. Dr. Duygu ANIL

¼ye Do. Dr. řeref TAN

¼ye Do. Dr. Mustafa DURMUřELEBİ

ONAY

Bu tez Hacettepe ¼niversitesi Lisans¼st¼ Eđitim-¼đretim ve Sınav Y¼netmeliđi'nin ilgili maddeleri uyarınca yukarıdaki j¼ri ¼yeleri tarafından 13/02/2017 tarihinde uygun g¼r¼lm¼ř ve Enstit¼ Y¼netim Kurulunca / / tarihinde kabul edilmiřtir.

Prof. Dr. Ali Ekber řAHİN
Eđitim Bilimleri Enstit¼s¼ M¼d¼r¼

YAYIMLAMA VE FİKRİ MÜLKİYET HAKLARI BEYANI

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

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

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

(Bu seçenikle teziniz arama motorlarında indekslenebilecek, daha sonra tezinizin erişim statüsünün değiştirilmesini talep etmeniz ve kütüphane bu talebinizi yerine getirirse bile, teziniz arama motorlarının önbelleklerinde kalmaya devam edebilecektir)

Tezimin/Raporumun 13.02.2022 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:

13/02/2017


Emre TOPRAK

ETİK BEYANNAMESİ

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 tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- ve bu tezin herhangi bir bölümünü bu üniversitede veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.


Emre TOPRAK

TEŞEKKÜR

Yazarı olarak kendimin görüldüğü bu araştırma sürecinde birçok kişinin desteğiyle işlerim kolaylaşmış, gücüm artmış, yollar kısalmış, düşüncelerim gelişmiş, klavyem hızlanmıştır.

Herkesin farklı bir katkısının olduğu bu süreçte Danışmanım Sayın Prof. Dr. Selahattin GELBAL'ın herkesten farklı olarak her konuda katkısı olmuş, her zaman gösterdiği desteğiyle işlerimi kolaylaştırmış, gücümü artırmış, düşüncelerimi geliştirmiştir. Üzerimdeki tüm emeklerinden dolayı en büyük teşekkür borcum Hocamadır.

Doç. Dr. Mustafa DURMUŞÇELEBİ Hocama da doktora eğitimimin yönünü belirlemede yaptığı öncülük için teşekkür ederim.

Aynı zamanda tüm doktora eğitimim boyunca akademik gelişimime katkı sağlayan Hocalarıma da ayrı ayrı teşekkür etmek isterim.

Yaşamın her anında varlığından güç aldığım sevgili aileme zorlu çalışma süreçlerinde gösterdikleri ilgi, özen ve sabırdan dolayı teşekkür ederim.

Eşim, yorgun ders dönüşlerinde beni neşeye karşılayıp bir tebessümüyle yorgunluğumu alan, her an her konuda bana daima destek olan, güç veren, neşem. Tüm özenin için teşekkür ederim.

Yakın zamanlarda varlığıyla ailemiz içinde nam salan, tüm ev halkının heyecanla, merakla, mutlulukla beklediği Ayaz Bey'in yaşamımıza kattığı ve katacağı güzellikler için şimdiden teşekkür ederim.

YAPAY SİNİR AĞI, KARAR AĞAÇLARI VE AYIRMA ANALİZİ YÖNTEMLERİ İLE PISA 2012 MATEMATİK BAŞARILARININ SINIFLANDIRILMA PERFORMANSLARININ KARŞILAŞTIRILMASI

Emre TOPRAK

ÖZ

Bu araştırmada yapay sinir ağı, karar ağaçları ve ayırma analizi yöntemlerinin öğrenci başarılarını sınıflandırma performansları karşılaştırmalı olarak incelenmiştir. Yöntemlerin performansları farklı örneklem büyüklükleri ve farklı alt grup sayılarına sınıflama yapmada ele alınmıştır. Araştırmanın çalışma grubunu PISA 2012 matematik uygulamasına katılan tüm öğrenciler oluşturmaktadır. Öğrenci başarılarının karşılaştırılmasında PISA 2012 uygulamasına dünyanın farklı ülkelerinden katılan tüm öğrencilerin matematik testi ve anket sonuçlarından faydalanılmıştır. Araştırmada yapay sinir ağı modelinin oluşturulmasında çok katmanlı algılayıcı model, karar ağaçları yönteminin uygulanmasında CHAID algoritması ve ayırma analizi çeşitlerinden doğrusal ayırma analizi kullanılmıştır.

6 alt gruba yönelik sınıflama Düzey1/Düzey2/Düzey3/Düzey4/Düzey5/Düzey6 şeklinde yapılmıştır. PISA sınıflamasında yer alan her bir başarı düzeyi bir grup oluşturmuştur. 3 alt gruba yönelik sınıflama Alt Düzey/Orta Düzey/Üst Düzey şeklinde yapılmıştır. Alt düzey grubu PISA'da Düzey1 ve Düzey2'de yer alan öğrencilerden, orta düzey grubu PISA'da Düzey3 ve Düzey4'te yer alan öğrencilerden, üst düzey grubu PISA'da Düzey5 ve Düzey6'da yer alan öğrencilerden oluşmaktadır. 2 alt gruba yönelik sınıflama Alt Düzey/Üst Düzey şeklinde yapılmıştır. Alt düzey grubu PISA'da Düzey1, Düzey2 ve Düzey3'te yer alan öğrencilerden, üst düzey grubu PISA'da Düzey4, Düzey5 ve Düzey6'da yer alan öğrencilerden oluşmaktadır.

Araştırma sonucunda 6, 3 ve 2 alt gruba sınıflama yapmada büyük, orta büyüklükteki ve küçük örneklerde en yüksek performansı gösteren yöntem yapay sinir ağı olmuştur. Varyans-kovaryans matrislerinde homojenliğin sağlandığı çok küçük örnekte 6, 3 ve 2 alt gruba sınıflama yapmada en yüksek performansı gösteren yöntem ayırma analizi olurken; varyans-kovaryans matrislerinde homojenliğin sağlanmadığı çok küçük örnekte en yüksek

performansı gösteren yöntem 6 alt grup için ayırma analizi, 3 ve 2 alt grup için yapay sinir ağı olmuştur. Varyans-kovaryans matrislerinde homojenliğin sağlandığı çok küçük örnekleme yöntemlerinin performansı, varyans-kovaryans matrislerinde homojenliğin sağlanmadığı örnekleme göre daha yüksek olmuştur. Yöntemlerin örneklem büyüklüklerine göre performansları ele alındığında örneklem büyüklüğü azaldıkça karar ağaçları yönteminin performansının düştüğü, ayırma analizi yönteminin performansının ise arttığı gözlenmiştir. Yapay sinir ağı açısından ise böyle doğrusal bir ilişki tespit edilmemiştir. Yapay sinir ağı her uygulamada verilerin bir kısmını eğitim seti, diğer bir kısmını test seti olarak ayırdığı için, yöntem aynı koşullardaki her uygulamada farklı performans göstermiştir. Araştırma sonuçları yapay sinir ağı ile yapılacak uygulamalarda mümkün olduğunca fazla deneme yapılmasının en yüksek performansı yakalama fırsatını artırdığını ortaya koymuştur. Bunun yanında karar ağaçlarıyla yapılacak uygulamalarda ise büyük örneklemle çalışılmasının yöntemin performansının yüksek olmasını sağladığı sonucuna ulaşılmıştır. Ayırma analizi ile yapılacak uygulamalarda ise küçük örneklemle çalışılmasının ve varyans-kovaryans matrislerinde homojenlik varsayımının karşılanması yöntemin performansını iki kata kadar artırdığı belirlenmiştir.

Anahtar sözcükler: Yapay sinir ağı, karar ağaçları, ayırma analizi, PISA, öğrenci başarısı

Danışman: Prof. Dr. Selahattin GELBAL, Hacettepe Üniversitesi, Eğitim Bilimleri Anabilim Dalı, Eğitimde Ölçme ve Değerlendirme Bilim Dalı

COMPARISON OF CLASSIFICATION PERFORMANCES OF MATHEMATICS ACHIEVEMENT AT PISA 2012 WITH ARTIFICIAL NEURAL NETWORK, DECISION TREES AND DISCRIMINANT ANALYSIS

Emre TOPRAK

ABSTRACT

This study aims to compare the performance of artificial neural network, decision trees and discriminant analysis methods to classify student success. The performance of each method is investigated in different sample sizes when classifying into different numbered sub-groups. The participants of the study are all the students who took part in PISA 2012 mathematics test. The mathematics test scores and data from the questionnaires of all the students from all over the world who took part in PISA 2012 are used to compare student success. The study uses multilayer perceptron model to form the artificial neural network model, CHAID algorithm to apply the decision trees method and linear discriminant analysis.

The six sub-groups are formed as Level1/Level2/Level3/Level4/Level5/Level6. Each performance level in PISA classification forms a sub-group. The three sub-groups are named as Below the Average, Average, and Above the Average. Below the Average group includes students from Level1 and Level2, Average group includes students from Level3 and Level4 and Above the Average group includes students from Level5 and Level6. When classifying into 2 sub-groups, students from Level1, Level2 and Level3 form Below the Average group and students from Level4, Level5 and Level6 form Above the Average group.

The study reveals that the artificial neural network has the best performance in big, medium and small sample sizes when classifying into six, three and two sub-groups. In the very small sample size which has homogeneous variance-covariance matrixes, discriminant analysis performs the best, while in the very small sample size which does not have homogeneous variance-covariance matrixes, it is the discriminant analysis which performs the best when classifying into six sub-groups and artificial neural network performs the best when classifying into two and three sub-groups. The performance of the methods in the very small sample size which has homogeneous variance-covariance matrixes is better than

that of the very small sample size which does not have homogeneous variance-covariance matrixes. Considering the performance of the methods with respect to sample size, it can be concluded that as the sample size gets smaller, the performance of decision trees method gets worse, whereas the performance of discriminant analysis method improves. When it comes to artificial neural network method, no correlation of this kind is found. Because the artificial neural network method divides the data into two groups, the education set and test set, in each application, the method performs differently in each application under the same circumstances. The findings of the study suggest that in artificial neural network method applications, it is better to carry out as many trials as possible in order to achieve the highest performance. It is also found that big sample sizes enable a better performance when the decision trees method is used. Finally, in discriminant analysis applications, working with a small sample size and homogeneous variance-covariance matrixes improves the performance of the method twice as much.

Keywords: Neural network, decision trees, discriminant analysis, PISA, student success

Advisor: Prof. Dr. Selahattin GELBAL, Hacettepe University, Department of Educational Sciences, Division of Educational Measurement and Evaluation

İÇİNDEKİLER

KABUL ve ONAY	ii
ETİK BEYANNAMESİ.....	iv
TEŞEKKÜR.....	v
ÖZ	vi
ABSTRACT.....	viii
İÇİNDEKİLER	x
TABLolar DİZİNİ	xiv
ŞEKİLLER DİZİNİ	xviii
SİMGELER VE KISALTMALAR DİZİNİ.....	xix
1. GİRİŞ	1
1.1. Problem Durumu.....	1
1.2. Araştırmanın Amacı ve Önemi.....	7
1.3. Problem Cümlesi	8
1.3.1. Alt Problemler	8
1.4. Sayıtlar:.....	10
1.5. Sınırlılıklar:.....	10
1.6. Tanımlar:	10
1.7. Araştırmanın Kuramsal Temeli	11
1.7.1. Yapay Sinir Ağları	11
1.7.1.1. Biyolojik Sinir Hücresi ve Yapay Sinir Hücresi Benzerliği	15
1.7.1.2. Yapay Sinir Ağlarının Genel Yapısı	19
1.7.1.3. Yapay Sinir Ağlarında Öğrenme	20
1.7.1.4. Yapay Sinir Ağlarında Öğrenme Kuralları	20
1.7.1.4.1. Hebb Kuralı	21
1.7.1.4.2. Hopfield Kuralı.....	22
1.7.1.4.3. Delta Kuralı	22
1.7.1.4.4. Kohonen Öğrenme Kuralı.....	22
1.7.1.5. Yapay Sinir Ağlarının Sınıflandırılması	22
1.7.1.5.1. İleri Beslemeli Yapay Sinir Ağları	24
1.7.1.5.2. Geri Beslemeli Yapay Sinir Ağları	24
1.7.2. Karar Ağaçları	25
1.7.2.1. Karar Ağaçlarının Avantajları ve Dezavantajları	28
1.7.2.2. Karar Ağacı Algoritmaları.....	29
1.7.2.2.1. ID3 Algoritması.....	30
1.7.2.2.2. C4.5 Algoritması.....	30
1.7.2.2.3. C5.0 Algoritması.....	30
1.7.2.2.4. SLIQ Algoritması	30
1.7.2.2.5. SPRINT Algoritması	31
1.7.2.2.6. CART Algoritması	31
1.7.2.2.7. CHAID Algoritması	32
1.7.3. Ayırma Analizi	34
1.7.3.1. Ayırma Analizinin Amaçları	35
1.7.3.2. Ayırma Analizinin Sayıtları	37

1.7.3.3. Doğrusal Ayırma Analizi	39
1.7.3.4. Karesel Ayırma Analizi.....	40
2. İLGİLİ ARAŞTIRMALAR	41
2.1. İlgili Araştırmalar Özet.....	46
3. YÖNTEM	47
3.1. Araştırmanın Türü	47
3.2. Çalışma Evreni	47
3.3. Veri Toplama Araçları	51
3.4. Veri Toplama Araçlarının Uygulanışı	52
3.5. Verilerin İşlenmesi ve Çözülmesi	52
3.5.1. Eksik veri durumu.....	52
3.5.2. Örneklem büyüklüğü	53
3.5.3. Normal dağılım	53
3.5.4. Değişken seçimi	55
3.5.5. Varyans-kovaryans matrislerinin homojenliği	55
3.5.6. Uç değerler	56
3.5.7. Çoklu bağlantı	56
4. BULGULAR VE TARTIŞMA	60
4.1. Araştırmanın Birinci Alt Problemine İlişkin Bulgular ve Yorumlar	60
4.2. Araştırmanın İkinci Alt Problemine İlişkin Bulgular ve Yorumlar.....	71
4.3. Araştırmanın Üçüncü Alt Problemine İlişkin Bulgular ve Yorumlar.....	83
4.4. Araştırmanın Dördüncü Alt Problemine İlişkin Bulgular ve Yorumlar	92
4.5. Araştırmanın Beşinci Alt Problemine İlişkin Bulgular ve Yorumlar	116
5. SONUÇ ve ÖNERİLER	126
5.1. Sonuçlar.....	126
5.2. Öneriler.....	134
5.2.1. Araştırmaya dönük öneriler	134
5.2.2. Araştırmacılar için öneriler.....	135
KAYNAKÇA.....	137
EKLER DİZİNİ.....	147
EK 1. ORJİNALLİK RAPORU	148
EK 2. Değişkenlerin büyük örneklemdeki dağılımlarına ilişkin histogram grafikleri.....	150
EK 3. Değişkenlerin orta büyüklükteki örneklemdeki dağılımlarına ilişkin histogram grafikleri	151
EK 4. Değişkenlerin küçük örneklemdeki dağılımlarına ilişkin histogram grafikleri.....	152
EK 5. Değişkenlerin çok küçük ve homojenliği sağlanmış örneklemdeki dağılımlarına ilişkin histogram grafikleri	153
EK 6. Değişkenlerin çok küçük ve homojenliği sağlanmamış örneklemdeki dağılımlarına ilişkin histogram grafikleri	154
EK 7. Büyük örneklemdeki değişkenlere ilişkin çarpıklık ve basıklık değerleri ile değerlerin standart hatalarına bölünmesiyle elde edilen z değerleri.....	155

EK 8. Orta büyüklükteki örneklemeledeki deęişkenlere ilişkin çarpıklık ve basıklık deęerleri ile deęerlerin standart hatalarına bölünmesiyle elde edilen z deęerleri	156
EK 9. Küçük örneklemeledeki deęişkenlere ilişkin çarpıklık ve basıklık deęerleri ile deęerlerin standart hatalarına bölünmesiyle elde edilen z deęerleri.....	157
EK 10. Çok küçük ve homojenlięi saęlanmış örneklemeledeki deęişkenlere ilişkin çarpıklık ve basıklık deęerleri ile deęerlerin standart hatalarına bölünmesiyle elde edilen z deęerleri.....	158
EK 11. Çok küçük ve homojenlięi saęlanmamış örneklemeledeki deęişkenlere ilişkin çarpıklık ve basıklık deęerleri ile deęerlerin standart hatalarına bölünmesiyle elde edilen z deęerleri.....	159
EK 12. Deęişkenlerin büyük örneklemeledeki korelasyonları	160
EK 13. Deęişkenlerin orta büyüklükteki örneklemeledeki korelasyonları	161
EK 14. Deęişkenlerin küçük örneklemeledeki korelasyonları	162
EK 15. Deęişkenlerin çok küçük ve homojenlięi saęlanmış örneklemeledeki korelasyonları	163
EK 16. Deęişkenlerin çok küçük ve homojenlięi saęlanmamış örneklemeledeki korelasyonları	164
EK 17. Deęişkenlerin farklı örnekleme büyüklüklerinde sahip oldukları tolerance, VIF ve CI deęerleri	165
EK 18. Büyük örneklemelede 6, 3 ve 2 alt gruba sınıflama yapmada yapay sinir aęlarına ait sonuçlar.....	166
EK 19. Orta büyüklükteki örneklemelede 6, 3 ve 2 alt gruba sınıflama yapmada yapay sinir aęlarına ait sonuçlar.....	167
EK 20. Küçük örneklemelede 6, 3 ve 2 alt gruba sınıflama yapmada yapay sinir aęlarına ait sonuçlar.....	168
EK 21. Çok küçük ve varyans-kovaryans matrislerinde homojenlięi saęlanmış örneklemelede 6, 3 ve 2 alt gruba sınıflama yapmada yapay sinir aęlarına ait sonuçlar.....	169
EK 22. Çok küçük ve varyans-kovaryans matrislerinde homojenlięi saęlanmamış örneklemelede 6, 3 ve 2 alt gruba sınıflama yapmada yapay sinir aęlarına ait sonuçlar	170
EK 23. Büyük örneklemelede 6, 3 ve 2 alt gruba sınıflama yapmada karar aęaęlarına ait sonuçlar.....	171
EK 24. Orta büyüklükteki örneklemelede 6, 3 ve 2 alt gruba sınıflama yapmada karar aęaęlarına ait sonuçlar.....	172
EK 25. Küçük örneklemelede 6, 3 ve 2 alt gruba sınıflama yapmada karar aęaęlarına ait sonuçlar.....	173
EK 26. Çok küçük ve varyans-kovaryans matrislerinde homojenlięi saęlanmış örneklemelede 6, 3 ve 2 alt gruba sınıflama yapmada karar aęaęlarına ait sonuçlar.....	174
EK 27. Çok küçük ve varyans-kovaryans matrislerinde homojenlięi saęlanmamış örneklemelede 6, 3 ve 2 alt gruba sınıflama yapmada karar aęaęlarına ait sonuçlar.....	175
EK 28. Büyük örneklemelede 6, 3 ve 2 alt gruba sınıflama yapmada ayırma analizine ait sonuçlar	176
EK 29. Orta büyüklükteki örneklemelede 6, 3 ve 2 alt gruba sınıflama yapmada ayırma analizine ait sonuçlar.....	177

EK 30. Küçük örnekleme 6, 3 ve 2 alt gruba sınıflama yapmada ayırma analizine ait sonuçlar	178
EK 31. Çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örnekleme 6, 3 ve 2 alt gruba sınıflama yapmada ayırma analizine ait sonuçlar	179
EK 32. Çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme 6, 3 ve 2 alt gruba sınıflama yapmada ayırma analizine ait sonuçlar	180
EK 33. Etik Komisyon İzin Muafiyet Formu.....	181
ÖZGEÇMİŞ	182



TABLolar DİZİNİ

Tablo 3. 1.: PISA 2012 uygulamasına katılan tüm öğrencilerin başarı düzeylerine göre dağılımı	48
Tablo 3. 2.: 126126 kişilik örneklemin başarı düzeylerine göre dağılımı	49
Tablo 3. 3.: 6186 kişilik örneklemin oluşturulması ve başarı düzeylerine göre dağılımı	49
Tablo 3. 4.: 603 kişilik örneklemin oluşturulması ve başarı düzeylerine göre dağılımı	50
Tablo 3. 5.: Çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış (102 kişilik) örneklemin oluşturulması ve başarı düzeylerine göre dağılımı	50
Tablo 3. 6.: Çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış (102 kişilik) örneklemin oluşturulması ve başarı düzeylerine göre dağılımı	50
Tablo 3. 7.: Tüm örneklem büyüklükleri ve sınıflama gruplarına göre dağılımları	51
Tablo 3. 8.: Araştırmada kullanılan bağımlı ve bağımsız değişkenler.....	55
Tablo 4. 1.: Öğrenci başarılarının büyük örnekleme, ilgili değişkenlerle 6 alt gruba sınıflanmasında yapay sinir ağı yönteminin performansı	61
Tablo 4. 2.: Öğrenci başarılarının büyük örnekleme, ilgili değişkenlerle 6 alt gruba sınıflanmasında karar ağaçları yönteminin performansı.....	62
Tablo 4. 3.: Öğrenci başarılarının büyük örnekleme, ilgili değişkenlerle 6 alt gruba sınıflanmasında ayırma analizi yönteminin performansı	63
Tablo 4. 4.: Öğrenci başarılarının büyük örnekleme, ilgili değişkenlerle 3 alt gruba sınıflanmasında yapay sinir ağı yönteminin performansı	64
Tablo 4. 5.: Öğrenci başarılarının büyük örnekleme, ilgili değişkenlerle 3 alt gruba sınıflanmasında karar ağaçları yönteminin performansı.....	65
Tablo 4. 6.: Öğrenci başarılarının büyük örnekleme, ilgili değişkenlerle 3 alt gruba sınıflanmasında ayırma analizi yönteminin performansı	66
Tablo 4. 7.: Öğrenci başarılarının büyük örnekleme, ilgili değişkenlerle 2 alt gruba sınıflanmasında yapay sinir ağı yönteminin performansı	68
Tablo 4. 8.: Öğrenci başarılarının büyük örnekleme, ilgili değişkenlerle 2 alt gruba sınıflanmasında karar ağaçları yönteminin performansı.....	69
Tablo 4. 9.: Öğrenci başarılarının büyük örnekleme, ilgili değişkenlerle 2 alt gruba sınıflanmasında ayırma analizi yönteminin performansı	70
Tablo 4. 10.: Öğrenci başarılarının orta büyüklükteki örnekleme, ilgili değişkenlerle 6 alt gruba sınıflanmasında yapay sinir ağı yönteminin performansı.....	72
Tablo 4. 11.: Öğrenci başarılarının orta büyüklükteki örnekleme, ilgili değişkenlerle 6 alt gruba sınıflanmasında karar ağaçları yönteminin performansı.....	73

Tablo 4. 12.: Öğrenci başarılarının orta büyüklükteki örnekleme, ilgili değişkenlerle 6 alt gruba sınıflanmasında ayırma analizi yönteminin performansı	74
Tablo 4. 13.: Öğrenci başarılarının orta büyüklükteki örnekleme, ilgili değişkenlerle 3 alt gruba sınıflanmasında yapay sinir ağı yönteminin performansı	76
Tablo 4. 14.: Öğrenci başarılarının orta büyüklükteki örnekleme, ilgili değişkenlerle 3 alt gruba sınıflanmasında karar ağaçları yönteminin performansı	77
Tablo 4. 15.: Öğrenci başarılarının orta büyüklükteki örnekleme, ilgili değişkenlerle 3 alt gruba sınıflanmasında ayırma analizi yönteminin performansı	79
Tablo 4. 16.: Öğrenci başarılarının orta büyüklükteki örnekleme, ilgili değişkenlerle 2 alt gruba sınıflanmasında yapay sinir ağı yönteminin performansı	80
Tablo 4. 17.: Öğrenci başarılarının orta büyüklükteki örnekleme, ilgili değişkenlerle 2 alt gruba sınıflanmasında karar ağaçları yönteminin performansı	81
Tablo 4. 18.: Öğrenci başarılarının orta büyüklükteki örnekleme, ilgili değişkenlerle 2 alt gruba sınıflanmasında ayırma analizi yönteminin performansı	82
Tablo 4. 19.: Öğrenci başarılarının küçük örnekleme, ilgili değişkenlerle 6 alt gruba sınıflanmasında yapay sinir ağı yönteminin performansı	84
Tablo 4. 20.: Öğrenci başarılarının küçük örnekleme, ilgili değişkenlerle 6 alt gruba sınıflanmasında karar ağaçları yönteminin performansı	85
Tablo 4. 21.: Öğrenci başarılarının küçük örnekleme, ilgili değişkenlerle 6 alt gruba sınıflanmasında ayırma analizi yönteminin performansı	86
Tablo 4. 22.: Öğrenci başarılarının küçük örnekleme, ilgili değişkenlerle 3 alt gruba sınıflanmasında yapay sinir ağı yönteminin performansı	87
Tablo 4. 23.: Öğrenci başarılarının küçük örnekleme, ilgili değişkenlerle 3 alt gruba sınıflanmasında karar ağaçları yönteminin performansı	88
Tablo 4. 24.: Öğrenci başarılarının küçük örnekleme, ilgili değişkenlerle 3 alt gruba sınıflanmasında ayırma analizi yönteminin performansı	89
Tablo 4. 25.: Öğrenci başarılarının küçük örnekleme, ilgili değişkenlerle 2 alt gruba sınıflanmasında yapay sinir ağı yönteminin performansı	90
Tablo 4. 26.: Öğrenci başarılarının küçük örnekleme, ilgili değişkenlerle 2 alt gruba sınıflanmasında karar ağaçları yönteminin performansı	91
Tablo 4. 27.: Öğrenci başarılarının küçük örnekleme, ilgili değişkenlerle 2 alt gruba sınıflanmasında ayırma analizi yönteminin performansı	91
Tablo 4. 28.: Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örnekleme, ilgili değişkenlerle 6 alt gruba sınıflanmasında yapay sinir ağı yönteminin performansı	93

Tablo 4. 29.: Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örnekleme, ilgili değişkenlerle 6 alt gruba sınıflanmasında karar ağaçları yönteminin performansı.....	94
Tablo 4. 30.: Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örnekleme, ilgili değişkenlerle 6 alt gruba sınıflanmasında ayırma analizi yönteminin performansı.....	95
Tablo 4. 31.: Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örnekleme, ilgili değişkenlerle 3 alt gruba sınıflanmasında yapay sinir ağı yönteminin performansı.....	96
Tablo 4. 32.: Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örnekleme, ilgili değişkenlerle 3 alt gruba sınıflanmasında karar ağaçları yönteminin performansı.....	97
Tablo 4. 33.: Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örnekleme, ilgili değişkenlerle 3 alt gruba sınıflanmasında ayırma analizi yönteminin performansı.....	98
Tablo 4. 34.: Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örnekleme, ilgili değişkenlerle 2 alt gruba sınıflanmasında yapay sinir ağı yönteminin performansı.....	100
Tablo 4. 35.: Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örnekleme, ilgili değişkenlerle 2 alt gruba sınıflanmasında karar ağaçları yönteminin performansı.....	101
Tablo 4. 36.: Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örnekleme, ilgili değişkenlerle 2 alt gruba sınıflanmasında ayırma analizi yönteminin performansı.....	101
Tablo 4. 37.: Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme, ilgili değişkenlerle 6 alt gruba sınıflanmasında yapay sinir ağı yönteminin performansı.....	104
Tablo 4. 38.: Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme, ilgili değişkenlerle 6 alt gruba sınıflanmasında karar ağaçları yönteminin performansı.....	105
Tablo 4. 39.: Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme, ilgili değişkenlerle 6 alt gruba sınıflanmasında ayırma analizi yönteminin performansı.....	106

Tablo 4. 40.: Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme, ilgili değişkenlerle 3 alt gruba sınıflanmasında yapay sinir ağı yönteminin performansı.....	108
Tablo 4. 41.: Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme, ilgili değişkenlerle 3 alt gruba sınıflanmasında karar ağaçları yönteminin performansı.....	109
Tablo 4. 42.: Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme, ilgili değişkenlerle 3 alt gruba sınıflanmasında ayırma analizi yönteminin performansı.....	110
Tablo 4. 43.: Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme, ilgili değişkenlerle 2 alt gruba sınıflanmasında yapay sinir ağı yönteminin performansı.....	112
Tablo 4. 44.: Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme, ilgili değişkenlerle 2 alt gruba sınıflanmasında karar ağaçları yönteminin performansı.....	113
Tablo 4. 45.: Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme, ilgili değişkenlerle 2 alt gruba sınıflanmasında ayırma analizi yönteminin performansı.....	114

ŞEKİLLER DİZİNİ

Şekil 1. 1. Biyolojik sinir hücresinin yapısı	16
Şekil 1. 2. Yapay sinir hücresinin yapısı	16
Şekil 1. 3. Yaygın olarak kullanılan aktivasyon fonksiyonları.....	18
Şekil 1. 4. Bir yapay sinir ağının genel yapısı	19
Şekil 1. 5. Pavlov deneyi	21
Şekil 1. 6. Örnek karar ağacı	26
Şekil 4. 1.: Yöntemlerin öğrenci başarısını büyük örneklemde 6, 3 ve 2 alt gruba sınıflama performansları.....	116
Şekil 4. 2.: Yöntemlerin öğrenci başarısını orta büyüklükteki örneklemde 6, 3 ve 2 alt gruba sınıflama performansları	117
Şekil 4. 3.: Yöntemlerin öğrenci başarısını küçük örneklemde 6, 3 ve 2 alt gruba sınıflama performansları.....	117
Şekil 4. 4.: Yöntemlerin öğrenci başarısını çok küçük ve varyans kovaryans matrislerinde homojenliği sağlanmış örneklemde 6, 3 ve 2 alt gruba sınıflama performansları.....	118
Şekil 4. 5.: Yöntemlerin öğrenci başarısını çok küçük ve varyans kovaryans matrislerinde homojenliği sağlanmamış örneklemde 6, 3 ve 2 alt gruba sınıflama performansları.....	118

SİMGELER VE KISALTMALAR DİZİNİ

PISA:

Uluslararası Öğrenci Değerlendirme Programı
(Programme for International Student Assessment)

OECD:

Ekonomik Kalkınma ve İşbirliği Örgütü
(Organisation for Economic Co-operation and Development)

DTY:

Doğru Tahmin Yüzdesi

6 alt gruplu sınıflamalar için;

Düzyey1:

PISA Matematik uygulamasında 358.000-419.999 puan alan öğrenci grubu.

Düzyey2:

PISA Matematik uygulamasında 420.000-481.999 puan alan öğrenci grubu.

Düzyey3:

PISA Matematik uygulamasında 482.000-544.999 puan alan öğrenci grubu.

Düzyey4:

PISA Matematik uygulamasında 545.000-606.999 puan alan öğrenci grubu.

Düzyey5:

PISA Matematik uygulamasında 607.000-668.999 puan alan öğrenci grubu.

Düzyey6:

PISA Matematik uygulamasında 669.000 ve üzeri puan alan öğrenci grubu.

3 alt gruplu sınıflamalar için;

Düşük düzey:

PISA Matematik uygulamasında 358.000-481.999 puan alan öğrenci grubu.

Orta düzey:

PISA Matematik uygulamasında 482.000-606.999 puan alan öğrenci grubu.

Üst düzey:

PISA Matematik uygulamasında 607.000 ve üzeri puan alan öğrenci grubu.

2 alt gruplu sınıflamalar için;

Alt düzey:

PISA Matematik uygulamasında 358.000-544.999 puan alan öğrenci grubu.

Üst düzey:

PISA Matematik uygulamasında 545.000 ve üzeri puan alan öğrenci grubu.

1. GİRİŞ

Araştırmanın bu bölümünde araştırmanın problem durumu, amacı ve önemi, problem cümlesi, alt problemleri, sayıtları, sınırlılıkları ve tanımlarına yer verilmiştir.

1.1. Problem Durumu

Eğitim bilimleri alanında yapılan çalışmaların amaçlarından biri, öğrencilerin mevcut özelliklerini belirleyebilmek ve belirlenen bu özelliklerden hareketle onların gelişimlerine yönelik bir yol haritası çizilebilmektir. Bu amaç doğrultusunda eğitim programcıları nitelikli programlar hazırlamaya, eğitim yöneticileri bu programların uygulanmasında düzeni ve kontrolü sağlamaya, eğitim psikologları ya da rehberlik uzmanları ise öğrencilerin ihtiyaç duydukları noktalarda rehberlik ve danışma hizmetleri sunmaya çalışmaktadır. Öğrencilerin gelişimlerini hedefleyen bu sistem, birbirine örtük olarak bağlı şekilde işlemektedir. Sistemin verimli şekilde çalışması ve süreç sonunda elde edilen çıktılarının güvenilir şekilde yorumlanması için sistemde yer alan öge ise ölçme ve değerlendirmedir. Hazırlanan programlar, gerçekleştirilen uygulamalar ve yapılan rehberliklerden sonra bireylerin başarılarının en doğru şekilde ölçülmesi ve değerlendirilmesi hem birey hem toplum hem de ülke geleceği açısından büyük önem taşımaktadır.

Öğrenciler hakkında geçerli ve güvenilir ölçme ve değerlendirmeler yapılmasının ardından uygun bir sınıflamayla ülkenin ihtiyaç duyduğu alanlara nitelikli ve istenilen özelliklere sahip bireylerin seçilmesi ve yetiştirilmesi sağlanır. Bu noktadan hareketle eğitimde yapılan ölçme ve değerlendirme çalışmalarının temel amacının öğrencilerin ölçülen konuyla ilgili özelliklere sahip olup olmama durumunu analiz etmek ve öğrencilerin başarı durumlarını doğru şekilde belirlemek olduğu söylenebilir. Ölçme amacıyla hazırlanan sorulara yönelik olarak öğrencilerin verdiği yanıtlar, onların “geçti/kaldı, yeterli/yetersiz, eksik/tam, düşük/orta/yüksek, kötü/orta/iyi/çok iyi” gibi sınıflama gruplarından birisine girmesine neden olmaktadır. Öğrencilerin gelecekte sahip olacakları konularının temelini oluşturan bu sınıflamalar ulusal ve uluslararası düzeydeki tüm sınavlarda karşımıza çıkmaktadır. Bugün temel eğitimden ortaöğretime geçişte farklı okul

türlerine öğrenci yerleştirmede TEOG sınavı, ortaöğretimden yükseköğretime geçişte farklı öğretim programlarına öğrenci yerleştirmede YGS ve LYS sınavları öğrencileri performanslarına göre sınıflandırmaktadır. Yine ulusal düzeyde YDS, uluslararası düzeyde TOEFL gibi dil yeterliklerini ölçmek amacıyla gerçekleştirilen sınavlarda öğrenci başarıları performansa göre belirli düzeylerde sınıflandırılmaktadır. Öğrencilerin başarı sınıflamasına yönelik yapılan çalışmalarda sınıflamaya etki eden farklı değişkenler bulunmaktadır. Öğrencilerin başarı durumlarını etkileyen bu değişkenler, öğrencilerin derslere yönelik kaygıları, okula karşı tutumları, okula ait olma duyguları, derse yönelik motivasyonları, derse olan ilgileri, derse ilişkin öz yeterlikleri, dersin öğretmenin etkisi, sınıf iklimi, evdeki eğitim olanakları, sahip oldukları sosyoekonomik değerler, gelir düzeyleri, yaşları, kardeş sayıları, zaman yönetimi becerileri, akademik özgüvenleri gibi daha da çoğaltılabilecek çok farklı verilerden oluşabilir. Öğrenciler hakkında elde edilen bu veriler, onların başarı sınıflamasını yaparken önemli yordayıcılar olmaktadır.

Son yıllarda öğrenci başarısını ve bu başarının şekillenmesine etki eden faktörleri belirlemek amacıyla yapılan yordama çalışmaları oldukça artmıştır (Anıl, 2008; Gelbal, 2008; Anıl, 2009; Doğan, 2009; Erdil, 2010; Anıl, 2011; Özer ve Anıl, 2011; Şahin, 2011; Arslantaş vd., 2012; Altun ve Yazıcı, 2013; Çiftçi ve Çağlar, 2014, Sadi vd., 2014). Başarının şekillenmesiyle ilişkili olan faktörlerin etki büyüklüğünün belirlenmesinin, gelişim ve daha yüksek başarı için hangi noktalara ağırlık verilmesi gerektiğine de rehberlik edecek olması, bu amaçla yapılan araştırmalarda kullanılan yöntemlerin titizlikle seçilmesini ve böylelikle en doğru yordamanın ve sınıflamanın sağlanmasını gerektirmektedir. Ancak bununla birlikte özellikleri birbirine benzeyen gruplarda sınıflamayı yapmak oldukça güç olmaktadır.

Öğrenci başarısını yordama ve buna göre sınıflamalar yapmak amacıyla alanyazında farklı uygulamalar geliştirilmiştir. Sınıflandırma uygulamalarında kullanılan her bir modelin kendine özgü bir algoritması bulunmaktadır. Bu algoritmaların değişen koşullar altında göstereceği performansın belirlenmesi çalışmaların daha verimli hale gelmesini sağlayacak, çalışmalardaki sınıflandırma başarılarını artıracaktır. Algoritmaların karşılaştırılarak değerlendirilmesi hangi algoritmanın hangi durumlarda başarılı olduğunun ortaya koyulması ve sınıflama performanslarının artırılması açısından büyük önem taşımaktadır (Kuyucu, 2012).

Alanyazın incelendiğinde araştırmacıların öğrenci başarısını ve bu başarıya etki eden faktörleri yordama ve sınıflama çalışmalarında genellikle farklı regresyon analizleri ve ayırma analizi ile yapısal eşitlik modellemesi gibi yine regresyon tabanlı yöntemleri kullandıkları görülmektedir (Yıldırım, 2000; Ercan vd., 2005; Özdemir ve Koruklu, 2011; Altun ve Yazıcı, 2013; Okioga, 2013).

Kullanılan bu yöntemler dışında verilen örneklerden aldıkları bilgilerle kendi bilgi süreçlerinin deneyimini oluşturan ve birbirine benzeyen konularla karşılaşmaları durumunda yine aynı kararları vererek günümüzde pek çok probleme çözüm üretebilecek yeteneğe sahip olan bir uygulama da yapay sinir ağlarıdır (Öztemel, 2012). Yapay sinir ağı uygulamaları ile işletme, istatistik, matematik, biyoistatistik, ekonomi, tıp, bankacılık, mühendislik, turizm, ziraat, sigortacılık gibi farklı alanlarda çok fazla sayıda çalışma yapılmasına rağmen (Çuhadar, 2006; Bayru, 2007; Tolon, 2007; Torun, 2007; Yüksek, 2007; Burmaoğlu, 2009; Şirvan, 2010; Kocadağlı, 2012; Köktürk, 2012; Sabancı, 2013; Kayıkçı, 2014; Kibar, 2015) eğitim alanında yapılan çalışmalar sınırlı sayıda kalmıştır. Yapay sinir ağı uygulamaları herhangi bir istatistiksel varsayıma ihtiyaç duymamakta ve eksik verilerle de başarılı sonuçlara ulaşmakta olup, verilerin kusurlu ya da çok boyutlu olduğu, doğrusal olmadığı ya da yüksek hata olasılığı taşıdığı durumlarda başarılı sonuçlar vermektedir (Çırak, 2012; Tepehan, 2011; Öztemel, 2012). Bu özellikler uygulamayı regresyon temelli yöntemlere üstün kılarak araştırmalarda tercih sebebi yapabilecek önemli avantajlar olarak öne çıkmaktadır.

Alanyazında özellikle fen bilimlerinde sıklıkla kullanılan, kolay bir kurulumla ve yorumlamaya sahip olan, veri tabanlarına kolay uyum gösteren, güvenilirlikleri yüksek olan ve bu nedenlerle yaygın olarak tercih edilen sınıflama modellerinden bir diğeri de karar ağaçları yöntemidir (Pehlivan, 2006). Karar ağaçlarında amaç bağımlı değişken ile ilgili verilerin mümkün olduğunca homojen alt setlerinin meydana getirilmesidir (Kuyucu, 2012). Karar ağaçları yöntemi, “parametrik regresyon tekniklerinin sayıtlarının karşılanmasını gerektirmeyen, veri setindeki değerlere müdahale etmeksizin kendi uzayında bağımlı değişken/ler ile bağımsız değişkenler arasında ilişkileri saptayabilen” bir sınıflama tekniğidir (Chang & Wang, 2006; Yamauchi vd., 2001; Akt. Kayri ve Günüş, 2010, 2472). Ayrıca karar ağaçları yönteminin yordanan değişken üzerinde etkili bağımsız değişkenleri önem düzeylerine göre ağaç şeklinde görselleştirerek vermesi, karar ağaçlarını

geleneksel regresyon yöntemlerinden daha etkileyici hale getirmektedir (Hebert vd., 2006; Akt. Kayri ve Boysan, 2008).

Sınıflama ve yordama çalışmalarında kullanılan geleneksel istatistiki yöntemlerden biri ise ayırma analizi yöntemidir. Araştırmalarda herhangi bir gruba üyeliği yordamak için modeller kurma amacına hizmet eden ayırma analizi, sayıtlarının karşılanması durumunda, güçlü temelleri olan bir istatistiksel bir yöntemdir (Çokluk vd., 2012). Çok değişkenli analiz yöntemlerinden biri olan ayırma analizi, alanyazında pek çok araştırmada kullanılmıştır (Demircioğlu vd., 2004; Oğuzlar, 2006; Güzeller ve Kelecioğlu, 2006; Serinkan ve Bardakçı, 2007; Ceylan, 2009; Çankaya vd., 2009; Çakmak ve Kara, 2011; Atar, 2012; Bektaş, 2012; Öztürk vd., 2012; Avcılar ve Yakut, 2015).

Alanyazında yapay sinir ağı ve karar ağaçları yöntemlerinin regresyon tabanlı yöntemlerle ikili karşılaştırılmasına yönelik farklı araştırmalar bulunmaktadır (Torun, 2007; Tosun, 2007; Burmaoğlu, 2009; Çölkesen, 2009; Köktürk, 2012). Yapay sinir ağı uygulamaları ile yapılan çalışmalar, yapay sinir ağları ile lojistik regresyon analizinin karşılaştırılması (Güneri ve Apaydın, 2004; Kurt ve Türe, 2005; Naik ve Ragothaman, 2004; Benli, 2005; Ocakoğlu, 2006; Burmaoğlu, 2009); yapay sinir ağları ile ayırma analizinin karşılaştırılması (Burmaoğlu, 2009), yapay sinir ağları ile çoklu regresyon analizinin karşılaştırılması (Thigpen, 2000; Baş, 2006; Brown, 2007; Yüksek, 2007) şeklinde örneklendirilebilir.

Karar ağaçları yöntemi ile yapılan çalışmalar ise karar ağaçları ile lojistik regresyon analizinin karşılaştırılması (Kuyucu, 2012; Zurada & Lonial, 2005), karar ağaçları ile yapay sinir ağı uygulamalarının karşılaştırılması (Tosun, 2007; Kuyucu, 2012) şeklinde örneklendirilebilir. Ancak, veri madenciliği yöntemleri arasında hem varsayım sorunu olmayan hem kolay yorumlanabilen hem de veri tabanı sistemleri ile rahatlıkla bütünleşebilen bu yöntemlerin eğitim bilimleri alanında çok fazla kullanılmadığı, gerçekleştirilen birkaç çalışmanın ise ikili yöntem karşılaştırması şeklinde olduğu görülmektedir. Bu yöntemlerin geleneksel yöntemlerle eğitim bilimleri alanında farklı uygulamalarda kullanılmasının araştırmacılar için faydalı olacağı düşünülmektedir. Ayrıca geliştirilen sınıflama yöntemlerinin her biri farklı koşullarda farklı sonuçlar verebilmektedir. Bu noktadan hareketle araştırmacının temel amacı yapay sinir ağı ve karar ağaçları yöntemleri ile geleneksel istatistiki yöntemlerden olan ayırma analizi yönteminin sınıflandırma performanslarının

karşılaştırmalı incelenmesi olarak belirlenmiştir. Bu temel amacın yanı sıra gerek bilişsel özellikleri ölçmek amacıyla yapılan sınavların, gerekse duyuşsal özellikleri ölçmek amacıyla kullanılan ölçeklerin uygulandığı grupların farklı örneklem büyüklüklerine sahip olduğu ve sınıflama çalışmalarının farklı alt grup sayılarında yapıldığı düşünöldüğünde, her üç yöntemin farklı örneklem büyüklüklerinde ve farklı alt grup sayılarına sınıflama yapmada göstereceği performansın incelenmesinin de faydalı olacağına inanılmaktadır. Bu nedenle araştırmaya farklı örneklem büyüklükleri ve farklı alt grup sayıları durumları da eklenmiştir.

Araştırmada PISA 2012 matematik testi ve bu uygulamada yer alan değişkenlerden bazıları kullanılmıştır. İlk uygulaması 2000 yılında gerçekleştirilen ve bugüne kadar her üç yılda bir uygulanmakta olan, Türkiye'nin ise ilk olarak 2003 yılındaki uygulamasına katıldığı PISA, katılımcı tüm ölkelerin eğitim sistemlerini değerlendirmelerine fırsat veren uluslararası ölçekli önemli bir projedir. *“Dünya genelinde, politika belirleyicileri kendi ölkelerindeki öğrencilerin bilgi ve beceri düzeylerini, projeye katılan diğer ölkelerdeki öğrencilerin bilgi ve beceri düzeyleriyle karşılaştırmak, eğitim düzeyinin yükseltilmesi amacıyla standartlar oluşturmak (örneğin ölkeler tarafından elde edilen ortalama puanlar, ölkelerin eğitim çıktıları ve eğitim fırsatlarında eşitliği en yüksek düzeyde sağlama kapasiteleri) ve eğitim sistemlerinin güçlü ve zayıf yönlerini belirlemek için PISA sonuçlarını kullanmaktadırlar (MEB, 2013, 9)”. PISA sonuçları ile ölkelerin ölçölen alanlardaki mevcut durumlarının ortaya çıkarılmasının yanı sıra her üç yılda bir gerçekleştirilmesi sayesinde dönemlik ilerleme, gerileme ya da durağanlıklar da tespit edilmektedir. Ekonomik Kalkınma ve İşbirliği Örgütü (OECD) tarafından gerçekleştirilen PISA uygulamaları, ölkelerin ekonomik gelişmişlikleriyle eğitim alanındaki durumlarını karşılaştıran ayrıntılı tabloları da ayrıca sunmaktadır (OECD, 2014, 7). Bu nedenlerle 2012 yılında gerçekleştirilen uygulamasına katılımcı 65 ölkeden 15 yaş grubu yaklaşık 510.000 öğrencinin yer aldığı PISA uygulaması sonuçları, tüm ölkeler tarafından büyük ilgiyle takip edilmektedir.*

PISA'da öğrenci başarılarını incelemek ve karşılaştırmak amacıyla en düşük düzey birin altı, en yüksek altıncı düzey olmak üzere toplam yedi yeterlik düzeyi bulunmaktadır. PISA uygulamalarının ardından hazırlanan ulusal ve uluslararası düzeydeki raporlarda ölkeler, her bir başarı düzeyinde sahip oldukları öğrenci sayılarına göre kendi mevcut durumlarını görebilmektedir. Örneğin, OECD

tarafından hazırlanan 2012 PISA raporunda OECD üyesi ülkelerden katılımcı öğrencilerin %13'ünün beşinci ve altıncı düzeyde yer aldığı, bununla birlikte Çin (Şanghay)'in bu düzeye %55'lik oranla en çok öğrenci yerleştirdiği ve OECD üyesi ülkelerin öğrencilerinin yaklaşık %23'ünün, tüm öğrencilerin ise yaklaşık %32'sinin ise ikinci düzeye bile ulaşamadığı gibi karşılaştırmalar yapmaya olanak veren ayrıntılı bilgiler verilmiştir (OECD, 2014).

Ülkelerin eğitim alanındaki mevcut durumlarını görmek buna bağlı olarak da eksiklerini düzeltmek adına PISA uygulamalarına verdiği önem göz önüne alındığında, son derece kritik olan PISA sınıflamalarının incelenmesi de önemli bir problem durumu olarak karşımıza çıkmıştır. Bu noktada araştırmada ele alınan üç farklı yöntemin sınıflama performansının incelenmesinin yanında, yöntemlerin PISA sınıflamaları hakkında verdiği sonuçlar da önemlidir. Sınıflamaların 6, 3 ve 2 alt gruba yönelik yapılması da PISA araştırmacıları için farklı bakış açıları sunacaktır.

1.2. Araştırmanın Amacı ve Önemi

Araştırmanın temel amacı yapay sinir ağı, karar ağaçları ve ayırma analizi yöntemlerinin öğrenci başarılarını sınıflama performansının karşılaştırmalı incelenmesidir. Bu temel amacın yanında her üç yöntemin farklı örneklem büyüklüklerinde ve farklı alt grup sayılarına yordama ve sınıflama yapmada göstereceği performansın incelenmesi hedeflenmektedir.

Eğitim bilimleri alanında yapılan çalışmaların genellikle farklı örneklem büyüklüklerinde gerçekleştirildiği düşünüldüğünde, örneklem büyüklüğünün yöntemlerin sınıflandırma performansına etkisini ortaya koymak, gelecek sınıflama araştırmalarında yöntem seçimi için yol gösterici olacaktır. Bununla birlikte sınıflama ve yordama çalışmaları farklı alt grup sayılarına yönelik olarak gerçekleştirilebilmektedir. Bu durumda araştırmada kullanılacak yöntemlerle yapılacak yordama ve sınıflamaların farklı alt grup sayılarındaki performansının incelenmesi gereklidir. Grup sayısına göre yordama ve sınıflama performansının ortaya konması yine gelecek araştırmalara bu konuda yol gösterici olacaktır.

Araştırma, bu üç yöntemin birbirleriyle karşılaştırılması açısından alanyazında ilk olması nedeniyle önem arz etmektedir. Araştırmadan elde edilecek sonuçlar, üç yöntemin eğitim bilimleri alanında farklı uygulamalarda kullanılabilmesi açısından önemli bir örnek oluşturacaktır. Yapılacak sınıflamaların farklı örneklem büyüklüklerinde ve 6, 3 ve 2 alt grup üzerinde ayrı ayrı olması, araştırmanın grup sayısı ve örneklem büyüklüğü değiştikçe hangi yöntemin daha başarılı sonuçlar verdiğini ortaya koyması bakımından da önemlidir. Araştırmada yapılan analizlerin PISA verileri üzerinde gerçekleştirilmesi, PISA uygulamalarında kullanılan öğrenci sınıflamalarının geçerliği hakkında da bilgi sağlayacaktır. Politika yapıcılar, bu araştırmada kullanılan bağımsız/yordayıcı değişkenlerden hareketle yöntemlerin sınıflama doğruluklarına göre, PISA uygulamalarında kullanılan bağımsız/yordayıcı değişkenlerin öğrenci başarısına etkisini de görmüş olacaklardır.

1.3. Problem Cümlesi

Yapay sinir ağı, karar ağaçları ve ayırma analizi yöntemlerinin öğrenci başarılarını 6, 3 ve 2 düzeyde sınıflama performansları farklı örneklem büyüklüklerinde farklılaşmakta mıdır?

1.3.1. Alt Problemler

1. Öğrenci başarılarının büyük (**126126 kişilik**) örnekleme, **6, 3** ve **2** alt gruba sınıflanması konusunda;
 - a) *yapay sinir ağı yönteminin performansı nasıldır?*
 - b) *karar ağaçları yönteminin performansı nasıldır?*
 - c) *ayırma analizi yönteminin performansı nasıldır?*
2. Öğrenci başarılarının orta büyüklükteki (**6186 kişilik**) örnekleme, **6, 3** ve **2** alt gruba sınıflanması konusunda;
 - a) *yapay sinir ağı yönteminin performansı nasıldır?*
 - b) *karar ağaçları yönteminin performansı nasıldır?*
 - c) *ayırma analizi yönteminin performansı nasıldır?*
3. Öğrenci başarılarının küçük (**603 kişilik**) örnekleme, **6, 3** ve **2** alt gruba sınıflanması konusunda;
 - a) *yapay sinir ağı yönteminin performansı nasıldır?*
 - b) *karar ağaçları yönteminin performansı nasıldır?*
 - c) *ayırma analizi yönteminin performansı nasıldır?*
4. i) Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde **homojenliği sağlanmış (102 kişilik)** örnekleme **6, 3** ve **2** alt gruba sınıflanması konusunda;
 - a) *yapay sinir ağı yönteminin performansı nasıldır?*
 - b) *karar ağaçları yönteminin performansı nasıldır?*
 - c) *ayırma analizi yönteminin performansı nasıldır?*

4. ii) Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde **homojenliği sağlanmamış (102 kişilik)** örnekleme **6, 3 ve 2** alt gruba sınıflanması konusunda;
- a) *yapay sinir ağı yönteminin performansı nasıldır?*
 - b) *karar ağaçları yönteminin performansı nasıldır?*
 - c) *ayırma analizi yönteminin performansı nasıldır?*
5. Öğrenci başarılarını **6, 3 ve 2** alt gruba sınıflandırmada, **büyük, orta, küçük ve çok küçük** örneklemlerde yapay sinir ağı, karar ağaçları ve ayırma analizi performansları farklılık göstermekte midir?



1.4. Sayılılar:

- PISA 2012 uygulamasına katılan öğrenciler matematik testi sorularını ve öğrenci anketinde yer alan maddeleri içtenlikle yanıtlamışlardır.

1.5. Sınırlılıklar:

Araştırmada elde edilen bulgular ve sonuçlar;

- PISA 2012 projesi kapsamında dünyanın farklı ülkelerinden çalışmaya katılan 15 yaş grubu öğrencilere uygulanan matematik başarı testi ve öğrenci anketleriyle,
- Yapay sinir ağı uygulamalarında kullanılan Çok Katmanlı Algılayıcı modelle,
- Karar ağacı uygulamalarında kullanılan CHAID algoritmasıyla,
- Doğrusal ayırma analizi ile sınırlıdır.
- Varyans-kovaryans matrislerinde homojenliğin sağlandığı 102 kişilik çok küçük örneklem dışındaki örneklerde değişkenlerin normal dağılım göstermemesi araştırmanın bir sınırlılığıdır.

1.6. Tanımlar:

- Matematik okuryazarlığı başarıları (OECD, 2013);

Çeşitli kapsam ve içeriklere yönelik olarak formüleştirebilme, matematiği işe koşabilme ve yorumlayabilme,

Fenomenleri tanımlama, açıklama ve tahmin etmede, matematiksel akıl yürütmeyi ve matematiksel kavramları, işlem aşamalarını, doğrulanmış bilgileri ve araçları kullanabilme,

Matematiğin dünyadaki rolünü fark etme ve yapıcı, duyarlı ve yansıtıcı vatandaşların ihtiyaç duyduğu sağlam dayanakları olan yargı ve kararları verebilme.

- Sınıflama performansı;

Öğrenci başarılarını yordamada kullanılan yöntemlerin öğrencinin yer aldığı başarı düzeyini doğru tahmin yüzdesi.

1.7. Araştırmanın Kuramsal Temeli

1.7.1. Yapay Sinir Ağları

İnsan beyninin çalışma sistemine ilişkin özelliklerden hareketle geliştirilen yapay sinir ağları, biyolojik sinir sisteminin bir simülasyonudur. "Biyolojik sinir sisteminin bilinen yapısını göz önünde bulundurarak, yüksek bir performansın elde edilmesini sağlayacak şekilde basit hesaplama elemanlarının yoğun bağlantılarından meydana gelen yapay sinir ağları (Akpınar, 2014, 239), insan idrakinin ve biyolojik sinirlerinin matematiksel modelinin genelleştirilmesi olarak tanımlanabilir (Fausett, 1993; Akt. Yakut, 2012, 52). İnsan beyninde yaklaşık olarak on milyar sinir hücresi ve altmış trilyon bağlantı olduğu düşünüldüğünde (Garson, 1998, 25), beyin çok hızlı çalışan kusursuz bir bilgisayar olarak değerlendirilebilir (Munakata, 2008, 7).

Bilgisayar teknolojisinde ve matematiksel modelleme çalışmalarında yaşanan ilerlemeler yapay sinir ağlarının oluşturulmasını ve gelişimini de sağlamıştır. Bu nedenle yapay sinir ağları "insan beyninden esinlenerek geliştirilmiş, ağırlıklı bağlantılar aracılığıyla birbirine bağlanan ve her biri kendi belleğine sahip işlem elemanlarından oluşan paralel ve dağıtılmış bilgi işleme yapıları"; bir başka deyişle "biyolojik sinir ağlarını taklit eden bilgisayar programları (Elmas, 2003, 23)"; "insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilme, yeni bilgiler oluşturabilme ve keşfedebilme gibi yetenekleri herhangi bir yardım almadan otomatik olarak gerçekleştirme amacı ile geliştirilen bilgisayar sistemleri (Öztemel, 2012, 29)" olarak da adlandırılmaktadır.

Haykin (1999), Sinir Ağları: Kapsamlı Bir Bakış (Neural Networks: A Comprehensive Foundation), adlı eserinde yapay sinir ağını "bilgiyi depolamak için doğal eğilimi olan basit birimlerden oluşan paralel dağıtılmış bir işlemci" olarak ifade ederken, Zurada (1992) Yapay Sinir Sistemlerine Giriş (Introduction to Artificial Neural Systems) adlı eserinde yapay sinir ağlarını, "bilgiyi alan, depolayan ve kullanan fiziksel hücreli sistemler" şeklinde açıklamaktadır (Sağıroğlu vd., 2003, 25).

Yapay sinir ağıları hakkındaki çalışmalar insan beyninin nasıl çalıştığına ilişkin araştırmaların ortaya konmasının ardından özellikle 1940'lı yıllardan itibaren başlamıştır. İlk olarak 19. yy. sonları ile 20. yy. başlarında Helmholtz, Ernst Mach ve Ivan Pavlov gibi bilim adamlarının fizik, psikoloji ve nöro-psikoloji alanlarında yaptığı çalışmalar görülse de bu çalışmalarda öğrenme, görme, şartlanma gibi konuların genel teorileri vurgulanmış, fakat nöron işlemlerin özel matematiksel modeli incelenmemiştir (Özkan, 2001, 60). Biyolojik sinir sistemlerinden hareketle yapay sinir ağının ilk modelini 1943 yılında McCulloch ve Pitts hazırlamış, Donald Hebb'in 1949'da hazırladığı Hebbian Öğrenme Kuralı günümüz için önemli bir nokta olmuş, 1958 yılında Rosenblatt tarafından geliştirilen ve daha sonraları yapay sinir ağıları konusunda devrim niteliği taşıyacak olan çok katmanlı algılayıcıların temelini oluşturan algılayıcı model (perceptron) ise yapay sinir ağıları tarihinde önemli bir gelişmeye öncülük etmiştir (Öztemel, 2012, 37).

1960'lı yıllarda ortaya atılan yapay zeka kavramı, o dönemde yapay sinir ağılarına olan ilginin azalmasına, yapay sinir ağıları ile ilgili çalışmalara olan finansal desteklerin kesilmesine ve çalışmaların bir süre duraklamasına neden olmuştur. Özellikle Misnky ve Pappert tarafından yazılan Algılayıcılar (Perceptrons) isimli kitapta yer alan "yapay sinir ağılarına dayalı algılayıcıların bilimsel bir değerinin olmadığı ve yapay sinir ağılarının doğrusal olmayan problemlere çözüm üretemediği" iddiasının, bu iddianın kanıtlanması için gösterilen meşhur XOR probleminin çözülememesi ile desteklenmesi üzerine birçok kişi durumu kabullenmiş ve konuyla ilgili çalışmalar oldukça azalmıştır. Yaşanan duraklamanın ardından 1970'li yıllara gelindiğinde ise özellikle Amari, Anderson, Cooper, Fukushima, Grossberg, Kohonen ve Hopfield gibi araştırmacıların çalışmaları meyvelerini vermeye başlamıştır (Öztemel, 2012, 37). 1980'li yıllardan sonra çok sayıda farklı model geliştirilmiş ve yapay sinir ağıları bugün mühendislik, matematik, fizik, istatistik, biyoistatistik, ekonomi, tıp, bankacılık, turizm, ziraat, sigortacılık, eğitim gibi pek çok disiplin tarafından kullanılan disiplinler arası bir yaklaşım haline gelmiştir (Çuhadar, 2006; Bayru, 2007; Tolon, 2007; Torun, 2007; Yüksek, 2007; Burmaoğlu, 2009; Kocadağlı, 2012; Köktürk, 2012; Sabancı, 2013).

Yapay sinir ađlarının farklı alanlarda yaygın olarak kullanılmaya başlamasında etkili olan birçok özelliđi bulunmaktadır (Simpson, 1990; Seven, 1993; Haykin, 1994; Dikmen, 2001; Bayru, 2007; Tosun, 2007; Yüksek, 2007; Burmaođlu, 2009; Köktürk, 2012; Öztemel, 2012; Kayıkçı, 2014). Aşađıda bu özelliklere yer verilmektedir:

- **Dođrusal olmama:** Yapay sinir ađlarının bu özelliđi işlemci elemanların dođrusal olmamasından kaynaklanmakta olup, yöntemin karmaşık yapıdaki dođrusal olmayan problemlere çözüm bulmasını sağlar.
- **Öğrenme:** Yapay sinir ađlarının en önemli özelliklerinden olan öğrenme yeteneđi, insan beyninden yola çıkarak hazırlanan çalışma sistemine, verilerden hareketle öğrenme yeteneđini vermektedir. Bu öğrenme sürecinde yapay sinir ađı, giriş-çıkış veri kümeleri arasında ađın sahip olduđu bağlantı ađırlıklarını öğrenme kuralına göre ayarlamaktadır.
- **Paralellik:** Yapay sinir ađlarında işlemler dođrusal olmayan bir yapıya sahiptir. Bu durum ađa geleneksel yöntemlerden farklı olarak bir hız olanađı sunmaktadır. Ađa yer alan işlemlerin ađın bütününe yayılmış olması, sistemin eş zamanlı olarak çalışabilmesine ve karmaşık problemlerin çözümüne olanak sağlamaktadır.
- **Uyarlanabilirlik:** Bu özellik yapay sinir ađlarına deđişen çevre şartlarına küçük deđişikliklerle birlikte yeni eğitimler gerçekleştirilerek farklı çevrelerde uyarlanabilme olanađı verir.
- **Genelleme:** Yapay sinir ađı, bu özelliđi sayesinde daha önce görmediđi veri setleri için yeni eğitimlerle etkili sonuçlar üretebilir. Plaka tanıma sistemleri düşünöldüğünde, yağışlı havalarda plakanın bir bölümünü okuyabilen yapay sinir ađı, daha önceki eğitim seti uygulamalarına dayanarak plakada bulunan harfleri ve sayıları keşfedebilir.
- **Eksik verilerle çalışma:** Geleneksel istatistiki yöntemlerden farklılık gösteren en önemli özellik olan eksik verilerle çalışabilme, uygulamalarda eksik veriler olsa da yapay sinir ađlarının performansını düşürmemektedir.
- **Hata toleransı:** Eksik ve/veya kusurlu verilerle de çalışabilen yapay sinir ađları, hangi hücrelerde sorun olduđuna kendisi karar vermektedir. Çok sayıda hücrenin çeşitli şekillerdeki yoğun bağlantılarından oluşan yapay sinir ađları, bazı hücrelerin bozulması veya çalışmaması şeklinde ortaya

çıkan hatalara rağmen çalışmaya devam eder. Çünkü giriş veri kümesinde ortaya çıkan hatalar ağırlıklar üzerine dağıtılmakta, böylelikle hata toleransı sağlanmaktadır.

- **Bilginin saklanması:** Yapay sinir ağlarında veriler ağın bağlantılarının değerlerine göre ölçülmekte olup, ağın üzerinde saklı tutulmaktadır.
- **Örüntü tanıma:** Eksik bilgilere sahip bir örüntü, yapay sinir ağı tarafından çok etkin şekilde çözülebilmekte ve tanımlanabilmektedir.

Bu özelliklerin dışında yapay sinir ağlarının sadece nümerik bilgiler ile çalışabilme, yüksek bir donanım ve hıza sahip olma, sınırsız sayıda değişken ve parametre kullanabilme, sınıflandırma, ilişkilendirme ve kendi kendini organize etme özellikleri de bulunmaktadır. Yapay sinir ağlarının öğrenme özelliği başta olmak üzere sahip olduğu tüm bu özellikler, yöntemin pek çok alanın farklı uygulamaları bağlamında dikkatleri üzerine çekmesini sağlamıştır. Yapay sinir ağları bugün mühendislik alanlarında, endüstriyel çalışmalarda, bilgi yönetiminde, tıp çalışmalarında; tıbbi görüntü işlemede, tıbbi tanı koymada, organ morfasyonlarının belirlenmesinde, biyomedikal uygulamalarda, (ses geliştirme uygulamalarında, biyomedikal ürün yönetiminde, protez tasarımında), tarımsal alanda; toplam ürün rekoltesinin tahmininde, hayvancılık alanında; hayvan davranış modellerinin oluşturulmasında, askeri alanda; uzay ve havacılık sanayinde, yüzey modellemede kullanılmaktadır (Sağıroğlu vd., 2003, 23). Başarılı yapay sinir ağı uygulamaları verilerin eksik, kusurlu ya da çok boyutlu olduğu, doğrusal olmadığı ya da yüksek hata olasılığı taşıdığı durumlarda, problemin çözümünde özellikle matematiksel bir modelin ya da herhangi bir algoritmanın bulunmaması durumunda sıklıkla tercih edildiğini göstermekte, yöntem sınıflama yapma, ilişkileri inceleme, örüntüleri tanıma ve eşleştirme, zaman serisi analizleri yapma, sinyalleri filtreleme ve verileri sıkıştırma gibi teorik uygulamaların yanında; veri madenciliği, bankalarda kredi müracaatlarını değerlendirme, kredi kartı hilelerini saptama, parmak izlerini tanıma, silahların otomasyonu ve hedef izleme, kalite kontrol çalışması yapma, üretim planlamaları yapma, kan analizlerini inceleme, kanser ve kalp hastalıklarınınin tedavi etme, beyin modelleme ve hastanelerde giderlerin optimizasyonu gibi pratik uygulamalarda da kullanılmaktadır (Öztemel, 2012, 36; Elmas, 2003; Saraç, 2004; Tepehan, 2011; Çırak, 2012).


Günümüzde pek çok alanda farklı uygulamalarla yer alan yapay sinir ağlarının biyolojik sinir sisteminden hareketle geliştirilme sürecini anlamak için biyolojik sinir hücresinin yapısının bilinmesi faydalı olacaktır. Bu noktada biyolojik sinir hücresinin yapısı açıklanmaya ve ardından yapay sinir hücresi ve bileşenleri ifade edilmeye çalışılmıştır.

1.7.1.1. Biyolojik Sinir Hücresi ve Yapay Sinir Hücresi Benzerliği

İnsan vücudunda yer alan çok sayıdaki sinir hücresinin bir araya gelmesiyle oluşan biyolojik sinir sistemi, dışardan gelen bilgileri alan, yorumlayan ve bir karar çıktısı üreten merkezdir. Bu merkezde yer alan alıcı sinirler, iç veya dış ortamdan aldıkları uyarıları elektriksel sinyallere dönüştürerek beyine iletirken; tepki sinirleri, beyinde üretilen elektriksel sinyalleri uyumlu tepkilere dönüştürerek organizmanın cevabını oluştururlar (Haykin, 1999; Akt. Elmas, 2003).

Biyolojik sinir sisteminin temel elemanı “nöron” olarak bilinen sinir hücreleridir. Hücre çekirdeğini saran bir hücre gövdesinden oluşan sinir hücresi, *dentrit* (dendrite), *çekirdek* (soma), *akson* (axon) ve *sinaps* (synapse) olmak üzere dört temel bileşene sahiptir (Öztemel, 2012).

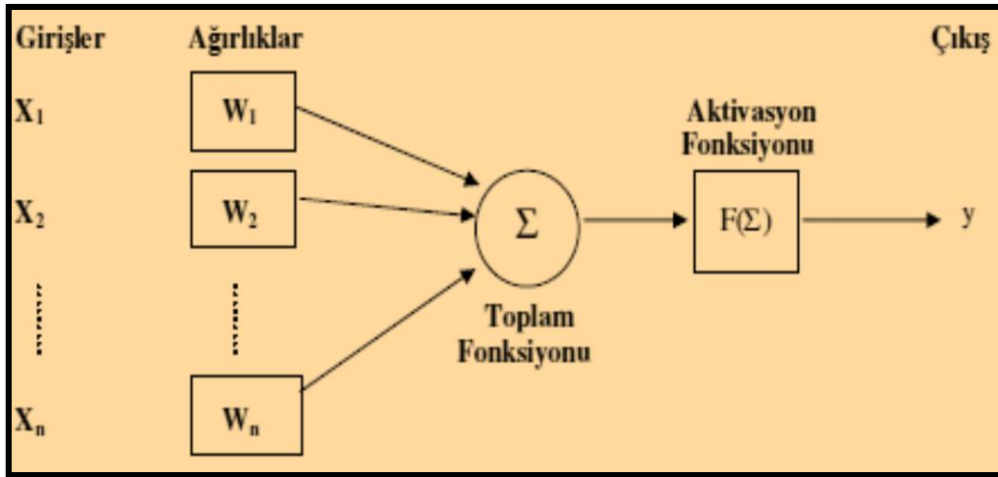
Çekirdeğin saça benzeyen uzantıları şeklinde olan *dentritler*, ağaca benzeyen topolojik bir yapıda elektrik sinyallerini hücre gövdesine taşıyan sinir fiber ağlarıdır (Özkan, 2001, 89). *Dentritler* girdi kanalı olarak işlev görürler ve bu girdi kanalları diğer nöronların *sinapsları* aracılığıyla girdilerini alırlar. Ardından *çekirdek*, gelen bu sinyalleri işleyerek bir çıktıya dönüştürür ve elde edilen bu çıktı hücre gövdesinden dışarı diğer nöronlara sinyalleri taşıyan uzun bir fiber yapıdaki *aksonlar* ve *sinapslar* aracılığıyla diğer nöronlara gönderilir (Yurtoğlu, 2005, 22). Biyolojik sinir hücresinin genel yapısı Şekil 1.1’de verilmiştir.



Şekil 1. 1. Biyolojik sinir hücresinin yapısı

(Kibar, 2015)

Yapay sinir ağlarının sahip olduğu yapay sinir hücreleri, biyolojik sinir ağlarında yer alan biyolojik sinir hücrelerine benzemektedir. Biyolojik sinir hücrelerinde bulunan dentrit, çekirdek, akson ve sinapslar yapay sinir hücresinde modellenmiştir. Bir yapay nöronun genel yapısı Şekil 1.2'de verilmiştir.



Şekil 1. 2. Yapay sinir hücresinin yapısı


(Köktürk, 2012)

Girdiler, bir yapay sinir hücresine dış dünyadan gelen bilgilerin tümüdür. Bu girdiler yapay sinir ağının öğrenmesi istenen örneklerden oluşmaktadır (Yurtoğlu, 2005, 30; Tepehan, 2011; Öztemel, 2012; Kibar, 2015, 62).


Ağırlıklar, sahip oldukları değerler vasıtasıyla yapay sinir hücrelerine gelen bilgilerin önem seviyesi ve hücreye olan etkisi hakkında bilgi vermektedir. Yapay sinir hücresine giren bilgiler bağlantılar üzerindeki ağırlıklara göre gelmektedir. Her bir girdiye ulaşan bilgi, o girdiye geçen ağırlığı taşımaktadır. Bir girdinin yapay sinir hücresi üzerindeki etkisi o girdinin ağırlığına bağlıdır. Ağırlıkların önemi pozitif ya da negatif olmasına bağlı olmadığı gibi, büyüklük veya küçüklükten de etkilenmemektedir. Öğrenme süreci, yapay sinir ağının sahip olduğu ağırlıklar değiştirilerek gerçekleştirilmektedir (Yurtoğlu, 2005; Baş, 2006; Tepehan, 2011; Öztemel, 2012).

Toplama fonksiyonu, yapay sinir hücresine giren net bilgiyi hesaplamaktadır. Bunun için değişik fonksiyonlar kullanılmakta olup, en sık kullanılan fonksiyon girdilerin kendi ağırlıklarıyla çarpımının toplamından oluşan ağırlıklı toplamı bulmaktır. Alanyazında yer alan çalışmalarda toplama fonksiyonu olarak farklı birçok formülün kullanıldığı görülmekle birlikte, bir problem için en iyi toplama fonksiyonunu seçmek için bulunmuş bir yol bulunmamaktadır. Toplama fonksiyonu genellikle deneme yanılma yoluyla belirlenmektedir (Öztemel, 2012, 49).


Aktivasyon fonksiyonu, toplama fonksiyonunun yapay sinir hücresine getirdiği net girdinin işlenerek üretilecek çıktının belirlendiği fonksiyondur. Toplama fonksiyonunda olduğu gibi aktivasyon fonksiyonu olarak da çıktıyı hesaplama konusunda farklı formüller kullanılabilir. Örneğin çok katmanlı algılayıcı model, türevi alınabilir bir fonksiyonun kullanılmasını şart koşsa da bunun dışında en uygun aktivasyon formülünü belirlemede kullanılacak bir yöntem mevcut değildir. Yapılacak uygulama için aktivasyon fonksiyonu seçimi araştırmacının deneme yanılma yoluyla belirlenmektedir (Yurtoğlu, 2005; Baş, 2006; Tepehan, 2011; Öztemel, 2012).




Doğrusal veya Lineer Fonksiyon




Sigmoid Fonksiyonu




Basamak Fonksiyonları




Parçalı Doğrusal fonksiyon



Tek Kutuplamalı Basamak Fonk.



Tanjant Hiperbolik Fonksiyonu



Sinüs Tipli Fonksiyon


Şekil 1. 3. Yaygın olarak kullanılan aktivasyon fonksiyonları

(Yakut, 2012)

Yapay sinir hücresinin çıktısı, aktivasyon fonksiyonunun belirlediği çıktı değeridir. Aktivasyon fonksiyonu ile elde edilen çıktı bir başka hücreye ya da dış dünyaya yollar, ayrıca ilgili yapay sinir hücresi ürettiği çıktıyı kendisine de girdi olarak yollayabilir. Bir yapay sinir hücresi farklı birçok girdiye sahip olması karşısında, sadece bir tek çıktıya sahiptir (Öztemel, 2012, 51).

1.7.1.2. Yapay Sinir Ağlarının Genel Yapısı

Yapay sinir hücrelerinin bir araya gelerek oluşturduğu yapay sinir ağı genel olarak üç katmandan oluşur (Elmas, 2003; Yurtoğlu, 2005; Tolon, 2007, Tosun, 2007; Demiryürek, 2009; Öztemel, 2012).



Şekil 1. 4. Bir yapay sinir ağının genel yapısı

(Demiryürek, 2009)

Girdi katmanı, en az bir yapay sinir hücresine sahiptir ve dış dünyadan aldığı bilgileri ara katmana iletir.

Ara (gizli/saklı) katmanlar, girdi katmanından gelen bilgileri işleyerek çıktı katmanına gönderir. Bir ağ içinde birden fazla ara katman olabilir. Bu katmanda

gerçekleşenlerin tam olarak açıklanamaması nedeniyle yapay sinir ağının gizli katmanı kara kutu olarak nitelendirilmektedir.

Çıktı katmanı, en az bir yapay sinir hücresine sahip olup ara katmandan gelen bilgileri işleyerek ağın girdi katmanından sunulan girdi seti için üretmesi gereken çıktıyı oluşturur. Üretilen çıktı dış dünyaya gönderilir.

1.7.1.3. Yapay Sinir Ağlarında Öğrenme

Yapay sinir ağlarında öğrenme, geçmiş deneyimleri özümseyerek problem çözme yeteneğinin geliştirilmesidir (Tosun, 2007, 41). Zaman içinde yeni bilgilerin keşfedilmesi yoluyla davranışların iyileştirilmesi süreci (Simon, 1983; Akt. Öztemel, 2012) olarak tanımlanan öğrenmenin temeli deneyim sürecidir. Bu süreç giriş örneklerine ve tercihen bu girişlerin çıkışlarına bağlı olarak ağın bağlantı ağırlıklarını değiştiren veya ayarlayan öğrenme kurallarıyla gerçekleştirilir (Durmuş, 2008, 44). Öğrenme sürecinde her bir örneğin girdi ve çıktıları arasındaki ilişkinin olayın genelini farklı açılardan temsil ettiği kabul edilmekte, böylelikle farklı örneklerle olayın değişik açılardan öğrenildiği düşünülmektedir. Bilgisayara öğrenme sürecinde sadece örnekler gösterilmekte olup, bunun dışında başka bir ön bilgi verilmemektedir (Öztemel, 2012). Yapay sinir ağlarında öğrenme sürecinde kullanılan farklı öğrenme kurallarına bir sonraki bölümde yer verilmiştir.


1.7.1.4. Yapay Sinir Ağlarında Öğrenme Kuralları

Yapay sinir ağları alanyazınında kullanılan birçok öğrenme algoritması bulunmaktadır. Bu öğrenme algoritmalarının çoğunluğu matematik tabanlı olup ağırlıkların güncelleştirilmesi için kullanılır. Birçok parametresi olan öğrenme süreci karmaşık bir yapıya sahip olmasının yanında matematiksel açıdan da açıklanması kolay olmayan bir bütünlüktür. Günümüzdeki öğrenme kuralları bu bütünlüğün sadeleştirilmiş ya da değişik formatlar ile açıklanmış türleridir. Alanyazında yer alan öğrenme algoritmalarının birçoğu özünde Hebb, Delta, Kohonen ve Hopfield olmak üzere bu dört değişik öğrenme kuralından faydalanılarak türetilmiştir. Adı geçen kurallar kısaca açıklanmıştır (Sağıroğlu vd., 2003)

1.7.1.4.1. Hebb Kuralı

Bilinen en eski öğrenme kuralı olan Hebb, diğer öğrenme kurallarının temelini oluşturmaktadır (Öztemel, 2012). 1949'da ortaya atılan kuralın temeli "bir nöron diğer bir nörondan giriş alıyorsa ve her iki nöron da aktif ise nöronlar arasındaki ağırlık kuvvetlendirilir" prensibi üzerine oturmaktadır (Sağıroğlu vd., 2003). Akpınar (2014), bu kuraldaki temel mantığın rahatlıkla yorumlanabilmesi için psikoloji biliminin temel deneylerinden birisi olan Pavlov Deneyi'nin hatırlanmasını yararlı görerek aşağıdaki açıklamalarda bulunmuştur:

Bilindiği üzere Pavlov'un köpekler üzerinde gerçekleştirdiği deneyde doğal uyarıcı olan etin verilmesi, köpeğin doğal bir tepki olarak salgılamada bulunmasına neden olmaktadır. Deneyde ise bir zil sesinden birkaç saniye sonra köpeğe et verilmiştir. Başlangıçta zil sesine herhangi bir salgılamada bulunmayan köpek, deneyin defalarca tekrarı sonucunda zil sesine tepki göstererek salgılamada bulunmuştur (Cüceloğlu, 1991). Zil sesi ve etin verilmesi sonucunda uyarılan sinir hücrelerinin sırasıyla C ve A ile salgılama tepkisi veren sinir hücresinin B ile oluşan iki sinaptik bağlantının ise S_{BA} ve S_{BC} ile simgelendiği üç sinir hücresi ve aralarındaki bağlantı yapısı şekilde görülmektedir (Freeman & Skapura, 1991).



Şekil 1. 5. Pavlov deneyi

Doğal uyarıcı olan etin görülmesi sonucunda uyarılan C sinir hücresi, doğal tepki kuralı gereğince salgılama tepkisi veren B sinir hücresini uyaracaktır. Ancak başlangıçta zil sesi gibi A sinir hücresinin uyarılmasını sağlayan ilave bir uyarıcı bulunmadığı için, A sinir hücresinin B sinir hücresini uyarması söz konusu değildir. Buna karşılık etin gösterilmesi ile uyarılan C sinir hücresinin B sinir hücresini uyarması sırasında A sinir hücresi zil sesi ile uyarılacak olursa B sinir hücresinin uyarılmasına A sinir hücresi de katılmış olacaktır. Hebb bu durumun yeterli sayıda tekrarlanması halinde A sinir hücresi ile B sinir hücresi arasında yeni bir düzenlemenin oluştuğunu, A sinir hücresinin B sinir hücresi üzerindeki etkisini artırdığını ve et verilmediği durumda dahi A sinir hücresinin B sinir hücresini uyarabildiğini savunmuştur.

1.7.1.4.2. Hopfield Kuralı

Zayıflatma veya kuvvetlendirme büyüklüğü dışında Hebb kuralına benzeyen bu kuralda, öncelikli olarak yapay sinir ağı elemanlarının bağlantılarının ne düzeyde kuvvetlendirilmesi veya zayıflatılması gerektiğine karar verilir (Öztemel, 2012). Beklenen çıkış ya da giriş değerlerinin her ikisi de aktif ya da değilse bağlantıların ağırlıkları öğrenme oranı aracılığıyla yükseltilir, başka durumlar olduğundaysa düşürülür (Sağıroğlu vd., 2003).

1.7.1.4.3. Delta Kuralı

Hebb kuralının değişik bir formu olan Delta kuralı, giriş bağlantılarının güçlendirilmesi ve devamlı biçimde değiştirilmesini temel alan bir düzende, nöronun gerçek çıkış değerleri ile beklenen çıkış değerleri arasındaki farkı azaltır. En çok kullanılan öğrenme algoritmalarından birisi olan kuralın işleyişinde ortaya çıkan hatanın, bir katmandan öndeki diğer katmana yayılmasıyla hata geriye doğru azaltılır ve çıkış katmanından giriş katmanına ulaşıncaya kadar bu yayılım sürer (Sağıroğlu vd., 2003).

1.7.1.4.4. Kohonen Öğrenme Kuralı

Biyolojik sistemlerdeki öğrenmeye benzeyen bu kuralda nöronlar öğrenmek için bir yarış içindedir ve kazanan nöronun ağırlıkları güncellenir. En büyük çıktıyı üreten hücre, kazanan olarak yakınındaki hücrelere karşı daha kuvvetli hale gelmekte ve komşularını uyarma ve yasaklama kapasitesine sahip olmaktadır. Bu kural “kazanan tamamını alır (winner takes all)” ismiyle de bilinir (Sağıroğlu vd., 2003; Öztemel, 2012).

1.7.1.5. Yapay Sinir Ağlarının Sınıflandırılması

Yapay sinir ağlarının alanyazını incelendiğinde birçok modelin geliştirildiği ve karşılaşılan yeni problemlere yönelik modellerin geliştirilmeye devam ettiği görülmektedir. Araştırmacılar yapay sinir ağı modellerini farklı şekillerde sınıflandırmışlardır. Akpınar (2014) yapay sinir ağlarını genel olarak,

- Ağın sahip olduğu yapıya,
- Ağda bulunan düğümlerin taşıdığı özelliklere,
- Analizde seçilen eşik fonksiyonunun durumuna,
- Düğüme sadece analog ya da sürekli değerlerin uygulanabilme durumuna,
- Eğitim veya öğrenme kurallarının türlerine

göre sınıflandırmıştır. Sağıroğlu ve diğerleri (2003), sınıflandırmayı yapay sinir ağlarının yapılarına ve öğrenme algoritmalarına göre yapmışlardır. Yapılarına göre yapay sinir ağlarını ileri beslemeli (feedforward) ve geri beslemeli (feedback) ağlar olmak üzere iki farklı yapıda incelemiştir. Yine Özkan (2001, 95), yapay sinir ağlarını yapılarına göre ileri beslemeli ve geri beslemeli ağlar, öğrenme algoritmalarına göre ise kontrollü öğrenme, kontrolsüz öğrenme ve pekiştireçli öğrenme olarak ele almıştır. Kayıkçı da (2014), sınıflandırmayı aynı şekilde yapmış ve yapay sinir ağlarını yapılarına göre ileri beslemeli ve geri beslemeli, öğrenme algoritmalarına göre danışmanlı öğrenme, danışmansız öğrenme ve takviyeli öğrenme şeklinde gerçekleştirmiştir. Burmaoğlu (2009) da benzer şekilde sınıflandırmayı yapılarına göre ileri beslemeli ağlar ve geri beslemeli ağlar, öğrenme algoritmalarına göre danışmanlı öğrenme (supervised learning), danışmansız öğrenme (unsupervised learning) ve pekiştireçli öğrenme (reinforcement learning) olarak yapmıştır. Yapay sinir ağlarına yönelik sınıflandırma birçok araştırmacı tarafından da bu şekilde ele alınmıştır.

Araştırmacıların genel olarak kabul ettiği bu sınıflamaların yanında Basit Algılayıcı (Perceptron) Modeli, Çok Katmanlı Algılayıcı (Multilayer Perceptron) Modeli ADALINE/MADALINE Modeli, Doğrusal Vektör Kuantizasyon (Linear Vector Quantization) LVQ Modeli, Radyal Tabanlı Fonksiyon Ağ Modeli, Hopfield Ağı, Jordan Ağı, Elman Ağı, Kohonen Ağı, Adaptif Rezonans Teorisi ART (Adaptive Resonance Theory) Ağları, öğrenme zamanlarına göre dinamik ağlar ve statik ağlar, Olasılıklı Ağ Modeli, Boltzman Makinesi Modeli gibi farklı modeller bulunmaktadır (Baş; 2006; Tepehan, 2011; Yakut, 2012; Köktürk, 2012; Öztemel, 2012; Akpınar, 2014). Sınıflandırma ve yordama problemlerinde istatistiki yöntemler yerine bu ağ modellerinden genellikle Çok Katmanlı Algılayıcı (Multilayer Perceptron) Model kullanılmaktadır (Tepehan, 2011). Bu nedenle araştırmada kullanılan çok katmanlı algılayıcı model yapısındaki ileri beslemeli ağlar ve geri beslemeli ağlar ayrıntılı olarak tanıtılmıştır.

1.7.1.5.1. İleri Beslemeli Yapay Sinir Ağları

İleri beslemeli yapay sinir ağları ilk kullanılan ve en basit ağların başında gelmektedir (Akpınar, 2014). İleri beslemeli bir ağda işlemci elemanlar genellikle katmanlara ayrılmış olup, işaretler giriş katmanından çıkış katmanına doğru tek yönlü bağlantılarla iletilmektedir (Saraç, 2004, 41). Bu ağlarda nöronlar girişten çıkışa doğru düzenli katmanlar şeklindedir ve bir katmandan sadece kendinden sonraki katmanlara bağ bulunmaktadır (Köktürk, 2012). İleri beslemeli yapay sinir ağları, öğrenme algoritması olarak genellikle geri yayılım öğrenme algoritmasını kullanmakta ve bu nedenle bazen geri yayılım ağları olarak da adlandırılmaktadır (Baş, 2006, 41).

1.7.1.5.2. Geri Beslemeli Yapay Sinir Ağları

Bir geri beslemeli yapay sinir ağı, çıkış ve ara katman çıkışların, giriş birimlerine veya önceki ara katmanlara doğru geri beslendiği bir ağ yapısıdır. Dinamik bir hafızaya sahip bu ağlarda girişler hem ileri hem de geri yönde aktarılırken, bir andaki çıkış hem o andaki hem de önceki girişleri yansıtır (Sağıroğlu vd., 2003). Yani ileri beslemeli ağların aksine bir nöronun çıktısı sadece kendinden sonra gelen nöron katmanına girdi olarak verilmemekte, kendinden önceki katmanda veya kendi katmanında bulunan herhangi bir nörona girdi olarak bağlanabilmektedir (Köktürk, 2012). Yinelemeli yapay sinir ağları adıyla da anılan geri beslemeli yapay sinir ağları, karmaşık bir çalışma düzeneğine sahip olmalarına rağmen, dinamik hafızaları nedeniyle önceden tahmin uygulamalarında başarılı sonuçlar vermektedir (Baş, 2006, 42).

1.7.2. Karar Ağaçları

Verileri farklı özelliklere göre sahip olduğu değerlerle sınıflandırmaya yarayan karar ağaçları, belirli karar adımları üzerinden, bir veri kümesini küçük gruplara bölmek için kullanılan ve her bölme işleminin ardından gruplarda bir araya gelen elemanları birbirine daha benzer hale getiren bir yöntemdir (Berry & Linoff, 2004; Sun & Hui, 2008).

Karar ağacı doğal bir ağaç şeklinde kök, dal ve yapraklardan oluşmaktadır. Akış şemasına benzeyen yapıdaki karar ağacında niteliklerin her biri bir düğüm ile temsil edilmektedir. Ağaçta bulunan en son yapı “yaprak”, en üst yapı “kök” ve bunların arasında kalan yapılar ise “dal” olarak isimlendirilir (Quinlan, 1993; Akt. Özkan, 2013, 53; Akpınar, 2014). Karar ağacı uygulamasında verilere ilişkin birçok sorular sorulmakta, alınan cevaplara dayalı olarak sonuca ulaşılmaya çalışılmaktadır. Kök düğümünden başlayarak yukarıdan aşağıya, genelden özele eğitilmiş verilerden karar ağaçları türetilmektedir (Oğuzlar, 2004). Bu süreçteki temel mantık, ilgili grubun her aşamada daha homojen iki alt gruba ayrılması üzerine kuruludur. Soru cevap sürecinde alınan yanıtlara dayalı olarak karar kuralları oluşturulmakta ve kök düğümünden itibaren başlayan sınıflandırma işlemi dalları olmayan düğümler veya yapraklar bulunana kadar, bir başka deyişle istatistiksel olarak anlamlı bir farklılığa ulaşıncaya kadar devam etmektedir (Thomas, 2000; Köktürk, 2012).

Karar ağacında sınıflama yapmada kullanılan testi belirten “karar düğümleri” bulunmaktadır. Karar düğümleri testleri ve dallara ayrılma işlemlerini ardışık olarak gerçekleştirmektedir. Ağacın her bir dalı sınıflama işlemini tamamlamaya aday olup, sınıflama işleminin gerçekleşmediği durumda bir karar düğümü oluşmaktadır. Eğer bir sınıfa ulaşıldıysa o dalın sonunda veri üzerinde belirlenmek istenen sınıflardan biri olan yaprak vardır. Bu işlemler en yukarıdaki kök düğümünden başlayıp en aşağıdaki yapraklara ulaşıncaya kadar sürekli devam etmektedir (Özekes, 2003).

Karar ağacı uygulaması, birinci adımı “öğrenme” ikinci adımı “sınıflama” olmak üzere iki yapılı bir düzende işlemektedir. Öğrenme basamağında önceden bilinen bir eğitim verisi, model oluşturmak amacıyla sınıflama algoritması tarafından analiz edilmektedir. Öğrenilen model de sınıflama kuralları veya karar ağacı olarak

gösterilmektedir. Sınıflama basamağında ise test verisi sınıflama kurallarının veya karar ağacının doğruluğunu belirlemek amacıyla kullanılmaktadır. Analizler sonucunda elde edilen doğruluk kabul edilebilir oranda olursa kurallar yeni verilerin sınıflanması amacıyla kullanılmaktadır. Bu kabul edilebilirlik oranı bilinen sınıf ve tahmin edilen sınıfın karşılaştırılması ile elde edilmektedir (Özekes, 2003; Argüden ve Erşahin, 2008; Kıran, 2010; Köktürk, 2012; Silahtaroğlu, 2013).


Sınıflandırma amacıyla kullanıldığı zaman, genellikle “sınıflandırma ağacı”, regresyon amacıyla kullanıldığı zaman ise “regresyon ağacı” olarak adlandırılan karar ağacı algoritmalarının (Rokach & Maimon, 2008), bir probleme uygulanabilmesi için olayların ve nesnelerin belli özellik değerleri ile ifade edilmesi ve sınıfları belirlemede etki edecek ayırıcı özelliklerin bulunması gerekmektedir (Altıntaş, 2010).

Silahtaroğlu (2013), karar ağaçlarının daha net anlaşılması için matematiksel ve şekilsel açıdan şöyle tanımlamıştır:

$D = \{ t_1 \dots t_n \}$ bir veri tabanı olsun.

Buradaki her t_i , $t_i = \langle t_{i1} \dots t_{i2} \rangle$ den oluşmaktadır ve bu veri tabanı $\{ A_1, A_2 \dots A_n \}$ alanlarından oluşmaktadır.

Bunun dışında, $C = \{ C_1 \dots C_n \}$ kadar da sınıf verilmiş olsun. Bu durumda bir karar ağacı aşağıdaki şekilde birlikte ifade edilebilir:



Şekil 1. 6. Örnek karar ağacı

- Her bir düğümü A_i alanıyla isimlendirilmiş
- Her düğümden ayrılan kollar bu alanla ilgili bir soruya yanıt veren
- Her yaprağın bir sınıf olduğu araçtır (Dungam, 2003).

Şekildeki örnek karar ağacındaki $A_1, A_2 \dots A_n$ 'dan her biri bir düğümü oluşturmaktadır. Her düğüm ise kendinden sonra iki dala ayrılmaktadır. Bu ayrılma işlemi sürecinde A_i düğümü hakkında cevabı veri tabanında bulunacak bir soru sorulmakta ve verilen yanıtta göre bir dal izlenmektedir. Ağaçtaki $C_1 \dots C_n$ 'lerin her biri birer yapraktır ve aynı zamanda bir sınıfı temsil etmektedir.

Karar ağacı algoritmaları istatistik, ekonometri, işletme, muhasebe, yönetim, bilişim, mühendislik, tıp, bankacılık gibi pek çok alanda farklı uygulamalarla kullanılmaktadır (Gülpınar, 2008; Altıntaş, 2010; Kıran, 2010; Kuyucu, 2012; Kuzey, 2012; Ulusoy, 2013; Alıç, 2014; Büyükişıklar, 2014; Uysal, 2014; Yücesoy, 2014). Karar ağaçları kullanılarak farklı alanlarda gerçekleştirilen uygulamalar aşağıdaki gibi sıralanabilir (Masseglia vd., 1999; Akpınar, 2000; Oğuzlar, 2004; Omिताomu, 2006; Köktürk, 2012):

- Bir sınıfın üyelerinin belirlenmesi,
- Belirlenmiş alt grupların sahip olduğu ilişkilerin tespiti,
- Çeşitli vakaların düşük, orta ve yüksek gibi kategorilere atanması,
- Kategorilerin birleştirilmesi ve sürekli değişkenlerin kesikli değişkenlere dönüştürülmesi,
- Bir grup değişkenden en önemli olanlarının seçilerek, parametrik modellerin kurulması,
- Olayların tahmininde kurallar oluşturulması,
- Kredi talep eden bireylerin geçmişinden hareketle kredi verilmesi,
- Tıbbi gözlem verilerinden yararlanarak en etkin kararların alınması,
- Daha önce bir çalışma birimine en çok faydası olan bireylerin özelliklerinden hareketle oraya birey seçim sürecinin oluşturulması,
- Satışları etkileyen değişkenlerin belirlenmesi,
- Ürün hatalarına yol açan değişkenlerin belirlenmesi,
- Üretim verilerinden hareketle ürün hatalarının belirlenmesi.

1.7.2.1. Karar Ağaçlarının Avantajları ve Dezavantajları

Tanımlayıcı ve tahmin edici özellikleri bulunan karar ağaçları yöntemi, alanyazında yaygın olarak kullanılan bir sınıflama algoritmasıdır. Yöntemin bu kadar yaygın olarak kullanılmasında sıralanabilecek pek çok özellik bulunmaktadır (Agrawal vd., 1993; Frank & Witten, 1998; Haughton & Oulabi, 1999; Akpınar, 2000; Doğan ve Özdamar, 2003; Vahaplar, 2003; Temel vd., 2005; Ayık vd., 2007; Bramer, 2007; Türe vd., 2009; Kavzoğlu ve Çölkesen, 2010; Köktürk, 2012):

- Kolay yorumlanabilmektedir.
- Kuralları anlaşılabilir ve sadedir.
- Yüksek güvenilirliklere sahiptir.
- Olayları bir ağacın yaprakları şeklinde görselleştirerek sunmaktadır.
- Veri tabanı sistemleri ile kolay bir şekilde bütünleşebilmektedir.
- Karmaşık yapıdaki büyük verilerde iyi çözümler sunmaktadır.
- Hiçbir varsayım gerektirmemektedir.
- Sınıflandırmaları yoğun hesaplamalar olmadan yapabilmektedir.
- Değişkenlerin sürekli ya da kesikli olması durumunda da kullanılabilir.
- Sınıflandırmalarda en önemli alanları net şekilde açıklamaktadır.

Karar ağacı uygulamalarının avantajları dışında bazı dezavantajlı yönleri de bulunmaktadır. Bunlar (Köktürk, 2012; Akpınar, 2014; Büyükişıklar, 2014);

- Algoritmalar eğitim verisini çoğu zaman genelleştiremediğinden dolayı ezberle öğrenme yoğun olmakta, bu da budama yöntemlerinin etkin kullanımını gerektirmektedir.
- Sürekli değişkenlerin değerlerini tahmin etme konusunda iyi sonuçlar vermemektedir.
- Sınıf sayısının çok, öğrenme kümesi örneklerinin az olduğu durumlarda model oluşturmada iyi sonuçlar vermemektedir.

1.7.2.2. Karar Ağacı Algoritmaları

Karar ağacı oluşturulurken göz önünde bulundurulması gereken en kritik durumlardan biri kullanılacak algoritmanın ne olduğunun belirlenmesidir (Kıran, 2010; Köktürk, 2012; Özkan, 2013). 1950'li yıllardan başlayarak geliştirilen algoritmalar kullanılan ölçü skalası, her düğümde ortaya çıkan yeni düğümlerin sayısı, ağacın büyümesini durdurma kriteri, en iyi bölen özneliğin seçilmesi ve budama süreci gibi temel özellikler açısından birbirinden ayrılmaktadır (Akpınar, 2014). Seçilecek algoritma ağaçtaki dallanmanın hangi ölçütlere göre yapılacağını belirleyecek, farklı ağaç yapıları da farklı sınıflandırmalar yapacaktır (Silahtaroglu, 2013). Alanyazında geliştirilmiş birçok uygulama bulunmaktadır (Özkan, 2013; Silahtaroglu, 2013; Akpınar, 2014).

- ID3 (Iterative Dichotomiser 3), C4.5 ve C5.0.
- SLIQ (Supervised Learning in Quest)
- SPRINT (Scalable Parallelizable Induction of Decision Trees)
- CART (Classification and Regression Trees)
- CHAID (Chi-Squared Automatic Interaction Detector)
- CLS (Concept Learning System)
- AID (Automatic Interaction Detection)
- QUEST (Quick, Unbiased, Efficient Statistical Tree)
- MARS (Multivariate Adaptive Regression Splines)

Bu araştırmada parametrik olmaması, verinin normal dağılması gibi bir zorunluluk taşımaması, çoklu ağaçlar üretebilmesi ve bütün ölçü skalaları ile çalışabilmesi gibi özellikleri nedeniyle en sık kullanılan ve en popüler algoritmalarından olan CHAID algoritması (Akpınar, 2014) kullanılmıştır.

Araştırmanın bu bölümünde öncelikle alanyazında öne çıkan bazı algoritmalar kısaca anlatılmış, daha sonra CHAID algoritması ayrıntılı olarak açıklanmıştır.

1.7.2.2.1. ID3 Algoritması

Ross Quinlan tarafından 1986 yılında açıklanan algoritma, makine öğrenimi ve doğal dil işleme alanlarında yaygın olarak kullanılmıştır. C4.5 algoritmasının öncülü olan bu algorithmada, bölen özneliğin seçilmesinde entropi veya gini indeksi kullanılmaktadır (Akpınar, 2014). Ağaçta yer alan her bir düğüm kökten itibaren dikkate hiç alınmamış özellikler içinden en kazançlısı seçilerek belirlenmektedir. Böylelikle bir kayıtn hangi sınıfa girdiği birkaç soruyla oluşan küçük karar ağaçları ile belirlenebilmektedir (Altıntaş, 2010). Basit bir yapıdaki ID3 algoritması hem akademi hem de sanayi alanında farklı sorunların çözümü üzerine geliştirilmiş ve yaşadığı değişimlerle yaygın bir kullanım alanına sahip olmuştur (Gülpınar, 2008).

1.7.2.2.2. C4.5 Algoritması

1993 yılında yine Ross Quinlan tarafından yayımlanan algorithmada, verilerin yinelemeli olarak alt kümelere ayrılmasıyla bir sınıflama ağacı oluşturulmaktadır (Sezer, 2008; Kıran, 2010). Bu algoritma ID3 algoritmasına ek olarak hem kategorik hem de sürekli öznelik değerlerini işleyebilmekte, kayıp verileri hesaba katmamakta, böylece daha duyarlı ve daha anlamlı kurallar çıkartabilen bir ağaç üretebilmektedir (Dunham, 2003; Akt. Silahtarolu, 2013; Akpınar, 2014).

1.7.2.2.3. C5.0 Algoritması

C5.0 algoritması, kendisinin öncülü niteliğinde olan ID3 ve C4.5 algoritmalarına göre gözle görülür bir şekilde hızlı bir yapıya sahiptir. C5.0'ın daha etkin bellek kullanımıyla küçük karar ağaçlarının üretilmesi ve faydasız öznelikleri eleyen winnowing özelliği algoritmayı daha önceki algoritmalarından ayıran en önemli özelliklerdir (Akpınar, 2014). Ayrıca C5.0 büyük veri tabanlarında C4.5'e göre daha etkili sonuçlar üretmektedir (Gülpınar, 2008).

1.7.2.2.4. SLIQ Algoritması

Hem sayısal hem de kategorik verilerin sınıflandırılmasında kullanılan algoritma, ağaç oluşturma sürecinde verileri değerlendirirken maliyeti azaltmak için sıralama tekniği kullanılır. Sıralama ile ağacı en iyi dallara ayırma kriterini bulmak

hedeflenir. Bu algoritma ağacı dallara ayırmada hızlı olmasının yanı sıra çok iyi sonuçlar veren karar ağaçları da üretebilmektedir (Sezer, 2008; Kıran, 2010; Silahtaroglu, 2013). Algoritmanın en önemli özelliklerinden biri de bellekte tutulması zor olan çok büyük veri gruplarına da uygulanabilmesidir (Atılğan, 2011).

1.7.2.2.5. SPRINT Algoritması

SPRINT algoritması, sınıf ve kayıt numaralarını tutan farklı bir liste ile değişkenlere ait bir sınıf ve sıra numarası belirler (Sezer, 2008). Ağaç oluşturma sürecinde eğitim kümelerinden elde edilen ilk listeler sınıflandırma köküyle ilişkilendirilmekte, ağaç büyüyüp düğümler yeni dallara bölündükçe düğümlere ait değişken listeleri de bölünerek yeni dallarla ilişkilendirilmektedir (Silahtaroglu, 2013).

1.7.2.2.6. CART Algoritması

CART ya da C&RT adlarıyla bilinen bu algoritma ikili ağaçlar üreterek hangi düğümün kök ya da düğüm olacağına karar vermekte, belirlenen düğümün hangi noktadan ikiye ayrılacağını da hesaplamaktadır. Algoritma bu süreçte hem dallara ayırmada en uygun değişkeni bulmakta hem de değişken ikiden fazla farklı türde değerler taşıyorsa hangi şekilde iki gruba ayrılacağını da belirlemektedir (Yohannes & Webb, 1991; Akt. Silahtaroglu, 2013).

Genellikle tıp, mühendislik ve endüstri alanlarına kullanılan algoritma ağacının oluşturulması, budanması ve en uygun ağaç seçimi basamaklarıyla yürütülmektedir (Chang & Wang, 2006). Bağımlı değişken ile bağımsız değişken arasındaki ilişkinin yapısını araştırmanın yanında, bağımsız değişkenlerin birbirleri ile olan etkileşimlerini de ortaya koyan CART algoritması, bağımsız değişkenlerin bağımlı değişkenle ilişkisini değerlendirme ve model içindeki etkileşim durumunu ortaya koyma konusunda da etkilidir (Kıran, 2010). Ayrıca algoritma oluşturduğu modelin sınanmasına ve optimal modelin seçilmesine fırsat sunması bakımından önemli bir avantaja sahiptir (Ulusoy, 2013).

1.7.2.2.7. CHAID Algoritması

1980 yılında ortaya atılan algoritma, parametrik olmaması, verilerin normal dağılması gibi bir zorunluluk taşımaması, eksik değerleri ayrı bir kategoride analiz edebilmesi gibi oldukça avantajlı esnekliklere sahiptir (Rokach & Maimon, 2008; Akpınar, 2014). En popüler karar ağacı algoritmalarının başında gelen CHAID (CH-i-squared Automatic Interaction Detection), analizlerde çapraz tablolar ve istatistiksel önem oranlarından faydalanmaktadır (Pehlivan, 2006). Karar ağacının istatistikte bilinen ki-kare testine dayanarak oluşturulması, algoritmaya hem bir karar ağacı algoritması hem de istatistiğe dayalı bir algoritma olma özelliği vermektedir (Silahtaroglu, 2013, 104). CHAID algoritmasının çoklu ağaçlar türetebilmesi, algoritmayı ikili ağaçlar türeten ID3, C4.5 ve CART algoritmalarından ayıran en önemli farklılıktır (Türe vd., 2009). Bununla birlikte sürekli ve kategorik tüm değişken tipleriyle çalışabilen CHAID algoritmasında sürekli tahmin edici değişkenler analizin amacına uygun şekilde otomatik olarak kategorize edilebilmektedir. Uygun bir istatistiksel kriter kullanılması durumunda oluşturulan modelin çok güçlü sonuçlar üretmesi sağlanacaktır (Köktürk, 2012).

CHAID analizinin temel amacı, kategorik değişkenlere ilişkin veri kümesini ve bağımlı değişkeni en iyi açıklayabilecek şekilde ayrıntılı homojen alt gruplara bölmektir (Breiman vd., 1984; Doğan ve Özdamar, 2003). Küçük tahmin edici gruplardan oluşan bu alt kümeler, en iyi tahmin sonucunu elde etmek için bağımsız olarak yeniden kategorileştirilir. Benzer kategorileri adımsal olarak birleştirmede ki-kare istatistiği kullanılmakta olup, bu işlem değişkenler arasında istatistiksel olarak daha fazla birleştirme sağlanamayacağına karar verilinceye kadar devam etmektedir. Değişkenlerin bölünmeye uygun olup olmadığına Bonferroni düzeltilmiş p değeri kullanılarak karar verilir (Doğan ve Özdamar, 2003).

Doğan ve Özdamar (2003), CHAID analizinin adımlarını ayrıntılı olarak şöyle açıklamışlardır:

Adım 1.

Her bir bağımsız değişken için, bağımlı değişkenin kategorileri ile bağımsız değişkenin kategorileri arasında çapraz tablo oluşturulur.

Adım 2.

2xd alt tablosunda bağımsız değişkene ait anlamlılığı en düşük olan kategori çiftleri bulunur. Birleşmeleri anlamlı bulunan iki kategori birleştirilir. Bu birleşme bir birleşik kategori olarak düşünülür ve bu adım bağımsız değişkenin kendi içindeki birleşmeleri anlamsız oluncaya kadar devam eder.

Adım 3.

Üç ya da daha çok sayıda orijinal kategori içeren birleşik kategorilerin her biri için birleşmenin tekrar çözümlendiği en önemli iki bölünme bulunur. Eğer anlamlılık bir kritik değerin altındaysa bölünme tamamlanarak ikinci adıma dönülür.

Adım 4.

Optimum düzeyde birleştirilen bağımsız değişkenlerin her birinin anlamlılığı hesaplanır. En çok anlamlı olan ayrılır. Eğer bu anlamlılık kritik bir değerden büyükse seçilen bağımsız değişkenin birleştirilen kategorilerine göre veri alt gruplara bölünür.

Adım 5.

Henüz analiz edilmemiş veri için birinci adıma gidilir.

CHAID analizi seçilen her bir çift için elde edilen p değerinin belli bir birleştirme eşik değerinden büyük olup olmama durumunu kontrol etme olarak da ifade edilmektedir. Yanıtın pozitif olması halinde birleştirme gerçekleştirilmekte ve birleştirme için potansiyel yeni çiftler aranmaktadır. Mevcut düğümü bölmek için kullanılan en iyi değişken seçilmekte ve böylelikle homojen alt gruplar oluşturulmaktadır. En iyi girdinin özneliliğinin düzeltilmiş p değerinden küçük olması durumunda ise artık bölme işlemi gerçekleştirilmemektedir (Rokach & Maimon, 2008, 72). Bu süreç aşağıdaki şartlardan birinin sağlanması halinde de durmaktadır:

- Maksimum ağaç derinliğine ulaşılması,
- Üst düğüm olmak için düğümdeki minimum sayıda duruma ulaşılması ve daha fazla bölünme olmaması,
- Alt düğüm olmak için düğümdeki minimum durumlar sayısına ulaşılması.

1.7.3. Ayırma Analizi

Diskriminanz kavramı ilk olarak 1851 yılında James Joseph Sylvester tarafından kullanılmıştır (Akpınar, 2014, 189). İstatistiksel bir yöntem olarak ise 1936 yılında Ronald A. Fisher tarafından "The Use of Multiple Measurements in Taxonomic Problems" isimli makalede ilk kez tanıtılan ayırma analizi (Albayrak 2006, Akpınar, 2014, 189), başlangıçta sadece iki grubun ayrılmasını sağlayabiliyor iken; günümüzde hesaplama gücünün artması ile daha fazla kategoriye veri dizisinin ayrılmasını sağlamaktadır. Roy'un (1939) p değişkenli iki normal dağılım için kovaryans matrislerinin eşitliğini test eden çalışmaları, Welch'in (1939) yanlış sınıflandırmanın minimuma indirildiğinde en iyi ayırmanın elde edileceğini ortaya koyan çalışmaları, Rao'nun (1948) ikiden çok grup olduğunda bireyleri minimum hata ile sınıflandırma üzerine çalışmaları, Anderson ve Bahadur'un (1962) farklı ortalamalı ve farklı varyans kovaryans matrisli çok değişkenli normal yığının gruplara ayrılması üzerine çalışmaları ve Hotelling ve Mahalanobis'in benzer çalışmaları ayırma analizinin tarihçesini oluşturmaktadır (Ünal, 2006).

Çok değişkenli analiz yöntemlerinden biri olan ayırma analizi, X veri setindeki değişkenlerin iki veya daha fazla gerçek gruplara ayrılmasını sağlayan ve birimlerin incelenecek p tane özelliğini ele alarak doğal ortamdaki gerçek gruplarına optimal düzeyde atanmalarını sağlayacak ayırma fonksiyonları türeten bir yöntemdir (Özdamar, 2010). Araştırmalarda herhangi bir gruba üye olmayı yordamak için oluşturulan modellerde kullanılan ayırma analizi (Çokluk vd., 2012), özelliği bilinen p tane birimin, sahip oldukları özelliklere göre alt kategorilere ayrılması istendiğinde kullanılır.

Ayırma analizinde hedeflenen, gruplarda yer alan bireyler arasındaki farklılıkları maksimum yapan değişkenlerin doğrusal birleşiminden oluşan, bir ya da daha fazla sayıda fonksiyonun belirlenmesidir (Çakmak, 1992). Temelde iki amacı bulunan ayırma analizi ile ilk olarak grupları birbirinden ayıran fonksiyonlar bulunur, daha sonra ise bulunan fonksiyonlar aracılığı ile yeni gözlenen bir birimin sınıflama hatası minimum olacak biçimde gruplardan birine atanması sağlanır (Güzeller ve Kelecioğlu, 2006). Ayırma analizinin bu iki işlevinden dolayı bazı yazarlarca farklı isimlerle anılması uygun görülmüştür. Örneğin, eğer ayırma analizi bir ayırma fonksiyonu belirlemeye yönelik olarak uygulanmış ise Belirtici

Ayırma Analizi, eğer sınıflama amacıyla uygulanmış ise Tahmin Edici Ayırma Analizi gibi isimlerle anılmaktadır (Özdamar, 2010). Tanımlayıcı/belirtici ayırma analizi, ayırma fonksiyonlarını saptayıp bu fonksiyonlar aracılığı ile gruplar arası farklılığı en fazla ortaya çıkaran ayırıcı değişkenleri belirlemeyi, tahmin edici ayırma analizi ise grubu bilinmeyen bir birimin hangi gruba dahil edileceğini tahmin etmeyi sağlar (Grimm & Yarnold, 1995; Tatlıdil, 1996; Özdamar, 2002; Akt. Güzeller ve Kelecioğlu, 2006). İki veya daha fazla sayıdaki grubun farklılıklarının ayırma değişkenleri vasıtasıyla ortaya konması işlemi olan ayırma analizi, birbiriyle yakından ilişkili birkaç istatistiksel yaklaşımı kapsayan geniş bir kavramdır (Klecka, 1980).

1.7.3.1. Ayırma Analizinin Amaçları

İki ya da daha çok grubun birbirinden en doğru biçimde ayrılmasına hizmet eden ayırma analizini kullananlar, grupların en fazla ilişkili olduğu değişkenleri açıklamak ve tahmin etmek, bunun yanında bu değişkenlerin grup üyeliğini tahmin edebilme düzeyini ortaya koymayı isterler (Akgül ve Çevik, 2003). Tek faktör çok değişkenli varyans analizinin bir uzantısı olan ayırma analizi gruplar arası farklılıkların temel nedenlerini ortaya çıkarır (Tabachnick & Fidell, 2001).

Özdamar (2010), ayırma analizinin kullanıldığı bir durum için şu örneği vermiştir:

Tıpta, birbirlerine yakın özellikler (semptomlar) taşıyan A, B, C gibi hastalıklar bulunduğunu varsayalım. Her hastalığın p özelliğine göre bir karakteristik yapısı vardır. Ayırma analizi ile her hastalığın p değişkene göre diğer hastalık/hastalıklardan farklılığını ortaya koyan ve grup özelliklerini belirleyen fonksiyonlar geliştirmek mümkündür. Böylece yeni gözlenen (n+1). hastanın x gözlem vektörünün hangi grup özelliğini taşıdığını (hangi hastalık tanısına sahip olabileceğini) belirlemek ve doğru sınıfa atamak (olasılı olarak doğru sınıfa koymak) ayırma analizi ile yapılabilir.

Teorik olarak her grubun temel özellikleri (grup profili, grup ortalamalar vektörü) vardır. Her grup bu temel özelliklerine göre tanımlanır ve bilinir. Doğada bazı grupların bazı özellikleri birbirine benzerlik gösterirken bazı özellikler farklılık gösterirler. g grupta p özellik ölçüldüğünde k özellik birbirine benzer ya da yakın parametrik değerlere sahip iken $h=p-k$ özellik, grupları birbirinden ayıracak küçük de olsa farklılıklara sahip olur.

Alanyazında ayırma analizinin kullanım amaçları için farklı tanımlamalar yer almaktadır. Örneğin;

Ayırma analizi aşağıda belirtilen amaçlar için uygulanabilir (Garson, 2008; Akt. Çokluk vd., 2012):

- Ayırma fonksiyonu ile birey veya birimleri alt gruplarına sınıflamak,
- Gerçekleştirilen tahminlerle birey ya da birimleri sınıflamaya ilişkin hipotezleri değerlendirmek,
- Gruplar arasında bulunan farklılıkları incelemek,
- Grupları ayırmada en tutucu (parsimonious) yolu araştırmak,
- Yordanan değişken üzerinde, yordayıcı değişkenler tarafından açıklanan varyansın oranını tespit etmek,
- Yordayıcı değişkenlerin bir değişkeni yordamada sahip oldukları önem düzeylerini karşılaştırmak,
- Grupları ayırma sürecinde önem düzeyi düşük olan yordayıcı değişkenleri çıkarmak.

Albayrak (2006) ise ayırma analizinin amaçlarını şu şekilde belirtmektedir (Burmaoğlu, 2009):

- İki ya da daha fazla grubun ortalama değerlerinin ayırma amacıyla kullanılacak değişkenlere göre anlamlı farklılık gösterme durumunu incelemek,
- Grupları birbirlerinden ayırmada etkili olan değişkenleri önem derecelerine göre incelemek,
- Ayırma yapmada kullanılan değişkenlere göre birimleri ayırma değerleri açısından sınıflamak için süreci ele almak,
- Yordayıcı değişkenlerin şekillendirdiği gruplar arasındaki ayırım durumunun yapısını ve sayısını incelemek,
- Sınıflandırma uygunluğunun değerlendirmesini yapmak.

Her bireyin, bir ya da daha fazla nicel değişkene ilişkin puan ya da puanlara ve grup üyeliğini gösteren sınıflamalı (kategorik) değişkene ilişkin bir değere sahip olmasının gerektiği ayırma analizi, sayıltılarının karşılanması durumunda, güçlü temelleri olan bir istatistiksel bir yöntemdir (Çokluk vd., 2012). Aşağıda ayırma analizinin sayıltılarına yer verilmiştir (Johnson & Wichern, 1992; Tabachnick & Fidell, 2001; Anderson, 2003; Çokluk vd., 2012).

1.7.3.2. Ayırma Analizinin Sayıltıları

➤ **Normal dağılım;**

Ayırma analizinde bağımsız değişkenler çok değişkenli normal dağılım göstermelidir. Her bir değişkenin ve bu değişkenlerin kombinasyonunun normal dağılım göstermesi çok değişkenli normal dağılımı da sağlayacaktır.

➤ **Örneklem büyüklüğü;**

Grupların örneklem büyüklüklerinin eşit olması gerekmemekle birlikte, en küçük olan grupta yer alan birey ya da birim sayısı, bağımsız (yordayıcı) değişken sayısından fazla olmalıdır.

➤ **Değişken seçimi;**

Grupları ayırmada faydalı olmayacak, gereğinden fazla ve gereksiz değişken bulunmamalıdır.

➤ **Varyans-kovaryans matrislerinin homojenliği;**

Analizde kullanılacak değişkenlerin varyans ve kovaryansları homojen olmalı, çalışmalarda grup içi varyanslar ve korelasyon matrisleri incelenmelidir.

Ayırma analizi grupların kovaryans matrislerinin eşit olup olmamasına göre farklı biçimlerde uygulanmaktadır. Her ne kadar ayırma analizinin temel varsayımlarından birisi grupların kovaryans matrislerinin birbirine eşit olduğu biçiminde olsa da bu varsayımın geçerli olmaması durumunda da ayırma analizi yapılabilmektedir (Özdamar, 2010).

➤ **Uç değerler;**

İstatistiksel analiz yöntemlerinin çoğu, uç değerlerin hem I. tip hem de II. tip hatalara neden olması ve sonuçların genellenebilirliğini düşürmesi nedeniyle bu varsayıma karşı hassastır. Gruplarda tek yönlü ve çok yönlü uç değerler incelenmeli ve bunlar ya dönüştürülmeli ya da çıkartılmalıdır. Evren özelliklerini yansıtan uç değerlerin dönüştürülmesi, evren özelliklerini yansıtmayan uç değerlerin ise çıkartılması gerekir.

➤ **Çoklu bağlantı;**

Değişkenler arasında çoklu doğrusal bağlantı (multicollinearity) bulunmamalıdır.

Açıklanan bu varsayımlar ayırma analizi için kurulacak matematiksel modelin gerçek sonuçları yansıtması için oldukça önemlidir. Analiz öncesinde bu varsayımlar test edilmeli ve süreç başlatılmalıdır.

Cangül (2006), ayırma analizi için karar sürecini 6 adımda açıklamıştır:

Adım 1	<i>Araştırma problemi</i> <i>Hedefleri seç</i> <i>Çok değişkenli bir profildeki grup farklılıklarını hesapla</i> <i>Gözlemleri gruplara göre sınıflandır</i> <i>Gruplar arasındaki ayırmanın boyutlarını belirle</i> <i>Araştırma dizaynı konuları</i>
Adım 2	<i>Bağımsız değişkenlerin seçimi</i> <i>Örnek boyutu gözlemleri</i> <i>Analizlerin ve çıktı örneklerinin yaratılması</i> <i>Varsayımlar</i>
Adım 3	<i>Bağımsız değişkenlerin normalliği</i> <i>İlişkilerin doğrusallığı</i> <i>Bağımsız değişkenler arasında çoklu ilişki olmayışı</i> <i>Eşit dağılım matrisleri</i>
Adım 4	<i>Ayrırma fonksiyonlarının tahmini</i> <i>Aynı anda ya da adım adım tahmin</i> <i>Ayrırma fonksiyonlarının tahmini</i> <i>Sınıflandırma matrisleri yardımıyla tahmin kesinliğinin değerlendirilmesi</i> <i>Uygun kesme seviyesini belirle</i> <i>Başarı oranının değerlendirme kriterlerini belirle</i> <i>Tahminin kesinliğinin istatistiksel önemi</i> <i>Ayrırma fonksiyonlarının yorumlanması</i>
Adım 5	<i>Kaç tane fonksiyon yorumlanacak?</i> <i>Bir</i> <i>İki ya da daha çok</i> <i>Ayrı ayrı</i> <i>Bir tek fonksiyonun değerlendirilmesi</i> <i>fonksiyonların değerlendirilmesi</i> <i>Ayrırma ağırlıkları</i> <i>Ayrırma ağırlıkları</i> <i>Ayrırma yükleri</i> <i>Ayrırma yükleri</i> <i>Kısmi f değerleri</i> <i>Kısmi f değerleri</i>
Adım 6	<i>Diskriminant değerlerinin geçerlik kazanması</i> <i>Ayrık durumlar ya da çapraz geçerlilik kazanma</i> <i>Grup farklılıklarının profilini çıkarma</i>

Ayrırma analizi, temel amacı açıklayıcı değişkenlere göre belirlenmiş ayırma fonksiyonlarına göre gözlemleri iki ya da daha fazla gruba ayırmak, yeni gözlemleri optimal olarak bu gruplara atamayı sağlamak olan, doğrusal (linear) ayırma analizi ve karesel (quadratic) ayırma analizi şeklinde iki ana başlık altında incelenmektedir (Özdamar, 2010).

1.7.3.3. Doğrusal Ayırma Analizi

Doğrusal ayırma analizi ile X veri setindeki değişkenlerin iki ve daha fazla gerçek gruba ayrılmasını sağlayan, birimlerin p tane özelliğini ele alarak bu birimlerin doğal ortamdaki gerçek gruplarına, sınıflarına optimal düzeyde atanmalarını sağlayacak fonksiyonlar türetilmektedir (Hastie Buja, 1995; Hardle Simar, 2003; Akt. Öztürk, 2006). Tüm grupların kovaryans matrislerinin eşit olduğunu varsayan doğrusal ayırma analizi (Özdamar, 2010) ile türetilen bu fonksiyonlar gruplar arası farklılığa etki eden değişkenleri belirler. Doğrusal ayırma analizi hangi gruba ait olduğu belli olmayan birimlerin en düşük hata ile ait olduğu gruba atanması konusunda etkilidir.

Doğrusal ayırma analizi ile türetilen ayırma fonksiyonlarının gücü kovaryans matrislerinin eşit olmadığı durumlarda olumsuz etkilenmektedir. Marks ve Dunn (1974), ayırma analizi ile küçük örneklerde, gruplara ilişkin kovaryans matrisleri arasındaki farklılığın fazla olmadığı durumlarda, Fisher'in doğrusal ayırma fonksiyonunun karesel ayırma fonksiyonuna göre daha iyi sonuç verdiğini belirlemişlerdir (Wahl & Kronmal, 1977).

Doğrusal ayırma analizi, ayırma analizinin temel varsayımları olan normal dağılım, varyans kovaryans matrislerinin homojenliği, değişkenlerin ortalamaları ve varyansları arasında korelasyon bulunmaması, çoklu bağlantı ve gereksiz değişken bulunmaması gibi temel varsayımlara sahiptir (Öztürk, 2006).

Ayrıca doğrusal ayırma analizi bazı araştırmacılar tarafından ayırma fonksiyonu katsayılarının hesaplanmasında başvurulan yöntemlere göre eklenen sözcüklerle Kanonik Ayırma Analizi, En Büyük Benzerlik Ayırma Analizi, Bayes Ayırma Analizi isimleriyle de anılmaktadır (Özdamar, 2010).

1.7.3.4. Karesel Ayırma Analizi

Karesel ayırma analizi verilerin normal dağıldığı fakat varyans kovaryans matrislerinin benzer olmadığı durumlarda kullanılır (Öztürk, 2006; Özdamar, 2010). Bu amaçla grupların kovaryans matrislerinin eşit olup olmadığı Box's M testi veya Barlett testi ile veri setlerinde incelenmelidir.

Karesel ayırma analizinde katsayıların hesaplanmasında ortak kovaryans matrisi (S) yerine grupların kovaryans matrislerinin farkları (S_1-S_2) şeklinde alınır (Öztürk, 2006; Özdamar, 2010).

Karesel ayırma analizinin uygulanmasında S_i , varyans-kovaryans matrisinin tersinin alınabilmesi için her bir gruptaki gözlem sayısı (n), değişken sayısı (p)'den fazla olmalıdır. Ancak bu kısıtlayıcı durum, doğrusal ayırma için geçerli değildir (Rencher, 2002; Akt. Sangün, 2007).

2. İLGİLİ ARAŞTIRMALAR

Wheler (1993), A Comparative Case Study of Neural Network Analysis and Statistical Discriminant Function Analysis for Predicting Law Students Passing The Bar Examination adlı araştırmasında, yapay sinir ağları ile ayırma analizi yöntemlerinin hukuk fakültesi öğrencilerinin avukatlık sınavı başarılarını doğru sınıflandırma oranlarını karşılaştırmıştır. Bu sınıflandırmada 460 kişilik küçük bir örneklem kullanılmıştır. Sınıflandırma 2 alt gruba yönelik olarak gerçekleştirilmiştir. Araştırma sonucunda yapay sinir ağlarının %87,5, ayırma analizinin ise %77,78 oranında doğru sınıflandırma yaptığını belirlemiştir.

Gonzalez ve DesJardins (2002), Artificial Neural Networks: A New Approach to Predicting Application Behavior adlı araştırmalarında, çeşitli bağımsız değişkenlere dayalı olarak öğrencilerin hangi lisans programlarını tercih edeceklerini yordamaya çalışmışlardır. Bu sınıflandırmada 20000 kişilik büyük bir örneklem kullanılmıştır. Sınıflandırma 2 alt gruba yönelik olarak gerçekleştirilmiştir. Araştırma sonucunda yapay sinir ağının doğru sınıflandırma oranı %78, lojistik regresyon analizinin doğru sınıflandırma oranı ise %72 olarak belirlenmiştir.

Güneri ve Apaydın (2004), Öğrenci Başarılarının Sınıflandırılmasında Lojistik Regresyon Analizi ve Yapay Sinir Ağları Yaklaşımı adlı araştırmalarında, yapay sinir ağları ile lojistik regresyon analizinin doğru sınıflandırma oranlarını karşılaştırmışlardır. Bu sınıflandırmada 352 kişilik küçük bir örneklem kullanılmıştır. Sınıflandırma 2 alt gruba yönelik olarak gerçekleştirilmiştir. Araştırma sonucunda yapay sinir ağından elde edilen doğru sınıflandırma oranının, lojistik regresyon yönteminden elde edilen doğru sınıflandırma oranına eşit olduğu tespit edilmiştir.

Benli (2005), Bankalarda Mali Başarısızlığın Öngörülmesi Lojistik Regresyon ve Yapay Sinir Ağı Karşılaştırılması adlı araştırmasında, yapay sinir ağı ve lojistik regresyon analizi modellerini karşılaştırmıştır. Bu sınıflandırmada 38 kişilik çok küçük bir örneklem kullanılmıştır. Sınıflandırma 2 alt gruba yönelik olarak gerçekleştirilmiştir. Araştırma sonucunda yapay sinir ağı modelinin lojistik regresyon modelinden daha iyi öngörüde bulunduğunu tespit edilmiştir.

Türe ve diğerleri (2005), Hipertansiyonun Tahmini İçin Çoklu Tahmin Modellerinin Karşılaştırılması (Sinir Ağları, Lojistik Regresyon ve Esnek Ayırma Analizleri) adlı araştırmalarında, primer hipertansiyonun yordanmasında lojistik regresyon analizi, ayırma analizi ve yapay sinir ağı yöntemlerini karşılaştırmışlardır. Bu sınıflandırmada 276 kişilik küçük bir örneklem kullanılmıştır. Araştırma sonucunda yapay sinir ağı performansının lojistik regresyon analizi ve ayırma analizinden istatistiksel olarak daha iyi sonuçlar verdiği belirlenmiştir.

Sığırlı (2006), Sınıflandırma Probleminin Çözülmesinde Yapay Sinir Ağları İle Diskriminant Analizinin Karşılaştırılması Ve Bir Uygulama adlı araştırmasında iki yöntemin sınıflandırma başarısını hastaların kronik hepatit veya siroz hastalığına sahip olma durumları üzerinden karşılaştırarak incelemiştir. Bu sınıflandırmada 164 kişilik küçük bir örneklem kullanılmıştır. Sınıflandırma 2 alt gruba yönelik olarak gerçekleştirilmiştir. Araştırma sonucunda diskriminant analizinin doğru sınıflandırma oranının %93,94, yapay sinir ağının doğru sınıflandırma oranının ise %100 olduğunu belirlenmiş, yapay sinir ağının daha yüksek performans gösterdiği vurgulanmıştır.

Bayru (2007), Elektronik Basında Tüketici Tercihleri Analizi: Yapay Sinir Ağları İle Lojit Modelin Performans Değerlendirilmesi adlı araştırmasında, yapay sinir ağları ile lojit model arasındaki ilişkileri incelemiş ve her iki yöntemin performansını karşılaştırmıştır. Bu sınıflandırmada 1108 kişilik orta büyüğe yakın bir örneklem kullanılmıştır. Araştırma sonucunda yapay sinir ağı ile yapılan yordamaların, lojit modelden elde edilenlerden daha iyi olmadığı görülmüştür.

Tosun (2007), Sınıflandırmada Yapay Sinir Ağları ve Karar Ağaçları Karşılaştırması: Öğrenci Başarıları Üzerine Bir Uygulama adlı araştırmasında, yapay sinir ağları ile karar ağaçları yönteminin sınıflandırma performanslarını karşılaştırmıştır. Bu sınıflandırmada 424 kişilik küçük bir örneklem kullanılmıştır. Sınıflandırma 2 alt gruba yönelik olarak gerçekleştirilmiştir. Araştırma sonuçlarına göre yapay sinir ağları %91,77'lik başarı oranı ile %86 başarı oranına sahip karar ağaçları yönteminden daha iyi sonuçlar ortaya koymuştur.

İbrahim ve Rusli (2007), Predicting Students' Academic Performance: Comparing Neural Network, Decision Tree and Linear Regression adlı arařtırmalarında öğrencilerin akademik başarılarını yordamada karar ağacı analizi, doğrusal regresyon analizi ve yapay sinir ağlarının performansını karşılařtırmıřlardır. Bu sınıflandırmada 206 kişilik küçük bir örneklem kullanılmıřtır. Arařtırma sonucunda yapay sinir ağlarının diđer iki yöntemden daha başarılı sonuçlar verdiđi görülmüřtür.

Burmaođlu (2009), Birleřmiř Milletler Kalkınma Programı Beřeri Kalkınma Endeksi Verilerini Kullanarak Diskriminant Analizi, Lojistik Regresyon Analizi ve Yapay Sinir Ağlarının Sınıflandırma Başarılarının Deđerlendirilmesi adlı arařtırmasında, 120 kişilik ve varyans kovaryans matrislerinde homojenliđi sađlanmamıř çok küçük bir örneklem kullanılmıřtır. Sınıflandırma 2 alt gruba yönelik olarak gerçekleřtirilmiřtir. Arařtırmasında çok deđişkenli istatistik yöntemleri ile yapay sinir ağlarının sınıflandırma güçlerini karşılařtırmıř ve analizler sonucunda çok katmanlı algılayıcı modeli ile lojistik regresyon modelinin, diskriminant analizine göre daha iyi sınıflandırma yaptığını belirlemiřtir.

Çölkesen (2009), Uzaktan Algılamada İleri Sınıflandırma Tekniklerinin Karşılařtırılması ve Analizi adlı arařtırmasında, Gebze ilçesini kapsayan Landsat ETM+ (1997) ve Terra ASTER (2002) görüntülerini yapay sinir ağları, karar ağaçları ve k-star algoritmaları ile sınıflandırarak arazi örtüsü ve kullanımının belirlenmesini amaçlamıřtır. Bu sınıflandırmada 6000 ve 3750 kişilik orta büyüklükte örneklem kullanılmıřtır. Sınıflandırmalar 6 alt gruba yönelik olarak gerçekleřtirilmiřtir. Arařtırma sonucunda ileri sınıflandırma tekniklerinin uzaktan algılanmıř görüntülerin sınıflandırılmasında geleneksel sınıflandırıcılara göre iyi ve etkili bir alternatif olduklarını belirlemiřtir.

Albayrak ve Yılmaz (2009), Veri Madenciliđi: Karar Ağacı Algoritmaları ve İMKB Verileri Üzerine Bir Uygulama adlı arařtırmalarında, İMKB 100 endeksinde sanayi ve hizmet sektörlerinde faaliyet gösteren řletmelerin 2004-2006 yıllarına ait yıllık finansal göstergelerinden yararlanarak karar ağaçları tekniđi uygulamıřlardır. Bu sınıflandırmada 173 kişilik küçük bir örneklem kullanılmıřtır. Sınıflandırma 2 alt gruba yönelik olarak gerçekleřtirilmiřtir. Seçilen finansal göstergelere göre sanayi ve hizmet sektörlerinde faaliyet gösteren firmaları ayıran en önemli deđişkenler saptanmıřtır.

Kayri ve Çokluk (2010), Using Multinomial Logistic Regression Analysis in Artificial Neural Network: An Application adlı arařtırmalarında, arařtırmadaki bağımsız deęişkenlerin bağımlı deęişkeni ne ölçüde yordadığını belirlemek amacıyla, çoklu lojistik regresyon analizi ile yapay sinir ağı temelli çoklu lojistik regresyon analizi modellerinin sonuçlarını birbiriyle karşılaştırmışlardır. Bu sınıflandırmada 723 kişilik küçük bir örneklem kullanılmıştır. Sınıflandırma 3 alt gruba yönelik olarak gerçekleştirilmiştir. Araştırma sonucunda yapay sinir ağı temelli çoklu lojistik regresyon analizi modelinin, daha uygun ve doğru olduğuna karar vermişlerdir.

Kavzođlu ve Çölkesen (2010), Karar Ağaçları ile Uydu Görüntülerinin Sınıflandırılması: Kocaeli Örneđi adlı arařtırmalarında, karar ağaçlarının sınıflandırma performansını güncel bir Landsat ETM+uydu görüntüsü kullanılarak detaylı şekilde analiz etmişlerdir. Bu sınıflandırmada 600 kişilik küçük bir örneklem kullanılmıştır. Sınıflandırma 6 alt gruba yönelik olarak gerçekleştirilmiştir. Yaygın kullanıma sahip en çok benzerlik yönteminin performansı ile karşılaştırıldığında yöntemin sınıflandırma performansının karar ağaçlarının uydu görüntülerinin sınıflandırmasında etkin bir yöntem olduğunu belirlemişlerdir.

Kayri ve Günüş (2010), Türkiye'deki Ortaöğretim Öğrencilerinin İnternet Bağımlılık Düzeyini Etkileyen Bazı Faktörlerin Karar Ağaçları Yöntemi ile İncelenmesi adlı arařtırmalarında veri madenciliđi yöntemlerinden karar ağaçlarının sınıflandırma ağaçları ve Chaid analizi yöntemlerini karşılaştırmışlardır. Bu sınıflandırmada 754 kişilik küçük bir örneklem kullanılmıştır. Sınıflandırma 4 alt gruba yönelik olarak gerçekleştirilmiştir. Araştırma sonucunda her iki yöntemle yapılan sınıflamalarda farklı deęişkenlerin farklı etki büyüklüklerine sahip olduğunu tespit etmişlerdir.

Tepehan (2011), Türk Öğrencilerinin PISA Başarılarının Yordanmasında Yapay Sinir Ağı ve Lojistik Regresyon Modeli Performanslarının Karşılaştırılması adlı arařtırmada, kurulan modellerle her iki yöntemin öğrencileri doğru sınıflandırma performansını incelemiştir. Bu sınıflandırmada 4855, 4942 ve 4996 kişilik orta büyüklükte örneklemle kullanılmıştır. Sınıflandırmalar 2 alt gruba yönelik olarak gerçekleştirilmiştir. Araştırma sonucunda elde edilen oranlara göre yapay sinir ağı ile yapılan yordamaların lojistik regresyona göre daha doğru sonuçlar verdiği belirlenmiştir.

Köktürk (2012), K-En Yakın Komşuluk, Yapay Sinir Ağları ve Karar Ağaçları Yöntemlerinin Sınıflandırma Başarılarının Karşılaştırılması adlı araştırmasında, bu üç yöntemin sınıflandırma başarılarını Bülent Ecevit Üniversitesi Uygulama ve Araştırma Hastanesi Kadın Hastalıkları ve Doğum Polikliniği'ne başvuran, erken ve zamanında doğum yapan gebelerden elde edilen veri setine uygulayarak karşılaştırmıştır. Bu sınıflandırmada 240 kişilik küçük bir örneklem kullanılmıştır. Sınıflandırma 2 alt gruba yönelik olarak gerçekleştirilmiştir. Yapılan analizler sonucunda doğru sınıflandırma oranları, k-en yakın komşuluk analizi için %78,3, yapay sinir ağı tekniği için %90,8 ve karar ağacı yöntemi için ise %82,5 olarak bulunmuş ve yapay sinir ağı tekniğinin diğer iki yonteme göre sınıflandırma başarısının daha iyi olduğu görülmüştür.

Kaya ve diğerleri (2012), Epileptik EEG İşaretlerinin Sınıflandırılmasında Karar Kuralları ve Karar Ağaçlarının Kullanılması adlı araştırmalarında, Ayrık Dalgacık Dönüşümü ile EEG işaretlerinin spektral çözümü yapılmış ve elde edilen her bir spektral bileşenin istatistiksel bazı özellikleri baz alınarak karar ağaçları ve karar kuralları yöntemleri ile sınıflandırma işlemi gerçekleştirilmiştir. Bu sınıflandırmada 500 kişilik küçük bir örneklem kullanılmıştır. Sınıflandırma 2 ve 3 alt gruba yönelik olarak gerçekleştirilmiştir. Araştırma sonucunda karar ağaçları ve karar kuralları yöntemlerinin sınıflandırmada %96,6 ve %99,7'lik yüksek performanslar gösterdiği görülmüştür.

Çırak (2012), Yükseköğretimde Öğrenci Başarılarının Sınıflandırılmasında Yapay Sinir Ağları ve Lojistik Regresyon Yöntemlerinin Kullanılması adlı araştırmasında, her iki yöntemin öğrencileri doğru sınıflandırma performanslarını incelemiştir. Bu sınıflandırmada 419 kişilik küçük bir örneklem kullanılmıştır. Sınıflandırma 2 alt gruba yönelik olarak gerçekleştirilmiştir. Araştırma sonucunda yapay sinir ağı ile yapılan sınıflamanın lojistik regresyon analizi ile yapılandan daha yüksek oranda başarılı sonuçlar verdiği görülmüştür.

Alan (2014), Karar Ağaçlarıyla Öğrenci Verilerinin Sınıflandırılması adlı araştırmasında, karar ağaçları yöntemiyle Cumhuriyet Üniversitesi İktisadi ve İdari Bilimler Fakültesi öğrencilerine ait verileri kullanarak veri madenciliği yapmıştır. Bu sınıflandırmada 4106 kişilik orta büyüklükte bir örneklem kullanılmıştır. Sınıflandırma 2 alt gruba yönelik olarak gerçekleştirilmiştir. Araştırmada öğrencilere ait verilerden yararlanarak, hem bu verileri en başarılı sınıflandıran

karar ağaçlarına ait algoritma hem de bu algoritmanın üreteceği sınıflar tespit edilmeye çalışılmıştır. Araştırmanın sonucunda LADTree algoritmasının öğrenci verilerini sınıflandırmada en başarılı algoritma olduğu ve on dokuz değişik sınıf ürettiği anlaşılmıştır.

2.1. İlgili Araştırmalar Özet

İlgili araştırmalarda yapay sinir ağları, karar ağaçları ve ayırma analizi yöntemleri farklı yöntemlerle ve birbirleriyle ikili şekillerde karşılaştırılmıştır. Her bir yöntemin farklı araştırmalarda gösterdiği performanslar sunulmuştur. Farklı alanlarda yapılan araştırmalardan elde edilen başarılı sonuçlar yapay sinir ağları, karar ağaçları ve ayırma analizi yöntemlerinin her birinin eğitim alanında da başarılı bir şekilde kullanılabileceğini göstermektedir. Eğitim alanında yapılan araştırmalar farklı örneklem büyüklüklerinde olmaktadır. Bununla birlikte alandaki sınıflama çalışmaları farklı alt grup sayılarına yönelik olarak gerçekleştirilebilmektedir. Bu çalışma ile yöntemlerin farklı örneklem büyüklüklerinde ve farklı alt grup sayılarına sınıflama yapmada göstereceği performansın incelendiği, araştırmacılara üç yöntem hakkında yeni bilgiler sunacak bir araştırma planlanmıştır.

3. YÖNTEM

Bu bölümde araştırmanın türü, çalışma evreni, veri toplama araçları, verilerin elde edilmesi, verilerin işlenmesi ve çözümlenmesi konularına yer verilmektedir.

3.1. Araştırmanın Türü

PISA 2012 uygulamasından elde edilen verilerin kullanıldığı bu araştırma, gerçek hayattan ve günlük yaşamın içinden alınması ve araştırmada herhangi bir müdahaleye bağlı yapaylık söz konusu olmaması yönüyle saha araştırması (Kaptan, 1995); araştırmaya konu olan olayın sadece belirli bir zaman birimine yönelik olarak incelenmesi yönüyle kesitsel araştırma (Büyüköztürk vd., 2008) ve var olan bir olay ya da durumun var olduğu şekilde tanımlanması nedeniyle betimsel araştırma (Karasar, 2014) niteliğindedir.

3.2. Çalışma Evreni

Araştırmanın temel problemi ve alt problemleri göz önünde bulundurularak sınıflama yapılacak alt grup sayısı ve örneklem büyüklükleri birbirine bağlı şekilde belirlenmiştir. Sınıflama gruplarının oluşturulmasında PISA'nın belirlediği başarı düzeylerinden faydalanılmış ve örneklem 6, 3 ve 2 alt gruba sınıflama yapmaya uyacak şekilde seçilmiştir;

- **6** alt gruba yönelik sınıflama **Düzyey1/Düzyey2/Düzyey3/Düzyey4/Düzyey5/Düzyey6** şeklinde yapılmıştır. PISA sınıflamasında yer alan her bir başarı düzeyi bir grup oluşturmuştur.
- **3** alt gruba yönelik sınıflama **Alt Düzyey/Orta Düzyey/Üst Düzyey** şeklinde yapılmıştır. Alt Düzyey Grubu PISA'da Düzyey1 ve Düzyey2'de yer alan öğrencilerden oluşmaktadır. Orta Düzyey Grubu PISA'da Düzyey3 ve Düzyey4'te yer alan öğrencilerden oluşmaktadır. Üst Düzyey Grubu PISA'da Düzyey5 ve Düzyey6'da yer alan öğrencilerden oluşmaktadır.
- **2** alt gruba yönelik sınıflama **Alt Düzyey/Üst Düzyey** şeklinde yapılmıştır. Alt Düzyey Grubu PISA'da Düzyey1, Düzyey2 ve Düzyey3'te yer alan öğrencilerden oluşmaktadır. Üst Düzyey Grubu PISA'da Düzyey4, Düzyey5 ve Düzyey6'da yer alan öğrencilerden oluşmaktadır.

Araştırmanın evreni PISA 2012 Matematik uygulamasına katılan tüm ülkelerde eğitim gören 15 yaş grubu öğrencilerden oluşmaktadır. Bu uygulamaya tüm ülkelerden katılan toplam 485490 kişilik bir öğrenci örneklemini bulunmaktadır. Örnekleme yer alan öğrencilerin başarı düzeylerine göre dağılımı Tablo 3.1'de verilmiştir.

Tablo 3. 1.: PISA 2012 uygulamasına katılan tüm öğrencilerin başarı düzeylerine göre dağılımı

Düzyeyler	f	%
Düzyey1'den düşük	69691	14,4
Düzyey1	91369	18,8
Düzyey2	109383	22,5
Düzyey3	99016	20,4
Düzyey4	67520	13,9
Düzyey5	34652	7,1
Düzyey6	13859	2,9
Toplam	485490	100,0

Ancak araştırmada sınıflama amacıyla kullanılan bağımsız/yordayıcı değişkenler göz önünde bulundurularak, ilgili değişkenlerde eksik verisi bulunan öğrenciler araştırma dışı tutulmuş ve en büyük örnekleme oluşturan öğrenci sayısı 126126 olarak belirlenmiştir. Ayrıca 6, 3 ve 2 alt grup oluşturabilmek amacıyla bu

belirlemede birinci düzeyin altındaki öğrenciler de araştırma kapsamına alınmamıştır.

Araştırmanın büyük örneklemini temsil eden öğrencilerin başarı düzeylerine göre dağılımı Tablo 3.2’de verilmiştir.

Tablo 3. 2.: 126126 kişilik örneklemin başarı düzeylerine göre dağılımı

6 Alt Grup	f	%
Düzye1	26292	20,8
Düzye2	32893	26,1
Düzye3	30424	24,1
Düzye4	20917	16,6
Düzye5	11105	8,8
Düzye6	4495	3,6
Toplam	126126	100,0

Tablo 3.2’de görüldüğü üzere farklı örneklem büyüklükleri üzerinde karşılaştırma yapmak üzere en büyük örneklem 126126 kişi olarak seçilmiştir. Bununla birlikte 6186 kişilik orta büyüklükte, 603 kişilik küçük büyüklükte ve varyans-kovaryans matrislerinde homojenliğin sağlandığı ve sağlanmadığı 102’şer kişilik çok küçük örneklem de hazırlanmıştır.

Büyük, orta büyüklükte ve küçük örneklem hazırlanmasında sistematik örnekleme yönteminden faydalanılmıştır. Seçim yapmadan önce tüm öğrenciler en düşük başarı düzeyinden en yüksek başarı düzeyine doğru sıralanmıştır. Sıralamanın ardından her bir başarı düzeyinde 1000 öğrenci olacak şekilde bir çalışma yürütülmüş ve ilk olarak 6186 kişilik örneklem oluşturulmuştur.

Tablo 3. 3.: 6186 kişilik örneklemin oluşturulması ve başarı düzeylerine göre dağılımı

6 Alt Grup	f	%	Sistematik örnekleme
Düzye1	1012	16,4	1’inci kişiden başlayarak her 26’da bir kişi
Düzye2	1028	16,6	1’inci kişiden başlayarak her 32’de bir kişi
Düzye3	1015	16,4	1’inci kişiden başlayarak her 30’da bir kişi
Düzye4	997	16,1	1’inci kişiden başlayarak her 21’de bir kişi
Düzye5	1010	16,3	1’inci kişiden başlayarak her 11’de bir kişi
Düzye6	1124	18,2	1’inci kişiden başlayarak her 4’te bir kişi
Toplam	6186	100,0	

Sıralamanın ardından her bir başarı düzeyinde 100 öğrenci olacak şekilde bir çalışma yürütülmüş ve 603 kişilik küçük örneklem oluşturulmuştur.

Tablo 3. 4.: 603 kişilik örneklemin oluşturulması ve başarı düzeylerine göre dağılımı

6 Alt Grup	f	%	Sistematiik örnekleme
Düze1	100	16,6	1'inci kişiden başlayarak her 262'de bir kişi
Düze2	100	16,6	1'inci kişiden başlayarak her 328'de bir kişi
Düze3	101	16,7	1'inci kişiden başlayarak her 304'te bir kişi
Düze4	101	16,7	1'inci kişiden başlayarak her 209'da bir kişi
Düze5	101	16,7	1'inci kişiden başlayarak her 111'de bir kişi
Düze6	100	16,6	1'inci kişiden başlayarak her 45'te bir kişi
Toplam	603	100,0	Toplam 603

Bu örneklemler dışında varyans-kovaryans matrislerinde homojenliğin yöntemlerin performansına etkisini görebilmek amacıyla varyans-kovaryans matrislerinde homojenliğin sağlandığı ve sağlanmadığı 102'şer kişilik iki çok küçük örneklem amaçlı örnekleme ile hazırlanmıştır. Bu örneklemler de Tablo 3.5. ve Tablo 3.6'da verilmiştir.

Tablo 3. 5.: Çok küçük ve varyans-kovaryans matrislerinde homojenliğı sağlanmış (102 kişilik) örneklemin oluşturulması ve başarı düzeylerine göre dağılımı

6 Alt Grup	f	%	Amaçlı örnekleme
Düze1	100	16,7	17 kişi
Düze2	100	16,7	17 kişi
Düze3	101	16,7	17 kişi
Düze4	101	16,7	17 kişi
Düze5	101	16,7	17 kişi
Düze6	100	16,7	17 kişi
Toplam	603	100,0	

Tablo 3. 6.: Çok küçük ve varyans-kovaryans matrislerinde homojenliğı sağlanmamış (102 kişilik) örneklemin oluşturulması ve başarı düzeylerine göre dağılımı

6 Alt Grup	f	%	Amaçlı örnekleme
Düze1	100	16,7	17 kişi
Düze2	100	16,7	17 kişi
Düze3	101	16,7	17 kişi
Düze4	101	16,7	17 kişi
Düze5	101	16,7	17 kişi
Düze6	100	16,7	17 kişi
Toplam	603	100,0	

Yapılan seçimler sonrası oluşturulan örneklem büyüklükleri ve sınıflama gruplarına göre dağılımları Tablo 3.7’de verilmiştir.

Tablo 3. 7.: Tüm örneklem büyüklükleri ve sınıflama gruplarına göre dağılımları

	6 Alt Grup	f	%	3 Alt Grup	f	%	2 Alt Grup	f	%
126126	Düzyey1	26292	20,8	Düşük düzey	59185	46,9	Alt düzey	89609	71,0
	Düzyey2	32893	26,1						
	Düzyey3	30424	24,1	Orta düzey	51341	40,7			
	Düzyey4	20917	16,6						
	Düzyey5	11105	8,8	Üst düzey	15600	12,4	Üst düzey	36517	29,0
	Düzyey6	4495	3,6						
6186	Düzyey1	1012	16,4	Düşük düzey	2040	33,0	Alt düzey	3055	49,4
	Düzyey2	1028	16,6						
	Düzyey3	1015	16,4	Orta düzey	2012	32,5			
	Düzyey4	997	16,1						
	Düzyey5	1010	16,3	Üst düzey	2134	34,5	Üst düzey	3131	50,6
	Düzyey6	1124	18,2						
603	Düzyey1	100	16,6	Düşük düzey	200	33,2	Alt düzey	301	49,9
	Düzyey2	100	16,6						
	Düzyey3	101	16,7	Orta düzey	202	33,5			
	Düzyey4	101	16,7						
	Düzyey5	101	16,7	Üst düzey	201	33,3	Üst düzey	302	50,1
	Düzyey6	100	16,6						
102 (Homojenliği sağlanmış)	Düzyey1	17	16,7	Düşük düzey	34	33,3	Alt düzey	51	50,0
	Düzyey2	17	16,7						
	Düzyey3	17	16,7	Orta düzey	34	33,3			
	Düzyey4	17	16,7						
	Düzyey5	17	16,7	Üst düzey	34	33,3	Üst düzey	51	50,0
	Düzyey6	17	16,7						
102 (Homojenliği sağlanmamış)	Düzyey1	17	16,7	Düşük düzey	34	33,3	Alt düzey	51	50,0
	Düzyey2	17	16,7						
	Düzyey3	17	16,7	Orta düzey	34	33,3			
	Düzyey4	17	16,7						
	Düzyey5	17	16,7	Üst düzey	34	33,3	Üst düzey	51	50,0
	Düzyey6	17	16,7						

3.3. Veri Toplama Araçları

Araştırmada PISA uygulaması kapsamında 2012 yılında gerçekleştirilen çalışmanın matematik başarı testi ve öğrenci anketi verilerinden faydalanılmıştır.

3.4. Veri Toplama Araçlarının Uygulanışı

Veri toplama araçlarının uygulanışı ile ilgili olarak MEB ulusal nihai raporunda ayrıntılı bilgi verilmiştir (MEB, 2013).

- *PISA 2012 uygulamaları diğer PISA uygulamalarında olduğu gibi, kağıt-kalem değerlendirmelerinde, bir veya daha fazla konuda gelen test maddeleri ile toplam iki saatlik 30'ar dakikalık dört tane küme şeklinde tasarlanmıştır.*
- *PISA taramasına katılan her bir ülkede PISA test maddelerinin tamamı, 13 test kitapçığına ayrılarak uygulanmaktadır. PISA uygulamasında kullanılan 13 kitapçık, her bir ülkede, cinsiyet, SED gibi değişkenlerin her bir kategorisinde öğrenci başarı düzeylerini karşılaştırabilmeye yönelik güvenilir tahminler yapılabilmesine olanak sağlayacak anlamlı sayıda öğrenciye uygulanmaktadır (OECD, 2013).*
- *PISA 2012 Türkiye uygulamasında kullanılan öğrenci anketi, standart PISA 2012 öğrenci anketinden farklılık göstermektedir. PISA 2012'de opsiyonel olarak sunulan "Bilişim Teknolojileri Anketi (ICT Questionnaire)" Türkiye'de uygulanmamıştır. Bunun yerine bilişim teknolojilerine erişim ve bunların kullanılması ile ilgili bazı veriler, öğrenci anketinin sonuna eklenen maddelerle toplanmıştır. Öğrenci anketinde öğrenciye kendiyile, ailesiyle ve evi ile ilgili bilgiler, matematik öğrenimi, problem çözme deneyimleri, matematik öğrenimiyle ilgili diğer sorular, bilişim teknolojilerine erişim imkanları, genel bilgisayar kullanımı, okul dışında bilişim teknolojileri kullanımı, okulda bilişim teknolojileri kullanımı, bilgisayara yönelik tutum bölümlerinden oluşan sorular bulunmaktadır.*

3.5. Verilerin İşlenmesi ve Çözümlemesi

Araştırma kapsamında kullanılan verilerin analizine geçmeden önce araştırmacının alt problemlerine yönelik olarak bazı düzenlemeler yapılmıştır. Yapılan düzenlemelerle farklı varsayımlara sahip olan ayırma analizinin bu varsayımları karşılanmaya çalışılmıştır. Veriler içinde eksik verisi olmayan, normale en yakın dağılıma sahip, uç değerler bulundurmeyen, varyans-kovaryans matrisleri homojen ve çoklu bağlantıya sahip olmayan değişkenler tercih edilmeye çalışılmıştır. Yapılan incelemeler sırasıyla sunulmuştur. Araştırmada yapılan tüm analizlerde SPSS 23.00 programı kullanılmıştır.

3.5.1. Eksik veri durumu

İlk olarak araştırmada kullanılması düşünülen bağımsız/yordayıcı değişkenler incelenmiş ve bu değişkenlerde eksik verisi bulunmayan öğrencilerin verileri araştırma kapsamına alınmıştır. Araştırmada örneklem büyüklüklerine göre karşılaştırma yapıldığı için veri sayısının yeterince büyüklüğe sahip olması istenmiştir. Bu noktada en iyi veriye sahip 17 değişken belirlenmiştir. 485490 kişilik

PISA örnekleminde araştırma kapsamına dahil edilen değişkenlerde eksik verisi olan öğrencilerin verileri temizlenmiş ve toplam 126126 öğrenci kalmıştır.

3.5.2. Örneklem büyüklüğü

Sınıflama yapılacak tüm alt gruplarda örneklem büyüklüğü varsayımı karşılanmıştır. Her alt gruba en az bağımsız değişken sayısı kadar öğrenci alınmıştır. Oluşturulan örneklemelerde yer alan alt grupların büyüklükleri ve sınıflama gruplarına göre dağılımları Tablo 3.7’de verilmiştir.

3.5.3. Normal dağılım

Normal dağılımın basıklık ve çarpıklık olmak üzere iki momenti vardır. Bir değişken normal dağılıma sahip olduğunda değişkene ait basıklık ve çarpıklık değerleri sıfıra eşit olur. Bununla birlikte basıklık ve çarpıklık değerleri (-1, +1) aralığında olduğunda da dağılım normale oldukça yakın olarak kabul edilir. Araştırmada yer alan değişkenlerin dağılımlarına ilişkin basıklık ve çarpıklık değerleri incelendiğinde, dağılımların normale yakın olduğu söylenebilir. Ancak çarpıklık ve basıklık değerlerinin anlamlılığı standart hatalarına bölünerek değerlendirilir. Değerler standart hatalarına bölüldüğünde elde edilen sonuçların anlamlı olduğu ve farklı örneklemelerde değişkenlerden bazılarının normal dağılıma sahip olmadığı gözlenmiştir. Ayrıca her bir örneklem büyüklüğünde değişkenlere ait histogram grafikleri çıkarılmış, EK 1, EK 2, EK 3, EK 4 ve EK 5’te sunulmuştur. Grafikler incelendiğinde de her bir örneklem büyüklüğünde bazı değişkenlerin normal dağılmadığı gözlenmiştir.

EK 6, EK 7, EK 8, EK 9 ve EK 10’da ise değişkenlere ilişkin basıklık ve çarpıklık değerleri ile değerlerin standart hatalarına bölünmesiyle elde edilen z değerleri verilmiştir.

- Büyük örnekleme değişkenlere ilişkin çarpıklık değerleri incelendiğinde çarpıklık değerlerinin normal dağılıma benzer olduğu, basıklık değerleri incelendiğinde ise 17 değişkenden 4’ünün normal dağılıma uygun olmadığı görülmüştür. Bununla birlikte çarpıklık ve basıklık değerlerinin standart hatalarına bölünmesiyle elde edilen z değerlerinin de normal bir dağılımda (-3,+3) aralığında olması beklenmektedir. Elde edilen sonuçlar çarpıklık

açısından 17 değişkenden 14'ünün, basıklık açısından 17 değişkenden hiçbirinin normal dağılıma uygun olmadığını göstermektedir.

- Orta büyüklükteki örnekleme değişkenlere ilişkin çarpıklık değerleri incelendiğinde çarpıklık değerlerinin normal dağılıma benzer olduğu, basıklık değerleri incelendiğinde ise 17 değişkenden 3'ünün normal dağılıma uygun olmadığı görülmüştür. Bununla birlikte çarpıklık ve basıklık değerlerinin standart hatalarına bölünmesiyle elde edilen z değerlerine göre, çarpıklık açısından 17 değişkenden 13'ünün, basıklık açısından 17 değişkenden 11'inin normal dağılıma uygun olmadığı belirlenmiştir.
- Küçük örnekleme değişkenlere ilişkin çarpıklık değerleri incelendiğinde çarpıklık değerlerinin normal dağılıma benzer olduğu, basıklık değerleri incelendiğinde ise 17 değişkenden 1'inin normal dağılıma uygun olmadığı görülmüştür. Bununla birlikte çarpıklık ve basıklık değerlerinin standart hatalarına bölünmesiyle elde edilen z değerlerine göre, çarpıklık açısından 17 değişkenden 7'sinin, basıklık açısından 17 değişkenden 5'inin normal dağılıma uygun olmadığı belirlenmiştir.
- Çok küçük ve homojenliği sağlanmış örnekleme değişkenlere ilişkin çarpıklık değerleri incelendiğinde çarpıklık değerlerinin normal dağılıma benzer olduğu, basıklık değerleri incelendiğinde ise 17 değişkenden 3'ünün normal dağılıma uygun olmadığı görülmüştür. Bununla birlikte çarpıklık ve basıklık değerlerinin standart hatalarına bölünmesiyle elde edilen z değerlerine göre, çarpıklık açısından 17 değişkenin tamamının normal dağılıma uygun olduğunu, basıklık açısından 17 değişkenden 1'inin normal dağılıma uygun olmadığı belirlenmiştir.
- Çok küçük ve homojenliği sağlanmamış örnekleme değişkenlere ilişkin çarpıklık değerleri incelendiğinde 17 değişkenden 1'inin normal dağılıma uygun olmadığı, basıklık değerleri incelendiğinde ise 17 değişkenden 8'inin normal dağılıma uygun olmadığı görülmüştür. Bununla birlikte çarpıklık ve basıklık değerlerinin standart hatalarına bölünmesiyle elde edilen z değerlerine göre, çarpıklık açısından 17 değişkenden 2'sinin normal dağılıma uygun olmadığı, basıklık açısından 17 değişkenden 1'inin normal dağılıma uygun olmadığı belirlenmiştir.

Tüm örneklem büyüklüklerinde değişkenlerin durumu ele alındığında örneklem büyüklüğü azaldıkça dağılımların çarpıklık ve basıklıklarının normal dağılıma yaklaştığı görülmüştür; ancak normal dağılım varsayımı tam olarak karşılanamamıştır.

3.5.4. Değişken seçimi

Fazla ve gereksiz değişken seçiminden kaçınılmış, sınıflama yapmada kullanılacak 17 değişken belirlenmiştir. Değişkenlerin seçiminde eksik verisi olmayan, normal dağılıma en yakın, uç değerler bulundurmeyen ve çoklu bağlantısı olmayan değişkenler seçilmiştir. Araştırmada kullanılan bağımlı ve bağımsız değişkenler Tablo 3.8'de verilmiştir.

Tablo 3. 8.: Araştırmada kullanılan bağımlı ve bağımsız değişkenler

<i>Bağımlı Değişken</i>	<i>Bağımsız Değişkenler</i>
	Matematik kaygısı
	Okula karşı tutum: Öğrenme çıktıları
	Okula karşı tutum: Öğrenme aktiviteleri
	Okula ait olma duygusu
	Matematik öğretmeninin sınıf yönetimi
	Matematik dersindeki bilişsel aktiviteler
	Sınıf iklimi
6 alt grup	Evdeki eğitim olanakları
3 alt grup	Matematik motivasyonu
2 alt grup	Matematik ilgisi
	Matematik davranışı
	Matematik öz yeterliği
	Matematik niyeti
	Matematik öğretmeninin desteği
	Problem çözmeye açıklık
	Matematik öz benlik algısı
	Öğretmen öğrenci ilişkileri

3.5.5. Varyans-kovaryans matrislerinin homojenliği

Her örneklem büyüklüğü için varyans-kovaryans matrislerinin homojenliği test edilmiştir. Örneklemelerin bu varsayımı karşılama durumlarına bağlı kalınarak yorumlar yapılmıştır.

3.5.6. Uç deęerler

Veri setinde uç deęerler olup olmadığı incelenmiş ve deęişkenlere ait bütün deęerler standart deęerlere dönüştürülmüştür. Örneklem büyüklüğü 100 veya daha az iken herhangi bir gözlemin z puanı (-3, +3) aralığında deęilse, 100'den fazla iken (-4, +4) aralığında deęilse gözlem uç deęerdir. Yapılan incelemeler sonunda uç deęerlerin olmadığı belirlenmiştir. Bu varsayım karşılanmıştır.

3.5.7. Çoklu baęlantı

Çoklu baęlantı deęişkenler arasında çok yüksek korelasyonlar olması durumunda ortaya çıkan bir sorundur. Çoklu baęlantıya sahip deęişkenlerin analizlere alınması hataları artırarak analizi zayıflatmaktadır. İki deęişken arasında 0,90 ve üzeri korelasyon çoklu baęlantıya işarettir. Bu konuda deęişkenler arası korelasyonlar incelenmiş olup, her örnekleme elde edilen sonuçlar EK 11, EK 12, EK 13, EK 14 ve EK 15'te verilmiştir.

- Büyük örnekleme deęişkenler arasındaki korelasyonlar incelendiğinde iki deęişken arasındaki korelasyon deęerlerinin ,007 ile ,656 arasında deęiştiiği ve bu örnekleme deęişkenler arasında çoklu baęlantı bulunmadığı görülmüştür.
- Orta büyüklükteki örnekleme deęişkenler arasındaki korelasyonlar incelendiğinde iki deęişken arasındaki korelasyon deęerlerinin ,024 ile ,555 arasında deęiştiiği ve bu örnekleme deęişkenler arasında çoklu baęlantı bulunmadığı görülmüştür.
- Küçük örnekleme deęişkenler arasındaki korelasyonlar incelendiğinde iki deęişken arasındaki korelasyon deęerlerinin ,005 ile -,683 arasında deęiştiiği ve bu örnekleme deęişkenler arasında çoklu baęlantı bulunmadığı görülmüştür.
- Çok küçük ve homojenlięi saęlanmış örnekleme deęişkenler arasındaki korelasyonlar incelendiğinde iki deęişken arasındaki korelasyon deęerlerinin ,006 ile -,755 arasında deęiştiiği ve bu örnekleme deęişkenler arasında çoklu baęlantı bulunmadığı görülmüştür.

- Çok küçük ve homojenliği sağlanmamış örnekleme değişkenler arasındaki korelasyonlar incelendiğinde iki değişken arasındaki korelasyon değerlerinin ,034 ile ,926 arasında değiştiği görülmektedir. Elde edilen en yüksek korelasyon değerinin ,90'ın üstünde olması, bu örnekleme değişkenler arasında çoklu bağlantı bulunduğunun bir göstergesidir.

Farklı örneklem büyüklüklerinde değişkenler arası korelasyonlar incelendiğinde büyük, orta büyüklükteki, küçük ve homojenliği sağlanmış çok küçük örnekleme çoklu bağlantı bulunmadığı belirlenirken; homojenliği sağlanmamış çok küçük örnekleme değişkenler arasında çoklu bağlantı bulunmuştur.

İki değişkenli korelasyon katsayılarının incelenmesi çoklu bağlantı probleminin belirlenmesi için yeterli değildir. Çünkü problem sadece iki değişken arasındaki korelasyonun yüksek olması değil, bir bağımsız değişkenin diğer bütün bağımsız değişkenlerle yüksek derecede korelasyona sahip olmasıdır. Bu nedenle çoklu bağlantı durumunu belirlemek için farklı incelemeler de yapılmıştır.

Çoklu bağlantı her bir değişkene ait tolerance (X_1 değişkeninde gözlenen varyansın modeldeki diğer bağımsız değişkenler tarafından açıklanmayan oranı), VIF (değişkenler arasındaki bağlantının, bir kestirimin doğruluğunu ne derecede düşüreceğinin ölçüsü) değerleri ve koşul indeksleri (bir değişkenin diğer değişkenlere ne kadar bağlı olduğunun ölçüsü) üzerinden de incelenebilir. Tolerance değerinin 0,10'dan küçük, VIF değerinin 10'dan büyük, koşul indeksinin ise 30'dan büyük olması çoklu bağlantının işaretidir. Bu durumu belirlemek için farklı örneklem büyüklüklerinde değişkenlere ilişkin tolerance, VIF ve CI değerleri incelenmiştir.

EK 16'da değişkenlerin farklı örneklem büyüklüklerinde sahip oldukları tolerance, VIF ve CI değerleri verilmiştir. Değişkenlerin büyük, orta büyüklükteki, küçük ve varyans kovaryans matrislerinde homojenliğin sağlandığı çok küçük örnekleme çoklu bağlantıya sahip olmadığı görülmüştür. Bunun yanında varyans kovaryans matrislerinde homojenliğin sağlanmadığı çok küçük örnekleme "okula ait olma duygusu, matematik motivasyonu, matematik ilgisi, matematik öğretmenin desteği ve öğretmen öğrenci ilişkileri" değişkenlerine ait Tolerance değerlerinin 0,10'dan küçük, VIF değerlerinin ise 10'dan yüksek olduğu belirlenirken; CI değerlerinin normal sınırlar içinde olduğu gözlenmiştir.

Yapılan incelemeler sonucunda arařtırmada kullanılan bağımsız/yordayıcı deęişkenler belirlenmiştir:

- Matematik kaygısı
- Okula karşı tutum: Öğrenme çıktıları
- Okula karşı tutum: Öğrenme aktiviteleri
- Okula ait olma duygusu
- Matematik öğretmenin sınıf yönetimi
- Matematik dersindeki bilişsel aktiviteler
- Sınıf iklimi
- Evdeki eğitim olanakları
- Matematik motivasyonu
- Matematik ilgisi
- Matematik davranışı
- Matematik öz yeterliği
- Matematik niyeti
- Matematik öğretmenin desteęi
- Problem çözmeye açıklık
- Matematik öz benlik algısı
- Öğretmen öğrenci ilişkileri

Arařtırmada sınıflama ve yordama iin bu deęiřkenlerin seilme nedenleri kısaca řöyle özetlenebilir:

1. Deęiřkenlerde eksik veri yoktur.
2. Normal daęılım varsayımını karřılayamasa da normal daęılıma en yakın düzeyde sahip deęiřkenlerdir.
3. Deęiřkenlerin uç deęerleri yoktur.
4. Deęiřkenler arasında oklu baęlantı problemi -varyans kovaryans matrislerinde homojenlięin saęlanmadıęı ok küçük örnekleme hari- yoktur.
5. Varyans-kovaryans matrislerinin homojenlięi varsayımı karřılanmıř olan ve olmayan ayrı örneklemler oluřturularak karřılařtırmalar yapılmıřtır.
6. Ayrıca bu deęiřkenler öęrenci bařarısını yordamaya yönelik yapılan alıřmalarda alanyazında sıklıkla kullanılan deęiřkenlerdir (Erayman, 2004; Ercan vd., 2005; Özabacı ve Acat, 2005; Keser ve Sarıbay, 2007; Anıl, 2008; Gelbal, 2008; Kaysılı, 2008; Anıl, 2009; Erdil, 2010; Anıl, 2011; Özer ve Anıl, 2011; řahin, 2011; Arslantař vd., 2012, Altun ve Yazıcı, 2013; ifti ve aęlar, 2014, Sadi vd., 2014).

4. BULGULAR VE TARTIŞMA

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

4.1. Araştırmanın Birinci Alt Problemine İlişkin Bulgular ve Yorumlar

Öğrenci başarılarının büyük örnekleme, 6, 3 ve 2 alt gruba sınıflanması konusunda;

- a) yapay sinir ağı yönteminin performansı nasıldır?
- b) karar ağaçları yönteminin performansı nasıldır?
- c) ayırma analizi yönteminin performansı nasıldır?

Örneklem Büyüklüğü : 126126

Sınıflama Grubu : 6 ALT GRUP

Öğrenci başarılarının yapay sinir ağı ile büyük örnekleme 6 alt gruba sınıflanması amacıyla “Çok Katmanlı Algılayıcı” modeli kullanılmıştır. Modelde yer alan bağımlı değişken öğrencilerin başarı düzeylerinden oluşan 6 alt grup, bağımsız değişkenler ise sınıflamada kullanılan 17 değişkenden oluşmaktadır.

Yapay sinir ağı analizlerinde aktivasyon fonksiyonu seçiminde gizli katmanda yer alan hücrelere Hiperbolik Tanjant Fonksiyonu, çıktı katmanında yer alan hücrelere ise Softmax Fonksiyonu uygulanmıştır. Analizlerdeki veri setinin %70'i eğitimde kullanılan örneklem, %30'u testte kullanılan örneklem olarak seçilmiştir.

Büyük örnekleme 6 alt gruba sınıflama yapma konusunda yapay sinir ağının performansını belirlemek amacıyla 50 farklı deneme analizi yapılmıştır. Yapay sinir ağı ile 50 analiz sonucunda, eğitim örnekleminde yer alan öğrencilerin matematik başarısını sınıflama performansı ortalaması %36,2, test örnekleminde yer alan öğrencilerin matematik başarısını sınıflama performansı ortalaması %36,1 olarak belirlenmiştir. Bununla birlikte elde edilen en yüksek sınıflama yüzdesi seçilerek Tablo 4.1'de sunulmuştur.

Tablo 4. 1.: Öğrenci başarılarının büyük örnekleme, ilgili değişkenlerle 6 alt gruba sınıflanmasında yapay sinir ağı yönteminin performansı

Örneklem	Gözlenen	Tahmin Edilen						
		Düzyey1	Düzyey2	Düzyey3	Düzyey4	Düzyey5	Düzyey6	DTY
Eğitim	Düzyey1	7760	7486	2569	483	55	27	42,2%
	Düzyey2	5284	10011	5928	1511	183	57	43,6%
	Düzyey3	2074	7033	8086	3514	623	87	37,8%
	Düzyey4	542	2672	5489	4586	1193	172	31,3%
	Düzyey5	129	732	2114	3135	1453	235	18,6%
	Düzyey6	29	156	525	1182	945	309	9,8%
	Toplam	17,9%	31,8%	28,0%	16,3%	5,0%	1,0%	36,4%
Test	Düzyey1	3372	3172	1129	204	25	10	42,6%
	Düzyey2	2235	4288	2577	720	81	18	43,2%
	Düzyey3	873	2919	3437	1473	262	43	38,2%
	Düzyey4	234	1161	2321	1998	490	59	31,9%
	Düzyey5	66	310	931	1278	619	103	18,7%
	Düzyey6	16	80	214	499	415	125	9,3%
	Toplam	18,0%	31,6%	28,1%	16,3%	5,0%	0,9%	36,7%

Tablo 4.1. incelendiğinde büyük örnekleme 6 alt gruba sınıflama yapma konusunda yapay sinir ağı yönteminin eğitim örnekleminde yer alan öğrencilerin matematik başarısını %36,4'lük bir performansla, test örnekleminde yer alan öğrencilerin matematik başarısını ise %36,7'lik bir performansla doğru sınıfladığı görülmektedir. Yapay sinir ağı ilk üç düzeydeki öğrencileri daha yüksek performansla sınıflarken; öğrenci düzeyi yükseldikçe sınıflama performansının düştüğü görülmüştür. Yöntemin özellikle yakın düzeylerdeki öğrencilerin sınıflanmasında zorlandığı görülmektedir. Birbirine yakın düzeylerdeki öğrencilerin benzer özelliklere sahip olması benzer gruplarda sınıflanmalarına sebep olmuş olabilir.

Düzyey1'de yer alan öğrencilerin başka düzeylerde sınıflanması yanlış sınıflandırmaları göstermektedir. Ancak belirtmek gerekir ki, yakın düzeylere yapılan sınıflamalarda hata daha az, uzak düzeylere yapılan sınıflamalarda hata daha fazladır. Bu nedenle Düzyey1'deki öğrencilerin Düzyey2'de sınıflandırılmasındaki hata Düzyey6'da sınıflandırmadaki hatadan daha azdır.

Örneğin eğitim setinde Düzyey1'de yer alan öğrencilerin Düzyey1'de sınıflanma doğruluğu %42,2 iken, öğrencilerin %40,7'si Düzyey2'de, %14,0'ü Düzyey3'te, %2,6'sı Düzyey4'te, %0,3'ü Düzyey5'te ve %0,2'si Düzyey6'da yanlış sınıflandırılmıştır. Bu sonuçlar sınıflamada yapılan hatanın görüldüğünden daha az olduğunu da göstermektedir.

Karar ağaçları yöntemi için de aynı bağımlı/bağımsız değişkenler seçilerek analizler gerçekleştirilmiş ve aşağıdaki bulgulara ulaşılmıştır.

Tablo 4. 2.: Öğrenci başarılarının büyük örnekleme, ilgili değişkenlerle 6 alt gruba sınıflanmasında karar ağaçları yönteminin performansı

Gözlenen	Tahmin Edilen						DTY
	Düzyey1	Düzyey2	Düzyey3	Düzyey4	Düzyey5	Düzyey6	
Düzyey1	10214	10537	4472	893	176	0	38,8%
Düzyey2	7313	14324	8712	2184	360	0	43,5%
Düzyey3	3483	10251	11492	4365	833	0	37,8%
Düzyey4	1069	4637	8079	5805	1327	0	27,8%
Düzyey5	298	1469	3534	4187	1617	0	14,6%
Düzyey6	82	359	964	1936	1154	0	0,0%
Toplam	17,8%	33,0%	29,5%	15,4%	4,3%	0,0%	34,5%

Tablo 4.2. incelendiğinde büyük örnekleme 6 alt gruba sınıflama yapma konusunda karar ağaçları yönteminin öğrencilerin matematik başarısını %34,5'lik bir performansla doğru sınıfladığı görülmektedir. Karar ağaçları yöntemi de yine alt düzeydeki öğrencileri sınıflamada daha başarılı olurken, öğrenci düzeyi arttıkça sınıflama performansı oldukça düşmüştür. Hatta yöntem altıncı düzeydeki öğrencilerin hiçbirini doğru sınıflandıramamıştır. Ayrıca yapay sinir ağlarına benzer şekilde yakın düzeylerdeki öğrencilerin sınıflanmasında karar ağaçlarının da zorlandığı belirlenmiştir. Birbirine yakın düzeylerdeki öğrencilerin benzer özelliklere sahip olması yine benzer gruplarda sınıflanmalarına sebep olmuş olabilir.

Karar ağaçlarında da Düzey1'de yer alan öğrencilerin başka düzeylerde sınıflanması yanlış sınıflandırmaları göstermektedir. Ancak belirtmek gerekir ki, burada da yakın düzeylere yapılan sınıflamalarda hata daha az, uzak düzeylere yapılan sınıflamalarda hata daha fazladır. Bu nedenle Düzey1'deki öğrencilerin Düzey2'de sınıflandırılmasındaki hata Düzey6'da sınıflandırmadaki hatadan daha azdır.

Örneğin Düzey1'de yer alan öğrencilerin Düzey1'de sınıflanma doğruluğu %38,8 iken, öğrencilerin %40,1'i Düzey2'de, %17,0'si Düzey3'te, %3,4'ü Düzey4'te, %0,7'si Düzey5'te ve %0,0'ı Düzey6'da yanlış sınıflandırılmıştır. Bu sonuçlar da sınıflamada yapılan hatanın görüldüğünden daha az olduğunu göstermektedir.

Ayırma analizi yöntemi için de aynı bağımlı/bağımsız değişkenler seçilerek analizler gerçekleştirilmiş ve aşağıdaki bulgulara ulaşılmıştır.

Tablo 4. 3.: Öğrenci başarılarının büyük örnekleme, ilgili değişkenlerle 6 alt gruba sınıflanmasında ayırma analizi yönteminin performansı

Gözlenen	Tahmin Edilen						Toplam
	Düzyey1	Düzyey2	Düzyey3	Düzyey4	Düzyey5	Düzyey6	
Düzyey1	15424	5305	3214	1100	480	769	26292
Düzyey2	12778	7696	6844	2879	1238	1458	32893
Düzyey3	6433	5844	7784	5072	2568	2723	30424
Düzyey4	2307	2267	4471	4562	3266	4044	20917
Düzyey5	632	639	1492	2136	2246	3960	11105
Düzyey6	142	138	318	505	743	2649	4495
Düzyey1	58,7	20,2	12,2	4,2	1,8	2,9	100,0
Düzyey2	38,8	23,4	20,8	8,8	3,8	4,4	100,0
Düzyey3	21,1	19,2	25,6	16,7	8,4	9,0	100,0
Düzyey4	11,0	10,8	21,4	21,8	15,6	19,3	100,0
Düzyey5	5,7	5,8	13,4	19,2	20,2	35,7	100,0
Düzyey6	3,2	3,1	7,1	11,2	16,5	58,9	100,0
DTY							32,0%

Tablo 4.3. incelendiğinde büyük örnekleme 6 alt gruba sınıflama yapma konusunda ayırma analizi yönteminin öğrencilerin matematik başarısını %32,0'lik bir performansla doğru sınıfladığı görülmektedir. Yapay sinir ağı ve karar ağaçları yöntemlerinin sınıflandırma performansı öğrenci düzeyi arttıkça düşerken, ayırma analizinin sınıflandırma performansı böyle bir eğilim göstermemiştir. Bununla birlikte genel sınıflandırma performansı yapay sinir ağı ve karar ağaçlarından düşük olsa da ayırma analizi, öğrencileri ait olduğu düzeylerde yüksek oranlarda sınıflandırmıştır. Ayrıca ayırma analizi ile özellikle birinci ve altıncı düzeydeki öğrencilerin sınıflandırılma performansları oldukça yüksek olmuştur.

Ayırma analizinde de Düzey1'de yer alan öğrencilerin başka düzeylerde sınıflanması yanlış sınıflandırmaları göstermektedir. Ancak belirtmek gerekir ki, yakın düzeylere yapılan sınıflamalarda hata daha az, uzak düzeylere yapılan sınıflamalarda hata daha fazladır. Bu nedenle Düzey1'deki öğrencilerin Düzey2'de sınıflandırılmasındaki hata Düzey6'da sınıflandırmadaki hatadan daha azdır.

Örneğin Düzey1'de yer alan öğrencilerin Düzey1'de sınıflanma doğruluğu %58,7 iken, öğrencilerin %20,2'si Düzey2'de, %12,2'si Düzey3'te, %4,2'si Düzey4'te, %1,8'i Düzey5'te ve %2,9'u Düzey6'da yanlış sınıflandırılmıştır. Bu sonuçlar sınıflamada yapılan hatanın görüldüğünden daha az olduğunu da göstermektedir.

Örneklem Büyüklüğü : 126126
Sınıflama Grubu : 3 ALT GRUP

Öğrenci başarılarının yapay sinir ağı ile büyük örnekleme 3 alt gruba sınıflanması amacıyla “Çok Katmanlı Algılayıcı” modeli kullanılmıştır. Modelde yer alan bağımlı değişken öğrencilerin başarı düzeylerinden oluşan 3 alt grup, bağımsız değişkenler ise sınıflamada kullanılan 17 değişkenden oluşmaktadır.

Analizlerde kullanılan veri setinin %70’i eğitim örnekleme, %30’u test örnekleme olarak seçilmiştir. Ağ mimarisinin oluşturulmasında gizli katmandaki yapay sinir hücrelerinin aktivasyon fonksiyonu olarak Hiperbolik Tanjant Fonksiyonu, çıktı katmanındaki yapay sinir hücrelerinin aktivasyon fonksiyonu olarak Softmax Fonksiyonu kullanılmıştır.

Büyük örnekleme 3 alt gruba sınıflama yapma konusunda yapay sinir ağının performansını belirlemek amacıyla 50 farklı deneme analizi yapılmıştır. Yapay sinir ağı ile 50 analiz sonucunda, eğitim örnekleminde yer alan öğrencilerin matematik başarısını sınıflama performansı ortalaması %62,1, test örnekleminde yer alan öğrencilerin matematik başarısını sınıflama performansı ortalaması %62,0 olarak belirlenmiştir. Bununla birlikte elde edilen en yüksek sınıflama yüzdesi seçilerek Tablo 4.4’te sunulmuştur.

Tablo 4. 4.: Öğrenci başarılarının büyük örnekleme, ilgili değişkenlerle 3 alt gruba sınıflanmasında yapay sinir ağı yönteminin performansı

Örneklem	Gözlenen	Tahmin edilen			
		Düşük düzey	Orta düzey	Üst düzey	DTY
Eğitim	Düşük düzey	30684	10352	259	74,3%
	Orta düzey	12572	21453	1785	59,9%
	Üst düzey	1087	7228	2676	24,3%
	Toplam	50,3%	44,3%	5,4%	62,2%
Test	Düşük düzey	13348	4421	121	74,6%
	Orta düzey	5415	9323	793	60,0%
	Üst düzey	464	2990	1155	25,1%
	Toplam	50,6%	44,0%	5,4%	62,7%

Tablo 4.4. incelendiğinde büyük örnekleme 3 alt gruba sınıflama yapma konusunda yapay sinir ağı yönteminin eğitim örnekleminde yer alan öğrencilerin matematik başarısını %62,2’lik bir performansla, test örnekleminde yer alan öğrencilerin matematik başarısını ise %62,7’lik bir performansla doğru sınıfladığı görülmektedir. Yapay sinir ağı düşük düzeydeki öğrencileri daha yüksek

performansla sınıflarken; öğrenci düzeyi yükseldikçe sınıflama performansının düştüğü görülmüştür. Bu konuda düşük ve orta düzeydeki öğrenci sayısının üst düzey öğrenci grubundan fazla olmasının etkisi olabilir. Bununla birlikte aynı örnekleme alt grup sayısı azaldığında sınıflama performansı artmıştır.

Düşük düzeyde yer alan öğrencilerin başka düzeylerde sınıflanması yanlış sınıflandırmaları göstermektedir. Ancak belirtmek gerekir ki, yakın düzeylere yapılan sınıflamalarda hata daha az, uzak düzeylere yapılan sınıflamalarda hata daha fazladır. Bu nedenle düşük düzeydeki öğrencilerin orta düzeyde sınıflandırılmasındaki hata üst düzeyde sınıflandırmadaki hatadan daha azdır.

Örneğin eğitim setinde düşük düzeyde yer alan öğrencilerin düşük düzeyde sınıflanma doğruluğu %74,3 iken, öğrencilerin %25,1'i orta düzeyde ve %0,6'sı üst düzeyde yanlış sınıflandırılmıştır. Bu sonuçlar sınıflamada yapılan hatanın görüldüğünden daha az olduğunu da göstermektedir.

Karar ağaçları yöntemi için de aynı bağımlı/bağımsız değişkenler seçilerek analizler gerçekleştirilmiş ve aşağıdaki bulgulara ulaşılmıştır.

Tablo 4. 5.: Öğrenci başarılarının büyük örnekleme, ilgili değişkenlerle 3 alt gruba sınıflanmasında karar ağaçları yönteminin performansı

<i>Gözlenen</i>	<i>Tahmin Edilen</i>			
	<i>Düşük düzey</i>	<i>Orta düzey</i>	<i>Üst düzey</i>	<i>DTY</i>
Düşük düzey	43792	14744	649	74,0%
Orta düzey	20663	28238	2440	55,0%
Üst düzey	2422	10172	3006	19,3%
Toplam	53,0%	42,1%	4,8%	59,5%

Tablo 4.5. incelendiğinde büyük örnekleme 3 alt gruba sınıflama yapma konusunda karar ağaçları yönteminin öğrencilerin matematik başarısını %59,5'lik bir performansla doğru sınıfladığı görülmektedir. Karar ağaçları yöntemi de yine düşük düzeydeki öğrencileri sınıflamada daha başarılı olurken, öğrenci düzeyi arttıkça sınıflama performansı oldukça düşmüştür. Özellikle üst düzey öğrencilerin çoğu, orta düzey olarak sınıflanmış ve bu durum sınıflama performansını üst düzey öğrenciler açısından düşürmüştür. Bu konuda düşük ve orta düzeydeki öğrenci sayısının üst düzey öğrenci grubundan fazla olmasının etkisi olabilir. Bununla birlikte aynı örnekleme alt grup sayısı azaldığında sınıflama performansı artmıştır.

Karar ağaçlarında da düşük düzeyde yer alan öğrencilerin başka düzeylerde sınıflanması yanlış sınıflandırmaları göstermektedir. Ancak belirtmek gerekir ki, burada da yakın düzeylere yapılan sınıflamalarda hata daha az, uzak düzeylere yapılan sınıflamalarda hata daha fazladır. Bu nedenle düşük düzeydeki öğrencilerin orta düzeyde sınıflandırılmasındaki hata üst düzeyde sınıflandırmadaki hatadan daha azdır.

Örneğin düşük düzeyde yer alan öğrencilerin düşük düzeyde sınıflanma doğruluğu %74,0 iken, öğrencilerin %24,9'u orta düzeyde ve %1,1'i üst düzeyde yanlış sınıflandırılmıştır. Bu sonuçlar da sınıflamada yapılan hatanın görüldüğünden daha az olduğunu göstermektedir.

Ayrırma analizi yöntemi için de aynı bağımlı/bağımsız değişkenler seçilerek analizler gerçekleştirilmiş ve aşağıdaki bulgulara ulaşılmıştır.

Tablo 4. 6.: Öğrenci başarılarının büyük örneklemde, ilgili değişkenlerle 3 alt gruba sınıflanmasında ayırma analizi yönteminin performansı

<i>Gözlenen</i>	<i>Tahmin Edilen</i>			<i>Toplam</i>
	<i>Düşük düzey</i>	<i>Orta düzey</i>	<i>Üst düzey</i>	
Düşük düzey	41243	13634	4308	59185
Orta düzey	16852	20868	13621	51341
Üst düzey	1546	4083	9971	15600
Düşük düzey	69,7	23,0	7,3	100,0
Orta düzey	32,8	40,6	26,5	100,0
Üst düzey	9,9	26,2	63,9	100,0
DTY				57,2%

Tablo 4.6. incelendiğinde büyük örneklemde 3 alt gruba sınıflama yapma konusunda ayırma analizi yönteminin öğrencilerin matematik başarısını %57,2'lik bir performansla doğru sınıfladığı görülmektedir. Ayırma analizi yapay sinir ağı ve karar ağaçlarından farklı olarak düşük düzeydeki öğrencileri yüksek performansla sınıflamanın yanında üst düzeydeki öğrencileri de başarılı bir şekilde sınıflandırmıştır. Ayırma analizi gruplardaki öğrenci sayısının farklılığından etkilenmemiş, daha çok orta düzeydeki öğrencilerin benzerliğini ayırmakta zorlanmıştır. Bununla birlikte aynı örneklemde alt grup sayısı azaldığında sınıflama performansı artmıştır.

Ayrırma analizinde de düşük düzeyde yer alan öğrencilerin başka düzeylerde sınıflanması yanlış sınıflandırmaları göstermektedir. Ancak belirtmek gerekir ki, yakın düzeylere yapılan sınıflamalarda hata daha az, uzak düzeylere yapılan

sınıflamalarda hata daha fazladır. Bu nedenle düşük düzeydeki öğrencilerin orta düzeyde sınıflandırılmasındaki hata üst düzeyde sınıflandırmadaki hatadan daha azdır.

Örneğin düşük düzeyde yer alan öğrencilerin düşük düzeyde sınıflanma doğruluğu %69,7 iken, öğrencilerin %23,0'ü orta düzeyde ve %7,3'ü üst düzeyde yanlış sınıflandırılmıştır. Bu sonuçlar da sınıflamada yapılan hatanın görüldüğünden daha az olduğunu göstermektedir.



Örneklem Büyüklüğü : 126126
Sınıflama Grubu : 2 ALT GRUP

Öğrenci başarılarının yapay sinir ağı ile büyük örnekleme 2 alt gruba sınıflanması amacıyla “Çok Katmanlı Algılayıcı” modeli kullanılmıştır. Modelde yer alan bağımlı değişken öğrencilerin başarı düzeylerinden oluşan 2 alt grup, bağımsız değişkenler ise sınıflamada kullanılan 17 değişkenden oluşmaktadır.

Yapay sinir ağı analizlerinde aktivasyon fonksiyonu seçiminde gizli katmanda yer alan hücrelere Hiperbolik Tanjant Fonksiyonu, çıktı katmanında yer alan hücrelere ise Softmax Fonksiyonu uygulanmıştır. Analizlerdeki veri setinin %70’i eğitimde kullanılan örneklem, %30’u testte kullanılan örneklem olarak seçilmiştir.

Büyük örnekleme 2 alt gruba sınıflama yapma konusunda yapay sinir ağının performansını belirlemek amacıyla 50 farklı deneme analizi yapılmıştır. Yapay sinir ağı ile 50 analiz sonucunda, eğitim örnekleminde yer alan öğrencilerin matematik başarısını sınıflama performansı ortalaması %78,2, test örnekleminde yer alan öğrencilerin matematik başarısını sınıflama performansı ortalaması %78,1 olarak belirlenmiştir. Bununla birlikte elde edilen en yüksek sınıflama yüzdesi seçilerek Tablo 4.7’de sunulmuştur.

Tablo 4. 7.: Öğrenci başarılarının büyük örnekleme, ilgili değişkenlerle 2 alt gruba sınıflanmasında yapay sinir ağı yönteminin performansı

Örneklem	Gözlenen	Tahmin Edilen		
		Alt düzey	Üst düzey	DTY
Eğitim	Alt düzey	56373	6225	90,1%
	Üst düzey	12880	12646	49,5%
	Toplam	78,6%	21,4%	78,3%
Test	Alt düzey	24444	2567	90,5%
	Üst düzey	5463	5528	50,3%
	Toplam	78,7%	21,3%	78,9%

Tablo 4.7. incelendiğinde büyük örnekleme 2 alt gruba sınıflama yapma konusunda yapay sinir ağı yönteminin eğitim örnekleminde yer alan öğrencilerin matematik başarısını %78,3’lük bir performansla, test örnekleminde yer alan öğrencilerin matematik başarısını ise %78,9’lük bir performansla doğru sınıfladığı görülmektedir. Yapay sinir ağı yöntemi alt düzeydeki öğrencileri sınıflamada daha başarılı olurken, üst düzeydeki öğrencileri sınıflama performansı oldukça düşmüştür. Yöntemin alt düzey gruptaki öğrencileri doğru sınıflandırma performansı %90,1’e ulaşırken, üst düzey gruptaki öğrencileri sınıflama

performansı %49,5'te kalmıştır. Alt düzeydeki öğrenci sayısının üst düzeydeki öğrenci sayısının iki katından fazla olması, grupların sınıflanma başarılarını etkilemiştir. Öğrenci sayısının daha çok olduğu alt düzey grup daha iyi performansla sınıflanmıştır. Bununla birlikte aynı örnekleme alt grup sayısı azaldığında sınıflama performansı artmıştır.

Karar ağaçları yöntemi için de aynı bağımlı/bağımsız değişkenler seçilerek analizler gerçekleştirilmiş ve aşağıdaki bulgulara ulaşılmıştır.

Tablo 4. 8.: Öğrenci başarılarının büyük örnekleme, ilgili değişkenlerle 2 alt gruba sınıflanmasında karar ağaçları yönteminin performansı

<i>Gözlenen</i>	<i>Tahmin Edilen</i>		
	<i>Alt düzey</i>	<i>Üst düzey</i>	<i>DTY</i>
Alt düzey	80769	8840	90,1%
Üst düzey	20279	16238	44,5%
Toplam	80,1%	19,9%	76,9%

Tablo 4.8. incelendiğinde büyük örnekleme 2 alt gruba sınıflama yapma konusunda karar ağaçları yönteminin öğrencilerin matematik başarısını %76,9'luk bir performansla doğru sınıfladığı görülmektedir. Karar ağaçları yöntemi de yine alt düzeydeki öğrencileri sınıflamada daha başarılı olurken, üst düzeydeki öğrencileri sınıflama performansı oldukça düşmüştür. Yöntemin alt düzey gruptaki öğrencileri doğru sınıflandırma performansı %90,1'e ulaşırken, üst düzey gruptaki öğrencileri sınıflama performansı %44,5'te kalmıştır. Alt düzeydeki öğrenci sayısının üst düzeydeki öğrenci sayısının iki katından fazla olması, grupların sınıflanma başarılarını etkilemiştir. Öğrenci sayısının daha çok olduğu alt düzey grup daha iyi performansla sınıflanmıştır. Bununla birlikte aynı örnekleme alt grup sayısı azaldığında sınıflama performansı artmıştır.

Ayırma analizi yöntemi için de aynı bağımlı/bağımsız değişkenler seçilerek analizler gerçekleştirilmiş ve aşağıdaki bulgulara ulaşılmıştır.

Tablo 4. 9.: Öğrenci başarılarının büyük örnekleme, ilgili değişkenlerle 2 alt gruba sınıflanmasında ayırma analizi yönteminin performansı

<i>Gözlenen</i>	<i>Tahmin Edilen</i>		<i>Toplam</i>
	<i>Alt düzey</i>	<i>Üst düzey</i>	
Alt düzey	68857	20752	89609
Üst düzey	11204	25313	36517
Alt düzey	76,8	23,2	100,0
Üst düzey	30,7	69,3	100,0
DTY			74,7%

Tablo 4.9. incelendiğinde büyük örnekleme 2 alt gruba sınıflama yapma konusunda ayırma analizi yönteminin öğrencilerin matematik başarısını %74,7'lik bir performansla doğru sınıfladığı görülmektedir. Ayırma analizi yine yapay sinir ağı ve karar ağaçlarından farklı bir durum ortaya koymuştur. Yapay sinir ağı ve karar ağaçları alt düzey grubu sınıflamada çok yüksek performans gösterirken, üst düzey grubu sınıflamada çok daha düşük kalmıştır. Ancak ayırma analizi iki düzey için birbirine benzer bir performans göstermiş, düzeylerdeki öğrenci sayılarından etkilenmemiştir. Bununla birlikte aynı örnekleme alt grup sayısı azaldığında sınıflama performansı artmıştır.

4.2. Araştırmanın İkinci Alt Problemine İlişkin Bulgular ve Yorumlar

Öğrenci başarılarının orta büyüklükteki örnekleme, 6, 3 ve 2 alt gruba sınıflanmasında konusunda;

- a) yapay sinir ağı yönteminin performansı nasıldır?
- b) karar ağaçları yönteminin performansı nasıldır?
- c) ayırma analizi yönteminin performansı nasıldır?

Örneklem Büyüklüğü : 6186

Sınıflama Grubu : 6 ALT GRUP

Öğrenci başarılarının yapay sinir ağı ile orta büyüklükteki örnekleme 6 alt gruba sınıflanması amacıyla “Çok Katmanlı Algılayıcı” modeli kullanılmıştır. Modelde yer alan bağımlı değişken öğrencilerin başarı düzeylerinden oluşan 6 alt grup, bağımsız değişkenler ise sınıflamada kullanılan 17 değişkenden oluşmaktadır.

Yapay sinir ağı analizlerinde aktivasyon fonksiyonu seçiminde gizli katmanda yer alan hücrelere Hiperbolik Tanjant Fonksiyonu, çıktı katmanında yer alan hücrelere ise Softmax Fonksiyonu uygulanmıştır. Analizlerdeki veri setinin %70'i eğitimde kullanılan örneklem, %30'u testte kullanılan örneklem olarak seçilmiştir.

Orta büyüklükteki örnekleme 6 alt gruba sınıflama yapma konusunda yapay sinir ağının performansını belirlemek amacıyla 50 farklı deneme analizi yapılmıştır. Yapay sinir ağı ile 50 analiz sonucunda, eğitim örnekleminde yer alan öğrencilerin matematik başarısını sınıflama performansı ortalaması %35,7, test örnekleminde yer alan öğrencilerin matematik başarısını sınıflama performansı ortalaması %34,7 olarak belirlenmiştir. Bununla birlikte elde edilen en yüksek sınıflama yüzdesi seçilerek Tablo 4.10'da sunulmuştur.

Tablo 4. 10.: Öğrenci başarılarının orta büyüklükteki örnekleme, ilgili değişkenlerle 6 alt gruba sınıflanmasında yapay sinir ağı yönteminin performansı

Örneklem Gözlenen	Tahmin Edilen							DTY
	Düzyey1	Düzyey2	Düzyey3	Düzyey4	Düzyey5	Düzyey6		
Eğitim	Düzyey1	402	162	55	32	6	28	58,7%
	Düzyey2	262	192	107	85	12	59	26,8%
	Düzyey3	146	174	136	133	42	89	18,9%
	Düzyey4	55	90	99	191	83	194	26,8%
	Düzyey5	35	41	79	147	108	307	15,1%
	Düzyey6	17	24	38	90	77	539	68,7%
	Toplam	21,1%	15,8%	11,9%	15,6%	7,6%	28,0%	36,2%
Test	Düzyey1	197	62	26	20	5	17	60,2%
	Düzyey2	120	82	46	34	10	19	26,4%
	Düzyey3	59	64	64	44	20	44	21,7%
	Düzyey4	29	33	42	76	28	77	26,7%
	Düzyey5	15	22	39	54	38	125	13,0%
	Düzyey6	7	15	19	34	39	225	66,4%
	Toplam	23,1%	15,0%	12,8%	14,2%	7,6%	27,4%	36,9%

Tablo 4.10. incelendiğinde orta büyüklükteki örnekleme 6 alt gruba sınıflama yapma konusunda yapay sinir ağı yönteminin eğitim örnekleminde yer alan öğrencilerin matematik başarısını %36,2'lik bir performansla, test örnekleminde yer alan öğrencilerin matematik başarısını ise %36,9'luk bir performansla doğru sınıfladığı görülmektedir. Yapay sinir ağı sırasıyla altıncı ve birinci düzeydeki öğrencileri en yüksek performansla sınıflarken orta düzeylerde bu performans düşmüştür. İki, üç, dört ve beşinci düzeydeki öğrenciler birbirine daha benzerken, birinci ve altıncı düzeydeki öğrencilerin gruptaki en düşük ve en yüksek olmak puanlara sahip olması, sınıflama performansının daha yüksek çıkmasında etkili olabilir. Ayrıca örneklem büyüklüğü azalıp her bir düzeyde yaklaşık aynı sayıda öğrenci olduğunda düzeylerin doğru sınıflandırılma oranları da artmıştır. Büyük örnekleme birinci düzeydeki öğrencilerin doğru sınıflandırılma oranı %43,2 ilken, orta büyüklükteki örnekleme %58,7'ye yükselmiştir. Benzer değişim altıncı düzey için de geçerlidir. Ancak yöntemin genel sınıflandırma performansında büyük bir artış olmamıştır.

Düzyey1'de yer alan öğrencilerin başka düzeylerde sınıflanması yanlış sınıflandırmaları göstermektedir. Ancak belirtmek gerekir ki, yakın düzeylere yapılan sınıflamalarda hata daha az, uzak düzeylere yapılan sınıflamalarda hata daha fazladır. Bu nedenle Düzyey1'deki öğrencilerin Düzyey2'de sınıflandırılmasındaki hata Düzyey6'da sınıflandırmadaki hatadan daha azdır.

Örneğin eğitim setinde Düzey1’de yer alan öğrencilerin Düzey1’de sınıflanma doğruluğu %58,7 iken, öğrencilerin %23,7’si Düzey2’de, %8,0’i Düzey3’te, %4,7’si Düzey4’te, %0,9’u Düzey5’te ve %4,1’i Düzey6’da yanlış sınıflandırılmıştır. Bu sonuçlar sınıflamada yapılan hatanın görüldüğünden daha az olduğunu da göstermektedir.

Karar ağaçları yöntemi için de aynı bağımlı/bağımsız değişkenler seçilerek analizler gerçekleştirilmiş ve aşağıdaki bulgulara ulaşılmıştır.

Tablo 4. 11.: Öğrenci başarılarının orta büyüklükteki örnekleme, ilgili değişkenlerle 6 alt gruba sınıflanmasında karar ağaçları yönteminin performansı

<i>Gözlenen</i>	<i>Tahmin Edilen</i>						<i>DTY</i>
	<i>Düzey1</i>	<i>Düzey2</i>	<i>Düzey3</i>	<i>Düzey4</i>	<i>Düzey5</i>	<i>Düzey6</i>	
Düzey1	608	184	98	46	39	37	60,1%
Düzey2	420	263	165	64	61	55	25,6%
Düzey3	228	228	231	120	89	119	22,8%
Düzey4	128	121	168	203	152	225	20,4%
Düzey5	65	80	141	134	217	373	21,5%
Düzey6	38	44	103	105	167	667	59,3%
Toplam	24,0%	14,9%	14,6%	10,9%	11,7%	23,9%	35,4%

Tablo 4.11. incelendiğinde orta büyüklükteki örnekleme 6 alt gruba sınıflama yapma konusunda karar ağaçları yönteminin öğrencilerin matematik başarısını %35,4’lük bir performansla doğru sınıfladığı görülmektedir. Karar ağaçları sırasıyla birinci ve altıncı düzeydeki öğrencileri en yüksek performansla sınıflarken orta düzeylerde bu performans düşmüştür. İki, üç, dört ve beşinci düzeydeki öğrenciler birbirine daha benzerken, birinci ve altıncı düzeydeki öğrencilerin gruptaki en düşük ve en yüksek olmak puanlara sahip olması, sınıflama performansının daha yüksek çıkmasında etkili olabilir. Ayrıca örneklem büyüklüğü azalıp her bir düzeyde yaklaşık aynı sayıda öğrenci olduğunda düzeylerin doğru sınıflandırılma oranları da artmıştır. Büyük örnekleme birinci düzeydeki öğrencilerin doğru sınıflandırılma oranı %38,8 ilken, orta büyüklükteki örnekleme %60,1’e yükselmiştir. Benzer değişim altıncı düzey için de geçerlidir. Ancak yöntemin genel sınıflandırma performansında büyük bir artış olmamıştır.

Karar ağaçlarında da Düzey1’de yer alan öğrencilerin başka düzeylerde sınıflanması yanlış sınıflandırmaları göstermektedir. Ancak belirtmek gerekir ki, burada da yakın düzeylere yapılan sınıflamalarda hata daha az, uzak düzeylere yapılan sınıflamalarda hata daha fazladır. Bu nedenle Düzey1’deki öğrencilerin

Düzyey2'de sınıflandırılmasındaki hata Düzyey6'da sınıflandırmadaki hatadan daha azdır.

Örneğin Düzyey1'de yer alan öğrencilerin Düzyey1'de sınıflanma doğruluğu %60,1 iken, öğrencilerin %18,2'si Düzyey2'de, %9,7'si Düzyey3'te, %4,6'sı Düzyey4'te, %3,9'u Düzyey5'te ve %3,7'si Düzyey6'da yanlış sınıflandırılmıştır. Bu sonuçlar da sınıflamada yapılan hatanın görüldüğünden daha az olduğunu göstermektedir.

Ayırma analizi yöntemi için de aynı bağımlı/bağımsız değişkenler seçilerek analizler gerçekleştirilmiş ve aşağıdaki bulgulara ulaşılmıştır.

Tablo 4. 12.: Öğrenci başarılarının orta büyüklükteki örnekleme, ilgili değişkenlerle 6 alt gruba sınıflanmasında ayırma analizi yönteminin performansı

6 Alt Grup	Tahmin Edilen						Toplam
	Düzyey1	Düzyey2	Düzyey3	Düzyey4	Düzyey5	Düzyey6	
Düzyey1	588	217	118	48	17	24	1012
Düzyey2	391	247	184	114	47	45	1028
Düzyey3	215	197	253	171	90	89	1015
Düzyey4	103	106	166	259	175	188	997
Düzyey5	64	66	135	178	215	352	1010
Düzyey6	34	37	84	135	181	653	1124
Düzyey1	58,1	21,4	11,7	4,7	1,7	2,4	100,0
Düzyey2	38,0	24,0	17,9	11,1	4,6	4,4	100,0
Düzyey3	21,2	19,4	24,9	16,8	8,9	8,8	100,0
Düzyey4	10,3	10,6	16,6	26,0	17,6	18,9	100,0
Düzyey5	6,3	6,5	13,4	17,6	21,3	34,9	100,0
Düzyey6	3,0	3,3	7,5	12,0	16,1	58,1	100,0
DTY							35,8%

Tablo 4.12. incelendiğinde orta büyüklükteki örnekleme 6 alt gruba sınıflama yapma konusunda ayırma analizi yönteminin öğrencilerin matematik başarısını %35,8'lik bir performansla doğru sınıfladığı görülmektedir. Ayırma analizi farklı düzeyleri sınıflamada büyük örnekleme benzer bir performans göstermiştir. Ancak örneklem büyüklüğü azaldığında genel sınıflama yüzdesi artmıştır. Bununla birlikte diğer iki yonteme benzer şekilde birinci ve altıncı düzeyde en yüksek performansı gösterirken, orta grumlarda daha düşük performans göstermiştir.

Ayırma analizinde de Düzyey1'de yer alan öğrencilerin başka düzeylerde sınıflanması yanlış sınıflandırmaları göstermektedir. Ancak belirtmek gerekir ki, yakın düzeylere yapılan sınıflamalarda hata daha az, uzak düzeylere yapılan sınıflamalarda hata daha fazladır. Bu nedenle Düzyey1'deki öğrencilerin Düzyey2'de sınıflandırılmasındaki hata Düzyey6'da sınıflandırmadaki hatadan daha azdır.

Örneğin Düzey1'de yer alan öğrencilerin Düzey1'de sınıflanma doğruluğu %58,1 iken, öğrencilerin %21,4'ü Düzey2'de, %11,7'si Düzey3'te, %4,7'si Düzey4'te, %1,7'si Düzey5'te ve %2,4'ü Düzey6'da yanlış sınıflandırılmıştır. Bu sonuçlar sınıflamada yapılan hatanın görüldüğünden daha az olduğunu da göstermektedir.



Örneklem Büyüklüğü : 6186
Sınıflama Grubu : 3 ALT GRUP

Öğrenci başarılarının yapay sinir ağı ile orta büyüklükteki örnekleme 3 alt gruba sınıflanması amacıyla “Çok Katmanlı Algılayıcı” modeli kullanılmıştır. Modelde yer alan bağımlı değişken öğrencilerin başarı düzeylerinden oluşan 3 alt grup, bağımsız değişkenler ise sınıflamada kullanılan 17 değişkenden oluşmaktadır.

Yapay sinir ağı analizlerinde aktivasyon fonksiyonu seçiminde gizli katmanda yer alan hücrelere Hiperbolik Tanjant Fonksiyonu, çıktı katmanında yer alan hücrelere ise Softmax Fonksiyonu uygulanmıştır. Analizlerdeki veri setinin %70’i eğitimde kullanılan örneklem, %30’u testte kullanılan örneklem olarak seçilmiştir.

Orta büyüklükteki örnekleme 3 alt gruba sınıflama yapma konusunda yapay sinir ağının performansını belirlemek amacıyla 50 farklı deneme analizi yapılmıştır. Yapay sinir ağı ile 50 analiz sonucunda, eğitim örnekleminde yer alan öğrencilerin matematik başarısını sınıflama performansı ortalaması %60,2, test örnekleminde yer alan öğrencilerin matematik başarısını sınıflama performansı ortalaması %59,6 olarak belirlenmiştir. Bununla birlikte elde edilen en yüksek sınıflama yüzdesi seçilerek Tablo 4.13’te sunulmuştur.

Tablo 4. 13.: Öğrenci başarılarının orta büyüklükteki örnekleme, ilgili değişkenlerle 3 alt gruba sınıflanmasında yapay sinir ağı yönteminin performansı

Örneklem	Gözlenen	Tahmin Edilen			DTY
		Düşük düzey	Orta düzey	Üst düzey	
Eğitim	Düşük düzey	1034	280	97	73,3%
	Orta düzey	425	563	412	40,2%
	Üst düzey	110	315	1052	71,2%
	Toplam	36,6%	27,0%	36,4%	61,8%
Test	Düşük düzey	437	144	48	69,5%
	Orta düzey	176	233	203	38,1%
	Üst düzey	48	158	451	68,6%
	Toplam	34,8%	28,2%	37,0%	59,1%

Tablo 4.13. incelendiğinde orta büyüklükteki örnekleme 3 alt gruba sınıflama yapma konusunda yapay sinir ağı yönteminin eğitim örnekleminde yer alan öğrencilerin matematik başarısını %61,8’lik bir performansla, test örnekleminde yer alan öğrencilerin matematik başarısını ise %59,1’lik bir performansla doğru sınıfladığı görülmektedir. Yapay sinir ağı düşük ve üst düzeydeki öğrencileri daha yüksek performansla sınıflarken; yöntemin orta düzeydeki öğrencileri sınıflama

performansının düştüğü görülmüştür. 3 alt grup sınıflamasında düşük düzey birinci ve ikinci düzeyin, üst düzey ise beşinci ve altıncı düzeyin birleştirilmesiyle oluşturulmuştu. Orta düzeydeki öğrencilerin alt ve üst düzeydeymiş gibi sınıflandırılmasının ve dolayısıyla sınıflandırılma oranlarının düşük olma nedeni bu grupta yer alan öğrencilerin alt ve üst düzeydeki öğrencilerin bir kısmıyla benzer özellikler taşıması olabilir. Özellikle alt düzeyde yer alan ikinci düzey öğrencileri ve üst düzeyde yer alan beşinci düzey öğrencileri orta düzeydeki üçüncü ve dördüncü düzey öğrencilere benzemektedir. Ayrıca örneklem büyüklüğü azalıp her bir düzeyde yaklaşık aynı sayıda öğrenci olduğunda düzeylerin doğru sınıflandırılma oranı üst düzey öğrenciler açısından artmıştır. Büyük örneklemde üst düzeydeki öğrencilerin doğru sınıflandırılma oranı %23,4 ilken, orta büyüklükteki örneklemde %71,2'ye yükselmiştir. Bununla birlikte aynı örneklemde alt grup sayısı azaldığında sınıflama performansı artmıştır.

Düşük düzeyde yer alan öğrencilerin başka düzeylerde sınıflanması yanlış sınıflandırmaları göstermektedir. Ancak belirtmek gerekir ki, yakın düzeylere yapılan sınıflamalarda hata daha az, uzak düzeylere yapılan sınıflamalarda hata daha fazladır. Bu nedenle düşük düzeydeki öğrencilerin orta düzeyde sınıflandırılmasındaki hata üst düzeyde sınıflandırmadaki hatadan daha azdır.

Örneğin eğitim setinde düşük düzeyde yer alan öğrencilerin düşük düzeyde sınıflanma doğruluğu %73,3 iken, öğrencilerin %19,8'i orta düzeyde ve %6,9'u üst düzeyde yanlış sınıflandırılmıştır. Bu sonuçlar sınıflamada yapılan hatanın görüldüğünden daha az olduğunu da göstermektedir.

Karar ağaçları yöntemi için de aynı bağımlı/bağımsız değişkenler seçilerek analizler gerçekleştirilmiş ve aşağıdaki bulgulara ulaşılmıştır.

Tablo 4. 14.: Öğrenci başarılarının orta büyüklükteki örneklemde, ilgili değişkenlerle 3 alt gruba sınıflanmasında karar ağaçları yönteminin performansı

<i>Gözlenen</i>	<i>Tahmin Edilen</i>			
	<i>Düşük düzey</i>	<i>Orta düzey</i>	<i>Üst düzey</i>	<i>DTY</i>
Düşük düzey	1480	422	138	72,5%
Orta düzey	687	751	574	37,3%
Üst düzey	256	474	1404	65,8%
Toplam	39,2%	26,6%	34,2%	58,8%

Tablo 4.14. incelendiğinde orta büyüklükteki örnekleme 3 alt gruba sınıflama yapma konusunda karar ağaçları yönteminin öğrencilerin matematik başarısını %58,8'lik bir performansla doğru sınıfladığı görülmektedir. Karar ağaçları düşük ve üst düzeydeki öğrencileri daha yüksek performansla sınıflarken; yöntemin orta düzeydeki öğrencileri sınıflama performansının düştüğü görülmüştür. 3 alt grup sınıflamasında düşük düzey birinci ve ikinci düzeyin, üst düzey ise beşinci ve altıncı düzeyin birleştirilmesiyle oluşturulmuştu. Orta düzeydeki öğrencilerin alt ve üst düzeydeymiş gibi sınıflandırılmasının ve dolayısıyla sınıflandırılma oranlarının düşük olma nedeni bu grupta yer alan öğrencilerin alt ve üst düzeydeki öğrencilerin bir kısmıyla benzer özellikler taşıması olabilir. Özellikle alt düzeyde yer alan ikinci düzey öğrencileri ve üst düzeyde yer alan beşinci düzey öğrencileri orta düzeydeki üçüncü ve dördüncü düzey öğrencilere benzemektedir. Bu durum altı gruba sınıflama yapıldığında da görülmüştür. Ayrıca örneklem büyüklüğü azalıp her bir düzeyde yaklaşık aynı sayıda öğrenci olduğunda düzeylerin doğru sınıflandırılma oranı üst düzey öğrenciler açısından artmıştır. Büyük örnekleme üst düzeydeki öğrencilerin doğru sınıflandırılma oranı %19,3 ilken, orta büyüklükteki örnekleme %65,8'e yükselmiştir. Bununla birlikte aynı örnekleme alt grup sayısı azaldığında sınıflama performansı artmıştır.

Karar ağaçlarında da düşük düzeyde yer alan öğrencilerin başka düzeylerde sınıflanması yanlış sınıflandırmaları göstermektedir. Ancak belirtmek gerekir ki, burada da yakın düzeylere yapılan sınıflamalarda hata daha az, uzak düzeylere yapılan sınıflamalarda hata daha fazladır. Bu nedenle düşük düzeydeki öğrencilerin orta düzeyde sınıflandırılmasındaki hata üst düzeyde sınıflandırmadaki hatadan daha azdır.

Örneğin düşük düzeyde yer alan öğrencilerin düşük düzeyde sınıflanma doğruluğu %72,5 iken, öğrencilerin %20,7'si orta düzeyde ve %6,8'i üst düzeyde yanlış sınıflandırılmıştır. Bu sonuçlar da sınıflamada yapılan hatanın görüldüğünden daha az olduğunu göstermektedir.

Ayırma analizi yöntemi için de aynı bağımlı/bağımsız değişkenler seçilerek analizler gerçekleştirilmiş ve aşağıdaki bulgulara ulaşılmıştır.

Tablo 4. 15.: Öğrenci başarılarının orta büyüklükteki örnekleme, ilgili değişkenlerle 3 alt gruba sınıflanmasında ayırma analizi yönteminin performansı

<i>Gözlenen</i>	<i>Tahmin Edilen</i>			<i>Toplam</i>
	<i>Düşük düzey</i>	<i>Orta düzey</i>	<i>Üst düzey</i>	
Düşük düzey	1447	469	124	2040
Orta düzey	628	861	523	2012
Üst düzey	194	532	1408	2134
Düşük düzey	70,9	23,0	6,1	100,0
Orta düzey	31,2	42,8	26,0	100,0
Üst düzey	9,1	24,9	66,0	100,0
DTY				60,1%

Tablo 4.15. incelendiğinde orta büyüklükteki örnekleme 3 alt gruba sınıflama yapma konusunda ayırma analizi yönteminin öğrencilerin matematik başarısını %60,1'lik bir performansla doğru sınıfladığı görülmektedir. Ayırma analizi de yine düşük ve üst düzey öğrencileri sınıflamada yüksek performans göstermiştir. Örneklem büyüklüğü azaldığında düşük ve üst düzeydeki sınıflama başarısı da artmıştır. Bununla birlikte aynı örnekleme alt grup sayısı azaldığında sınıflama performansı artmıştır.

Ayırma analizinde de düşük düzeyde yer alan öğrencilerin başka düzeylerde sınıflanması yanlış sınıflandırmaları göstermektedir. Ancak belirtmek gerekir ki, yakın düzeylere yapılan sınıflamalarda hata daha az, uzak düzeylere yapılan sınıflamalarda hata daha fazladır. Bu nedenle düşük düzeydeki öğrencilerin orta düzeyde sınıflandırılmasındaki hata üst düzeyde sınıflandırmadaki hatadan daha azdır.

Örneğin düşük düzeyde yer alan öğrencilerin düşük düzeyde sınıflanma doğruluğu %70,9 iken, öğrencilerin %23,0'ü orta düzeyde ve %6,1'i üst düzeyde yanlış sınıflandırılmıştır. Bu sonuçlar da sınıflamada yapılan hatanın görüldüğünden daha az olduğunu göstermektedir.

Örneklem Büyüklüğü : 6186
Sınıflama Grubu : 2 ALT GRUP

Öğrenci başarılarının yapay sinir ağı ile orta büyüklükteki örnekleme 2 alt gruba sınıflanması amacıyla “Çok Katmanlı Algılayıcı” modeli kullanılmıştır. Modelde yer alan bağımlı değişken öğrencilerin başarı düzeylerinden oluşan 2 alt grup, bağımsız değişkenler ise sınıflamada kullanılan 17 değişkenden oluşmaktadır.

Yapay sinir ağı analizlerinde aktivasyon fonksiyonu seçiminde gizli katmanda yer alan hücrelere Hiperbolik Tanjant Fonksiyonu, çıktı katmanında yer alan hücrelere ise Softmax Fonksiyonu uygulanmıştır. Analizlerdeki veri setinin %70'i eğitimde kullanılan örneklem, %30'u testte kullanılan örneklem olarak seçilmiştir.

Orta büyüklükteki örnekleme 2 alt gruba sınıflama yapma konusunda yapay sinir ağının performansını belirlemek amacıyla 50 farklı deneme analizi yapılmıştır. Yapay sinir ağı ile 50 analiz sonucunda, eğitim örnekleminde yer alan öğrencilerin matematik başarısını sınıflama performansı ortalaması %77,7, test örnekleminde yer alan öğrencilerin matematik başarısını sınıflama performansı ortalaması %77,3 olarak belirlenmiştir. Bununla birlikte elde edilen en yüksek sınıflama yüzdesi seçilerek Tablo 4.16'da sunulmuştur.

Tablo 4. 16.: Öğrenci başarılarının orta büyüklükteki örnekleme, ilgili değişkenlerle 2 alt gruba sınıflanmasında yapay sinir ağı yönteminin performansı

Örneklem	Gözlenen	Tahmin Edilen		
		Alt düzey	Üst düzey	DTY
Eğitim	Alt düzey	1669	461	78,4%
	Üst düzey	463	1737	79,0%
	Toplam	49,2%	50,8%	78,7%
Test	Alt düzey	742	183	80,2%
	Üst düzey	198	733	78,7%
	Toplam	50,6%	49,4%	79,5%

Tablo 4.16. incelendiğinde orta büyüklükteki örnekleme 2 alt gruba sınıflama yapma konusunda yapay sinir ağı yönteminin eğitim örnekleminde yer alan öğrencilerin matematik başarısını %78,7'lik bir performansla, test örnekleminde yer alan öğrencilerin matematik başarısını ise %79,5'lik bir performansla doğru sınıfladığı görülmektedir. 2 alt grup sınıflamasında alt düzey birinci, ikinci ve üçüncü düzeyin, üst düzey ise dördüncü, beşinci ve altıncı düzeyin birleştirilmesiyle oluşturulmuştu. Hazırlanan yeni düzeylerdeki öğrenci sayısının birbirine yakın olması sınıflama performansını da dengelemiştir. Örneklem

büyüklüğü azalıp her bir düzeyde yaklaşık aynı sayıda öğrenci olduğunda düzeylerin doğru sınıflandırılma oranı üst düzey öğrenciler açısından artmıştır. Büyük örnekleme üst düzeydeki öğrencilerin doğru sınıflandırılma oranı %49,5 ilken, orta büyüklükteki örnekleme %79,5'e yükselmiştir. Bununla birlikte aynı örnekleme alt grup sayısı azaldığında sınıflama performansı artmıştır.

Karar ağaçları yöntemi için de aynı bağımlı/bağımsız değişkenler seçilerek analizler gerçekleştirilmiş ve aşağıdaki bulgulara ulaşılmıştır.

Tablo 4. 17.: Öğrenci başarılarının orta büyüklükteki örnekleme, ilgili değişkenlerle 2 alt gruba sınıflanmasında karar ağaçları yönteminin performansı

<i>Gözlenen</i>	<i>Tahmin Edilen</i>		
	<i>Alt düzey</i>	<i>Üst düzey</i>	<i>DTY</i>
Alt düzey	2377	678	77,8%
Üst düzey	791	2340	74,7%
Toplam	51,2%	48,8%	76,3%

Tablo 4.17. incelendiğinde orta büyüklükteki örnekleme 2 alt gruba sınıflama yapma konusunda karar ağaçları yönteminin öğrencilerin matematik başarısını %76,3'lük bir performansla doğru sınıfladığı görülmektedir. 2 alt grup sınıflamasında alt düzey birinci, ikinci ve üçüncü düzeyin, üst düzey ise dördüncü, beşinci ve altıncı düzeyin birleştirilmesiyle oluşturulmuştu. Hazırlanan yeni düzeylerdeki öğrenci sayısının birbirine yakın olması sınıflama performansını da dengelemiştir. Örneklem büyüklüğü azalıp her bir düzeyde yaklaşık aynı sayıda öğrenci olduğunda düzeylerin doğru sınıflandırılma oranı üst düzey öğrenciler açısından artmıştır. Büyük örnekleme üst düzeydeki öğrencilerin doğru sınıflandırılma oranı %44,5 ilken, orta büyüklükteki örnekleme %74,7'ye yükselmiştir. Bununla birlikte aynı örnekleme alt grup sayısı azaldığında sınıflama performansı artmıştır.

Ayırma analizi yöntemi için de aynı bağımlı/bağımsız değişkenler seçilerek analizler gerçekleştirilmiş ve aşağıdaki bulgulara ulaşılmıştır.

Tablo 4. 18.: Öğrenci başarılarının orta büyüklükteki örnekleme, ilgili değişkenlerle 2 alt gruba sınıflanmasında ayırma analizi yönteminin performansı

<i>Gözlenen</i>	<i>Tahmin Edilen</i>		<i>Toplam</i>
	<i>Alt düzey</i>	<i>Üst düzey</i>	
Alt düzey	2451	604	3055
Üst düzey	838	2293	3131
Alt düzey	80,2	19,8	100,0
Üst düzey	26,8	73,2	100,0
DTY			76,7%

Tablo 4.18. incelendiğinde orta büyüklükteki örnekleme 2 alt gruba sınıflama yapma konusunda ayırma analizi yönteminin öğrencilerin matematik başarısını %76,7'lik bir performansla doğru sınıfladığı görülmektedir. 2 alt grup sınıflamasında alt düzey birinci, ikinci ve üçüncü düzeyin, üst düzey ise dördüncü, beşinci ve altıncı düzeyin birleştirilmesiyle oluşturulmuştu. Örneklem büyüklüğü azalıp her bir düzeyde yaklaşık aynı sayıda öğrenci olduğunda düzeylerin doğru sınıflandırılma oranı her iki düzeydeki öğrenciler açısından artmıştır. Bununla birlikte aynı örnekleme alt grup sayısı azaldığında sınıflama performansı artmıştır.

4.3. Araştırmanın Üçüncü Alt Problemine İlişkin Bulgular ve Yorumlar

Öğrenci başarılarının küçük örnekleme, 6, 3 ve 2 alt gruba sınıflanması konusunda;

- a) *yapay sinir ağı yönteminin performansı nasıldır?*
- b) *karar ağaçları yönteminin performansı nasıldır?*
- c) *ayırma analizi yönteminin performansı nasıldır?*

Örneklem Büyüklüğü : 603

Sınıflama Grubu : 6 ALT GRUP

Öğrenci başarılarının yapay sinir ağı ile küçük örnekleme 6 alt gruba sınıflanması amacıyla “Çok Katmanlı Algılayıcı” modeli kullanılmıştır. Modelde yer alan bağımlı değişken öğrencilerin başarı düzeylerinden oluşan 6 alt grup, bağımsız değişkenler ise sınıflamada kullanılan 17 değişkenden oluşmaktadır.

Yapay sinir ağı analizlerinde aktivasyon fonksiyonu seçiminde gizli katmanda yer alan hücrelere Hiperbolik Tanjant Fonksiyonu, çıktı katmanında yer alan hücrelere ise Softmax Fonksiyonu uygulanmıştır. Analizlerdeki veri setinin %70’i eğitimde kullanılan örneklem, %30’u testte kullanılan örneklem olarak seçilmiştir.

Küçük örnekleme 6 alt gruba sınıflama yapma konusunda yapay sinir ağının performansını belirlemek amacıyla 50 farklı deneme analizi yapılmıştır. Yapay sinir ağı ile 50 analiz sonucunda, eğitim örnekleminde yer alan öğrencilerin matematik başarısını sınıflama performansı ortalaması %38,4, test örnekleminde yer alan öğrencilerin matematik başarısını sınıflama performansı ortalaması %34,8 olarak belirlenmiştir. Bununla birlikte elde edilen en yüksek sınıflama yüzdesi seçilerek Tablo 4.19’da sunulmuştur.

Tablo 4. 19.: Öğrenci başarılarının küçük örnekleme, ilgili değişkenlerle 6 alt gruba sınıflanmasında yapay sinir ağı yönteminin performansı

Örneklem	Gözlenen	Tahmin Edilen						DTY
		Düzyey1	Düzyey2	Düzyey3	Düzyey4	Düzyey5	Düzyey6	
Eğitim	Düzyey1	43	7	5	2	3	3	68,3%
	Düzyey2	23	26	9	9	1	3	36,6%
	Düzyey3	9	8	26	11	7	8	37,7%
	Düzyey4	7	8	8	21	10	14	30,9%
	Düzyey5	2	4	9	10	17	27	24,6%
	Düzyey6	4	0	3	7	5	46	70,8%
	Toplam	21,7%	13,1%	14,8%	14,8%	10,6%	24,9%	44,2%
Test	Düzyey1	19	9	2	2	3	2	51,4%
	Düzyey2	14	10	4	1	0	0	34,5%
	Düzyey3	5	10	6	7	2	2	18,8%
	Düzyey4	5	3	8	4	6	7	12,1%
	Düzyey5	2	1	2	9	9	9	28,1%
	Düzyey6	0	1	1	2	5	26	74,3%
	Toplam	22,7%	17,2%	11,6%	12,6%	12,6%	23,2%	37,4%

Tablo 4.19. incelendiğinde küçük örnekleme 6 alt gruba sınıflama yapma konusunda yapay sinir ağı yönteminin eğitim örnekleminde yer alan öğrencilerin matematik başarısını %44,2'lik bir performansla, test örnekleminde yer alan öğrencilerin matematik başarısını ise %37,4'lük bir performansla doğru sınıfladığı görülmektedir. Yapay sinir ağı sırasıyla altıncı ve birinci düzeydeki öğrencileri en yüksek performansla sınıflarken orta düzeylerde bu performans düşmüştür. İki, üç, dört ve beşinci düzeydeki öğrenciler birbirine daha yakınken, birinci ve altıncı düzeydeki öğrencilerin gruptaki en düşük ve en yüksek puanlara sahip olması, sınıflama performansının daha yüksek çıkmasında etkili olabilir. Ayrıca örneklem büyüklüğü azalıp her bir düzeyde yaklaşık aynı sayıda öğrenci olduğunda düzeylerin doğru sınıflandırılma oranları da artmıştır. Büyük örnekleme birinci düzeydeki öğrencilerin doğru sınıflandırılma oranı %43,2 ilken, orta büyüklükteki örnekleme %58,7'ye, küçük örnekleme %68,3' e yükselmiştir. Benzer değişim altıncı düzey için de geçerlidir. Bununla birlikte yapay sinir ağının genel sınıflandırma performansı da artmıştır.

Düzyey1'de yer alan öğrencilerin başka düzeylerde sınıflanması yanlış sınıflandırmaları göstermektedir. Ancak belirtmek gerekir ki, yakın düzeylere yapılan sınıflamalarda hata daha az, uzak düzeylere yapılan sınıflamalarda hata daha fazladır. Bu nedenle Düzyey1'deki öğrencilerin Düzyey2'de sınıflandırılmasındaki hata Düzyey6'da sınıflandırmadaki hatadan daha azdır.

Örneğin eğitim setinde Düzey1’de yer alan öğrencilerin Düzey1’de sınıflanma doğruluğu %58,7 iken, öğrencilerin %23,7’si Düzey2’de, %8,0’i Düzey3’te, %4,7’si Düzey4’te, %0,9’u Düzey5’te ve %4,1’i Düzey6’da yanlış sınıflandırılmıştır. Bu sonuçlar sınıflamada yapılan hatanın görüldüğünden daha az olduğunu da göstermektedir.

Karar ağaçları yöntemi için de aynı bağımlı/bağımsız değişkenler seçilerek analizler gerçekleştirilmiş ve aşağıdaki bulgulara ulaşılmıştır.

Tablo 4. 20.: Öğrenci başarılarının küçük örnekleme, ilgili değişkenlerle 6 alt gruba sınıflanmasında karar ağaçları yönteminin performansı

<i>Gözlenen</i>	<i>Tahmin Edilen</i>						<i>DTY</i>
	<i>Düzey1</i>	<i>Düzey2</i>	<i>Düzey3</i>	<i>Düzey4</i>	<i>Düzey5</i>	<i>Düzey6</i>	
Düzey1	41	27	8	0	10	14	41,0%
Düzey2	34	32	15	0	4	15	32,0%
Düzey3	18	32	30	0	7	14	29,7%
Düzey4	10	21	30	0	22	18	0,0%
Düzey5	4	18	24	0	29	26	28,7%
Düzey6	0	2	18	0	27	53	53,0%
Toplam	17,7%	21,9%	20,7%	0,0%	16,4%	23,2%	30,7%

Tablo 4.20. incelendiğinde küçük örnekleme 6 alt gruba sınıflama yapma konusunda karar ağaçları yönteminin öğrencilerin matematik başarısını %30,7’lik bir performansla doğru sınıfladığı görülmektedir. Hatta yöntem dördüncü düzeydeki öğrencilerin hiçbirini doğru sınıflandıramamıştır. Örnekleme büyüklüğü azaldığında karar ağaçlarının genel sınıflandırma performansı da düşmüştür.

Karar ağaçlarında da Düzey1’de yer alan öğrencilerin başka düzeylerde sınıflanması yanlış sınıflandırmaları göstermektedir. Ancak belirtmek gerekir ki, burada da yakın düzeylere yapılan sınıflamalarda hata daha az, uzak düzeylere yapılan sınıflamalarda hata daha fazladır. Bu nedenle Düzey1’deki öğrencilerin Düzey2’de sınıflandırılmasındaki hata Düzey6’da sınıflandırmadaki hatadan daha azdır.

Örneğin Düzey1’de yer alan öğrencilerin Düzey1’de sınıflanma doğruluğu %38,8 iken, öğrencilerin %40,1’i Düzey2’de, %17,0’si Düzey3’te, %3,4’ü Düzey4’te, %0,7’si Düzey5’te ve %0,0’ı Düzey6’da yanlış sınıflandırılmıştır. Bu sonuçlar da sınıflamada yapılan hatanın görüldüğünden daha az olduğunu göstermektedir.

Ayırma analizi yöntemi için de aynı bağımlı/bağımsız değişkenler seçilerek analizler gerçekleştirilmiş ve aşağıdaki bulgulara ulaşılmıştır.

Tablo 4. 21.: Öğrenci başarılarının küçük örnekleme, ilgili değişkenlerle 6 alt gruba sınıflanmasında ayırma analizi yönteminin performansı

6 Alt Grup	Tahmin Edilen						Toplam
	Düzyey1	Düzyey2	Düzyey3	Düzyey4	Düzyey5	Düzyey6	
Düzyey1	58	22	11	3	3	3	100
Düzyey2	34	32	18	10	4	2	100
Düzyey3	17	18	31	17	12	6	101
Düzyey4	12	12	18	23	18	18	101
Düzyey5	6	5	12	13	37	28	101
Düzyey6	6	1	0	7	22	64	100
Düzyey1	58,0	22,0	11,0	3,0	3,0	3,0	100,0
Düzyey2	34,0	32,0	18,0	10,0	4,0	2,0	100,0
Düzyey3	16,8	17,8	30,7	16,8	11,9	5,9	100,0
Düzyey4	11,9	11,9	17,8	22,8	17,8	17,8	100,0
Düzyey5	5,9	5,0	11,9	12,9	36,6	27,7	100,0
Düzyey6	6,0	1,0	,0	7,0	22,0	64,0	100,0
DTY							40,6%

Tablo 4.21. incelendiğinde küçük örnekleme 6 alt gruba sınıflama yapma konusunda ayırma analizi yönteminin öğrencilerin matematik başarısını %40,6'lık bir performansla doğru sınıfladığı görülmektedir. Örneklem büyüklüğü azaldığında karar ağaçlarının genel sınıflandırma performansı artmıştır.

Ayırma analizinde de Düzyey1'de yer alan öğrencilerin başka düzeylerde sınıflanması yanlış sınıflandırmaları göstermektedir. Ancak belirtmek gerekir ki, yakın düzeylere yapılan sınıflamalarda hata daha az, uzak düzeylere yapılan sınıflamalarda hata daha fazladır. Bu nedenle Düzyey1'deki öğrencilerin Düzyey2'de sınıflandırılmasındaki hata Düzyey6'da sınıflandırmadaki hatadan daha azdır.

Örneğin Düzyey1'de yer alan öğrencilerin Düzyey1'de sınıflanma doğruluğu %58,7 iken, öğrencilerin %20,2'si Düzyey2'de, %12,2'si Düzyey3'te, %4,2'si Düzyey4'te, %1,8'i Düzyey5'te ve %2,9'u Düzyey6'da yanlış sınıflandırılmıştır. Bu sonuçlar sınıflamada yapılan hatanın görüldüğünden daha az olduğunu da göstermektedir.

Örneklem Büyüklüğü : 603
Sınıflama Grubu : 3 ALT GRUP

Öğrenci başarılarının yapay sinir ağı ile küçük örnekleme 3 alt gruba sınıflanması amacıyla “Çok Katmanlı Algılayıcı” modeli kullanılmıştır. Modelde yer alan bağımlı değişken öğrencilerin başarı düzeylerinden oluşan 3 alt grup, bağımsız değişkenler ise sınıflamada kullanılan 17 değişkenden oluşmaktadır.

Yapay sinir ağı analizlerinde aktivasyon fonksiyonu seçiminde gizli katmanda yer alan hücrelere Hiperbolik Tanjant Fonksiyonu, çıktı katmanında yer alan hücrelere ise Softmax Fonksiyonu uygulanmıştır. Analizlerdeki veri setinin %70’i eğitimde kullanılan örneklem, %30’u testte kullanılan örneklem olarak seçilmiştir.

Küçük örnekleme 3 alt gruba sınıflama yapma konusunda yapay sinir ağının performansını belirlemek amacıyla 50 farklı deneme analizi yapılmıştır. Yapay sinir ağı ile 50 analiz sonucunda, eğitim örnekleminde yer alan öğrencilerin matematik başarısını sınıflama performansı ortalaması %63,1, test örnekleminde yer alan öğrencilerin matematik başarısını sınıflama performansı ortalaması %61,6 olarak belirlenmiştir. Bununla birlikte elde edilen en yüksek sınıflama yüzdesi seçilerek Tablo 4.22’de sunulmuştur.

Tablo 4. 22.: Öğrenci başarılarının küçük örnekleme, ilgili değişkenlerle 3 alt gruba sınıflanmasında yapay sinir ağı yönteminin performansı

Örneklem	Gözlenen	Tahmin Edilen			
		Düşük düzey	Orta düzey	Üst düzey	DTY
Eğitim	Düşük düzey	104	27	9	74,3%
	Orta düzey	41	69	40	46,0%
	Üst düzey	12	27	98	71,5%
	Toplam	36,8%	28,8%	34,4%	63,5%
Test	Düşük düzey	41	15	4	68,3%
	Orta düzey	12	27	13	51,9%
	Üst düzey	1	11	52	81,3%
	Toplam	30,7%	30,1%	39,2%	68,2%

Tablo 4.22. incelendiğinde küçük örnekleme 3 alt gruba sınıflama yapma konusunda yapay sinir ağı yönteminin eğitim örnekleminde yer alan öğrencilerin matematik başarısını %63,5’lik bir performansla, test örnekleminde yer alan öğrencilerin matematik başarısını ise %68,2’lik bir performansla doğru sınıfladığı görülmektedir. Örneklem büyüklüğü azalıp her bir düzeyde yaklaşık aynı sayıda öğrenci olduğunda düzeylerin doğru sınıflandırılma oranları da artmıştır. Bununla

birlikte aynı örnekleme alt grup sayısı azaldığında sınıflama performansı artmıştır.

Düşük düzeyde yer alan öğrencilerin başka düzeylerde sınıflanması yanlış sınıflandırmaları göstermektedir. Ancak belirtmek gerekir ki, yakın düzeylere yapılan sınıflamalarda hata daha az, uzak düzeylere yapılan sınıflamalarda hata daha fazladır. Bu nedenle düşük düzeydeki öğrencilerin orta düzeyde sınıflandırılmasındaki hata üst düzeyde sınıflandırmadaki hatadan daha azdır.

Örneğin eğitim setinde düşük düzeyde yer alan öğrencilerin düşük düzeyde sınıflanma doğruluğu %74,3 iken, öğrencilerin %19,3'ü orta düzeyde ve %6,4'ü üst düzeyde yanlış sınıflandırılmıştır. Bu sonuçlar sınıflamada yapılan hatanın görüldüğünden daha az olduğunu da göstermektedir.

Karar ağaçları yöntemi için de aynı bağımlı/bağımsız değişkenler seçilerek analizler gerçekleştirilmiş ve aşağıdaki bulgulara ulaşılmıştır.

Tablo 4. 23.: Öğrenci başarılarının küçük örnekleme, ilgili değişkenlerle 3 alt gruba sınıflanmasında karar ağaçları yönteminin performansı

<i>Gözlenen</i>	<i>Tahmin Edilen</i>			
	<i>Düşük düzey</i>	<i>Orta düzey</i>	<i>Üst düzey</i>	<i>DTY</i>
Düşük düzey	127	57	16	63,5%
Orta düzey	56	106	40	52,5%
Üst düzey	12	78	111	55,2%
Toplam	32,3%	40,0%	27,7%	57,0%

Tablo 4.23. incelendiğinde küçük örnekleme 3 alt gruba sınıflama yapma konusunda karar ağaçları yönteminin öğrencilerin matematik başarısını %57,0'lik bir performansla doğru sınıfladığı görülmektedir. Orta büyüklükteki örnekleme göre küçük örnekleme düzeylerin doğru sınıflandırılma oranları düşük ve üst düzey için düşerken, orta düzey için artmıştır. Bununla birlikte aynı örnekleme alt grup sayısı azaldığında sınıflama performansı artmıştır. Ancak 3 alt gruba sınıflama performansı orta büyüklükteki örnekleme göre küçük örnekleme düşmüştür.

Karar ağaçlarında da düşük düzeyde yer alan öğrencilerin başka düzeylerde sınıflanması yanlış sınıflandırmaları göstermektedir. Ancak belirtmek gerekir ki, burada da yakın düzeylere yapılan sınıflamalarda hata daha az, uzak düzeylere yapılan sınıflamalarda hata daha fazladır. Bu nedenle düşük düzeydeki öğrencilerin orta düzeyde sınıflandırılmasındaki hata üst düzeyde sınıflandırmadaki hatadan daha azdır.

Örneğin düşük düzeyde yer alan öğrencilerin düşük düzeyde sınıflanma doğruluğu %63,5 iken, öğrencilerin %28,5'i orta düzeyde ve %8,0'i üst düzeyde yanlış sınıflandırılmıştır. Bu sonuçlar da sınıflamada yapılan hatanın görüldüğünden daha az olduğunu göstermektedir.

Ayırma analizi yöntemi için de aynı bağımlı/bağımsız değişkenler seçilerek analizler gerçekleştirilmiş ve aşağıdaki bulgulara ulaşılmıştır.

Tablo 4. 24.: Öğrenci başarılarının küçük örnekleme, ilgili değişkenlerle 3 alt gruba sınıflanmasında ayırma analizi yönteminin performansı

<i>Gözlenen</i>	<i>Tahmin Edilen</i>			<i>Toplam</i>
	<i>Düşük düzey</i>	<i>Orta düzey</i>	<i>Üst düzey</i>	
Düşük düzey	144	40	16	200
Orta düzey	49	99	54	202
Üst düzey	17	39	145	201
Düşük düzey	72,0	20,0	8,0	100,0
Orta düzey	24,3	49,0	26,7	100,0
Üst düzey	8,5	19,4	72,1	100,0
DTY				64,3%

Tablo 4.24. incelendiğinde küçük örnekleme 3 alt gruba sınıflama yapma konusunda ayırma analizi yönteminin öğrencilerin matematik başarısını %64,3'lük bir performansla doğru sınıfladığı görülmektedir. Ayırma analizi de yine düşük ve üst düzey öğrencileri sınıflamada yüksek performans göstermiştir. Orta büyüklükteki örnekleme göre her düzeydeki genel sınıflama performansı küçük örnekleme artmıştır.

Ayırma analizinde de düşük düzeyde yer alan öğrencilerin başka düzeylerde sınıflanması yanlış sınıflandırmaları göstermektedir. Ancak belirtmek gerekir ki, yakın düzeylere yapılan sınıflamalarda hata daha az, uzak düzeylere yapılan sınıflamalarda hata daha fazladır. Bu nedenle düşük düzeydeki öğrencilerin orta düzeyde sınıflandırılmasındaki hata üst düzeyde sınıflandırmadaki hatadan daha azdır.

Örneğin düşük düzeyde yer alan öğrencilerin düşük düzeyde sınıflanma doğruluğu %72,0 iken, öğrencilerin %20,0'si orta düzeyde ve %8,0'i üst düzeyde yanlış sınıflandırılmıştır. Bu sonuçlar da sınıflamada yapılan hatanın görüldüğünden daha az olduğunu göstermektedir.

Örneklem Büyüklüğü : 603
Sınıflama Grubu : 2 ALT GRUP

Öğrenci başarılarının yapay sinir ağı ile küçük örnekleme 2 alt gruba sınıflanması amacıyla “Çok Katmanlı Algılayıcı” modeli kullanılmıştır. Modelde yer alan bağımlı değişken öğrencilerin başarı düzeylerinden oluşan 2 alt grup, bağımsız değişkenler ise sınıflamada kullanılan 17 değişkenden oluşmaktadır.

Yapay sinir ağı analizlerinde aktivasyon fonksiyonu seçiminde gizli katmanda yer alan hücrelere Hiperbolik Tanjant Fonksiyonu, çıktı katmanında yer alan hücrelere ise Softmax Fonksiyonu uygulanmıştır. Analizlerdeki veri setinin %70’i eğitimde kullanılan örneklem, %30’u testte kullanılan örneklem olarak seçilmiştir.

Küçük örnekleme 2 alt gruba sınıflama yapma konusunda yapay sinir ağının performansını belirlemek amacıyla 50 farklı deneme analizi yapılmıştır. Yapay sinir ağı ile 50 analiz sonucunda, eğitim örnekleminde yer alan öğrencilerin matematik başarısını sınıflama performansı ortalaması %77,5, test örnekleminde yer alan öğrencilerin matematik başarısını sınıflama performansı ortalaması %78,0 olarak belirlenmiştir. Bununla birlikte elde edilen en yüksek sınıflama yüzdesi seçilerek Tablo 4.25’te sunulmuştur.

Tablo 4. 25.: Öğrenci başarılarının küçük örnekleme, ilgili değişkenlerle 2 alt gruba sınıflanmasında yapay sinir ağı yönteminin performansı

Örneklem	Gözlenen	Tahmin Edilen		
		Alt düzey	Üst düzey	DTY
Eğitim	Alt düzey	153	46	76,9%
	Üst düzey	56	173	75,5%
	Toplam	48,8%	51,2%	76,2%
Test	Alt düzey	87	15	85,3%
	Üst düzey	17	56	76,7%
	Toplam	59,4%	40,6%	81,7%

Tablo 4.25. incelendiğinde küçük örnekleme 2 alt gruba sınıflama yapma konusunda yapay sinir ağı yönteminin eğitim örnekleminde yer alan öğrencilerin matematik başarısını %76,2’lik bir performansla, test örnekleminde yer alan öğrencilerin matematik başarısını ise %81,7’lik bir performansla doğru sınıfladığı görülmektedir. Orta büyüklükteki örnekleme göre küçük örnekleme yapay sinir ağının genel sınıflandırma performansı artmıştır.

Karar ağaçları yöntemi için de aynı bağımlı/bağımsız değişkenler seçilerek analizler gerçekleştirilmiş ve aşağıdaki bulgulara ulaşılmıştır.

Tablo 4. 26.: Öğrenci başarılarının küçük örnekleme, ilgili değişkenlerle 2 alt gruba sınıflanmasında karar ağaçları yönteminin performansı

<i>Gözlenen</i>	<i>Tahmin Edilen</i>		
	<i>Alt düzey</i>	<i>Üst düzey</i>	<i>DTY</i>
Alt düzey	202	99	67,1%
Üst düzey	54	248	82,1%
Toplam	42,5%	57,5%	74,6%

Tablo 4.26. incelendiğinde küçük örnekleme 2 alt gruba sınıflama yapma konusunda karar ağaçları yönteminin öğrencilerin matematik başarısını %74,6'lık bir performansla doğru sınıfladığı görülmektedir. Orta büyüklükteki örnekleme göre küçük örnekleme karar ağacının genel sınıflandırma performansı düşmüştür.

Ayırma analizi yöntemi için de aynı bağımlı/bağımsız değişkenler seçilerek analizler gerçekleştirilmiş ve aşağıdaki bulgulara ulaşılmıştır.

Tablo 4. 27.: Öğrenci başarılarının küçük örnekleme, ilgili değişkenlerle 2 alt gruba sınıflanmasında ayırma analizi yönteminin performansı

<i>Gözlenen</i>	<i>Tahmin Edilen</i>		<i>Toplam</i>
	<i>Alt düzey</i>	<i>Üst düzey</i>	
Alt düzey	240	61	301
Üst düzey	76	226	302
Alt düzey	79,7	20,3	100,0
Üst düzey	25,2	74,8	100,0
DTY			77,3%

Tablo 4.27. incelendiğinde küçük örnekleme 2 alt gruba sınıflama yapma konusunda ayırma analizi yönteminin öğrencilerin matematik başarısını %77,3'lük bir performansla doğru sınıfladığı görülmektedir. Orta büyüklükteki örnekleme göre küçük örnekleme ayırma analizinin genel sınıflandırma performansı artmıştır.

4.4. Araştırmanın Dördüncü Alt Problemine İlişkin Bulgular ve Yorumlar

i) Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örnekleme 6, 3 ve 2 alt gruba sınıflanması konusunda;

- a) yapay sinir ağı yönteminin performansı nasıldır?
- b) karar ağaçları yönteminin performansı nasıldır?
- c) ayırma analizi yönteminin performansı nasıldır?

Örnekleme Büyüklüğü : 102

Sınıflama Grubu : 6 ALT GRUP

Öğrenci başarılarının yapay sinir ağı ile çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örnekleme 6 alt gruba sınıflanması amacıyla “Çok Katmanlı Algılayıcı” modeli kullanılmıştır. Modelde yer alan bağımlı değişken öğrencilerin başarı düzeylerinden oluşan 6 alt grup, bağımsız değişkenler ise sınıflamada kullanılan 17 değişkenden oluşmaktadır.

Yapay sinir ağı analizlerinde aktivasyon fonksiyonu seçiminde gizli katmanda yer alan hücrelere Hiperbolik Tanjant Fonksiyonu, çıktı katmanında yer alan hücrelere ise Softmax Fonksiyonu uygulanmıştır. Analizlerdeki veri setinin %70'i eğitimde kullanılan örneklem, %30'u testte kullanılan örneklem olarak seçilmiştir.

Çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örnekleme 6 alt gruba sınıflama yapma konusunda yapay sinir ağının performansını belirlemek amacıyla 50 farklı deneme analizi yapılmıştır. Yapay sinir ağı ile 50 analiz sonucunda, eğitim örnekleminde yer alan öğrencilerin matematik başarısını sınıflama performansı ortalaması %39,9, test örnekleminde yer alan öğrencilerin matematik başarısını sınıflama performansı ortalaması %30,9 olarak belirlenmiştir. Bununla birlikte elde edilen en yüksek sınıflama yüzdesi seçilerek Tablo 4.28'de sunulmuştur.

Tablo 4. 28.: Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örnekleme, ilgili değişkenlerle 6 alt gruba sınıflanmasında yapay sinir ağı yönteminin performansı

Örnekleme	Gözlenen	Tahmin Edilen						DTY
		Düzey1	Düzey2	Düzey3	Düzey4	Düzey5	Düzey6	
Eğitim	Düzey1	9	3	1	0	2	0	60,0%
	Düzey2	3	8	0	0	1	0	66,7%
	Düzey3	4	2	6	0	1	1	42,9%
	Düzey4	0	9	2	0	1	0	0,0%
	Düzey5	2	1	2	0	8	0	61,5%
	Düzey6	0	0	0	0	1	13	92,9%
	Toplam	22,5%	28,8%	13,8%	0,0%	17,5%	17,5%	55,0%
Test	Düzey1	1	0	0	0	1	0	50,0%
	Düzey2	1	3	1	0	0	0	60,0%
	Düzey3	1	0	2	0	0	0	66,7%
	Düzey4	1	1	1	0	2	0	0,0%
	Düzey5	0	1	1	0	2	0	50,0%
	Düzey6	0	1	0	0	0	2	66,7%
	Toplam	18,2%	27,3%	22,7%	0,0%	22,7%	9,1%	45,5%

Tablo 4.28. incelendiğinde çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örnekleme 6 alt gruba sınıflama yapma konusunda yapay sinir ağı yönteminin eğitim örnekleminde yer alan öğrencilerin matematik başarısını %55,0'lik bir performansla, test örnekleminde yer alan öğrencilerin matematik başarısını ise %45,5'lik bir performansla doğru sınıfladığı görülmektedir. Küçük örnekleme göre çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örnekleme yapay sinir ağının genel sınıflandırma performansı artmıştır. Yapay sinir ağlarının varyans-kovaryans matrislerinde homojenlik gibi bir varsayımı olmamasına rağmen, bu varsayımın karşılanması durumunda yöntemin performansı %55'e kadar yükselmiştir.

Düzey1'de yer alan öğrencilerin başka düzeylerde sınıflanması yanlış sınıflandırmaları göstermektedir. Ancak belirtmek gerekir ki, yakın düzeylere yapılan sınıflamalarda hata daha az, uzak düzeylere yapılan sınıflamalarda hata daha fazladır. Bu nedenle Düzey1'deki öğrencilerin Düzey2'de sınıflandırılmasındaki hata Düzey6'da sınıflandırmadaki hatadan daha azdır.

Örneğin eğitim setinde Düzey1'de yer alan öğrencilerin Düzey1'de sınıflanma doğruluğu %60,0 iken, öğrencilerin %20,0'si Düzey2'de, %6,7'si Düzey3'te, %0,0'ı Düzey4'te, %13,3'ü Düzey5'te ve %0,0'ı Düzey6'da yanlış sınıflandırılmıştır. Bu

sonular sınıflamada yapılan hatanın grldğnden daha az olduėunu da gstermektedir.

Karar aėaları yntemi iin de aynı baėımlı/baėımsız deėiėkenler seilerek analizler gerekleėtirilmiė ve aėaėıdaki bulgulara ulaėılmıėtır.

Tablo 4. 29.: ğrenci baėarılarının ok kk ve varyans-kovaryans matrislerinde homojenliėi saėlanmıė rneklemde, ilgili deėiėkenlerle 6 alt gruba sınıflanmasında karar aėaları ynteminin performansı

Gzlenen	Tahmin Edilen						DTY
	Dzey1	Dzey2	Dzey3	Dzey4	Dzey5	Dzey6	
Dzey1	0	0	9	0	0	8	0,0%
Dzey2	0	0	10	0	0	7	0,0%
Dzey3	0	0	14	0	0	3	82,4%
Dzey4	0	0	9	0	0	8	0,0%
Dzey5	0	0	8	0	0	9	0,0%
Dzey6	0	0	2	0	0	15	88,2%
Toplam	0,0%	0,0%	51,0%	0,0%	0,0%	49,0%	28,4%

Tablo 4.29. incelendiėinde ok kk ve varyans-kovaryans matrislerinde homojenliėi saėlanmıė rneklemde 6 alt gruba sınıflama yapma konusunda karar aėaları ynteminin ğrencilerin matematik baėarısını %28,4'lk bir performansla doėru sınıfladıėı grlmektedir. Kk rneklem gre ok kk ve varyans-kovaryans matrislerinde homojenliėi saėlanmıė rneklemde karar aėalarının genel sınıflandırma performansı dėmėtr.

zellikle Dzey1, Dzey2, Dzey4 ve Dzey5'teki ğrencilerin hibiri doėru sınıflandırılmamıėtır. rneėin Dzey1'deki ğrencilerin %52,9'u Dzey3'te, %47,1'i Dzey6'da sınıflandırılmıėtır. Benzer yanlış sınıflandırmalar Dzey2, Dzey4 ve Dzey5'teki ğrenciler iin de geerlidir. Buna karėın Dzey3 ve Dzey6'da yer alan ğrenciler iin yapılan sınıflandırma doėruluklarının sırasıyla %82,4 ve %88,2 olduėu grlmektedir. Bununla birlikte ilk  dzeydeki ğrenciler aėırlıklı olarak Dzey3'e, son  dzeydeki ğrenciler aėırlıklı olarak Dzey6'ya sınıflandırılmıėtır. Bu sonular sınıflamalarda yapılan hatanın bu rneklem byklėnde olduka fazla olduėunu gstermektedir. Karar aėalarının diėer rneklem byklklerindeki performansı gz nne alındıėında rneklem klmesinin yntemin performansının dėmesinde nemli etkisi olduėu sylenebilir.

Ayırma analizi yntemi iin de aynı baėımlı/baėımsız deėiėkenler seilerek analizler gerekleėtirilmiė ve aėaėıdaki bulgulara ulaėılmıėtır.

Tablo 4. 30.: Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örnekleme, ilgili değişkenlerle 6 alt gruba sınıflanmasında ayırma analizi yönteminin performansı

6 Alt Grup	Tahmin Edilen						Toplam
	Düzyey1	Düzyey2	Düzyey3	Düzyey4	Düzyey5	Düzyey6	
Düzyey1	10	0	2	3	1	1	17
Düzyey2	2	12	1	1	1	0	17
Düzyey3	4	0	9	2	2	0	17
Düzyey4	0	1	2	12	2	0	17
Düzyey5	1	2	1	3	9	1	17
Düzyey6	0	0	0	0	1	16	17
Düzyey1	58,8	,0	11,8	17,6	5,9	5,9	100,0
Düzyey2	11,8	70,6	5,9	5,9	5,9	,0	100,0
Düzyey3	23,5	,0	52,9	11,8	11,8	,0	100,0
Düzyey4	,0	5,9	11,8	70,6	11,8	,0	100,0
Düzyey5	5,9	11,8	5,9	17,6	52,9	5,9	100,0
Düzyey6	,0	,0	,0	,0	5,9	94,1	100,0
DTY							66,7%

Tablo 4.30. incelendiğinde çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örnekleme 6 alt gruba sınıflama yapma konusunda ayırma analizi yönteminin öğrencilerin matematik başarısını %66,7'lik bir performansla doğru sınıfladığı görülmektedir. Küçük örnekleme göre çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örnekleme ayırma analizinin genel sınıflandırma performansı yükselmiştir. Ayırma analizi varyans-kovaryans matrislerinin homojenliğine çok duyarlıdır. Yöntemin performansı varyans-kovaryans matrislerinin homojenliğinin sağlanmadığı örneklemlerde, örneklem büyüklüğü azaldıkça artmıştır, fakat bu artış %32,0, %35,8, %40,6 şeklinde olmuştur. Varyans-kovaryans matrislerinin homojenliğinin sağlandığı bu örnekleme ise performans yaklaşık olarak iki katına çıkmıştır.

Ayırma analizinde de Düzyey1'de yer alan öğrencilerin başka düzeylerde sınıflanması yanlış sınıflandırmaları göstermektedir. Ancak belirtmek gerekir ki, yakın düzeylere yapılan sınıflamalarda hata daha az, uzak düzeylere yapılan sınıflamalarda hata daha fazladır. Bu nedenle Düzyey1'deki öğrencilerin Düzyey2'de sınıflandırılmasındaki hata Düzyey6'da sınıflandırmadaki hatadan daha azdır.

Örneğin Düzyey1'de yer alan öğrencilerin Düzyey1'de sınıflanma doğruluğu %58,0 iken, öğrencilerin %0,0'ı Düzyey2'de, %11,8'i Düzyey3'te, %17,6'sı Düzyey4'te, %5,9'u Düzyey5'te ve %5,9'u Düzyey6'da yanlış sınıflandırılmıştır. Bu sonuçlar sınıflamada yapılan hatanın görüldüğünden daha az olduğunu da göstermektedir.

Örneklem Büyüklüğü : 102
Sınıflama Grubu : 3 ALT GRUP

Öğrenci başarılarının yapay sinir ağı ile çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örneklemde 3 alt gruba sınıflanması amacıyla “Çok Katmanlı Algılayıcı” modeli kullanılmıştır. Modelde yer alan bağımlı değişken öğrencilerin başarı düzeylerinden oluşan 3 alt grup, bağımsız değişkenler ise sınıflamada kullanılan 17 değişkenden oluşmaktadır.

Yapay sinir ağı analizlerinde aktivasyon fonksiyonu seçiminde gizli katmanda yer alan hücrelere Hiperbolik Tanjant Fonksiyonu, çıktı katmanında yer alan hücrelere ise Softmax Fonksiyonu uygulanmıştır. Analizlerdeki veri setinin %70’i eğitimde kullanılan örneklem, %30’u testte kullanılan örneklem olarak seçilmiştir.

Çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örneklemde 3 alt gruba sınıflama yapma konusunda yapay sinir ağının performansını belirlemek amacıyla 50 farklı deneme analizi yapılmıştır. Yapay sinir ağı ile 50 analiz sonucunda, eğitim örnekleminde yer alan öğrencilerin matematik başarısını sınıflama performansı ortalaması %62,3, test örnekleminde yer alan öğrencilerin matematik başarısını sınıflama performansı ortalaması %61,3 olarak belirlenmiştir. Bununla birlikte elde edilen en yüksek sınıflama yüzdesi seçilerek Tablo 4.31’de sunulmuştur.

Tablo 4. 31.: Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örneklemde, ilgili değişkenlerle 3 alt gruba sınıflanmasında yapay sinir ağı yönteminin performansı

Örneklem	Gözlenen	Tahmin Edilen			
		Düşük düzey	Orta düzey	Üst düzey	DTY
Eğitim	Düşük düzey	16	2	3	76,2%
	Orta düzey	10	12	2	50,0%
	Üst düzey	2	6	18	69,2%
	Toplam	39,4%	28,2%	32,4%	64,8%
Test	Düşük düzey	11	1	1	84,6%
	Orta düzey	3	5	2	50,0%
	Üst düzey	1	0	7	87,5%
	Toplam	48,4%	19,4%	32,3%	74,2%

Tablo 4.31. incelendiğinde çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örneklemde 3 alt gruba sınıflama yapma konusunda yapay sinir ağı yönteminin eğitim örnekleminde yer alan öğrencilerin matematik başarısını %64,8’lik bir performansla, test örnekleminde yer alan öğrencilerin

matematik başarısını ise %74,2'lik bir performansla doğru sınıfladığı görülmektedir. Küçük örnekleme göre çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örnekleme yapay sinir ağının genel sınıflandırma performansı artmıştır. Yapay sinir ağlarının varyans-kovaryans matrislerinde homojenlik gibi bir varsayımı olmamasına rağmen, bu varsayımın karşılanması durumunda yöntemin performansı %74,2'ye kadar yükselmiştir.

Düşük düzeyde yer alan öğrencilerin başka düzeylerde sınıflanması yanlış sınıflandırmaları göstermektedir. Ancak belirtmek gerekir ki, yakın düzeylere yapılan sınıflamalarda hata daha az, uzak düzeylere yapılan sınıflamalarda hata daha fazladır. Bu nedenle düşük düzeydeki öğrencilerin orta düzeyde sınıflandırılmasındaki hata üst düzeyde sınıflandırmadaki hatadan daha azdır.

Örneğin eğitim setinde düşük düzeyde yer alan öğrencilerin düşük düzeyde sınıflanma doğruluğu %76,2 iken, öğrencilerin %9,5'i orta düzeyde ve %14,3'ü üst düzeyde yanlış sınıflandırılmıştır. Bu sonuçlar sınıflamada yapılan hatanın görüldüğünden daha az olduğunu da göstermektedir.

Karar ağaçları yöntemi için de aynı bağımlı/bağımsız değişkenler seçilerek analizler gerçekleştirilmiş ve aşağıdaki bulgulara ulaşılmıştır.

Tablo 4. 32.: Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örnekleme, ilgili değişkenlerle 3 alt gruba sınıflanmasında karar ağaçları yönteminin performansı

<i>Gözlenen</i>	<i>Tahmin Edilen</i>			<i>DTY</i>
	<i>Düşük düzey</i>	<i>Orta düzey</i>	<i>Üst düzey</i>	
Düşük düzey 0	19	15	0,0%	0,0%
Orta düzey 0	23	11	67,6%	67,6%
Üst düzey 0	10	24	70,6%	70,6%
Toplam	0,0%	51,0%	49,0%	46,1%

Tablo 4.32. incelendiğinde çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örnekleme 3 alt gruba sınıflama yapma konusunda karar ağaçları yönteminin öğrencilerin matematik başarısını %46,1'lik bir performansla doğru sınıfladığı görülmektedir. Küçük örnekleme göre çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örnekleme karar ağaçlarının genel sınıflandırma performansı düşmüştür.

Özellikle düşük düzeydeki öğrencilerin hiçbiri doğru sınıflandırılmamıştır. Örneğin düşük düzeydeki öğrencilerin %55,9'u orta düzeyde, %44,1'i üst düzeyde sınıflandırılmıştır. Buna karşın orta düzeydeki ve üst düzeydeki öğrenciler için

yapılan sınıflandırma doğruluklarının sırasıyla %67,6 ve %70,6 olduğu görülmektedir. Bu sonuçlar sınıflamalarda yapılan hatanın bu örneklem büyüklüğünde düşük düzeydeki öğrenciler için oldukça fazla olduğunu göstermektedir.

Ayırma analizi yöntemi için de aynı bağımlı/bağımsız değişkenler seçilerek analizler gerçekleştirilmiş ve aşağıdaki bulgulara ulaşılmıştır.

Tablo 4. 33.: Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örnekleme, ilgili değişkenlerle 3 alt gruba sınıflanmasında ayırma analizi yönteminin performansı

<i>Gözlenen</i>	<i>Tahmin Edilen</i>			<i>Toplam</i>
	<i>Düşük düzey</i>	<i>Orta düzey</i>	<i>Üst düzey</i>	
Düşük düzey	25	5	4	34
Orta düzey	7	25	2	34
Üst düzey	3	5	26	34
Düşük düzey	73,5	14,7	11,8	100,0
Orta düzey	20,6	73,5	5,9	100,0
Üst düzey	8,8	14,7	76,5	100,0
DTY				74,5%

Tablo 4.33. incelendiğinde çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örnekleme 3 alt gruba sınıflama yapma konusunda ayırma analizi yönteminin öğrencilerin matematik başarısını %74,5'lik bir performansla doğru sınıfladığı görülmektedir. Küçük örnekleme göre çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örnekleme ayırma analizinin genel sınıflandırma performansı yükselmiştir. Ayırma analizi varyans-kovaryans matrislerinin homojenliğine çok duyarlıdır. Yöntemin performansı varyans-kovaryans matrislerinin homojenliğinin sağlanmadığı örneklerde, örneklem büyüklüğü azaldıkça artmıştır, fakat bu artış %57,2, %60,1, %64,3 şeklinde olmuştur. Varyans-kovaryans matrislerinin homojenliğinin sağlandığı bu örnekleme ise performans daha da yüksek artış göstermiştir.

Ayırma analizinde de düşük düzeyde yer alan öğrencilerin başka düzeylerde sınıflanması yanlış sınıflandırmaları göstermektedir. Ancak belirtmek gerekir ki, yakın düzeylere yapılan sınıflamalarda hata daha az, uzak düzeylere yapılan sınıflamalarda hata daha fazladır. Bu nedenle düşük düzeydeki öğrencilerin orta düzeyde sınıflandırılmasındaki hata üst düzeyde sınıflandırmadaki hatadan daha azdır.

Örneğin düşük düzeyde yer alan öğrencilerin düşük düzeyde sınıflanma doğruluğu %73,5 iken, öğrencilerin %14,7'si orta düzeyde ve %11,8'i üst düzeyde yanlış sınıflandırılmıştır. Bu sonuçlar da sınıflamada yapılan hatanın görüldüğünden daha az olduğunu göstermektedir.



Örneklem Büyüklüğü : 102
Sınıflama Grubu : 2 ALT GRUP

Öğrenci başarılarının yapay sinir ağı ile çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örneklemde 2 alt gruba sınıflanması amacıyla “Çok Katmanlı Algılayıcı” modeli kullanılmıştır. Modelde yer alan bağımlı değişken öğrencilerin başarı düzeylerinden oluşan 2 alt grup, bağımsız değişkenler ise sınıflamada kullanılan 17 değişkenden oluşmaktadır.

Yapay sinir ağı analizlerinde aktivasyon fonksiyonu seçiminde gizli katmanda yer alan hücrelere Hiperbolik Tanjant Fonksiyonu, çıktı katmanında yer alan hücrelere ise Softmax Fonksiyonu uygulanmıştır. Analizlerdeki veri setinin %70’i eğitimde kullanılan örneklem, %30’u testte kullanılan örneklem olarak seçilmiştir.

Çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örneklemde 2 alt gruba sınıflama yapma konusunda yapay sinir ağının performansını belirlemek amacıyla 50 farklı deneme analizi yapılmıştır. Yapay sinir ağı ile 50 analiz sonucunda, eğitim örneğinde yer alan öğrencilerin matematik başarısını sınıflama performansı ortalaması %76,5, test örneğinde yer alan öğrencilerin matematik başarısını sınıflama performansı ortalaması %73,7 olarak belirlenmiştir. Bununla birlikte elde edilen en yüksek sınıflama yüzdesi seçilerek Tablo 4.34’te sunulmuştur.

Tablo 4. 34.: Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örneklemde, ilgili değişkenlerle 2 alt gruba sınıflanmasında yapay sinir ağı yönteminin performansı

Örneklem	Gözlenen	Tahmin Edilen		
		Alt düzey	Üst düzey	DTY
Eğitim	Alt düzey	26	5	83,9%
	Üst düzey	7	29	80,6%
	Toplam	49,3%	50,7%	82,1%
Test	Alt düzey	17	3	85,0%
	Üst düzey	4	11	73,3%
	Toplam	60,0%	40,0%	80,0%

Tablo 4.34. incelendiğinde çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örneklemde 2 alt gruba sınıflama yapma konusunda yapay sinir ağı yönteminin eğitim örneğinde yer alan öğrencilerin matematik başarısını %82,1’lik bir performansla, test örneğinde yer alan öğrencilerin matematik başarısını ise %80,0’lik bir performansla doğru sınıfladığı

görülmektedir. Küçük örnekleme göre çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örnekleme yapay sinir ağının genel sınıflandırma performansı artmıştır. Yapay sinir ağlarının varyans-kovaryans matrislerinde homojenlik gibi bir varsayımı olmamasına rağmen, bu varsayımın karşılanması durumunda yöntemin performansı %82,1'e kadar yükselmiştir.

Karar ağaçları yöntemi için de aynı bağımlı/bağımsız değişkenler seçilerek analizler gerçekleştirilmiş ve aşağıdaki bulgulara ulaşılmıştır.

Tablo 4. 35.: Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örnekleme, ilgili değişkenlerle 2 alt gruba sınıflanmasında karar ağaçları yönteminin performansı

<i>Gözlenen</i>	<i>Tahmin Edilen</i>		
	<i>Alt düzey</i>	<i>Üst düzey</i>	<i>DTY</i>
Alt düzey	33	18	64,7%
Üst düzey	19	32	62,7%
Toplam	51,0%	49,0%	63,7%

Tablo 4.35. incelendiğinde çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örnekleme 2 alt gruba sınıflama yapma konusunda karar ağaçları yönteminin öğrencilerin matematik başarısını %63,7'lik bir performansla doğru sınıfladığı görülmektedir. Küçük örnekleme göre çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örnekleme karar ağaçlarının genel sınıflandırma performansı çok düşmüştür.

Ayrırma analizi yöntemi için de aynı bağımlı/bağımsız değişkenler seçilerek analizler gerçekleştirilmiş ve aşağıdaki bulgulara ulaşılmıştır.

Tablo 4. 36.: Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örnekleme, ilgili değişkenlerle 2 alt gruba sınıflanmasında ayırma analizi yönteminin performansı

<i>Gözlenen</i>	<i>Tahmin Edilen</i>		<i>Toplam</i>
	<i>Alt düzey</i>	<i>Üst düzey</i>	
Alt düzey	42	9	51
Üst düzey	9	42	51
Alt düzey	82,4	17,6	100,0
Üst düzey	17,6	82,4	100,0
DTY			82,4%

Tablo 4.36. incelendiğinde çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örnekleme 2 alt gruba sınıflama yapma konusunda ayırma analizi yönteminin öğrencilerin matematik başarısını %82,4'lük bir performansla doğru sınıfladığı görülmektedir. Küçük örnekleme göre çok küçük ve varyans-

kovaryans matrislerinde homojenliđi sađlanmıř rneklemede ayırma analizinin genel sınıflandırma performansı ykselmiřtir. Ayırma analizi varyans-kovaryans matrislerinin homojenliđine ok duyarlıdır. Yntemin performansı varyans-kovaryans matrislerinin homojenliđinin sađlanmadıđı rneklemlerde, rneklem byklđ azaldıka artmıřtır, fakat bu artıř %74,7, %76,7, %77,3 řeklinde olmuřtur. Varyans-kovaryans matrislerinin homojenliđinin sađlandıđı bu rneklemede ise performans daha da yksek artıř gstermiřtir.



4.4. Araştırmanın Dördüncü Alt Problemine İlişkin Bulgular ve Yorumlar

ii) Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme 6, 3 ve 2 alt gruba sınıflanması konusunda;

a) yapay sinir ağı yönteminin performansı nasıldır?

b) karar ağaçları yönteminin performansı nasıldır?

c) ayırma analizi yönteminin performansı nasıldır?

Örneklem Büyüklüğü : 102

Sınıflama Grubu : 6 ALT GRUP

Öğrenci başarılarının yapay sinir ağı ile çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme 6 alt gruba sınıflanması amacıyla “Çok Katmanlı Algılayıcı” modeli kullanılmıştır. Modelde yer alan bağımlı değişken öğrencilerin başarı düzeylerinden oluşan 6 alt grup, bağımsız değişkenler ise sınıflamada kullanılan 17 değişkenden oluşmaktadır.

Yapay sinir ağı analizlerinde aktivasyon fonksiyonu seçiminde gizli katmanda yer alan hücrelere Hiperbolik Tanjant Fonksiyonu, çıktı katmanında yer alan hücrelere ise Softmax Fonksiyonu uygulanmıştır. Analizlerdeki veri setinin %70’i eğitimde kullanılan örneklem, %30’u testte kullanılan örneklem olarak seçilmiştir.

Çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme 6 alt gruba sınıflama yapma konusunda yapay sinir ağının performansını belirlemek amacıyla 50 farklı deneme analizi yapılmıştır. Yapay sinir ağı ile 50 analiz sonucunda, eğitim örnekleminde yer alan öğrencilerin matematik başarısını sınıflama performansı ortalaması %28,2, test örnekleminde yer alan öğrencilerin matematik başarısını sınıflama performansı ortalaması %25,3 olarak belirlenmiştir. Bununla birlikte elde edilen en yüksek sınıflama yüzdesi seçilerek Tablo 4.37’de sunulmuştur.

Tablo 4. 37.: Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme, ilgili değişkenlerle 6 alt gruba sınıflanmasında yapay sinir ağı yönteminin performansı

Örneklem	Gözlenen	Tahmin Edilen						DTY
		Düzyey1	Düzyey2	Düzyey3	Düzyey4	Düzyey5	Düzyey6	
Eğitim	Düzyey1	8	0	0	1	0	0	88,9%
	Düzyey2	3	0	0	3	3	3	0,0%
	Düzyey3	7	0	0	2	2	1	0,0%
	Düzyey4	4	0	1	1	2	5	7,7%
	Düzyey5	1	0	1	2	4	7	26,7%
	Düzyey6	0	0	0	1	2	9	75,0%
	Toplam		31,5%	0,0%	2,7%	13,7%	17,8%	34,2%
Test	Düzyey1	7	0	0	0	0	1	87,5%
	Düzyey2	3	0	0	1	0	1	0,0%
	Düzyey3	1	0	1	1	0	2	20,0%
	Düzyey4	1	0	0	0	1	2	0,0%
	Düzyey5	0	0	0	0	2	0	100,0%
	Düzyey6	0	0	0	0	0	5	100,0%
	Toplam		41,4%	0,0%	3,4%	6,9%	10,3%	37,9%

Tablo 4.37. incelendiğinde çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme 6 alt gruba sınıflama yapma konusunda yapay sinir ağı yönteminin eğitim örnekleminde yer alan öğrencilerin matematik başarısını %30,1'lik bir performansla, test örnekleminde yer alan öğrencilerin matematik başarısını ise %51,7'lik bir performansla doğru sınıfladığı görülmektedir. Küçük örnekleme göre çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme yapay sinir ağının genel sınıflandırma performansı artmıştır. Ancak bu artış varyans-kovaryans matrislerinde homojenliği sağlanmış örneklemden daha düşük kalmıştır.

Özellikle Düzyey2 ve Düzyey3'teki öğrencilerin hiçbiri doğru sınıflandırılmamıştır. Aynı zamanda Düzyey4 için yapılan sınıflandırma performansı %7,7'de Düzyey5 için yapılan sınıflandırma performansı %26,7'de kalmıştır. Buna karşın Düzyey1 ve Düzyey6 için yapılan sınıflandırma doğruluklarının sırasıyla %82,9 ve %75,0 olduğu görülmektedir. Örneklem büyüklüğü çok küçük olduğunda ve varyans-kovaryans matrislerinde homojenliğin sağlanmadığı durumda öğrencilerin genelinin %31,5 ile Düzyey1'de, %34,2 ile Düzyey6'da sınıflandığı da görülmektedir. Bu noktadan hareketle çok küçük örneklemlerde öğrencilerin en düşük ve en yüksek düzeylere doğru sınıflandığı söylenebilir. Bu sonuçlar sınıflamalarda yapılan hatanın bu örneklem büyüklüğünde oldukça fazla olduğunu göstermektedir.

Karar ağaçları yöntemi için de aynı bağımlı/bağımsız değişkenler seçilerek analizler gerçekleştirilmiş ve aşağıdaki bulgulara ulaşılmıştır.

Tablo 4. 38.: Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme, ilgili değişkenlerle 6 alt gruba sınıflanmasında karar ağaçları yönteminin performansı

Gözlenen	Tahmin Edilen						DTY
	Düzyey1	Düzyey2	Düzyey3	Düzyey4	Düzyey5	Düzyey6	
Düzyey1	17	0	0	0	0	0	100,0%
Düzyey2	17	0	0	0	0	0	0,0%
Düzyey3	17	0	0	0	0	0	0,0%
Düzyey4	17	0	0	0	0	0	0,0%
Düzyey5	17	0	0	0	0	0	0,0%
Düzyey6	17	0	0	0	0	0	0,0%
Toplam	100,0%	0,0%	0,0%	0,0%	0,0%	0,0%	16,7%

Tablo 4.38. incelendiğinde çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme 6 alt gruba sınıflama yapma konusunda karar ağaçları yönteminin öğrencilerin matematik başarısını %16,7'lik bir performansla doğru sınıfladığı görülmektedir. Küçük örnekleme göre çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme karar ağaçlarının genel sınıflandırma performansı düşmüştür. Hatta yöntem tüm öğrencileri birinci düzeyde olarak sınıflamıştır. Yani sınıflama işlemi çalışmamıştır.

Ayrıca yöntemin sınıflama performansı homojenliği sağlanmış çok küçük örnekleme göre de düşük kalmıştır. Homojenliğin sağlandığı çok küçük örnekleme %28,4 olan sınıflama doğruluğu, homojenliğin sağlanmadığı aynı büyüklükteki bu örnekleme %16,7'ye kadar düşmüştür. Elde edilen bu sonuçlara göre, karar ağaçlarının çok küçük örneklemlerde 6 alt gruba sınıflama yapmada performansının düşük olduğu, buna ek olarak varyans-kovaryans matrislerinde homojenliğin sağlanmadığı durumlarda performansın daha da başarısız olduğu söylenebilir.

Karar ağaçları yöntemi 6 alt gruba sınıflama yapmada varyans-kovaryans matrislerinde homojenliğin sağlanmadığı büyük, orta büyüklükteki ve küçük örneklemlerde çok küçük örnekleme göre çok daha başarılı olmuştur. Bunun yanında varyans-kovaryans matrislerinde homojenliğin sağlandığı çok küçük örnekleme başarıları da varyans-kovaryans matrislerinde homojenliğin sağlanmadığı çok küçük örnekleme göre daha yüksektir. Bu sonuçlar örneklemin çok küçük olmasının ve varyans-kovaryans matrislerinde homojenliğin

sağlanmamış olmasının yöntemin performansını oldukça düşürdüğünü göstermektedir.

Ayrırma analizi yöntemi için de aynı bağımlı/bağımsız değişkenler seçilerek analizler gerçekleştirilmiş ve aşağıdaki bulgulara ulaşılmıştır.

Tablo 4. 39.: Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme, ilgili değişkenlerle 6 alt gruba sınıflanmasında ayırma analizi yönteminin performansı

6 Alt Grup	Tahmin Edilen						Toplam
	Düzyey1	Düzyey2	Düzyey3	Düzyey4	Düzyey5	Düzyey6	
Düzyey1	11	0	4	1	0	1	17
Düzyey2	1	4	4	2	6	0	17
Düzyey3	3	1	9	1	1	2	17
Düzyey4	1	1	0	12	0	3	17
Düzyey5	1	2	0	2	9	3	17
Düzyey6	1	1	0	1	3	11	17
Düzyey1	64,7	,0	23,5	5,9	,0	5,9	100,0
Düzyey2	5,9	23,5	23,5	11,8	35,3	,0	100,0
Düzyey3	17,6	5,9	52,9	5,9	5,9	11,8	100,0
Düzyey4	5,9	5,9	,0	70,6	,0	17,6	100,0
Düzyey5	5,9	11,8	,0	11,8	52,9	17,6	100,0
Düzyey6	5,9	5,9	,0	5,9	17,6	64,7	100,0
DTY							54,9%

Tablo 4.39. incelendiğinde çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme 6 alt gruba sınıflama yapma konusunda ayırma analizi yönteminin öğrencilerin matematik başarısını %54,9'luk bir performansla doğru sınıfladığı görülmektedir. Küçük örnekleme göre çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme ayırma analizinin genel sınıflandırma performansı yükselmiştir. Ayırma analizi varyans-kovaryans matrislerinin homojenliğine çok duyarlıdır. Yöntem varyans-kovaryans matrislerinin homojenliğinin sağlandığı örnekleme %66,7'lik performans gösterirken, varyans-kovaryans matrislerinin homojenliğinin sağlanmadığı örnekleme bu performans düşmüştür. Ancak yine de çok küçük örneklemedeki performansın daha büyük örneklemlere göre daha yüksek olduğu gözlenmiştir.

Ayrırma analizinde de Düzyey1'de yer alan öğrencilerin başka düzeylerde sınıflanması yanlış sınıflandırmaları göstermektedir. Ancak belirtmek gerekir ki, yakın düzeylere yapılan sınıflamalarda hata daha az, uzak düzeylere yapılan sınıflamalarda hata daha fazladır. Bu nedenle Düzyey1'deki öğrencilerin Düzyey2'de sınıflandırılmasındaki hata Düzyey6'da sınıflandırmadaki hatadan daha azdır.

Örneğin Düzey1'de yer alan öğrencilerin Düzey1'de sınıflanma doğruluğu %64,7 iken, öğrencilerin %0'ı Düzey2'de, %23,5'i Düzey3'te, %5,9'u Düzey4'te, %0,0'ı Düzey5'te ve %5,9'u Düzey6'da yanlış sınıflandırılmıştır. Bu sonuçlar sınıflamada yapılan hatanın görüldüğünden daha az olduğunu da göstermektedir.



Örneklem Büyüklüğü : 102
Sınıflama Grubu : 3 ALT GRUP

Öğrenci başarılarının yapay sinir ağı ile çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme 3 alt gruba sınıflanması amacıyla “Çok Katmanlı Algılayıcı” modeli kullanılmıştır. Modelde yer alan bağımlı değişken öğrencilerin başarı düzeylerinden oluşan 3 alt grup, bağımsız değişkenler ise sınıflamada kullanılan 17 değişkenden oluşmaktadır.

Yapay sinir ağı analizlerinde aktivasyon fonksiyonu seçiminde gizli katmanda yer alan hücrelere Hiperbolik Tanjant Fonksiyonu, çıktı katmanında yer alan hücrelere ise Softmax Fonksiyonu uygulanmıştır. Analizlerdeki veri setinin %70’i eğitimde kullanılan örneklem, %30’u testte kullanılan örneklem olarak seçilmiştir.

Çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme 3 alt gruba sınıflama yapma konusunda yapay sinir ağının performansını belirlemek amacıyla 50 farklı deneme analizi yapılmıştır. Yapay sinir ağı ile 50 analiz sonucunda, eğitim örnekleminde yer alan öğrencilerin matematik başarısını sınıflama performansı ortalaması %49,0, test örnekleminde yer alan öğrencilerin matematik başarısını sınıflama performansı ortalaması %47,1 olarak belirlenmiştir. Bununla birlikte elde edilen en yüksek sınıflama yüzdesi seçilerek Tablo 4.40’ta sunulmuştur.

Tablo 4. 40.: Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme, ilgili değişkenlerle 3 alt gruba sınıflanmasında yapay sinir ağı yönteminin performansı

Örneklem	Gözlenen	Tahmin Edilen			DTY
		Düşük düzey	Orta düzey	Üst düzey	
Eğitim	Düşük düzey	17	4	4	68,0%
	Orta düzey	7	8	8	34,8%
	Üst düzey	1	4	17	77,3%
	Toplam	35,7%	22,9%	41,4%	60,0%
Test	Düşük düzey	7	0	2	77,8%
	Orta düzey	2	6	3	54,5%
	Üst düzey	1	3	8	66,7%
	Toplam	31,3%	28,1%	40,6%	65,6%

Tablo 4.40. incelendiğinde çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme 3 alt gruba sınıflama yapma konusunda yapay sinir ağı yönteminin eğitim örnekleminde yer alan öğrencilerin matematik başarısını %60,0’lık bir performansla, test örnekleminde yer alan öğrencilerin

matematik başarısını ise %65,6'lık bir performansla doğru sınıfladığı görülmektedir. Küçük örnekleme göre çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme yapay sinir ağının genel sınıflandırma performansı artmıştır. Ancak bu artış varyans-kovaryans matrislerinde homojenliği sağlanmış örneklemden daha düşük kalmıştır.

Düşük düzeyde yer alan öğrencilerin başka düzeylerde sınıflanması yanlış sınıflandırmaları göstermektedir. Ancak belirtmek gerekir ki, yakın düzeylere yapılan sınıflamalarda hata daha az, uzak düzeylere yapılan sınıflamalarda hata daha fazladır. Bu nedenle düşük düzeydeki öğrencilerin orta düzeyde sınıflandırılmasındaki hata üst düzeyde sınıflandırmadaki hatadan daha azdır.

Örneğin eğitim setinde düşük düzeyde yer alan öğrencilerin düşük düzeyde sınıflanma doğruluğu %68,0 iken, öğrencilerin %16,0'ı orta düzeyde ve %16,0'ı üst düzeyde yanlış sınıflandırılmıştır. Bu sonuçlar sınıflamada yapılan hatanın görüldüğünden daha az olduğunu da göstermektedir.

Karar ağaçları yöntemi için de aynı bağımlı/bağımsız değişkenler seçilerek analizler gerçekleştirilmiş ve aşağıdaki bulgulara ulaşılmıştır.

Tablo 4. 41.: Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme, ilgili değişkenlerle 3 alt gruba sınıflanmasında karar ağaçları yönteminin performansı

<i>Gözlenen</i>	<i>Tahmin Edilen</i>			
	<i>Düşük düzey</i>	<i>Orta düzey</i>	<i>Üst düzey</i>	<i>DTY</i>
Düşük düzey	34	0	0	100,0%
Orta düzey	34	0	0	0,0%
Üst düzey	34	0	0	0,0%
Toplam	100,0%	0,0%	0,0%	33,3%

Tablo 4.41. incelendiğinde çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme 3 alt gruba sınıflama yapma konusunda karar ağaçları yönteminin öğrencilerin matematik başarısını %33,3'lük bir performansla doğru sınıfladığı görülmektedir. Küçük örnekleme göre çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme karar ağaçlarının genel sınıflandırma performansı düşmüştür. Hatta yöntem tüm öğrencileri birinci düzeyde olarak sınıflamıştır. Yani sınıflama işlemi çalışmamıştır.

Ayrıca yöntemin sınıflama performansı homojenliği sağlanmış çok küçük örnekleme göre de düşük kalmıştır. Homojenliğin sağlandığı çok küçük örnekleme %46,1 olan sınıflama doğruluğu, homojenliğin sağlanmadığı aynı

büyükölükteki bu örneklemede %33,3'e kadar düşmüştür. Elde edilen bu sonuçlara göre, karar ağaçlarının çok küçük örneklemlerde 3 alt gruba sınıflama yapmada performansının düşük olduğu, buna ek olarak varyans-kovaryans matrislerinde homojenliğin sağlanamadığı durumlarda performansın daha da başarısız olduğu söylenebilir.

Karar ağaçları yöntemi 3 alt gruba sınıflama yapmada varyans-kovaryans matrislerinde homojenliğin sağlanmadığı büyük, orta büyüklükteki ve küçük örneklemlerde çok küçük örnekleme göre çok daha başarılı olmuştur. Bunun yanında varyans-kovaryans matrislerinde homojenliğin sağlandığı çok küçük örneklemdaki başarısı da varyans-kovaryans matrislerinde homojenliğin sağlanmadığı çok küçük örnekleme göre daha yüksektir. Bu sonuçlar örneklemin çok küçük olmasının ve varyans-kovaryans matrislerinde homojenliğin sağlanmamış olmasının yöntemin performansını oldukça düşürdüğünü göstermektedir.

Ayırma analizi yöntemi için de aynı bağımlı/bağımsız değişkenler seçilerek analizler gerçekleştirilmiş ve aşağıdaki bulgulara ulaşılmıştır.

Tablo 4. 42.: Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliğı sağlanmamış örneklemede, ilgili değişkenlerle 3 alt gruba sınıflanmasında ayırma analizi yönteminin performansı

<i>Gözlenen</i>	<i>Tahmin Edilen</i>			<i>Toplam</i>
	<i>Düşük düzey</i>	<i>Orta düzey</i>	<i>Üst düzey</i>	
Düşük düzey	22	7	5	34
Orta düzey	10	15	9	34
Üst düzey	7	5	22	34
Düşük düzey	64,7	20,6	14,7	100,0
Orta düzey	29,4	44,1	26,5	100,0
Üst düzey	20,6	14,7	64,7	100,0
DTY				57,8%

Tablo 4.42. incelendiğinde çok küçük ve varyans-kovaryans matrislerinde homojenliğı sağlanmamış örneklemede 3 alt gruba sınıflama yapma konusunda ayırma analizi yönteminin öğrencilerin matematik başarısını %57,8'lik bir performansla doğru sınıfladığı görülmektedir. Küçük örnekleme göre çok küçük ve varyans-kovaryans matrislerinde homojenliğı sağlanmamış örneklemede ayırma analizinin genel sınıflandırma performansı yükselmiştir. Ayırma analizi varyans-kovaryans matrislerinin homojenliğine çok duyarlıdır. Yöntem varyans-kovaryans matrislerinin homojenliğinin sağlandığı örneklemede %74,5'lik performans

gösterirken, varyans-kovaryans matrislerinin homojenliğinin sağlanmadığı örnekleme bu performans düşmüştür. Bununla birlikte varyans-kovaryans matrislerinin homojenliğinin sağlanmadığı çok küçük örnekleme performansı da büyük örnekleme göre yüksek ancak orta büyüklükteki ve küçük örnekleme göre de düşük olduğu gözlenmiştir.

Ayırma analizinde de düşük düzeyde yer alan öğrencilerin başka düzeylerde sınıflanması yanlış sınıflandırmaları göstermektedir. Ancak belirtmek gerekir ki, yakın düzeylere yapılan sınıflamalarda hata daha az, uzak düzeylere yapılan sınıflamalarda hata daha fazladır. Bu nedenle düşük düzeydeki öğrencilerin orta düzeyde sınıflandırılmasındaki hata üst düzeyde sınıflandırmadaki hatadan daha azdır.

Örneğin düşük düzeyde yer alan öğrencilerin düşük düzeyde sınıflanma doğruluğu %64,7 iken, öğrencilerin %20,6'sı orta düzeyde ve %14,7'si üst düzeyde yanlış sınıflandırılmıştır. Bu sonuçlar da sınıflamada yapılan hatanın görüldüğünden daha az olduğunu göstermektedir.

Örneklem Büyüklüğü : 102
Sınıflama Grubu : 2 ALT GRUP

Öğrenci başarılarının yapay sinir ağı ile çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme 2 alt gruba sınıflanması amacıyla “Çok Katmanlı Algılayıcı” modeli kullanılmıştır. Modelde yer alan bağımlı değişken öğrencilerin başarı düzeylerinden oluşan 2 alt grup, bağımsız değişkenler ise sınıflamada kullanılan 17 değişkenden oluşmaktadır.

Yapay sinir ağı analizlerinde aktivasyon fonksiyonu seçiminde gizli katmanda yer alan hücrelere Hiperbolik Tanjant Fonksiyonu, çıktı katmanında yer alan hücrelere ise Softmax Fonksiyonu uygulanmıştır. Analizlerdeki veri setinin %70’i eğitimde kullanılan örneklem, %30’u testte kullanılan örneklem olarak seçilmiştir.

Çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme 2 alt gruba sınıflama yapma konusunda yapay sinir ağının performansını belirlemek amacıyla 50 farklı deneme analizi yapılmıştır. Yapay sinir ağı ile 50 analiz sonucunda, eğitim örnekleminde yer alan öğrencilerin matematik başarısını sınıflama performansı ortalaması %75,0, test örnekleminde yer alan öğrencilerin matematik başarısını sınıflama performansı ortalaması %71,5 olarak belirlenmiştir. Bununla birlikte elde edilen en yüksek sınıflama yüzdesi seçilerek Tablo 4.43’te sunulmuştur.

Tablo 4. 43.: Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme, ilgili değişkenlerle 2 alt gruba sınıflanmasında yapay sinir ağı yönteminin performansı

Örneklem	Gözlenen	Tahmin Edilen		
		Alt düzey	Üst düzey	DTY
Eğitim	Alt düzey	31	5	86,1%
	Üst düzey	3	34	91,9%
	Toplam	46,6%	53,4%	89,0%
Test	Alt düzey	13	2	86,7%
	Üst düzey	3	11	78,6%
	Toplam	55,2%	44,8%	82,8%

Tablo 4.43. incelendiğinde çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme 2 alt gruba sınıflama yapma konusunda yapay sinir ağı yönteminin eğitim örnekleminde yer alan öğrencilerin matematik başarısını %89,0’luk bir performansla, test örnekleminde yer alan öğrencilerin matematik başarısını ise %82,8’lik bir performansla doğru sınıfladığı

görülmektedir. Küçük örnekleme göre çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme yapay sinir ağının genel sınıflandırma performansı artmıştır. %89,0'luk performans yapay sinir ağının tüm örneklem büyüklüklerinde 2 alt gruba sınıflama yapmada ulaştığı en yüksek performanstır. Ancak homojenliği sağlanmamış çok küçük bu veri setinde yapay sinir ağı en yüksek performansı göstermiş olsa da 50 deneme analizinden elde edilen bulguların ortalamaları karşılaştırıldığında homojenliğin etkisi ortaya çıkmaktadır. Homojenliğin sağlandığı çok küçük veri setinde yöntemin performansı %76,5 iken, homojenliğin sağlanmadığı çok küçük veri setinde bu performans %75,0 olmuştur. Bu durumda homojenliğin sağlanmasının yapay sinir ağının performansını da artırdığı söylenebilir.

Karar ağaçları yöntemi için de aynı bağımlı/bağımsız değişkenler seçilerek analizler gerçekleştirilmiş ve aşağıdaki bulgulara ulaşılmıştır.

Tablo 4. 44.: Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme, ilgili değişkenlerle 2 alt gruba sınıflanmasında karar ağaçları yönteminin performansı

Gözlenen	Tahmin Edilen		
	Alt düzey	Üst düzey	DTY
Alt düzey	51	0	100,0%
Üst düzey	51	0	0,0%
Toplam	100,0%	0,0%	50,0%

Tablo 4.44. incelendiğinde çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme 2 alt gruba sınıflama yapma konusunda karar ağaçları yönteminin öğrencilerin matematik başarısını %50,0'lik bir performansla doğru sınıfladığı görülmektedir. Küçük örnekleme göre çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme karar ağaçlarının genel sınıflandırma performansı düşmüştür. Hatta yöntem tüm öğrencileri birinci düzeyde olarak sınıflamıştır. Yani sınıflama işlemi çalışmamıştır.

Ayrıca yöntemin sınıflama performansı homojenliği sağlanmış çok küçük örnekleme göre de düşük kalmıştır. Homojenliğin sağlandığı çok küçük örnekleme %63,7 olan sınıflama doğruluğu, homojenliğin sağlanmadığı aynı büyüklükteki bu örnekleme %50,0'ye kadar düşmüştür. Elde edilen bu sonuçlara göre, karar ağaçlarının çok küçük örneklemlerde iki alt gruba sınıflama yapmada performansının düşük olduğu, buna ek olarak varyans-kovaryans matrislerinde

homojenliğin sağlanamadığı durumlarda performansın daha da başarısız olduğu söylenebilir.

Karar ağaçları yöntemi 2 alt gruba sınıflama yapmada varyans-kovaryans matrislerinde homojenliğin sağlanmadığı büyük, orta büyüklükteki ve küçük örneklerde çok küçük örnekleme göre çok daha başarılı olmuştur. Bunun yanında varyans-kovaryans matrislerinde homojenliğin sağlandığı çok küçük örneklemedeki başarısı da varyans-kovaryans matrislerinde homojenliğin sağlanmadığı çok küçük örnekleme göre daha yüksektir. Bu sonuçlar örneklemin çok küçük olmasının ve varyans-kovaryans matrislerinde homojenliğin sağlanmamış olmasının yöntemin performansını oldukça düşürdüğünü göstermektedir.

Ayırma analizi yöntemi için de aynı bağımlı/bağımsız değişkenler seçilerek analizler gerçekleştirilmiş ve aşağıdaki bulgulara ulaşılmıştır.

Tablo 4. 45.: Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme, ilgili değişkenlerle 2 alt gruba sınıflanmasında ayırma analizi yönteminin performansı

<i>Gözlenen</i>	<i>Tahmin Edilen</i>		<i>Toplam</i>
	<i>Alt düzey</i>	<i>Üst düzey</i>	
Alt düzey	39	12	51
Üst düzey	13	38	51
Alt düzey	76,5	23,5	100,0
Üst düzey	25,5	74,5	100,0
DTY			75,5%

Tablo 4.45. incelendiğinde çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme 2 alt gruba sınıflama yapma konusunda ayırma analizi yönteminin öğrencilerin matematik başarısını %75,5'lik bir performansla doğru sınıfladığı görülmektedir. Çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme ayırma analizinin genel sınıflandırma performansı büyük örnekleme göre artarken, orta büyüklükteki ve küçük örnekleme göre düşmüştür. Ayırma analizi varyans-kovaryans matrislerinin homojenliğine çok duyarlıdır. Yöntem varyans-kovaryans matrislerinin homojenliğinin sağlandığı örnekleme %82,4'lük performans gösterirken, varyans-kovaryans matrislerinin homojenliğinin sağlanmadığı örnekleme bu performans düşmüştür. Bununla birlikte varyans-kovaryans matrislerinin homojenliğinin sağlanmadığı çok küçük örnekleme performansı da büyük örnekleme göre

yüksek ancak orta büyüklükteki ve küçük örnekleme göre de düşük olduğu gözlenmiştir.




4.5. Araştırmanın Beşinci Alt Problemine İlişkin Bulgular ve Yorumlar

Öğrenci başarılarını 6, 3 ve 2 alt gruba sınıflandırmada, büyük, orta, küçük ve çok küçük örneklerde yapay sinir ağı, karar ağaçları ve ayırma analizi performansları farklılık göstermekte midir?


Örneklem Büyüklüğü : 126126, 6186, 603, 102

Sınıflama Grubu : 6, 3, 2 ALT GRUP


Yöntemlerin öğrenci başarılarını büyük, orta büyüklükteki, küçük ve çok küçük örneklem büyüklüklerinde 6, 3 ve 2 alt gruba sınıflandırma performanslarına ilişkin elde edilen bulgular Şekil 4.1, Şekil 4.2, Şekil 4.3, Şekil 4.4 ve Şekil 4.5'te verilmiştir.




Şekil 4. 1.: Yöntemlerin öğrenci başarısını büyük örneklemde 6, 3 ve 2 alt gruba sınıflama performansları




Şekil 4. 2.: Yöntemlerin öğrenci başarısını orta büyüklükteki örnekleme 6, 3 ve 2 alt gruba sınıflama performansları



Şekil 4. 3.: Yöntemlerin öğrenci başarısını küçük örnekleme 6, 3 ve 2 alt gruba sınıflama performansları



Şekil 4. 4.: Yöntemlerin öğrenci başarısını çok küçük ve varyans kovaryans matrislerinde homojenliği sağlanmış örneklemede 6, 3 ve 2 alt gruba sınıflama performansları



Şekil 4. 5.: Yöntemlerin öğrenci başarısını çok küçük ve varyans kovaryans matrislerinde homojenliği sağlanmamış örneklemede 6, 3 ve 2 alt gruba sınıflama performansları

Elde edilen bulgular incelendiğinde 6 alt gruba sınıflama yapma konusunda büyük, orta büyüklükteki ve küçük örneklem büyüklüklerinde en başarılı yöntemin yapay sinir ağı olduğu görülmektedir. Büyük örnekleme ikinci en iyi yöntem karar ağaçları iken, orta büyüklükteki ve küçük örneklemelerde ayırma analizi olmuştur. Homojenliği sağlanmış olan ve sağlanmamış olan çok küçük örneklemelerde 6 alt gruba sınıflama yapmada ise en başarılı yöntem ayırma analizi olurken; ikinci en iyi yöntem yapay sinir ağı olmuştur.

6 alt gruba sınıflama yapma konusunda örneklem büyüklüğü değiştikçe yapay sinir ağının performansı ile ilgili farklı bulgular elde edilmiştir. Yapay sinir ağının en iyi performansını belirlemek amacıyla her örneklem büyüklüğünde yapılan 50 farklı deneme analizinin performans ortalamaları, en iyi performans ortalamasının %39,9 ile varyans-kovaryans matrislerinde homojenliğin sağlandığı çok küçük örnekleme olduğunu gösterirken; 50 farklı deneme analizinde en yüksek sınıflama performansına da %55,0 ile yine varyans-kovaryans matrislerinde homojenliğin sağlandığı çok küçük örnekleme ulaşılmıştır. Bu performansı ortalama performansın %38,4 olduğu küçük örneklem izlerken; en yüksek ikinci performans varyans-kovaryans matrislerinde homojenliğin sağlanmadığı çok küçük örnekleme elde edilmiştir. Üçüncü en iyi ortalama performans büyük örnekleme elde edilirken, en yüksek üçüncü performans küçük örnekleme gözlenmiştir. Dördüncü en iyi ortalama performans orta büyüklükteki örnekleme elde edilirken, en yüksek dördüncü performans yine orta büyüklükteki örnekleme gözlenmiştir. En düşük ortalama performansın ise varyans-kovaryans matrislerinde homojenliğin sağlanmadığı çok küçük örnekleme olduğu, en düşük performansın da büyük örnekleme olduğu gözlenmiştir. Bu bulgular 6 alt gruba sınıflama yapmada yapay sinir ağı ile yapılacak uygulamalarda en iyi performansı yakalayabilmek için deneme sayısının artırılmasının, en iyi performansı yakalama fırsatını da artıracığını ortaya koymaktadır. Aynı zamanda varyans-kovaryans matrislerinin homejenliğinin sağlanmasının yapay sinir ağının 6 alt gruba sınıflama performansını da artırdığı görülmektedir.

Karar ağaçları 6 alt gruba sınıflama yapma konusunda en yüksek performansı orta büyüklükteki örnekleme göstermiş, orta büyüklükteki örnekleme göre büyük örnekleme performansı yaklaşık %0,9'luk bir kayıp yaşarken küçük ve çok küçük örneklemelerde bu kayıp daha da artmıştır. En yüksek performansı yakaladığı orta

büyükölükteki örnekleme sınıflama performansı %35,4 olurken, özellikle varyans-kovaryans matrislerinde homojenliđin sađlanmadığı çok küçük örnekleme yöntemin performansı %16,7'ye kadar gerilemiştir. Ayrıca karar ağaçları yöntemi de örnekleme büyüklüğü azaldığında performansını kaybetmesine karşılık, varyans-kovaryans matrislerinde homojenliđin sađlanması durumunda, çok küçük örnekleme varyans-kovaryans matrislerinde homojenliđin sađlanmadığı çok küçük örnekleme göre daha yüksek performans göstermiştir.

Ayırma analizi varyans-kovaryans matrislerinin homojenliđine çok duyarlıdır. Çok küçük ve varyans-kovaryans matrislerinde homojenliđi sađlanmış örnekleme ayırma analizinin gösterdiği yüksek performans bu durumu ortaya koymaktadır. 6 alt gruba sınıflama yapma konusunda büyük örnekleme %32,0, orta büyüklükteki örnekleme %35,8 ve küçük örnekleme %40,6'ya yükselen sınıflama performansı, varyans-kovaryans matrislerinde homojenliđin sađlandığı çok küçük örnekleme yaklaşık olarak iki kat artarak %66,7 olmuştur. Ayrıca 6 alt gruba sınıflama yapmada varyans-kovaryans matrislerinde homojenliđin sađlanmadığı çok küçük örnekleme sınıflama performansının da %54,9 olması, örnekleme büyüklüğü azaldıkça yöntemin performansının arttığını desteklemektedir.

3 alt gruba sınıflama yapma konusunda büyük, orta büyüklükteki ve küçük örnekleme büyüklüklerinde de en başarılı yöntemin yapay sinir ađı olduđu görölmektedir. Büyük örnekleme ikinci en iyi yöntem karar ağaçları iken, orta büyüklükteki ve küçük örneklemlerde ayırma analizi olmuştur. Homojenliđi sađlanmış olan çok küçük örnekleme 3 alt gruba sınıflama yapmada en başarılı yöntem ayırma analizi olurken; ikinci en iyi yöntem yapay sinir ađı olmuştur. Homojenliđi sađlanmamış olan çok küçük örnekleme 3 alt gruba sınıflama yapmada ise en başarılı yöntem yapay sinir ađı olurken; ikinci en iyi yöntem ayırma analizi olmuştur.

3 alt gruba sınıflama yapma konusunda da örnekleme büyüklüğü deđiştikçe yapay sinir ađının performansı ile ilgili farklı bulgular elde edilmiştir. Yapay sinir ađının en iyi performansını belirlemek amacıyla her örnekleme büyüklüğünde yapılan 50 farklı deneme analizinin performans ortalamaları, en iyi performans ortalamasının %63,1 ile küçük örnekleme olduğunu gösterirken; 50 farklı deneme analizinde en yüksek sınıflama performansına ise %74,2 ile varyans-kovaryans matrislerinde

homojenliğin sağlandığı çok küçük örnekleme ulaşılmıştır. Bu performansı ortalama performansın %62,3 olduğu varyans-kovaryans matrislerinde homojenliğin sağlandığı çok küçük örneklem izlerken; en yüksek ikinci performans küçük örnekleme elde edilmiştir. Üçüncü en iyi ortalama performans büyük örnekleme elde edilirken, en yüksek üçüncü performans varyans-kovaryans matrislerinde homojenliğin sağlanmadığı örnekleme gözlenmiştir. Dördüncü en iyi ortalama performans orta büyüklükteki örnekleme elde edilirken, en yüksek dördüncü performans büyük örnekleme gözlenmiştir. En düşük ortalama performansın ise varyans-kovaryans matrislerinde homojenliğin sağlanmadığı çok küçük örnekleme olduğu, en düşük performansın ise orta büyüklükteki örnekleme olduğu gözlenmiştir. Bu bulgular 3 alt gruba sınıflama yapmada yapay sinir ağı ile yapılacak uygulamalarda en iyi performansı yakalayabilmek için deneme sayısının artırılmasının, en iyi performansı yakalama fırsatını da artıracaklarını ortaya koymaktadır. Aynı zamanda varyans-kovaryans matrislerinin homejenliğinin sağlanmasının yapay sinir ağının performansını da artırdığı görülmektedir.

Karar ağaçları yönteminin sınıflama performansı 3 alt gruba sınıflama yapma konusunda örneklem büyüklüğü azaldıkça düşmüştür. Karar ağaçları en yüksek performansı büyük örnekleme göstermiş, büyük örnekleme göre orta büyüklükteki örnekleme performansı yaklaşık %0,7'lik bir kayıp yaşarken küçük ve çok küçük örneklerde bu kayıp daha da artmıştır. En yüksek performansı yakaladığı orta büyüklükteki örnekleme sınıflama performansı %59,5 olurken, özellikle varyans-kovaryans matrislerinde homojenliğin sağlanmadığı çok küçük örnekleme yöntemin performansı %33,3'e kadar gerilemiştir. Ayrıca karar ağaçları yöntemi de örneklem büyüklüğü azaldığında performansını kaybetmesine karşılık, varyans-kovaryans matrislerinde homojenliğin sağlanması durumunda, çok küçük örnekleme varyans-kovaryans matrislerinde homojenliğin sağlanmadığı çok küçük örnekleme göre daha yüksek performans göstermiştir.

Ayırma analizi varyans-kovaryans matrislerinin homojenliğine çok duyarlıdır. Çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örnekleme ayırma analizinin gösterdiği yüksek performans bu durumu ortaya koymaktadır. 3 alt gruba sınıflama yapma konusunda büyük örnekleme %57,2, orta büyüklükteki örnekleme %60,1 ve küçük örnekleme %64,3'e yükselen sınıflama performansı,

varyans-kovaryans matrislerinde homojenliğin sađlandığı çok küçük örnekleme %74,5 olmuştur. Varyans-kovaryans matrislerinde homojenliğin sađlanmadığı çok küçük örnekleme sınıflama performansının %57,8 olması ise varyans-kovaryans matrislerinde homojenliğin sađlanmadığı durumlarda yöntemin 3 alt gruba sınıflama performansının düşük olduğunu ortaya koymaktadır. Bu varsayımın karşılanmadığı durumda performansın en yüksek olduğu örneklem küçük örneklem olarak belirlenmiştir.

2 alt gruba sınıflama yapma konusunda büyük, orta büyüklükteki ve küçük örneklem büyüklüklerinde de en başarılı yöntemin yapay sinir ağı olduğu görülmektedir. Büyük örnekleme ikinci en iyi yöntem karar ağaçları iken, orta büyüklükteki ve küçük örneklemde ayırma analizi olmuştur. Homojenliği sađlanmış olan çok küçük örnekleme 2 alt gruba sınıflama yapmada en başarılı yöntem ayırma analizi olurken; ikinci en iyi yöntem yapay sinir ağı olmuştur. Homojenliği sađlanmamış olan çok küçük örnekleme 2 alt gruba sınıflama yapmada ise en başarılı yöntem yapay sinir ağı olurken; ikinci en iyi yöntem ayırma analizi olmuştur.

2 alt gruba sınıflama yapma konusunda örneklem büyüklüğü deđiştikçe yapay sinir ağının performansı ile ilgili yine farklı bulgular elde edilmiştir. Yapay sinir ağının en iyi performansını belirlemek amacıyla her örneklem büyüklüğünde yapılan 50 farklı deneme analizinin performans ortalamaları, en iyi performans ortalamasının %78,2 ile büyük örnekleme olduğunu gösterirken; 50 farklı deneme analizinde en yüksek sınıflama performansına ise %89,0 ile varyans-kovaryans matrislerinde homojenliğin sađlanmadığı çok küçük örnekleme ulaşılmıştır. Bu performansı ortalama performansın %78,0 olduğu küçük örneklem izlerken; en yüksek ikinci performans varyans-kovaryans matrislerinde homojenliğin sađlandığı çok küçük örnekleme elde edilmiştir. Üçüncü en iyi ortalama performans orta büyüklükteki örnekleme elde edilirken, en yüksek üçüncü performans küçük örnekleme gözlenmiştir. Dördüncü en iyi ortalama performans varyans-kovaryans matrislerinde homojenliğin sađlandığı çok küçük örnekleme elde edilirken, en yüksek dördüncü performans orta büyüklükteki örnekleme gözlenmiştir. En düşük ortalama performansın ise varyans-kovaryans matrislerinde homojenliğin sađlanmadığı çok küçük örnekleme olduğu, en düşük performansın ise büyük örnekleme olduğu gözlenmiştir. Bu bulgular 2 alt gruba sınıflama yapmada yapay

sinir ağı ile yapılacak uygulamalarda en iyi performansı yakalayabilmek için deneme sayısının artırılmasının, en iyi performansı yakalama fırsatını da artıracaklarını ortaya koymaktadır. Aynı zamanda varyans-kovaryans matrislerinin homejenliğinin sağlanmasının yapay sinir ağının performansını da artırdığı görülmektedir.

Karar ağaçları yönteminin sınıflama performansı 2 alt gruba sınıflama yapma konusunda örneklem büyüklüğü azaldıkça düşmüştür. Karar ağaçları en yüksek performansı büyük örneklemde göstermiş, büyük örnekleme göre orta büyüklükteki örneklemde performansı yaklaşık %0,6'lık bir kayıp yaşarken küçük ve çok küçük örneklemde bu kayıp daha da artmıştır. En yüksek performansı yakaladığı orta büyüklükteki örneklemde sınıflama performansı %76,9 olurken, özellikle varyans-kovaryans matrislerinde homojenliğin sağlanmadığı çok küçük örneklemde yöntemin performansı %50'ye kadar gerilemiştir. Ayrıca karar ağaçları yöntemi de örneklem büyüklüğü azaldığında performansını kaybetmesine karşılık, varyans-kovaryans matrislerinde homojenliğin sağlanması durumunda, çok küçük örneklemde varyans-kovaryans matrislerinde homojenliğin sağlanmadığı çok küçük örnekleme göre daha yüksek performans göstermiştir.

Ayırma analizi varyans-kovaryans matrislerinin homojenliğine çok duyarlıdır. Çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örneklemde ayırma analizinin gösterdiği yüksek performans bu durumu ortaya koymaktadır. 2 alt gruba sınıflama yapma konusunda büyük örneklemde %74,7, orta büyüklükteki örneklemde %76,7 ve küçük örneklemde %77,3'e yükselen sınıflama performansı, varyans-kovaryans matrislerinde homojenliğin sağlandığı çok küçük örneklemde %82,4 olmuştur. Varyans-kovaryans matrislerinde homojenliğin sağlanmadığı çok küçük örneklemdeki 2 alt gruba sınıflama performansının %75,5 olması ise varyans-kovaryans matrislerinde homojenliğin sağlanmadığı durumlarda yöntemin performansının düşük olduğunu ortaya koymaktadır. Bu varsayımın karşılanmadığı durumda performansın en yüksek olduğu örneklem küçük örneklem olarak belirlenmiştir.

Araştırmadan elde edilen sonuçlar alanyazında yer alan çalışmalarla karşılaştırılmış ve bu araştırmanın alanyazında yer alan çalışmalarla benzerlik ve farklılıkları ele alınmıştır.

Karar ağaçları yöntemi sürekli değişkenlerin değerlerini tahmin etme konusunda iyi sonuçlar vermemektedir. Bunun yanında sınıf sayısının çok, öğrenme kümesi örneklerinin az olduğu durumlarda model oluşturmada da iyi sonuçlar vermemektedir (Köktürk, 2012; Akpınar, 2014; Büyükişıklar, 2014). Araştırmada elde edilen bulgular alanyazında elde edilen sonuçlarla benzerlik göstermektedir.

Wheler (1993), hukuk fakültesi öğrencilerinin avukatlık sınavı başarılarını 460 kişilik küçük bir örnekleme 2 alt gruba sınıflandırmada yapay sinir ağı ve ayırma analizi yöntemlerini karşılaştırmış ve analizler sonucunda; yapay sinir ağının daha yüksek performans gösterdiğini belirlemiştir.

Sığırlı (2006), hastaların kronik hepatit veya siroz hastalığına sahip olma durumları üzerinden yapay sinir ağı ve ayırma analizi yöntemlerini 164 kişilik küçük bir örnekleme 2 alt gruba sınıflandırmada karşılaştırmış ve analizler sonucunda; yapay sinir ağının daha yüksek performans gösterdiğini belirlemiştir.

Türe ve diğerleri (2005), primer hipertansiyonun yordanmasında sinir ağları, lojistik regresyon analizi ve esnek ayırma analizi yöntemlerini 276 kişilik küçük bir örnekleme 2 alt gruba sınıflandırmada karşılaştırmış ve analizler sonucunda; sinir ağlarının performansının ayırma analizinden daha yüksek olduğunu belirlemiştir.

Tosun (2007), 424 kişilik küçük bir örnekleme öğrenci başarılarını 2 alt gruba sınıflandırmada yapay sinir ağı ve karar ağaçlarını kullanmış ve analizler sonucunda; yapay sinir ağının performansının daha yüksek olduğunu tespit etmiştir.

İbrahim ve Rusli (2007), 206 kişilik küçük bir örnekleme öğrencilerin akademik başarılarını sınıflandırmada, karar ağaçları, regresyon analizi ve yapay sinir ağının performansını karşılaştırmış ve analizler sonucunda; yapay sinir ağının diğer iki yöntemden daha başarılı sonuçlar verdiğini belirlemiştir.

Burmaoğlu (2009), birleşmiş milletler kalkınma programı beşeri kalkınma endeksi verilerini kullanarak 120 kişilik çok küçük ve varyans kovaryans matrislerinin homojenliği sağlanamamış bir örnekleme ayırma analizi, lojistik regresyon analizi ve yapay sinir ağının 2 alt gruba sınıflandırma başarılarını karşılaştırmış ve analizler sonucunda; çok katmanlı algılayıcı modelin, ayırma analizine göre daha iyi sınıflandırma yaptığını belirlemiştir.

Çölkesen (2009), uydu görüntülerini yapay sinir ağları, karar ağaçları ve k-star algoritmaları ile 6000 ve 3750 kişilik orta büyüklükte örneklerde 6 alt gruba sınıflandırma başarılarını karşılaştırmış ve analizler sonucunda; ileri sınıflandırma tekniklerinin uzaktan algılanmış görüntülerin sınıflandırılmasında geleneksel sınıflandırıcılara göre iyi ve etkili bir alternatif olduklarını belirlemiştir.

Kavzoğlu ve Çölkesen (2010), karar ağaçlarının sınıflandırma performansını güncel uydu görüntülerini kullanarak 600 kişilik küçük bir örnekte 6 alt gruba sınıflandırmada en çok benzerlik yönteminin performansı ile karşılaştırmış ve analizler sonucunda; karar ağaçlarının uydu görüntülerinin sınıflandırmasında etkin bir yöntem olduğunu belirlemiştir.

Köktürk (2012), K-en yakın komşuluk, yapay sinir ağı ve karar ağaçları yöntemlerinin sınıflandırma başarılarını kadın hastalıkları ve doğum polikliniğine başvuran 240 kişilik küçük bir örnekte, gebelerden elde edilen verileri 2 alt gruba sınıflandırmada karşılaştırmış ve analizler sonucunda; yapay sinir ağı tekniğinin sınıflandırma başarısının diğer iki yöntemle göre daha iyi olduğunu belirlemiştir.

Kuyucu (2012), lojistik regresyon, yapay sinir ağı ve karar ağaçları yöntemlerinin sınıflandırma performansını 236 kişilik küçük bir örnekte 2 alt gruba sınıflandırma yapmada karşılaştırmış ve analizler sonucunda; en yüksek performansı gösteren yöntemin yapay sinir ağı olduğunu belirlemiştir.

Avcılar ve Yakut (2015), yerel seçimlerde seçmen tercihlerinin belirlenmesinde 500 kişilik küçük bir örnekte yapay sinir ağı, lojistik regresyon ve ayırma analizi yöntemlerinin sınıflandırma performansını 3 alt gruba sınıflandırma yapmada karşılaştırmış ve analizler sonucunda; yapay sinir ağının performansının ayırma analizinden daha yüksek olduğunu belirlemiştir.

Bu araştırmadan elde edilen sonuçlar alanyazında yer alan çalışmaların sonuçlarıyla benzerlik göstermiştir. Bunun yanında araştırmada kullanılan yöntemlerin farklı örneklem büyüklüklerinde ve farklı alt grup sayılarına sınıflamada gösterdiği performans sonuçları alanyazına yeni bulgular eklemiştir.

5. SONUÇ ve ÖNERİLER

Bu bölümde araştırmanın bulgu ve yorumlarına dayalı olarak ulaşılan sonuçlara ve bu sonuçlardan yola çıkarak geliştirilen önerilere yer verilmiştir.

5.1. Sonuçlar

Araştırmanın bulgu ve yorumlarına dayalı olarak ulaşılan sonuçlar alt problemlerin sırasına uygun olarak sunulmuştur.

1. Öğrenci başarılarının büyük (126126 kişilik) örnekleme 6 alt gruba sınıflanması konusunda;
 - a) *Yapay sinir ağı %36,7'lik bir performans göstermiştir.*
 - b) *Karar ağaçları %34,5'lik bir performans göstermiştir.*
 - c) *Ayırma analizi %32,0'lik bir performans göstermiştir.*

Bu sonuçlara bakılarak büyük (126126 kişilik) örnekleme 6 alt gruba sınıflama yapmada en yüksek performans gösteren yöntemin yapay sinir ağı olduğu, bunu sırasıyla karar ağaçları ve ayırma analizinin izlediği söylenebilir.

Öğrenci başarılarının büyük (126126 kişilik) örnekleme 3 alt gruba sınıflanması konusunda;

- a) *Yapay sinir ağı %62,7'lik bir performans göstermiştir.*
- b) *Karar ağaçları %59,5'lik bir performans göstermiştir.*
- c) *Ayırma analizi %57,2'lik bir performans göstermiştir.*

Bu sonuçlara bakılarak büyük (126126 kişilik) örnekleme 3 alt gruba sınıflama yapmada en yüksek performans gösteren yöntemin yapay sinir ağı olduğu, bunu sırasıyla karar ağaçları ve ayırma analizinin izlediği söylenebilir.

Öğrenci başarılarının büyük (126126 kişilik) örnekleme 2 alt gruba sınıflandırılması konusunda;

- a) Yapay sinir ağı %78,9'luk bir performans göstermiştir.**
- b) Karar ağaçları %76,9'luk bir performans göstermiştir.**
- c) Ayırma analizi %74,7'lik bir performans göstermiştir.**

Bu sonuçlara bakılarak büyük (126126 kişilik) örnekleme 2 alt gruba sınıflama yapmada en yüksek performans gösteren yöntemin yapay sinir ağı olduğu, bunu sırasıyla karar ağaçları ve ayırma analizinin izlediği söylenebilir.

2. Öğrenci başarılarının orta büyüklükteki (6186 kişilik) örnekleme 6 alt gruba sınıflandırılması konusunda;

- a) Yapay sinir ağı %36,9'luk bir performans göstermiştir.**
- b) Karar ağaçları %35,4'lük bir performans göstermiştir.**
- c) Ayırma analizi %35,8'lik bir performans göstermiştir.**

Bu sonuçlara bakılarak orta büyüklükteki (6186 kişilik) örnekleme 6 alt gruba sınıflama yapmada en yüksek performans gösteren yöntemin yapay sinir ağı olduğu, bunu sırasıyla ayırma analizi ve karar ağaçlarının izlediği söylenebilir.

Öğrenci başarılarının orta büyüklükteki (6186 kişilik) örnekleme 3 alt gruba sınıflandırılması konusunda;

- a) Yapay sinir ağı %61,8'lik bir performans göstermiştir.**
- b) Karar ağaçları %58,8'lik bir performans göstermiştir.**
- c) Ayırma analizi %60,1'lik bir performans göstermiştir.**

Bu sonuçlara bakılarak orta büyüklükteki (6186 kişilik) 3 alt gruba sınıflama yapmada en yüksek performans gösteren yöntemin yapay sinir ağı olduğu, bunu sırasıyla ayırma analizi ve karar ağaçlarının izlediği söylenebilir.

Öğrenci başarılarının orta büyüklükteki (6186 kişilik) örnekleme 2 alt gruba sınıflanması konusunda;

- a) Yapay sinir ağı %79,5'lik bir performans göstermiştir.**
- b) Karar ağaçları %76,3'lük bir performans göstermiştir.**
- c) Ayırma analizi %76,7'lik bir performans göstermiştir.**

Bu sonuçlara bakılarak orta büyüklükteki (6186 kişilik) 2 alt gruba sınıflama yapmada en yüksek performans gösteren yöntemin yapay sinir ağı olduğu, bunu sırasıyla ayırma analizi ve karar ağaçlarının izlediği söylenebilir.

3. Öğrenci başarılarının küçük (603 kişilik) örnekleme 6 alt gruba sınıflanması konusunda;

- a) Yapay sinir ağı %44,2'lik bir performans göstermiştir.**
- b) Karar ağaçları %30,7'lik bir performans göstermiştir.**
- c) Ayırma analizi %40,6'lık bir performans göstermiştir.**

Bu sonuçlara bakılarak küçük (603 kişilik) örnekleme 6 alt gruba sınıflama yapmada en yüksek performans gösteren yöntemin yapay sinir ağı olduğu, bunu sırasıyla ayırma analizi ve karar ağaçlarının izlediği söylenebilir.

Öğrenci başarılarının küçük (603 kişilik) örnekleme 3 alt gruba sınıflanması konusunda;

- a) Yapay sinir ağı %68,2'lik bir performans göstermiştir.**
- b) Karar ağaçları %57,0'lik bir performans göstermiştir.**
- c) Ayırma analizi %64,3'lük bir performans göstermiştir.**

Bu sonuçlara bakılarak küçük (603 kişilik) örnekleme 3 alt gruba sınıflama yapmada en yüksek performans gösteren yöntemin yapay sinir ağı olduğu, bunu sırasıyla ayırma analizi ve karar ağaçlarının izlediği söylenebilir.

Öğrenci başarılarının küçük (603 kişilik) örnekleme 2 alt gruba sınıflanması konusunda;

- a) Yapay sinir ağı %81,7'lik bir performans göstermiştir.**
- b) Karar ağaçları %74,6'lık bir performans göstermiştir.**
- c) Ayırma analizi %77,3'lük bir performans göstermiştir.**

Bu sonuçlara bakılarak küçük (603 kişilik) örnekleme 2 alt gruba sınıflama yapmada en yüksek performans gösteren yöntemin yapay sinir ağı olduğu, bunu sırasıyla ayırma analizi ve karar ağaçlarının izlediği söylenebilir.

4. i) Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış (102 kişilik) örnekleme 6 alt gruba sınıflanması konusunda;

- a) Yapay sinir ağı %55,0'lik bir performans göstermiştir.**
- b) Karar ağaçları %28,4'lük bir performans göstermiştir.**
- c) Ayırma analizi %66,7'lik bir performans göstermiştir.**

Bu sonuçlara bakılarak çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış (102 kişilik) örnekleme 6 alt gruba sınıflama yapmada en yüksek performans gösteren yöntemin ayırma analizi olduğu, bunu sırasıyla yapay sinir ağı ve karar ağaçlarının izlediği söylenebilir.

Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış (102 kişilik) örnekleme 3 alt gruba sınıflanması konusunda;

- a) Yapay sinir ağı %74,2'lik bir performans göstermiştir.**
- b) Karar ağaçları %46,1'lik bir performans göstermiştir.**
- c) Ayırma analizi %74,5'lik bir performans göstermiştir.**

Bu sonuçlara bakılarak çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış (102 kişilik) örnekleme 3 alt gruba sınıflama yapmada en yüksek performans gösteren yöntemin ayırma analizi olduğu, bunu sırasıyla yapay sinir ağı ve karar ağaçlarının izlediği söylenebilir.

Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış (102 kişilik) örnekleme 2 alt gruba sınıflanması konusunda;

- a) Yapay sinir ağı %82,4'lük bir performans göstermiştir.**
- b) Karar ağaçları %82,1'lik bir performans göstermiştir.**
- c) Ayırma analizi %63,7'lik bir performans göstermiştir.**

Bu sonuçlara bakılarak çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış (102 kişilik) örnekleme 2 alt gruba sınıflama yapmada en yüksek performans gösteren yöntemin ayırma analizi olduğu, bunu sırasıyla yapay sinir ağı ve karar ağaçlarının izlediği söylenebilir.

4. ii) Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış (102 kişilik) örnekleme 6 alt gruba sınıflanması konusunda;

- a) Yapay sinir ağı %51,7'lik bir performans göstermiştir.**
- b) Karar ağaçları %16,7'lik bir performans göstermiştir.**
- c) Ayırma analizi %54,9'luk bir performans göstermiştir.**

Bu sonuçlara bakılarak çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış (102 kişilik) örnekleme 6 alt gruba sınıflama yapmada en yüksek performans gösteren yöntemin yapay sinir ağı olduğu, bunu sırasıyla ayırma analizi ve karar ağaçlarının izlediği söylenebilir.

Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış (102 kişilik) örnekleme 3 alt gruba sınıflanması konusunda;

- a) Yapay sinir ağı %65,6'lık bir performans göstermiştir.**
- b) Karar ağaçları %33,3'lük bir performans göstermiştir.**
- c) Ayırma analizi %57,8'lik bir performans göstermiştir.**

Bu sonuçlara bakılarak çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış (102 kişilik) örnekleme 3 alt gruba sınıflama yapmada en yüksek performans gösteren yöntemin yapay sinir ağı olduğu, bunu sırasıyla ayırma analizi ve karar ağaçlarının izlediği söylenebilir.

Öğrenci başarılarının çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış (102 kişilik) örnekleme 2 alt gruba sınıflanması konusunda;

- a) Yapay sinir ağı %89,0'luk bir performans göstermiştir.**
- b) Karar ağaçları %75,5'lik bir performans göstermiştir.**
- c) Ayırma analizi %50,0'lik bir performans göstermiştir.**

Bu sonuçlara bakılarak çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış (102 kişilik) örnekleme 2 alt gruba sınıflama yapmada en yüksek performans gösteren yöntemin yapay sinir ağı olduğu, bunu sırasıyla ayırma analizi ve karar ağaçlarının izlediği söylenebilir.

Araştırmada kullanılan yöntemlerin farklı örneklem büyüklükleri ve alt grup sayılarına sınıflama yapmada gösterdikleri performansların birbirleriyle karşılaştırılmaları dışında, her bir yöntemin en iyi performansı hangi koşullarda gösterdiğine ilişkin sonuçlara da ulaşılmıştır.

Yöntemlerin her biri için genel olarak söylenebilecek bir sonuç, sınıflama yapılan alt grup sayısı azaldıkça yöntemlerin daha yüksek performans gösterdiğidir. Alt grup sayısının fazla olması beklendiği gibi sınıflandırmayı zorlaştırmıştır.

Her örneklem büyüklüğünde yapay sinir ağı ile en yüksek performansı yakalamak için yapılan 50 farklı deneme analizi sonucunda en yüksek performans %89,0 ile

varyans-kovaryans matrislerinde homojenliğin sağlanmadığı çok küçük örnekleme ulaşılmıştır. Ancak 50 farklı deneme analizinin ortalaması incelendiğinde en yüksek performans ortalamasının %78,2 ile büyük örnekleme elde edildiği belirlenmiştir. Yine ikinci en yüksek performans %82,1 ile varyans-kovaryans matrislerinde homojenliğin sağlandığı çok küçük örnekleme görülürken; bu örneklemedeki 50 farklı deneme analizinin ortalamasının da büyük örnekleme elde edilen performans ortalamasından düşük olması benzer bir durumu göstermiştir. Yapay sinir ağı her analizde araştırma verilerinin farklı bir bölümünü eğitim seti, farklı diğer bir bölümünü de test seti olarak kullanmaktadır. Bu sebeple her analizde elde edilen bulgular farklılaşmaktadır. Bu sonuçlar deneme analizlerinin sayısının artırılmasının en yüksek performansı yakalama şansını da artırdığını göstermektedir. Sonuç olarak yapay sinir ağının en yüksek performansı varyans-kovaryans matrislerinde homojenliğin sağlanmadığı çok küçük örnekleme gösterdiğini söylemek mümkündür.

Karar ağaçları yöntemi açısından en yüksek sınıflama performansı büyük örnekleme 2 alt gruba sınıflama yapmada elde edilmiştir. Bununla birlikte büyük örnekleme 6 alt gruba sınıflama yapma performansının, orta büyüklükteki örnekleme 6 alt gruba sınıflama yapma performansından yaklaşık olarak %0,9 düşük olması dışında, örneklem büyüklüğü azaldıkça yöntemin performansının da doğrusal olarak düştüğünü söylemek mümkündür. Ayrıca yöntemin çok küçük örnekleme varyans-kovaryans matrislerinde homojenliğin sağlanması durumunda tüm alt gruplara sınıflama yapma performansının, homojenliğin sağlanmadığı çok küçük örnekleme göre yüksek olması da bu varsayımın karşılanması durumunda yöntemin performansının artacağını göstermiştir.

Ayırma analizinin performansı örneklem büyüklüğünden ve yöntemin temel varsayımlarından biri olan varyans-kovaryans matrislerinde homojenlikten önemli ölçüde etkilenmiştir. Örneklem büyüklüğü azaldıkça ayırma analizinin performansı doğrusal olarak artmış; varyans-kovaryans matrislerinde homojenliğin sağlanması yöntemin performansını daha da güçlü hale getirmiştir. Ayırma analizi en yüksek performansı varyans-kovaryans matrislerinde homojenliğin sağlandığı örnekleme 2 alt gruba sınıflama yapmada ulaşılmıştır. Bununla birlikte homojenliği sağlanamadığı durumda çok küçük örnekleme 2 ve 3 alt gruba sınıflama performansı büyük örneklemeden yüksek olsa da orta büyüklükteki ve küçük

örnekleme elde edilen performansların gerisinde kalmıştır. Bu sonuçlar varyans-kovaryans matrislerinde homojenliğin sağlanması durumunda ayırma analizinin çok yüksek performansa ulaştığını ortaya koymaktadır.



5.2. Öneriler

Araştırmada elde edilen sonuçlardan hareketle geliştirilen öneriler, bu araştırmanın sonuçlarına dayalı öneriler ve yapılacak yeni çalışmalarda araştırmacılar için öneriler olmak üzere iki başlık altında sunulmuştur.

5.2.1. Araştırmaya dönük öneriler

1. Araştırma sonucunda büyük, orta büyüklükteki ve küçük örneklerde öğrenci başarılarının 6, 3 ve 2 alt gruba sınıflandırılmasında yapay sinir ağlarının en yüksek performansı göstermesi, yöntemin bu örneklem büyüklükleri ve bu alt grup sayılarında güvenilir bir şekilde kullanılabileceğini ortaya koymuştur. Bu nedenle araştırmalarda yapay sinir ağının bu örneklem büyüklüklerinde 6, 3 ve 2 alt gruba sınıflama yapmada tercih edilmesi önerilir.
2. Varyans-kovaryans matrislerinde homojenliğin sağlanmadığı çok küçük örneklem büyüklüklerinde 2 ve 3 alt gruba sınıflama yapmada yine yapay sinir ağlarının en yüksek performansı göstermesi, yöntemin bu alt grup sayılarına sınıflama yapmada da tercih edilmesini sağlayacak önemli bir gerekçedir.
3. Yapay sinir ağının her uygulamada veri setinin bir bölümünü eğitim verisi, diğer bölümünü test seti olarak alması farklı sınıflama performansları göstermesine neden olmaktadır. Bu nedenle en yüksek performansa ulaşmak için mümkün olduğunca fazla sayıda deneme yapılması en yüksek performansı belirleyebilmek açısından faydalı olacaktır.
4. Karar ağaçları yöntemi örneklem büyüklüğü azaldıkça sınıflama performansını büyük ölçüde yitirmiştir. Örneklem büyüklüğünün azalmasının yanında varyans-kovaryans matrislerinde homojenliğin sağlanmadığı durumlarda yöntemin performans kaybı daha da artmıştır. Bu nedenle karar ağaçları ile gerçekleştirilecek sınıflama çalışmalarında büyük örneklemelere ulaşılması yöntemin performansının yüksek olması açısından önemli ve gereklidir.

5. Ayırma analizi yönteminin performansı ise örneklem büyüklüğü azaldıkça artmıştır. Bunun yanında ayırma analizi, varyans-kovaryans matrislerinde homojenliğin sağlandığı koşulda yapay sinir ağları ve karar ağaçlarına göre çok daha başarılı olmuştur. Araştırmadan elde edilen sonuçlara göre çok küçük örneklemelerde yapılacak sınıflama çalışmalarında varyans-kovaryans matrislerinde homojenliğin sağlanması durumunda ayırma analizinin tercih edilmesinin yerinde olacağı söylenebilir.

5.2.2. Araştırmacılar için öneriler

1. Araştırmada elde edilen yapay sinir ağı bulguları çok katmanlı algılayıcı model ile sınırlıdır. Yapay sinir ağlarının farklı örneklem büyüklüklerinde ve alt grup sayılarına sınıflama yapmada performansı hakkında daha çok bilgi elde edebilmek amacıyla başka araştırmalarda farklı ağ modellerin incelenmesi yararlı olabilir.
2. Araştırmada yapay sinir ağı ile yapılan analizlerde verilerin %70'i eğitim seti, %30'u test seti olarak ayrılmıştır. Yapılacak yeni araştırmalarda eğitim ve test setlerinin oranları değiştirilerek yöntemin göstereceği performans farklı koşullarda ele alınabilir.
3. Araştırmada elde edilen karar ağaçları bulguları CHAID algoritması ile sınırlıdır. Karar ağaçlarının farklı örneklem büyüklüklerinde ve alt grup sayılarına sınıflama yapmada performansı hakkında daha çok bilgi elde edebilmek amacıyla başka araştırmalarda farklı algoritmaların incelenmesi de yararlı olabilir.
4. Araştırmada elde edilen ayırma analizi bulguları da doğrusal ayırma analizi ile sınırlıdır. Ayırma analizinin farklı örneklem büyüklüklerinde ve alt grup sayılarına sınıflama yapmada performansı hakkında daha çok bilgi elde edebilmek amacıyla başka araştırmalarda karesel ayırma analizi ve esnek ayırma analizi gibi ayırma analizinin farklı türlerinin kullanılması yararlı olabilir.

5. Arařtırmada öğrenci başarılarının sınıflandırılmasında eksik verisi olmayan, normal dağılıma en yakın, uç değerleri olmayan, mümkün olduğunca değişkenler arasında çoklu bağlantı problemi bulunmayan ve öğrenci başarısını yordamada alanyazında en sık kullanıldığı gözlenen değişkenler kullanılmıştır. Bu değişkenler dışında farklı değişkenlerle yapılacak yeni arařtırmalar yöntemlerin performanslarının genellenebilirliğine katkı sağlayabilir.
6. Eğitim alanında yapılan arařtırmalarda eksik verilerin olduğu veri setleri ile çalışılabilmektedir. Bu nedenle yöntemlerin göstereceği performansın farklı bir çalışma ile veri setlerinde eksik verilerin olması durumunda incelenmesi alanyazına katkı sağlayabilir.
7. Arařtırmada PISA 2012 matematik testi ve anket sonuçları kullanılmıştır. Matematik dışında farklı alanların veri setleriyle de çalışmalar yapılması, yöntemlerin diğer alanlardaki performansını ortaya koyarak arařtırmacılara yeni bakış açıları kazandırabilir.
8. PISA uygulamalarında öğrenci başarısını belirlemek amacıyla düzey birin altı, düzey bir, düzey iki, düzey üç, düzey dört, düzey beş ve düzey altı olmak üzere toplam 7 düzey bulunmaktadır. Bu arařtırmada 6, 3 ve 2 alt grup oluşturabilmek amacıyla düzey birin altında yer alan öğrenciler arařtırma dışı tutulmuş ve çalışmalar 6, 3 ve 2 alt grup üzerinde gerçekleştirilmiştir. Farklı arařtırmalarda 4, 5, 7 vb. farklı alt grup sayılarına sahip örneklerde karşılařtırmalar yapılabilir.
9. Bu arařtırmada büyük, orta büyüklükteki, küçük ve çok küçük örneklem büyüklüklerinde yöntemlerin gösterdiği performanslar ele alınmıştır. Yöntemlerin karşılařtırılmasında farklı örneklem büyüklükleri oluşturularak yeni arařtırma planları hazırlanabilir.

KAYNAKÇA

- Agrawal, R., Imielinski, T. & Swami, A. (1993). Mining association rules between sets of items in large databases. Proceedings of the ACM SIGMOID, International Conference on the Management of Data. ACM Washington DC, 207-216.
- Akgül, A. ve Çevik, O. (2003). *İstatistiksel analiz teknikleri: SPSS'te işletme yönetimi uygulamaları*, Ankara: Emek Ofset.
- Akpınar, H. (2000). Veri tabanlarında bilgi keşfi ve veri madenciliği. *İ. Ü. İşletme Fakültesi Dergisi*, 29, 1-22.
- Akpınar, H. (2014). *DATA, veri madenciliği veri analizi* (1. baskı). İstanbul: Papatya Yayıncılık.
- Alan, M. A. (2014). Karar ağaçlarıyla öğrenci verilerinin sınıflandırılması. *Atatürk Üniversitesi İktisadi Ve İdari Bilimler Dergisi*, 28(4), 101-112.
- Albayrak, A. S. (2006). *Uygulamalı çok değişkenli istatistik teknikleri*, Ankara: Asil Yayın Dağıtım.
- Albayrak, S. A. ve Yılmaz, Ş. K. (2009). Veri madenciliği: Karar ağacı algoritmaları ve İMKB verileri üzerine bir uygulama. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 14(1), 31-52.
- Alıç, Z. H. (2014). *Akut pankreatit hastalarının mortalite risklerinin karar ağacı yöntemi ile belirlenmesi*. Yayımlanmamış Yüksek Lisans Tezi. Gazi Üniversitesi, Bilişim Enstitüsü, Ankara.
- Altıntaş, Y. (2010). *Veri madenciliğinin tıpta kullanımı ve bir uygulama: hemodiyaliz hastaları için risk seviyelerine göre risk faktörlerinin etkileşimlerinin incelemesi*. Yayımlanmamış Yüksek Lisans Tezi, Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Altun, F. ve Yazıcı, H. (2013). Ergenlerin benlik algılarının yordayıcıları olarak: akademik öz-yeterlik inancı ve akademik başarı. *Kastamonu Eğitim Dergisi*, 21(1), 145-156.
- Anıl, D. (2008). The analysis of factors affecting the mathematical success of turkish students in the PISA 2006 evaluation program with structural equation modeling. *American-Eurasian Journal of Scientific Research*, 3(2), 222-227.
- Anıl, D. (2009). Uluslararası öğrenci başarılarını değerlendirme programı (PISA)'nda Türkiye'deki öğrencilerin fen bilimleri başarılarını etkileyen faktörler. *Eğitim ve Bilim*, 34(152), 87-100.
- Anıl, D. (2011). Türkiye'nin PISA 2006 fen bilimleri başarısını etkileyen faktörlerin yapısal eşitlik modeli ile incelenmesi. *Kuram ve Uygulamada Eğitim Bilimleri*, 11(3), 1253-1266.
- Anderson, T. W. (2003). An introduction to multivariate statistical analysis, 3rd edition. USA: Wiley.
- Argüden, Y. ve Erşahin, B. (2008). *Veri madenciliği: veriden bilgiye, masraftan değere*. İstanbul: ARGE Danışmanlık, 48-63.

- Arslantaş, İ. H., Özkan, M. ve Külekçi, E. (2012). Eğitim fakültesi öğrencilerinin akademik başarı düzeylerinin bazı demografik değişkenler açısından incelenmesi. *Elektronik Sosyal Bilimler Dergisi*, 11(39), (395-407).
- Atar, H. Y. (2012). Resim-iş öğretmenliği özel yetenek sınavlarının sınıflama doğruluğu üzerine bir çalışma. *Eğitim ve Bilim*, 37(163), 283-296.
- Atılğan, E. S. (2011). *Karayollarında meydana gelen trafik kazalarının karar ağaçları ve birliktelik analizi ile incelenmesi*. Yayımlanmamış Yüksek Lisans Tezi. Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Avcılar, Y. ve Yakut, E. (2015). Yapay sinir ağları çoklu lojistik regresyon ve çoklu diskriminant analiz yöntemlerinden yararlanarak yerel seçimlerde seçmen tercihlerinin belirlenmesi: Osmaniye ili uygulaması. *Uluslararası Alanya İşletme Fakültesi Dergisi*, 7(2), 207-224.
- Ayık Y. Z., Özdemir A. ve Yavuz U. (2007). Lise türü ve lise mezuniyet başarısının, kazanılan fakülte ile ilişkisinin veri madenciliği tekniği ile analizi. *Atatürk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 10(2), 441-454.
- Baş, N. (2006). *Yapay sinir ağları yaklaşımı ve bir uygulama*. Yayımlanmamış Yüksek Lisans Tezi. Mimar Sinan Güzel Sanatlar Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Bayru, P. (2007). *Elektronik basında tüketici tercihleri analizi: yapay sinir ağları ile lojistik modelin performans değerlendirilmesi*. Yayımlanmamış Doktora Tezi. İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, İstanbul.
- Bektaş, S. (2012). Çok şeritli bölünmüş karayollarında kaza tahmin modeli. *İleri Teknoloji Bilimleri Dergisi*. 1(1), 27-34.
- Benli, Y. K. (2005). Bankalarda mali başarısızlığın öngörülmesi lojistik regresyon ve yapay sinir ağı karşılaştırması. *Gazi Üniversitesi Endüstriyel Sanatlar Eğitim Fakültesi Dergisi*, 16, 31-46.
- Berry, M. J. & Linoff, G. S. (2004). *Data mining techniques: for marketing, sales, and customer relationship management* (2nd ed). USA: Wiley.
- Bramer, M. (2007). *Principles of data mining*. Springer-Verlag London Limited, 173-185.
- Breiman, L., Friedman, J. H., Olshen, R. A., & Stone, C. J. (1984). *Classification and regression trees*. Monterey: Wadsworth and Brooks/Cole.
- Brown, J.D. (2007). *Neural network prediction of math and reading proficiency as reported in the educational longitudinal study 2002 based on non-curricular variables*. Doktora Tezi, Duquesne University, Pennsylvania, ABD. (ProQuest Digital Document ID: 1467886041)
- Burmaoğlu, S. (2009). *Birleşmiş milletler kalkınma programı beşeri kalkınma endeksi verilerini kullanarak diskriminant analizi, lojistik regresyon analizi ve yapay sinir ağlarının sınıflandırma başarılarının değerlendirilmesi*. Yayımlanmamış Doktora Tezi. Atatürk Üniversitesi, Sosyal Bilimler Enstitüsü, Erzurum.

- Büyükişıklar, A. (2014). *Karar ağaçları sınıflandırma algoritması ile toprak özgül direnci tespitinde jeolojik veri kullanımı*. Yayınlanmamış Yüksek Lisans Tezi, Bilecik Şeyh Edebali Üniversitesi, Bilecik.
- Büyüköztürk, Ş., Çakmak, E. K., Akgün, Ö. E., Karadeniz, Ş. ve Demirel, F. (2008). *Bilimsel araştırma yöntemleri*. (1. baskı), Ankara: Pegem Akademi.
- Cangül, O. (2006). *Diskriminant analizi ve bir uygulama denemesi*. Yayınlanmamış Yüksek Lisans Tezi, Uludağ Üniversitesi Sosyal Bilimler Enstitüsü, Bursa.
- Ceylan, E. (2009). PISA 2006 sonuçlarına göre Türkiye’de fen okuryazarlığında düşük ve yüksek performans gösteren okullar arasındaki farklar. *Yüzüncü Yıl Üniversitesi Eğitim Fakültesi Dergisi*, 6(2), 55-75.
- Chang, L. Y. & Wang, H. W. (2006). Analysis of traffic injury: an application of non-parametric classification tree techniques. *Accident Analysis Prevention*, 38, 1019-1027.
- Çakmak, Z. (1992). *Çoklu ayırma ve sınıflandırma analizi: eğitimde öğrencilerin meslek seçimine uygulanması*, No: 658, Eskişehir: Anadolu Üniversitesi Basımevi Anadolu Üniversitesi Yayınları.
- Çakmak, Z. ve Kara, H. (2011). Yöneticilerde benlik algılamalarının belirlenmesi: sanayi örgütlerinde bir araştırma. *Dumlupınar Üniversitesi Sosyal Bilimler Dergisi*, 30, 301-310.
- Çankaya, A. B., Taşdemir, G., Taşdemir, S. ve Zilelioğlu, O. (2009). Delici göz yaralanması olgularımızın uzun dönem sonuçları ve görsel prognozu etkileyen faktörlerin analizi. *Turkish Journal of Ophthalmology*, 39, 220-226.
- Çırak, G. (2012). *Yükseköğretimde öğrenci başarılarının sınıflandırılmasında yapay sinir ağları ve lojistik regresyon yöntemlerinin kullanılması*. Yayınlanmamış Yüksek Lisans Tezi. Ankara Üniversitesi, Eğitim Bilimleri Enstitüsü, Ankara.
- Çiftçi, C. ve Çağlar, A. (2014). Ailelerin sosyo-ekonomik özelliklerinin öğrenci başarısı üzerindeki etkisi: fakirlik kader midir?. *International Journal of Human Sciences*, 11(2), 155-175.
- Çokluk, Ö., Şekercioğlu, G. ve Büyüköztürk, Ş. (2012). *Sosyal bilimler için çok değişkenli istatistik SPSS ve LISREL uygulamaları*. (2. baskı), Ankara: Pegem Akademi.
- Çölkesen, İ. (2009). *Uzaktan algılamada ileri sınıflandırma tekniklerinin karşılaştırılması ve analizi*. Yayınlanmamış Yüksek Lisans Tezi, Gebze Yüksek Teknoloji Üniversitesi Mühendislik ve Fen Bilimleri Enstitüsü, Kocaeli.
- Çuhadar, M. (2006). *Turizm sektöründe talep tahmini için yapay sinir ağları kullanımı ve diğer yöntemlerle karşılaştırmalı analizi (Antalya ilinin dış turizm talebinde uygulama)*. Yayınlanmamış Doktora Tezi. Süleyman Demirel Üniversitesi, Sosyal Bilimler Enstitüsü, Isparta.
- Demircioğlu, N., Ayan, S., Avanoğlu, B. ve Sivacioğlu, A. (2004). Kastamonu-taşköprü orman fidanlığında üretilen 2+0 yaşlı sarıçam (*Pinus sylvestris* L.) fidanlarının TSE normlarına göre değerlendirilmesi. *Pamukkale Üniversitesi Mühendislik Fakültesi Mühendislik Bilimleri Dergisi*, 10(2), 243-251.

- Demiryürek, O. (2009). *Polyester/viskon karışimli open-end rotor iplik özelliklerinin yapay sinir ağları ve istatistiksel modeller kurularak tahmin edilmesi*. Yayınlanmamış Doktora Tezi. Çukurova Üniversitesi, Fen Bilimleri Enstitüsü, Adana.
- Dikmen, İ. (2001). Strategic decision making in construction companies: An artificial neural network based decision support system for international market selection. Orta Doğu Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Doğan, N. (2009). Bilgisayar destekli istatistik öğretiminin başarıya ve istatistiğe karşı tutuma etkisi. *Eğitim ve Bilim*, 34(154), 3-16.
- Doğan, N. ve Özdamar, K. (2003). CHAID analizi ve aile planlaması ile ilgili bir uygulama. *Türkiye Klinik Tıp Bilimleri Dergisi*. 23(5), 392-397.
- Durmuş, G. (2008). *Çimentolu harç özelliklerine yüksek sıcaklık etkisinin belirlenmesi ve yapay sinir ağı ile modellenmesi*. Yayınlanmamış Doktora Tezi. Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Elmas, Ç. (2003). *Yapay sinir ağları*. Ankara: Seçkin Kitabevi.
- Erayman, Y. (2004). *KSÜ öğrencilerinin sosyo-ekonomik yapılarının başarıları üzerine etkisi*. Yayınlanmamış Yüksek Lisans Tezi. Kahramanmaraş Sütçü İmam Üniversitesi, Fen Bilimleri Enstitüsü, Kahramanmaraş.
- Ercan, S., Işık, O. ve Çakır, V. (2005). *HHO Öğrencilerinin akademik Başarılarına Etki Eden Faktörlerin Çoklu Regresyon Yöntemiyle İncelenmesi*. V. Ulusal Üretim Araştırmaları Sempozyumu, İstanbul Ticaret Üniversitesi, İstanbul, 25-27 Kasım 2005.
- Erdil, Z. (2010). Sosyoekonomik olarak risk altında bulunan çocuklara yönelik erken müdahale programları ve akademik başarı ilişkisi. *Hacettepe Üniversitesi Sağlık Bilimleri Fakültesi Hemşirelik Dergisi*. 72-78.
- Frank, E. & Witten, I. H. (1998). *Generating Accurate Rule Sets without global optimization*. In: Fifth International Conference on Machine Learning, 144-151.
- Garson, D. G. (1998). *Neural networks, an introductory guide for social scientists*. London: Sage Publications, 25.
- Gelbal, S. (2008). Sekizinci sınıf öğrencilerinin sosyoekonomik özelliklerinin Türkçe başarıları üzerindeki etkisi. *Eğitim ve Bilim*, 33(150), 1-13.
- Gonzalez, J. M. B. ve DesJardins, S. L. (2002). Artificial neural networks: A new approach to predicting application behavior. *Research In Higher Education*, 43(2), 235-258.
- Grimm, L. G. & Yarnold, P. R. (1995). *Reading and understanding multivariate statistics*. Washington D. C.: American Psychological Association.
- Gülpınar, V. (2008). *Avrupa birliği ülkeleri ile Türkiye'nin ekonomik göstergelerinin karar ağacı yöntemi ile karşılaştırılması*. Yayınlanmamış Yüksek Lisans Tezi. Marmara Üniversitesi, Sosyal Bilimler Üniversitesi, İstanbul.
- Güneri, N. ve Apaydın, A. (2004). Öğrenci başarılarının sınıflandırılmasında lojistik regresyon analizi ve sinir ağları yaklaşımı. *GÜ Ticaret ve Turizm Eğitim Fakültesi Dergisi*, 1, 170-188.

- Güzeller, C. ve Kelecioğlu, H. (2006). Ortaöğretim kurumları öğrenci seçme sınavının sınıflama geçerliği üzerine bir çalışma. *H. Ü. Eğitim Fakültesi Dergisi (H. U. Journal of Education)*, 30, 140-148.
- Haughton, D. & Oulabi, S. (1999). Direct marketing modeling with CART and CHAID, *Journal of Direct Marketing*, 11(4), 42-52.
- Haykin, S. (1994). *Neural networks: a comprehensive foundation*. New York: Mcmillan Press.
- İbrahim, Z. ve Rusli, D. (2007). Predicting students' academic performance: Comparing neural network, decision tree and linear regression. 21. Annual SAS Malasia Forum, Kuala Lumpur, Malezya.
- Johnson, R. A. & Wichern, D. W. (1992). *Applied multivariate statistical analysis*. Third Ed., USA: Prentice-Hall Inc.
- Kaptan, S. (1995). *Bilimsel araştırma ve istatistik teknikleri*. Ankara: Tekişik Web Ofset Tesisleri.
- Karasar, N. (2014). *Bilimsel araştırma yöntemi*. (27. basım), Ankara: Nobel Akademik Yayıncılık.
- Kavzoğlu, T. ve Çölkesen, İ. (2010). Karar ağaçları ile uydu görüntülerinin sınıflandırılması. *Harita Teknolojileri Elektronik Dergisi*, 2(1), 36-45.
- Kaya, Y., Ertuğrul, Ö. F. ve Tekin, R. (2012). Epileptik EEG işaretlerinin sınıflandırılmasında karar kuralları ve karar ağaçlarının kullanılması. *Batman Üniversitesi Yaşam Bilimleri Dergisi*, 1(2), 403-413.
- Kayıkcı, Ş. (2014). *Web sayfalarının yapay sinir ağları ile sınıflandırılması*. Yayımlanmamış Doktora Tezi. Marmara Üniversitesi, Sosyal Bilimler Enstitüsü, İstanbul.
- Kayri, M. ve Boysan, M. (2008). Bilişsel yatkınlık ile depresyon düzeyleri ilişkisinin sınıflandırma ve regresyon ağacı analizi ile incelenmesi. *H. Ü. Eğitim Fakültesi Dergisi (H. U. Journal of Education)*, 34, 168-177.
- Kayri, M. ve Çokluk, Ö. (2010). Using multinomial logistic regression analysis in artificial neural network: an application. *Ozean Journal of Applied Sciences*, 3(2), 259-268.
- Kayri, M. ve Günüş, S. (2010). Türkiye'deki ortaöğretim öğrencilerinin internet bağımlılık düzeyini etkileyen bazı faktörlerin karar ağaçları yöntemleri ile incelenmesi. *Kuram ve Uygulamada Eğitim Bilimleri*, 10(4), 2465-2500.
- Kaysılı, B. (2008). Akademik başarının artırılmasında aile katılımı. Ankara Üniversitesi Eğitim Bilimleri Fakültesi Özel Eğitim Dergisi, 9(1), 69-83.
- Keser, İ. ve Sarıbay, E. (2007). İzmir'deki özel ve devlet üniversitelerindeki öğrencilerin başarılarını etkileyen faktörlerin belirlenmesi ve karşılaştırılması. *Muğla Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 18.
- Kıran, Z. (2010). *Lojistik regresyon ve C&RT Analizi Yöntemleriyle Sosyal Güvenlik Kurumu İlaç Provizyon Sistemi Üzerinde Bir Uygulama*. Yayımlanmamış Yüksek Lisans Tezi. Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.

- Kibar, F. (2015). Türkiye’de kamyon kazaları ile trafik ve karayolu geometrik özellikleri arasındaki ilişkinin istatistiksel ve yapay sinir ağları yöntemleri ile modellenmesi. Yayımlanmamış Doktora Tezi. Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Trabzon.
- Klecka, W. (1980). *Discriminant analysis*. London: Sage Publications.
- Kocadağlı, O. (2012). Genetik algoritmalar ve bulanık üyelik fonksiyonlarıyla hibrit bayes yapay sinir ağları. Yayımlanmamış Doktora Tezi. Mimar Sinan Güzel Sanatlar Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Köktürk, F. (2012). *K-en yakın komşuluk, yapay sinir ağları ve karar ağaçları yöntemlerinin sınıflandırma başarılarının karşılaştırılması*. Yayımlanmamış Doktora Tezi. Bülent Ecevit Üniversitesi, Sağlık Bilimleri Enstitüsü, Zonguldak.
- Kurt İ. ve Türe M. (2005). Tıp öğrencilerinde alkol kullanımını etkileyen faktörlerin belirlenmesinde yapay sinir ağları ile lojistik regresyon analizinin karşılaştırılması. *Trakya Üniversitesi Tıp Fakültesi Dergisi*, 22(3),142-153.
- Kuyucu, Y. E. (2012). *Lojistik regresyon analizi (LRA), yapay sinir ağları (YSA) ve sınıflandırma ve regresyon ağaçları (C&RT) yöntemlerinin karşılaştırılması ve tıp alanında bir uygulama*. Yayımlanmamış Yüksek Lisans Tezi. Gaziosmanpaşa Üniversitesi, Sağlık Bilimleri Enstitüsü, Tokat.
- Kuzey, C. (2012). *Veri madenciliğinde destek vektör makinaları ve karar ağaçları yöntemlerini kullanarak bilgi çalışanlarının kurum performansı üzerine etkisinin ölçülmesi ve bir uygulama*. Yayımlanmamış Doktora Tezi. İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, İstanbul.
- MEB, (2013). *PISA 2012 Ulusal ön raporu*. (<http://pisa.meb.gov.tr/wp-content/uploads/2013/12/pisa2012-ulusal-on-raporu.pdf>), Erişim tarihi: 10 Temmuz 2016.
- Munakata, T. (2008). *Fundamentals of the new artificial intelligence, neural, evolutionary, fuzzy and more*. Springer-Verlag London Limited.
- Masseglia, F., Poncelet, P. & Teisseire, M. (1999). Using data mining techniques on web access logs to dynamically improve hypertext structure. *ACM Sigweb Newsletter*, 8(3), 1-19.
- Naik, B., & Ragotiaman, S. (2004). Using neural networks to predict MBA student success. *College Student Journal*, 38(1), 143-149.
- Ocakoğlu, G. (2006). Lojistik regresyon analizi ve yapay sinir ağı tekniklerinin sınıflama karşılaştırması ve bir uygulama. Yüksek Lisans Tezi. Uludağ Üniversitesi Sağlık Bilimleri Enstitüsü, Bursa.
- OECD, (2013). *PISA 2012 Assessment and analytical framework mathematics, reading, science, problem solving and financial literacy*. (https://www.oecd.org/pisa/pisaproducts/PISA%202012%20framework%20e-book_final.pdf), Erişim tarihi: 5 Temmuz 2016.
- OECD, (2014). *PISA 2012 results in focus*. (<https://www.oecd.org/pisa/keyfindings/pisa-2012-results-overview.pdf>), Erişim tarihi: 5 Temmuz 2016.

- Oğuzlar, A. (2004). CART analizi ile hanehalkı işgücü anketi sonuçlarının özetlenmesi. *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 18(3-4), (79-90).
- Oğuzlar, A. (2006). Hanehalkı tipi ve kırsal-kent ayrımının diskriminant analizi ile incelenmesi. *Akdeniz İ.İ.B.F. Dergisi*, 11, 70-84.
- Okioga, C. K. (2013). The impact of students' socio-economic background on academic performance in universities, a case of students in Kisii University College. *American International Journal Of Science*, 2(2), 38-46.
- Omitaomu, O. A. (2006). Decision trees. In Berry, M. V. and Browne, M. (Eds.). *Lecture notes in data mining*, 39-51. New Jersey, USA: World Scientific Publishing of Hackensack.
- Özabacı, N. ve Acat, M. B. (2005). Sosyo ekonomik çevreye göre ilköğretim öğrencilerinin başarısızlık nedenleri. *Eskişehir Osmangazi Üniversitesi Sosyal Bilimler Dergisi*, 6(1), 145-170.
- Özdamar, K. (2010). *Paket programlar ile istatistiksel veri analizi (çok değişkenli analizler)*. (7. Baskı), Eskişehir: Kaan Kitabevi.
- Özdemir, Y. ve Koruklu, N. (2011). Üniversite öğrencilerinde değerler ve mutluluk arasındaki ilişkinin incelenmesi. *YYÜ, Eğitim Fakültesi Dergisi*, 8(1), 190-210.
- Özekes, S. (2003). Veri madenciliği modelleri ve uygulama alanları. *İstanbul Ticaret Üniversitesi Dergisi*, 3, 65-82.
- Özer, Y. ve Anıl, D. (2011). Öğrencilerin fen ve matematik başarılarını etkileyen faktörlerin yapısal eşitlik modeli ile incelenmesi. *Hacettepe Üniversitesi Eğitim Fakültesi Dergisi*, 41, 313-324.
- Özkan, C. (2001). *Uydu görüntü verisinin yapay sinir ağları ile sınıflandırılması*. Yayımlanmamış Doktora Tezi. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Özkan, Y. (2013). *Veri madenciliği yöntemleri*. (2. Basım). İstanbul: Papatya Yayıncılık.
- Öztemel, E. (2012). *Yapay sinir ağları*. (1. baskı). İstanbul: Papatya Yayıncılık.
- Öztürk, A. (2006). *Esnek ayırma analizi ve bir uygulama*. Doktora Tezi. Eskişehir Osmangazi Üniversitesi, Sağlık Bilimleri Enstitüsü, Eskişehir.
- Öztürk, S., Coşkun, A. ve Dirsehan, T. (2012). Fırsat sitelerine yönelik e-sadakati belirleyen boyutların incelenmesi. *Eskişehir Osmangazi Üniversitesi İİBF Dergisi*, 7(2), 217-239.
- Pehlivan, G. (2006). *CHAID analizi ve bir uygulama*. Yayımlanmamış Yüksek Lisans Tezi. Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Rokach, L. & Maimon, O. (2008). Data mining with decision trees: Theory and applications. Series in Machine Perception and Artificial Intelligence Vol. 69, USA: World Scientific Publishing Co. Pte. Ltd.
- Sabancı, K. (2013). *Şeker pancarı tarımında yabancı ot mücadelesi için değişken düzeyli herbisit uygulama parametrelerinin yapay sinir ağlarıyla belirlenmesi*.

- Yayımlanmamış Doktora Tezi. Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Konya.
- Sadi, Ö., Uyar, M. ve Yalçın, H. (2014). Lise öğrencilerinin biyoloji dersi başarılarında, cinsiyet, sınıf düzeyi ve aile yapısının rolü. *Eğitim ve Öğretim Araştırmaları Dergisi*, 3(2), 138-151.
- Sağiroğlu, Ş., Beşdok, E. ve Erler, M. (2003). *Mühendislikte yapay zeka uygulamaları-I, yapay sinir ağları*. (1. baskı). Kayseri: Ufuk Kitap Kırtasiye Yayıncılık.
- Sangün, L. (2007). *Temel bileşenler analizi, ayırma analizi, kümeleme analizleri ve ekolojik verilere uygulanması üzerine bir araştırma*. Yayımlanmamış Doktora Tezi. Çukurova Üniversitesi, Fen Bilimleri Enstitüsü, Adana.
- Saraç, T. (2004). *Yapay sinir ağları*. Basılmamış Seminer Projesi. Gazi Üniversitesi Endüstri Mühendisliği Anabilim Dalı, Ankara.
- Serinkan, C. ve Bardakçı, A. (2007). Pamukkale üniversitesinde çalışan öğretim elemanlarının iş tatminlerine ilişkin bir araştırma. *Selçuk Üniversitesi Karaman İ.İ.B.F. Dergisi*, 12, 152-163.
- Seven, A. (1993). *Yapay sinir ağları ile doku sınıflandırma*. Yayımlanmamış Yüksek Lisans Tezi. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Sezer, Ü. (2008). *Karar ağaçlarının birliktelik kuralları ile iyileştirilmesi*. Yayımlanmamış Yüksek Lisans Tezi. Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Kocaeli.
- Sığırlı, D. (2006). *Sınıflandırma probleminin çözümlenmesinde yapay sinir ağları ile diskriminant analizinin karşılaştırılması ve bir uygulama*. Yayımlanmamış Yüksek Lisans Tezi. Uludağ Üniversitesi, Sağlık Bilimleri Enstitüsü. Bursa.
- Silahtaroglu, G. (2013). *Veri madenciliği kavram ve algoritmaları*. (Güncellenmiş ve genişletilmiş 2. Basım). İstanbul: Papatya Yayıncılık.
- Simpson, P. K. (1990). *Artificial neural systems foundations, paradigms, application and implementation*, Elmsford NY: Pergamon Press.
- Sun, J. & Hui L. (2008). Data mining method for listed companies' financial distress prediction, *Knowledge-Based Systems*, 21(1), 1-5.
- Şahin, A. (2011). İlköğretim 6. sınıf öğrencilerinin dinleme becerisi farkındalıklarının sosyo-ekonomik düzeye göre incelenmesi. *Çankırı Karatekin Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 2(1), 178-188.
- Şirvan, O. (2010). *Yapay sinir ağları kullanılarak retina görüntülerinden hastalık tanılama sistemi tasarımı ve gerçekleştirimi*. Yayımlanmamış Doktora Tezi. Ege Üniversitesi, Fen Bilimleri Enstitüsü, İzmir.
- Tabachnick, B. G. & Fidell, L.S. (2001). *Using multivariate statistics* (Fourth edition). USA: Pearson Education Company.
- Tatlıdil, H. (1996). *Uygulamalı çok değişkenli istatistiksel analiz*, Ankara: Cem Web Ofset.
- Temel, G. O., Çamdeviren, H. ve Akkuş, Z. (2005). Sınıflama ağaçları yardımıyla restless legs syndrome (RLS) hastalarına tanı koyma. *İnönü Üniversitesi Tıp Fakültesi Dergisi*, 12(2), 111-117.

- Tepehan, T. (2011). *Türk öğrencilerinin PISA başarılarının yordanmasında yapay sinir ağı ve lojistik regresyon modeli performanslarının karşılaştırılması*. Yayınlanmamış Doktora Tezi. Hacettepe Üniversitesi, Sosyal Bilimler Enstitüsü, Ankara.
- Thomas, Lyn. C. (2000). A survey of credit and behavioral scoring: forecasting financial risk of lending to consumer. *International Journal of Forecasting*, 16(2), 149-172.
- Thigpen, M. K. (2000). *Data mining techniques in education: a comparison of conventional statistical linear regression and neural network based tools*. Doktora Tezi, The University of Alabama, Alabama, ABD.
- Tolon, M. (2007). *Tüketici tatmininin yapay sinir ağı yöntemiyle ölçülmesi ve Ankara'daki perakendeci mağazaların müşterileri üzerinde bir uygulama*. Yayınlanmamış Doktora Tezi. Gazi Üniversitesi, Sosyal Bilimler Enstitüsü, Ankara.
- Torun, T. (2007). *Finansal başarısızlık tahmininde geleneksel istatistiki yöntemlerle yapay sinir ağlarının karşılaştırılması ve sanayi işletmeleri üzerinde uygulama*. Yayınlanmamış Doktora Tezi. Erciyes Üniversitesi, Sosyal Bilimler Enstitüsü, Kayseri.
- Tosun, S. (2007). *Sınıflandırmada yapay sinir ağı ve karar ağaçları karşılaştırması: Öğrenci başarıları üzerine bir uygulama*. Yayınlanmamış Yüksek Lisans Tezi. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Türe, M., Tokatlı, F. ve Kurt, İ. (2009). Using kaplan-meier analysis together with decision tree methods (C&RT, CHAID, QUEST, C4.5 and ID3) in determining recurrence-free survival of breast cancer patients. *Expert Systems With Applications*, 36, 2017-2026.
- Ulusoy, G. (2013). *Karar ağacı analizi ile AB genişleme kriterlerinin değerlendirilmesi*. Yüksek Lisans Tezi, Marmara Üniversitesi, Sosyal Bilimler Enstitüsü, İstanbul.
- Uysal, M. (2014). *Veri analizi için genişleyebilir bir karar ağacının oluşturulması, web ve mobil uygulamalarının geliştirilmesi*. Yayınlanmamış Yüksek Lisans Tezi. Gazi Üniversitesi, Bilişim Enstitüsü, Ankara.
- Ünal, M. (2006). *Ayırma analizi ve bir uygulama*. Yayınlanmamış Yüksek Lisans Tezi. Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Vahaplar, A. (2003). *Bir coğrafi veri madenciliği uygulaması*. Yayınlanmamış Yüksek Lisans Tezi, Ege Üniversitesi, Fen Bilimleri Enstitüsü, İzmir.
- Wahl, P. W. & Kronmal, R. A. (1977). Discriminant functions when covariances are unequal and sample sizes are moderate. *Biometrics*, 33, 479-484.
- Yakut, E. (2012). *Veri madenciliği tekniklerinden c5.0 algoritması ve destek vektör makineleri ile yapay sinir ağlarının sınıflandırma başarılarının karşılaştırılması: imalat sektöründe bir uygulama*. Yayınlanmamış Doktora Tezi. Atatürk Üniversitesi, Sosyal Bilimler Enstitüsü, Erzurum.
- Yıldırım, İ. (2000). Akademik başarının yordayıcısı olarak yalnızlık, sınav kaygısı ve sosyal destek. *Hacettepe Üniversitesi Eğitim Fakültesi Dergisi*, 18, 167-176.

- Yurtođlu, H. (2005). *Yapay sinir ađları metodolojisi ile öngörü modellemesi: bazı makroekonomik deđişkenler için Türkiye örneđi*. Uzmanlık Tezi. DPT Ekonomik Modeller ve Stratejik Arařtırmalar Genel Müdürlüđü.
- Yücesoy, U. (2014). *Firmaların finansal kararlarında uyguladıkları finansal karar yöntemleri ve karar ađacı uygulaması*. Yayınlanmamıř Yüksek Lisans Tezi. Gazi Üniversitesi, Biliřim Enstitüsü, Ankara.
- Yüksek, A. G. (2007). *Hava kirliliđi tahmininde çoklu regresyon analizi ve yapay sinir ađları yönteminin karřılařtırılması*. Yayınlanmamıř Doktora Tezi. Cumhuriyet Üniversitesi, Sosyal Bilimler Enstitüsü, Sivas.
- Zurada, J. & Lonial, S. (2005). Comparison of the performance of several data mining methods for bad dept recovery in the healthcare industry. *The Journal Of Applied Business Research*, 21(2), 37-54.



EKLER DİZİNİ

EK 1.

Orjinallik raporu

EK 2-6.

Değişkenlerin farklı örneklemlerdeki dağılımlarına ilişkin histogram grafikleri

EK 7-11.

Değişkenlerin farklı örneklemlerdeki çarpıklık ve basıklık değerleri ile değerlerin standart hatalarına bölünmesiyle elde edilen z değerleri

EK 12-16.

Değişkenlerin farklı örneklemlerdeki korelasyonları

EK 17.

Değişkenlerin farklı örneklemlerde sahip oldukları tolerance, VIF ve CI değerleri




EK 18-32.

Yöntemlerin sınıflama performansları

EK 33.

Etik komisyon izin muafiyet formu

EK 1. ORJİNALLİK RAPORU

	HACETTEPE ÜNİVERSİTESİ EĞİTİM BİLİMLERİ ENSTİTÜSÜ YÜKSEK LİSANS/DOKTORA TEZ ÇALIŞMASI ORJİNALLİK RAPORU												
HACETTEPE ÜNİVERSİTESİ EĞİTİM BİLİMLER ENSTİTÜSÜ EĞİTİM BİLİMLERİ ANA BİLİM DALI BAŞKANLIĞINA													
Tarih: <u>06.03.2017</u>													
Tez Başlığı: YAPAY SINIR AĞLI KARAR AĞAÇLARI VE AYIRMA ANALİZİ YÖNTEMLERİ İLE PISA 2012 MATEMATİK BAŞARILARININ SINIFLANDIRILMA PERFORMANSLARININ KARŞILAŞTIRILMASI													
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.													
<table border="1"><thead><tr><th>Rapor Tarihi</th><th>Sayfa Sayısı</th><th>Karakter Sayısı</th><th>Savunma Tarihi</th><th>Benzerlik Endeksi</th><th>Gönderim Numarası</th></tr></thead><tbody><tr><td><u>06.03.2017</u></td><td><u>135</u></td><td><u>211480</u></td><td><u>13.02.2017</u></td><td><u>% 8</u></td><td><u>780027219</u></td></tr></tbody></table>	Rapor Tarihi	Sayfa Sayısı	Karakter Sayısı	Savunma Tarihi	Benzerlik Endeksi	Gönderim Numarası	<u>06.03.2017</u>	<u>135</u>	<u>211480</u>	<u>13.02.2017</u>	<u>% 8</u>	<u>780027219</u>	
Rapor Tarihi	Sayfa Sayısı	Karakter Sayısı	Savunma Tarihi	Benzerlik Endeksi	Gönderim Numarası								
<u>06.03.2017</u>	<u>135</u>	<u>211480</u>	<u>13.02.2017</u>	<u>% 8</u>	<u>780027219</u>								
Uygulanan filtreler: 1- Kaynakça 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 ederim.													
Gereğini saygılarımla arz ederim.													
Adı Soyadı: <u>Emre TOPRAK</u>	 Tarih ve İmza <u>06.03.2017</u>												
Öğrenci No: <u>N11142189</u>													
Anabilim Dalı: <u>Eğitim Bilimleri</u>													
Programı: <u>Eğitimde Ölçme ve Değerlendirme</u>													
Statüsü: <input type="checkbox"/> Y.Lisans <input checked="" type="checkbox"/> Doktora <input type="checkbox"/> Bütünleşik Dr.													
DANIŞMAN ONAYI													
UYGUNDUR.  (Prof. Dr. Selahattin GELBAL)													



HACETTEPE UNIVERSITY
GRADUATE SCHOOL OF EDUCATIONAL SCIENCES
THESIS/DISSERTATION ORIGINALITY REPORT

HACETTEPE UNIVERSITY
GRADUATE SCHOOL OF EDUCATIONAL SCIENCES
TO THE DEPARTMENT OF EDUCATIONAL SCIENCES

Date: 06/03/2017

Thesis Title: COMPARISON OF CLASSIFICATION PERFORMANCES OF MATHEMATICS ACHIEVEMENT AT PISA 2012 WITH ARTIFICIAL NEURAL NETWORK, DECISION TREES AND DISCRIMINANT ANALYSIS

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
06.03.2017	135	211680	13.03.2017	%8	780027219

Filtering options applied:

1. Bibliography excluded
2. Quotes excluded
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.


Date and Signature
06.03.2017


















Name Surname: Emre TOPRAK
Student No: N11142189
Department: Educational Sciences
Program: Measurement and Evaluation in Education
Status: Masters Ph.D. Integrated Ph.D.

ADVISOR APPROVAL

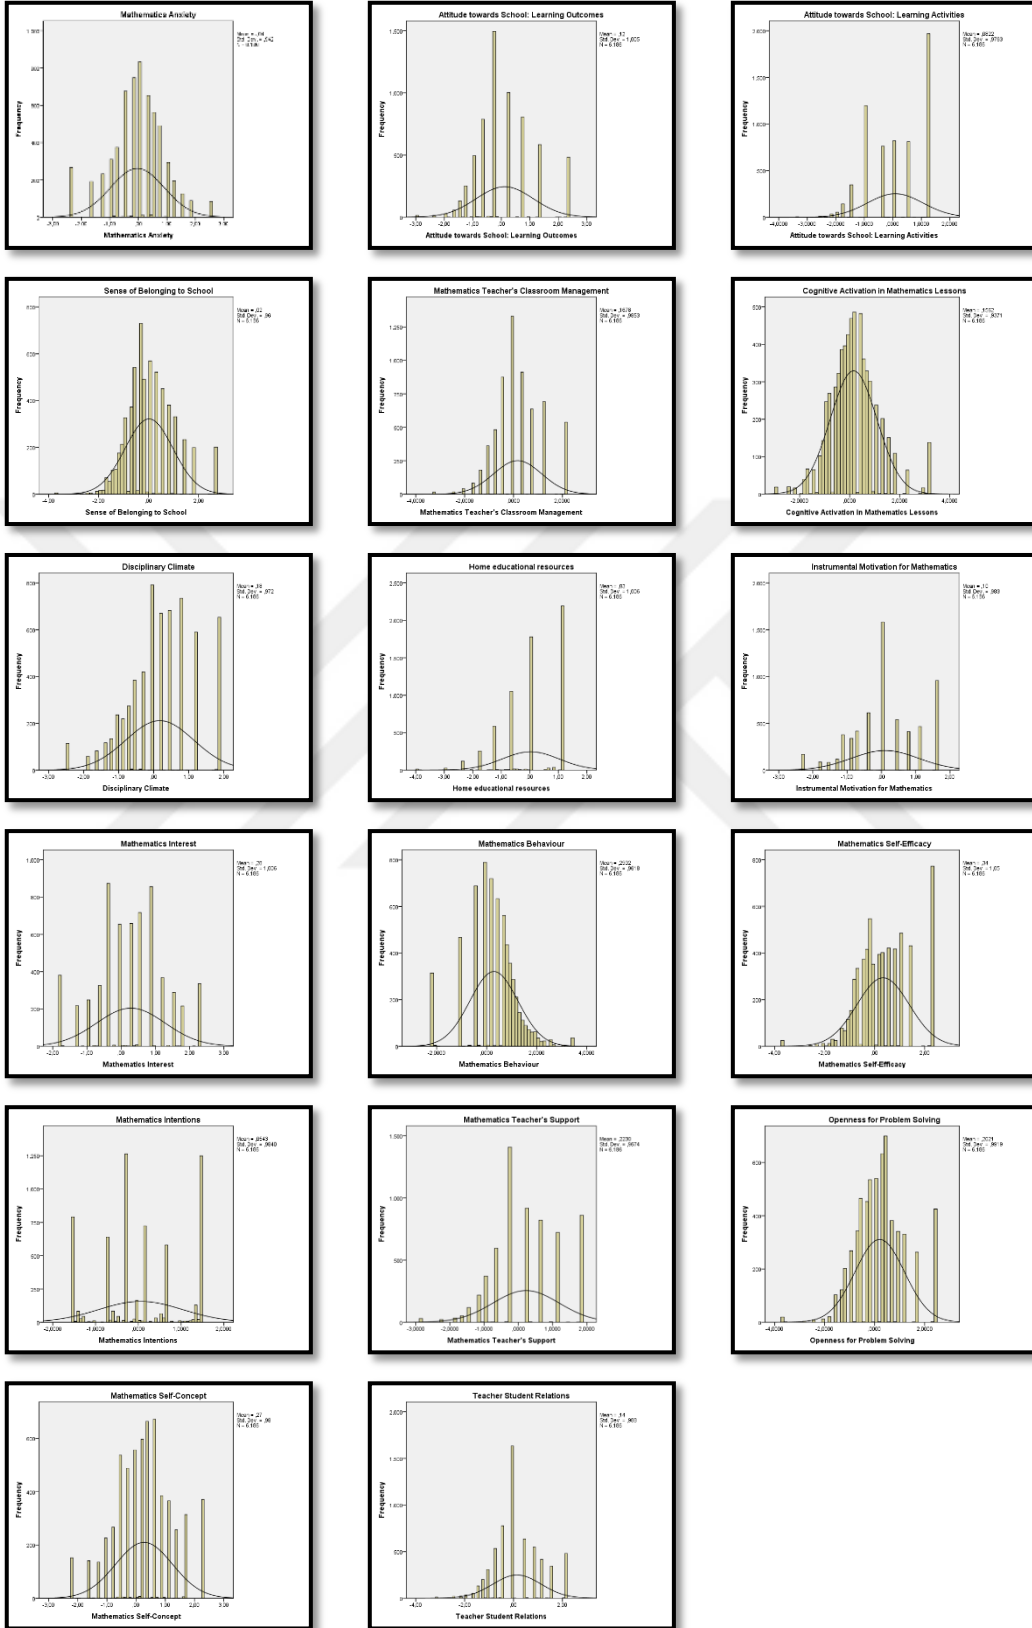
APPROVED.

(Prof. Dr. Selahattin GELBAL)


















EK 2. Değişkenlerin büyük örneklemedeki dağılımlarına ilişkin histogram grafikleri




















EK 3. Değişkenlerin orta büyüklükteki örneklemdeki dağılımlarına ilişkin histogram grafikleri




















EK 4. Değişkenlerin küçük örneklemdaki dağılımlarına ilişkin histogram grafikleri



EK 5. Değişkenlerin çok küçük ve homojenliği sağlanmış örneklemdeki dağılımlarına ilişkin histogram grafikleri



EK 6. Değişkenlerin çok küçük ve homojenliği sağlanmamış örneklemdeki dağılımlarına ilişkin histogram grafikleri



EK 7. Büyük örneklemedeki değişkenlere ilişkin çarpıklık ve basıklık değerleri ile değerlerin standart hatalarına bölünmesiyle elde edilen z değerleri

<i>Değişkenler</i>	<i>Çarpıklık</i>	<i>Std. Hata</i>	<i>z</i>	<i>Basıklık</i>	<i>Std. Hata</i>	<i>z</i>
Matematik kaygısı	-,190	,007	-27,14	,964	,014	68,86
Okula karşı tutum: Öğrenme çıktıları	,570	,007	81,43	,077	,014	5,50
Okula karşı tutum: Öğrenme aktiviteleri	-,313	,007	-44,71	-,989	,014	-70,64
Okula ait olma duygusu	,584	,007	83,43	,421	,014	30,07
Matematik öğretmenin sınıf yönetimi	,314	,007	44,86	,124	,014	8,86
Matematik dersindeki bilişsel aktiviteler	,314	,007	44,86	2,374	,014	169,57
Sınıf iklimi	-,136	,007	-19,43	-,143	,014	-10,21
Evdeki eğitim olanakları	-,431	,007	-61,57	-,462	,014	-33,00
Matematik motivasyonu	-,160	,007	-22,86	-,457	,014	-32,64
Matematik ilgisi	-,048	,007	-6,86	-,400	,014	-28,57
Matematik davranışı	-,097	,007	-13,86	1,212	,014	86,57
Matematik öz yeterliği	,434	,007	62,00	1,004	,014	71,71
Matematik niyeti	,014	,007	2,00	-1,058	,014	-75,57
Matematik öğretmenin desteği	-,005	,007	-0,71	-,439	,014	-31,36
Problem çözmeye açıklık	,377	,007	53,86	,809	,014	57,79
Matematik öz benlik algısı	-,016	,007	-2,29	,116	,014	8,29
Öğretmen öğrenci ilişkileri	,226	,007	32,29	-,149	,014	-10,64

EK 8. Orta büyüklükteki örneklemedeki değişkenlere ilişkin çarpıklık ve basıklık değerleri ile değerlerin standart hatalarına bölünmesiyle elde edilen z değerleri

<i>Değişkenler</i>	<i>Çarpıklık</i>	<i>Std. Hata</i>	<i>z</i>	<i>Basıklık</i>	<i>Std. Hata</i>	<i>z</i>
Matematik kaygısı	-,270	,031	-8,71	,578	,062	9,32
Okula karşı tutum: Öğrenme çıktıları	,540	,031	17,42	,044	,062	0,71
Okula karşı tutum: Öğrenme aktiviteleri	-,316	,031	-10,19	-1,007	,062	-16,24
Okula ait olma duygusu	,578	,031	18,65	,478	,062	7,71
Matematik öğretmenin sınıf yönetimi	,296	,031	9,55	,042	,062	0,68
Matematik dersindeki bilişsel aktiviteler	,595	,031	19,19	1,772	,062	28,58
Sınıf iklimi	-,196	,031	-6,32	-,140	,062	-2,26
Evdeki eğitim olanakları	-,578	,031	-18,65	-,238	,062	-3,84
Matematik motivasyonu	-,206	,031	-6,65	-,459	,062	-7,40
Matematik ilgisi	-,091	,031	-2,94	-,329	,062	-5,31
Matematik davranışı	-,360	,031	-11,61	,933	,062	15,05
Matematik öz yeterliği	,192	,031	6,19	,155	,062	2,50
Matematik niyeti	-,009	,031	-0,29	-1,016	,062	-16,39
Matematik öğretmenin desteği	,018	,031	0,58	-,393	,062	-6,34
Problem çözmeye açıklık	,304	,031	9,81	,664	,062	10,71
Matematik öz benlik algısı	-,056	,031	-1,81	-,003	,062	-0,05
Öğretmen öğrenci ilişkileri	,252	,031	8,13	-,160	,062	-2,58

EK 9. Küçük örneklemdaki değişkenlere ilişkin çarpıklık ve basıklık değerleri ile değerlerin standart hatalarına bölünmesiyle elde edilen z değerleri

<i>Değişkenler</i>	<i>Çarpıklık</i>	<i>Std. Hata</i>	<i>z</i>	<i>Basıklık</i>	<i>Std. Hata</i>	<i>z</i>
Matematik kaygısı	-,184	,100	-1,84	,801	,199	4,03
Okula karşı tutum: Öğrenme çıktıları	,528	,100	5,28	,101	,199	0,51
Okula karşı tutum: Öğrenme aktiviteleri	-,221	,100	-2,21	-1,222	,199	-6,14
Okula ait olma duygusu	,646	,100	6,46	,378	,199	1,90
Matematik öğretmenin sınıf yönetimi	,344	,100	3,44	-,053	,199	-0,27
Matematik dersindeki bilişsel aktiviteler	,253	,100	2,53	,640	,199	3,22
Sınıf iklimi	-,085	,100	-0,85	-,207	,199	-1,04
Evdeki eğitim olanakları	-,698	,100	-6,98	,298	,199	1,50
Matematik motivasyonu	-,197	,100	-1,97	-,393	,199	-1,97
Matematik ilgisi	-,038	,100	-0,38	-,350	,199	-1,76
Matematik davranışı	-,409	,100	-4,09	,650	,199	3,27
Matematik öz yeterliği	,354	,100	3,54	-,275	,199	-1,38
Matematik niyeti	-,019	,100	-0,19	-,956	,199	-4,80
Matematik öğretmenin desteği	,083	,100	0,83	-,543	,199	-2,73
Problem çözmeye açıklık	,639	,100	6,39	,185	,199	0,93
Matematik öz benlik algısı	-,020	,100	-0,2	,004	,199	0,02
Öğretmen öğrenci ilişkileri	,275	,100	2,75	,008	,199	0,04

EK 10. Çok küçük ve homojenliği sağlanmış örneklemden değişkenlere ilişkin çarpıklık ve basıklık değerleri ile değerlerin standart hatalarına bölünmesiyle elde edilen z değerleri

<i>Değişkenler</i>	<i>Çarpıklık</i>	<i>Std. Hata</i>	<i>z</i>	<i>Basıklık</i>	<i>Std. Hata</i>	<i>z</i>
Matematik kaygısı	-,320	,239	-1,34	,587	,474	1,24
Okula karşı tutum: Öğrenme çıktıları	,561	,239	2,35	-,500	,474	-1,05
Okula karşı tutum: Öğrenme aktiviteleri	-,093	,239	-0,39	-1,285	,474	-2,71
Okula ait olma duygusu	,100	,239	0,42	,687	,474	1,45
Matematik öğretmenin sınıf yönetimi	,274	,239	1,15	-,357	,474	-0,75
Matematik dersindeki bilişsel aktiviteler	,693	,239	2,90	1,916	,474	4,04
Sınıf iklimi	-,152	,239	-0,64	-,444	,474	-0,94
Evdeki eğitim olanakları	-,287	,239	-1,20	-1,127	,474	-2,38
Matematik motivasyonu	-,267	,239	-1,12	-,502	,474	-1,06
Matematik ilgisi	-,196	,239	-0,82	-,741	,474	-1,56
Matematik davranışı	-,448	,239	-1,87	-,278	,474	-0,59
Matematik öz yeterliği	-,028	,239	-0,12	,149	,474	0,31
Matematik niyeti	,051	,239	0,21	-,930	,474	-1,96
Matematik öğretmenin desteği	,093	,239	0,39	-,961	,474	-2,03
Problem çözmeye açıklık	,475	,239	1,99	-,557	,474	-1,18
Matematik öz benlik algısı	,031	,239	0,13	-,191	,474	-0,40
Öğretmen öğrenci ilişkileri	,052	,239	0,22	-,431	,474	-0,91

EK 11. Çok küçük ve homojenliği sağlanmamış örneklemdeki değişkenlere ilişkin çarpıklık ve basıklık değerleri ile değerlerin standart hatalarına bölünmesiyle elde edilen z değerleri

<i>Değişkenler</i>	<i>Çarpıklık</i>	<i>Std. Hata</i>	<i>z</i>	<i>Basıklık</i>	<i>Std. Hata</i>	<i>z</i>
Matematik kaygısı	,268	,239	1,12	-,325	,474	-0,69
Okula karşı tutum: Öğrenme çıktıları	,143	,239	0,60	-,995	,474	-2,10
Okula karşı tutum: Öğrenme aktiviteleri	-,475	,239	-1,99	-1,110	,474	-2,34
Okula ait olma duygusu	,058	,239	0,24	-,789	,474	-1,66
Matematik öğretmenin sınıf yönetimi	-,050	,239	-0,21	-,924	,474	-1,95
Matematik dersindeki bilişsel aktiviteler	-,192	,239	-0,80	-,910	,474	-1,92
Sınıf iklimi	-,525	,239	-2,20	-,904	,474	-1,91
Evdeki eğitim olanakları	-1,280	,239	-5,36	1,317	,474	2,78
Matematik motivasyonu	-,174	,239	-0,73	-1,417	,474	-2,99
Matematik ilgisi	,142	,239	0,59	-1,440	,474	-3,04
Matematik davranışı	,512	,239	2,14	-,775	,474	-1,64
Matematik öz yeterliği	-,795	,239	-3,33	-,391	,474	-0,82
Matematik niyeti	-,203	,239	-0,85	-1,382	,474	-2,92
Matematik öğretmenin desteği	-,300	,239	-1,26	-1,162	,474	-2,45
Problem çözmeye açıklık	-,327	,239	-1,37	-,802	,474	-1,69
Matematik öz benlik algısı	,080	,239	0,33	-1,028	,474	-2,17
Öğretmen öğrenci ilişkileri	-,209	,239	-0,87	-1,101	,474	-2,32

EK 12. Değişkenlerin büyük örneklemedeki korelasyonları

Değişkenler	Matematik kaygısı	Okula karşı tutum: Öğrenme çıktıları	Okula karşı tutum: Öğrenme aktiviteleri	Okula ait olma duygusu	Matematik öğretmenin sınıf yönetimi	Matematik dersindeki bilişsel aktiviteler	Sınıf iklimi	Evdeki eğitim olanakları	Matematik motivasyonu	Matematik ilgisi	Matematik davranışı	Matematik öz yeterliği	Matematik niyeti	Matematik öğretmenin desteği	Problem çözmeye açıklık	Matematik öz benlik algısı	Öğretmen öğrenci ilişkileri
Matematik kaygısı	r 1 p N 126126																
Okula karşı tutum: Öğr. çıktıları	r -.098 p .000 N 126126	1															
Okula karşı tutum: Öğr. aktiviteleri	r -.013 p .000 N 126126	.463	1														
Okula ait olma duygusu	r -.154 p 0,000 N 126126	.489	.363	1													
Matematik öğret. sınıf yönetimi	r -.098 p .000 N 126126	.282	.248	.261	1												
Matematik dersi. bilişsel aktiviteler	r -.046 p .000 N 126126	.224	.246	.210	.352	1											
Sınıf iklimi	r -.162 p 0,000 N 126126	.178	.081	.166	.540	.132	1										
Evdeki eğitim olanakları	r -.118 p 0,000 N 126126	.069	.101	.116	.048	.103	.078	1									
Matematik motivasyonu	r -.197 p 0,000 N 126126	.332	.396	.228	.248	.272	.115	.036	1								
Matematik ilgisi	r -.307 p 0,000 N 126126	.236	.242	.172	.266	.273	.168	.011	.656	1							
Matematik davranışı	r -.056 p .000 N 126126	.110	.148	.094	.143	.214	.057	.063	.340	.470	1						
Matematik öz yeterliği	r -.326 p 0,000 N 126126	.161	.218	.207	.186	.236	.138	.214	.312	.348	.263	1					
Matematik niyeti	r -.221 p 0,000 N 126126	.063	.071	.057	.097	.091	.072	.007	.387	.395	.218	.186	1				
Matematik öğretmenin desteği	r -.045 p .000 N 126126	.310	.312	.251	.473	.502	.195	.032	.318	.335	.198	.180	.106	1			
Problem çözmeye açıklık	r -.240 p 0,000 N 126126	.171	.242	.216	.137	.250	.027	.158	.288	.328	.338	.447	.106	.178	1		
Matematik öz benlik algısı	r -.590 p 0,000 N 126126	.159	.180	.173	.178	.211	.121	.095	.480	.634	.349	.482	.378	.202	.449	1	
Öğretmen öğrenci ilişkileri	r -.061 p .000 N 126126	.422	.361	.408	.330	.325	.160	.043	.304	.300	.184	.184	.061	.447	.193	.182	1

EK 13. Değişkenlerin orta büyüklükteki örneklemedeki korelasyonları

Değişkenler	Matematik kaygısı	Okula karşı tutum: Öğrenme çıktıları	Okula karşı tutum: Öğrenme aktiviteleri	Okula ait olma duygusu	Matematik öğretmenin sınıf yönetimi	Matematik dersindeki bilişsel aktiviteler	Sınıf iklimi	Evdeki eğitim olanakları	Matematik motivasyonu	Matematik ilgisi	Matematik davranışı	Matematik öz yeterliği	Matematik niyeti	Matematik öğretmenin desteği	Problem çözmeye açıklık	Matematik öz benlik algısı	Öğretmen öğrenci ilişkileri
Matematik kaygısı	r 1 p N 6186																
Okula karşı tutum: Öğr. çıktıları	r -,109 p ,000 N 6186	1															
Okula karşı tutum: Öğr. aktiviteleri	r -,035 p ,006 N 6186	,467	1														
Okula ait olma duygusu	r -,157 p ,000 N 6186	,497	,363	1													
Matematik öğret. sınıf yönetimi	r -,115 p ,000 N 6186	,268	,240	,252	1												
Matematik dersi. bilişsel aktiviteler	r -,073 p ,000 N 6186	,253	,247	,222	,329	1											
Sınıf iklimi	r -,167 p ,000 N 6186	,164	,084	,164	,555	,152	1										
Evdeki eğitim olanakları	r -,176 p ,000 N 6186	,100	,115	,127	,044	,100	,093	1									
Matematik motivasyonu	r -,222 p ,000 N 6186	,338	,401	,228	,245	,257	,109	,052	1								
Matematik ilgisi	r -,345 p ,000 N 6186	,257	,236	,181	,266	,254	,162	,036	,638	1							
Matematik davranışı	r -,094 p ,000 N 6186	,138	,139	,104	,138	,207	,060	,079	,329	,465	1						
Matematik öz yeterliği	r -,403 p ,000 N 6186	,122	,172	,167	,169	,205	,170	,253	,287	,343	,281	1					
Matematik niyeti	r -,238 p ,000 N 6186	,049	,064	,043	,089	,094	,064	,031	,388	,386	,213	,203	1				
Matematik öğretmenin desteği	r -,049 p ,000 N 6186	,322	,309	,251	,470	,462	,216	,024	,308	,333	,191	,144	,082	1			
Problem çözmeye açıklık	r -,330 p ,000 N 6186	,200	,239	,231	,138	,272	,047	,188	,307	,337	,330	,479	,119	,180	1		
Matematik öz benlik algısı	r -,651 p 0,000 N 6186	,168	,180	,186	,177	,206	,102	,127	,476	,621	,341	,506	,381	,185	,497	1	
Öğretmen öğrenci ilişkileri	r -,078 p ,000 N 6186	,431	,376	,419	,319	,317	,168	,061	,306	,289	,185	,180	,040	,453	,216	,173	1
																	6186

EK 14. Değişkenlerin küçük örneklemedeki korelasyonları

Değişkenler	Matematik kaygısı	Okula karşı tutum: Öğrenme çıktıları	Okula karşı tutum: Öğrenme aktiviteleri	Okula ait olma duygusu	Matematik öğretmeninin sınıf yönetimi	Matematik dersindeki bilişsel aktiviteler	Sınıf iklimi	Evdaki eğitim olanakları	Matematik motivasyonu	Matematik ilgisi	Matematik davranışı	Matematik öz yeterliği	Matematik niyeti	Matematik öğretmeninin desteği	Problem çözmeye açıklık	Matematik öz benlik algısı	Öğretmen öğrenci ilişkileri	
Matematik kaygısı	r 1 p N 603																	
Okula karşı tutum: Öğr. çıktıları	r -,113 p ,005 N 603	1																
Okula karşı tutum: Öğr. aktiviteleri	r -,088 p ,031 N 603	,492 ,000	1															
Okula ait olma duygusu	r -,160 p ,000 N 603	,532 ,000	,382 ,000	1														
Matematik öğret. sınıf yönetimi	r -,148 p ,000 N 603	,281 ,000	,196 ,000	,206 ,000	1													
Matematik ders. bilişsel aktiviteler	r -,139 p ,001 N 603	,293 ,000	,271 ,000	,270 ,000	,394 ,000	1												
Sınıf iklimi	r -,204 p ,000 N 603	,110 ,007	,076 ,061	,151 ,000	,566 ,000	,209 ,000	1											
Evdaki eğitim olanakları	r -,039 p ,337 N 603	,045 ,266	,118 ,004	,129 ,002	,031 ,451	,104 ,011	,056 ,166	1										
Matematik motivasyonu	r -,270 p ,000 N 603	,355 ,000	,400 ,000	,231 ,000	,201 ,000	,209 ,000	,099 ,015	,059 ,147	1									
Matematik ilgisi	r -,386 p ,000 N 603	,279 ,000	,192 ,000	,135 ,001	,242 ,000	,227 ,000	,174 ,000	-,013 ,743	,630 ,000	1								
Matematik davranışı	r -,060 p ,142 N 603	,218 ,000	,130 ,001	,107 ,008	,082 ,044	,187 ,000	,018 ,660	,069 ,088	,304 ,000	,427 ,000	1							
Matematik öz yeterliği	r -,391 p ,000 N 603	,066 ,106	,153 ,000	,161 ,000	,243 ,000	,290 ,000	,261 ,000	,259 ,000	,257 ,000	,358 ,000	,222 ,000	1						
Matematik niyeti	r -,152 p ,000 N 603	,072 ,077	,100 ,014	,065 ,112	,071 ,080	,074 ,069	,045 ,265	,042 ,306	,406 ,000	,343 ,000	,210 ,000	,166 ,000	1					
Matematik öğretmeninin desteği	r -,086 p ,036 N 603	,319 ,000	,256 ,000	,174 ,000	,473 ,000	,545 ,000	,194 ,000	-,030 ,465	,254 ,000	,293 ,000	,118 ,004	,147 ,000	,032 ,440	1				
Problem çözmeye açıklık	r -,297 p ,000 N 603	,142 ,000	,174 ,000	,166 ,000	,113 ,006	,262 ,000	,005 ,900	,130 ,001	,254 ,000	,368 ,000	,322 ,000	,464 ,000	,126 ,002	,122 ,003	1			
Matematik öz benlik algısı	r -,683 p ,000 N 603	,149 ,000	,165 ,000	,110 ,007	,189 ,000	,193 ,000	,142 ,000	,017 ,683	,513 ,000	,666 ,000	,308 ,000	,469 ,000	,367 ,000	,157 ,000	,502 ,000	1		
Öğretmen öğrenci ilişkileri	r -,145 p ,000 N 603	,421 ,000	,353 ,000	,400 ,000	,393 ,000	,344 ,000	,221 ,000	-,016 ,704	,244 ,000	,258 ,000	,203 ,000	,204 ,000	,020 ,622	,444 ,000	,129 ,001	,147 ,000	1	
																		603

EK 15. Değişkenlerin çok küçük ve homojenliği sağlanmış örneklemdeki korelasyonları

Değişkenler	Matematik kaygısı	Okula karşı tutum: Öğrenme çıktıları	Okula karşı tutum: Öğrenme aktiviteleri	Okula ait olma duygusu	Matematik öğretmenin sınıf yönetimi	Matematik dersindeki bilişsel aktiviteler	Sınıf iklimi	Evdeki eğitim olanakları	Matematik motivasyonu	Matematik ilgisi	Matematik davranışı	Matematik öz yeterliği	Matematik niyeti	Matematik öğretmenin desteği	Problem çözmeye açıklık	Matematik öz benlik algısı	Öğretmen öğrenci ilişkileri
Matematik kaygısı	r 1 p N 102																
Okula karşı tutum: Öğr. çıktıları	r -.047 p N 102	1															
Okula karşı tutum: Öğr. aktiviteleri	r -.107 p N 102	.361 102	1														
Okula ait olma duygusu	r -.161 p N 102	.613 102	.371 102	1													
Matematik öğret. sınıf yönetimi	r -.201 p N 102	.425 102	.188 102	.451 102	1												
Matematik dersi. bilişsel aktiviteler	r -.124 p N 102	.387 102	.165 102	.302 102	.406 102	1											
Sınıf iklimi	r -.317 p N 102	.270 102	.154 102	.353 102	.600 102	.221 102	1										
Evdeki eğitim olanakları	r -.015 p N 102	.026 102	.014 102	.050 102	.253 102	.067 102	.196 102	1									
Matematik motivasyonu	r -.213 p N 102	.323 102	.409 102	.407 102	.460 102	.174 102	.272 102	.222 102	1								
Matematik ilgisi	r -.454 p N 102	.188 102	.303 102	.314 102	.432 102	.201 102	.464 102	.147 102	.645 102	1							
Matematik davranışı	r -.236 p N 102	.138 102	.254 102	.128 102	.352 102	.261 102	.345 102	.106 102	.330 102	.666 102	1						
Matematik öz yeterliği	r -.503 p N 102	.211 102	.302 102	.205 102	.324 102	.322 102	.361 102	.212 102	.339 102	.373 102	.222 102	1					
Matematik niyeti	r -.221 p N 102	.002 102	.076 102	.082 102	.103 102	.023 102	.055 102	.023 102	.323 102	.298 102	.166 102	.127 102	1				
Matematik öğretmenin desteği	r -.064 p N 102	.345 102	.199 102	.422 102	.556 102	.554 102	.305 102	.168 102	.407 102	.469 102	.424 102	.320 102	.068 102	1			
Problem çözmeye açıklık	r -.374 p N 102	.274 102	.383 102	.166 102	.252 102	.270 102	.339 102	.245 102	.285 102	.459 102	.439 102	.580 102	-.084 102	.264 102	1		
Matematik öz benlik algısı	r -.755 p N 102	.152 102	.313 102	.286 102	.359 102	.181 102	.403 102	.094 102	.510 102	.709 102	.425 102	.537 102	.242 102	.306 102	.542 102	1	
Öğretmen öğrenci ilişkileri	r -.271 p N 102	.504 102	.440 102	.624 102	.570 102	.349 102	.415 102	.112 102	.554 102	.426 102	.315 102	.419 102	.186 102	.558 102	.309 102	.438 102	1

EK 16. Değişkenlerin çok küçük ve homojenliği sağlanmamış örneklemdeki korelasyonları

Değişkenler	Matematik kaygısı	Okula karşı tutum: Öğrenme çıktıları	Okula karşı tutum: Öğrenme aktiviteleri	Okula ait olma duygusu	Matematik öğretmeninin sınıf yönetimi	Matematik dersindeki bilişsel aktiviteler	Sınıf iklimi	Evdeki eğitim olanakları	Matematik motivasyonu	Matematik ilgisi	Matematik davranışı	Matematik öz yeterliği	Matematik niyeti	Matematik öğretmeninin desteği	Problem çözmeye açıklık	Matematik öz benlik algısı	Öğretmen öğrenci ilişkileri
Matematik kaygısı	r 1 p N 102																
Okula karşı tutum: Öğr. çıktıları	r -,045 p N 102	1															
Okula karşı tutum: Öğr. aktiviteleri	r ,179 p ,073 N 102	,823 102	1														
Okula ait olma duygusu	r -,061 p ,545 N 102	,919 102	,841 102	1													
Matematik öğret. sınıf yönetimi	r ,042 p ,672 N 102	,819 102	,787 102	,830 102	1												
Matematik dersi. bilişsel aktiviteler	r ,075 p ,455 N 102	,840 102	,870 102	,859 102	,827 102	1											
Sınıf iklimi	r -,087 p ,385 N 102	,598 102	,414 102	,520 102	,624 102	,468 102	1										
Evdeki eğitim olanakları	r ,054 p ,588 N 102	,535 102	,580 102	,522 102	,497 102	,605 102	,287 102	1									
Matematik motivasyonu	r ,072 p ,473 N 102	,863 102	,868 102	,865 102	,799 102	,877 102	,489 102	,544 102	1								
Matematik ilgisi	r ,012 p ,902 N 102	,864 102	,805 102	,875 102	,850 102	,881 102	,562 102	,577 102	,916 102	1							
Matematik davranışı	r ,034 p ,735 N 102	,802 102	,753 102	,828 102	,751 102	,838 102	,491 102	,526 102	,829 102	,889 102	1						
Matematik öz yeterliği	r ,062 p ,538 N 102	,689 102	,792 102	,736 102	,719 102	,800 102	,381 102	,551 102	,765 102	,761 102	,734 102	1					
Matematik niyeti	r -,077 p ,442 N 102	,603 102	,553 102	,594 102	,589 102	,586 102	,394 102	,401 102	,725 102	,728 102	,559 102	,486 102	1				
Matematik öğretmeninin desteği	r ,143 p ,151 N 102	,832 102	,854 102	,867 102	,830 102	,908 102	,405 102	,584 102	,836 102	,850 102	,802 102	,793 102	,544 102	1			
Problem çözmeye açıklık	r ,092 p ,355 N 102	,786 102	,781 102	,818 102	,737 102	,824 102	,350 102	,543 102	,811 102	,854 102	,813 102	,772 102	,560 102	,799 102	1		
Matematik öz benlik algısı	r -,215 p ,030 N 102	,836 102	,737 102	,817 102	,793 102	,808 102	,525 102	,533 102	,839 102	,876 102	,800 102	,773 102	,667 102	,774 102	,787 102	1	
Öğretmen öğrenci ilişkileri	r ,117 p ,243 N 102	,847 102	,870 102	,897 102	,856 102	,913 102	,472 102	,610 102	,883 102	,917 102	,852 102	,816 102	,624 102	,926 102	,842 102	,801 102	1

EK 17. Değişkenlerin farklı örneklem büyüklüklerinde sahip oldukları tolerance, VIF ve CI değerleri

<i>Değişkenler</i>	<i>Büyük (126126 kişilik) örneklem</i>			<i>Orta büyüklükteki (6186 kişilik) örneklem</i>			<i>Küçük (603 kişilik) örneklem</i>		
	<i>Tolerance</i>	<i>VIF</i>	<i>CI</i>	<i>Tolerance</i>	<i>VIF</i>	<i>CI</i>	<i>Tolerance</i>	<i>VIF</i>	<i>CI</i>
Matematik kaygısı	,589	1,699	1,000	,513	1,949	1,000	,464	2,155	1,000
Okula karşı tutum: Öğrenme çıktıları	,617	1,621	1,561	,606	1,651	1,604	,536	1,867	1,562
Okula karşı tutum: Öğrenme aktiviteleri	,656	1,525	1,877	,655	1,528	1,970	,641	1,561	1,856
Okula ait olma duygusu	,673	1,487	1,967	,669	1,496	2,033	,624	1,602	2,027
Matematik öğretmenin sınıf yönetimi	,540	1,852	2,077	,539	1,856	2,147	,507	1,971	2,089
Matematik dersindeki bilişsel aktiviteler	,686	1,458	2,320	,718	1,392	2,463	,604	1,656	2,277
Sınıf iklimi	,676	1,480	2,411	,656	1,524	2,510	,621	1,610	2,396
Evdeki eğitim olanakları	,923	1,083	2,584	,898	1,113	2,781	,877	1,140	2,655
Matematik motivasyonu	,474	2,112	2,709	,483	2,071	2,810	,467	2,142	2,794
Matematik ilgisi	,380	2,635	2,808	,399	2,509	2,937	,380	2,632	2,895
Matematik davranışı	,711	1,406	2,986	,718	1,392	3,063	,724	1,380	3,036
Matematik öz yeterliği	,658	1,519	3,117	,625	1,599	3,370	,587	1,704	3,261
Matematik niyeti	,773	1,294	3,250	,765	1,307	3,410	,768	1,303	3,384
Matematik öğretmenin desteği	,573	1,745	3,280	,585	1,708	3,430	,540	1,850	3,731
Problem çözmeye açıklık	,664	1,505	3,355	,618	1,618	3,519	,610	1,640	3,901
Matematik öz benlik algısı	,359	2,788	3,730	,327	3,056	3,892	,267	3,740	3,978
Öğretmen öğrenci ilişkileri	,645	1,551	4,039	,634	1,576	4,283	,613	1,632	4,356

<i>Değişkenler</i>	<i>Çok küçük (102 kişilik) ve homojenliği sağlanmış örneklem</i>			<i>Çok küçük (102 kişilik) ve homojenliği sağlanmamış örneklem</i>		
	<i>Tolerance</i>	<i>VIF</i>	<i>CI</i>	<i>Tolerance</i>	<i>VIF</i>	<i>CI</i>
Matematik kaygısı	,319	3,139	1,000	,491	2,037	1,000
Okula karşı tutum: Öğrenme çıktıları	,498	2,010	1,864	,100	10,030	2,524
Okula karşı tutum: Öğrenme aktiviteleri	,622	1,608	2,232	,132	7,548	3,970
Okula ait olma duygusu	,436	2,295	2,312	,083	12,050	4,056
Matematik öğretmenin sınıf yönetimi	,398	2,512	2,464	,165	6,054	4,483
Matematik dersindeki bilişsel aktiviteler	,584	1,712	2,554	,104	9,623	4,546
Sınıf iklimi	,507	1,973	2,581	,409	2,447	6,138
Evdeki eğitim olanakları	,814	1,228	2,943	,571	1,751	6,575
Matematik motivasyonu	,364	2,747	3,312	,088	11,406	7,541
Matematik ilgisi	,220	4,537	3,517	,052	19,095	7,986
Matematik davranışı	,441	2,265	3,888	,171	5,862	9,319
Matematik öz yeterliği	,458	2,182	4,081	,219	4,574	9,930
Matematik niyeti	,759	1,318	4,353	,358	2,795	10,216
Matematik öğretmenin desteği	,387	2,586	4,948	,095	10,541	11,965
Problem çözmeye açıklık	,403	2,479	5,065	,178	5,619	13,294
Matematik öz benlik algısı	,213	4,694	5,268	,116	8,623	14,951
Öğretmen öğrenci ilişkileri	,357	2,797	7,034	,060	16,652	15,087

EK 18. Büyük örneklemede 6, 3 ve 2 alt gruba sınıflama yapmada yapay sinir ağlarına ait sonuçlar

Classification

Sample	Observed	Predicted						Predicted
		Düzey 1	Düzey 2	Düzey 3	Düzey 4	Düzey 5	Düzey 6	Percent Correct
Training	Düzey 1	7760	7486	2569	483	55	27	42,2%
	Düzey 2	5284	10011	5928	1511	183	57	43,6%
	Düzey 3	2074	7033	8086	3514	623	87	37,8%
	Düzey 4	542	2672	5489	4586	1193	172	31,3%
	Düzey 5	129	732	2114	3135	1453	235	18,6%
	Düzey 6	29	156	525	1182	945	309	9,8%
	Overall Percent		17,9%	31,8%	28,0%	16,3%	5,0%	1,0%
Testing	Düzey 1	3372	3172	1129	204	25	10	42,6%
	Düzey 2	2235	4288	2577	720	81	18	43,2%
	Düzey 3	873	2919	3437	1473	262	43	38,2%
	Düzey 4	234	1161	2321	1998	490	59	31,9%
	Düzey 5	66	310	931	1278	619	103	18,7%
	Düzey 6	16	80	214	499	415	125	9,3%
	Overall Percent		18,0%	31,6%	28,1%	16,3%	5,0%	0,9%

Dependent Variable: 6 Alt Grup

Classification

Sample	Observed	Predicted			Percent Correct
		Düşük düzey	Orta düzey	Üst düzey	
Training	Düşük düzey	30684	10352	259	74,3%
	Orta düzey	12572	21453	1785	59,9%
	Üst düzey	1087	7228	2676	24,3%
	Overall Percent	50,3%	44,3%	5,4%	62,2%
Testing	Düşük düzey	13348	4421	121	74,6%
	Orta düzey	5415	9323	793	60,0%
	Üst düzey	464	2990	1155	25,1%
	Overall Percent	50,6%	44,0%	5,4%	62,7%

Dependent Variable: 3 Alt Grup

Classification

Sample	Observed	Predicted		Percent Correct
		Alt düzey	Üst düzey	
Training	Alt düzey	56373	6225	90,1%
	Üst düzey	12880	12646	49,5%
	Overall Percent	78,6%	21,4%	78,3%
Testing	Alt düzey	24444	2567	90,5%
	Üst düzey	5463	5528	50,3%
	Overall Percent	78,7%	21,3%	78,9%

Dependent Variable: 2 Alt Grup

EK 19. Orta büyüklükteki örnekleme 6, 3 ve 2 alt gruba sınıflama yapmada yapay sinir ağlarına ait sonuçlar

Classification

Sample	Observed	Predicted						Percent Correct
		Düzey 1	Düzey 2	Düzey 3	Düzey 4	Düzey 5	Düzey 6	
Training	Düzey 1	422	144	65	28	10	29	60,5%
	Düzey 2	264	183	121	60	34	46	25,8%
	Düzey 3	141	148	165	106	65	90	23,1%
	Düzey 4	58	79	105	163	112	176	23,5%
	Düzey 5	38	53	93	104	123	314	17,0%
	Düzey 6	18	27	38	74	85	529	68,6%
	Overall Percent		21,8%	14,7%	13,6%	12,4%	10,0%	27,5%
Testing	Düzey 1	187	68	36	10	2	11	59,6%
	Düzey 2	123	79	51	31	16	20	24,7%
	Düzey 3	74	64	59	40	35	28	19,7%
	Düzey 4	29	32	55	61	48	79	20,1%
	Düzey 5	17	19	24	54	48	123	16,8%
	Düzey 6	4	15	25	38	51	220	62,3%
	Overall Percent		23,1%	14,8%	13,3%	12,5%	10,7%	25,6%

Dependent Variable: 6 Alt Grup

Classification

Sample	Observed	Predicted			Percent Correct
		Alt düzey	Orta düzey	Üst düzey	
Training	Alt düzey	1034	280	97	73,3%
	Orta düzey	425	563	412	40,2%
	Üst düzey	110	315	1052	71,2%
	Overall Percent	36,6%	27,0%	36,4%	61,8%
Testing	Alt düzey	437	144	48	69,5%
	Orta düzey	176	233	203	38,1%
	Üst düzey	48	158	451	68,6%
	Overall Percent	34,8%	28,2%	37,0%	59,1%

Dependent Variable: 3 Alt Grup

Classification

Sample	Observed	Predicted		Percent Correct
		Alt düzey	Üst düzey	
Training	Alt düzey	1669	461	78,4%
	Üst düzey	463	1737	79,0%
	Overall Percent	49,2%	50,8%	78,7%
Testing	Alt düzey	742	183	80,2%
	Üst düzey	198	733	78,7%
	Overall Percent	50,6%	49,4%	79,5%

Dependent Variable: 2 Alt Grup

EK 20. Küçük örnekleimde 6, 3 ve 2 alt gruba sınıflama yapmada yapay sinir ağlarına ait sonuçlar

Classification

Sample	Observed	Predicted						Percent Correct
		Düzey 1	Düzey 2	Düzey 3	Düzey 4	Düzey 5	Düzey 6	
Training	Düzey 1	43	7	5	2	3	3	68,3%
	Düzey 2	23	26	9	9	1	3	36,6%
	Düzey 3	9	8	26	11	7	8	37,7%
	Düzey 4	7	8	8	21	10	14	30,9%
	Düzey 5	2	4	9	10	17	27	24,6%
	Düzey 6	4	0	3	7	5	46	70,8%
	Overall Percent		21,7%	13,1%	14,8%	14,8%	10,6%	24,9%
Testing	Düzey 1	19	9	2	2	3	2	51,4%
	Düzey 2	14	10	4	1	0	0	34,5%
	Düzey 3	5	10	6	7	2	2	18,8%
	Düzey 4	5	3	8	4	6	7	12,1%
	Düzey 5	2	1	2	9	9	9	28,1%
	Düzey 6	0	1	1	2	5	26	74,3%
	Overall Percent		22,7%	17,2%	11,6%	12,6%	12,6%	23,2%

Dependent Variable: 6 Alt Grup

Classification

Sample	Observed	Predicted			Percent Correct
		Düşük düzey	Orta düzey	Üst düzey	
Training	Düşük düzey	104	27	9	74,3%
	Orta düzey	41	69	40	46,0%
	Üst düzey	12	27	98	71,5%
	Overall Percent	36,8%	28,8%	34,4%	63,5%
Testing	Düşük düzey	41	15	4	68,3%
	Orta düzey	12	27	13	51,9%
	Üst düzey	1	11	52	81,3%
	Overall Percent	30,7%	30,1%	39,2%	68,2%

Dependent Variable: 3 Alt Grup

Classification

Sample	Observed	Predicted		Percent Correct
		Alt düzey	Üst düzey	
Training	Alt düzey	153	46	76,9%
	Üst düzey	56	173	75,5%
	Overall Percent	48,8%	51,2%	76,2%
Testing	Alt düzey	87	15	85,3%
	Üst düzey	17	56	76,7%
	Overall Percent	59,4%	40,6%	81,7%

Dependent Variable: 2 Alt Grup

EK 21. Çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örnekleme 6, 3 ve 2 alt gruba sınıflama yapmada yapay sinir ağlarına ait sonuçlar

Classification

Sample	Observed	Predicted						Percent Correct
		Düzey 1	Düzey 2	Düzey 3	Düzey 4	Düzey 5	Düzey 6	
Training	Düzey 1	9	3	1	0	2	0	60,0%
	Düzey 2	3	8	0	0	1	0	66,7%
	Düzey 3	4	2	6	0	1	1	42,9%
	Düzey 4	0	9	2	0	1	0	0,0%
	Düzey 5	2	1	2	0	8	0	61,5%
	Düzey 6	0	0	0	0	1	13	92,9%
	Overall Percent		22,5%	28,8%	13,8%	0,0%	17,5%	17,5%
Testing	Düzey 1	1	0	0	0	1	0	50,0%
	Düzey 2	1	3	1	0	0	0	60,0%
	Düzey 3	1	0	2	0	0	0	66,7%
	Düzey 4	1	1	1	0	2	0	0,0%
	Düzey 5	0	1	1	0	2	0	50,0%
	Düzey 6	0	1	0	0	0	2	66,7%
	Overall Percent		18,2%	27,3%	22,7%	0,0%	22,7%	9,1%

Dependent Variable: 6 Alt Grup

Classification

Sample	Observed	Predicted			Percent Correct
		Düşük düzey	Orta düzey	Üst düzey	
Training	Düşük düzey	16	2	3	76,2%
	Orta düzey	10	12	2	50,0%
	Üst düzey	2	6	18	69,2%
	Overall Percent	39,4%	28,2%	32,4%	64,8%
Testing	Düşük düzey	11	1	1	84,6%
	Orta düzey	3	5	2	50,0%
	Üst düzey	1	0	7	87,5%
	Overall Percent	48,4%	19,4%	32,3%	74,2%

Dependent Variable: 3 Alt Grup

Classification

Sample	Observed	Predicted		Percent Correct
		Alt düzey	Üst düzey	
Training	Alt düzey	26	5	83,9%
	Üst düzey	7	29	80,6%
	Overall Percent	49,3%	50,7%	82,1%
Testing	Alt düzey	17	3	85,0%
	Üst düzey	4	11	73,3%
	Overall Percent	60,0%	40,0%	80,0%

Dependent Variable: 2 Alt Grup

EK 22. Çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme 6, 3 ve 2 alt gruba sınıflama yapmada yapay sinir ağlarına ait sonuçlar

Classification

Sample	Observed	Predicted						Percent Correct
		Düzey 1	Düzey 2	Düzey 3	Düzey 4	Düzey 5	Düzey 6	
Training	Düzey 1	8	0	0	1	0	0	88,9%
	Düzey 2	3	0	0	3	3	3	0,0%
	Düzey 3	7	0	0	2	2	1	0,0%
	Düzey 4	4	0	1	1	2	5	7,7%
	Düzey 5	1	0	1	2	4	7	26,7%
	Düzey 6	0	0	0	1	2	9	75,0%
	Overall Percent		31,5%	0,0%	2,7%	13,7%	17,8%	34,2%
Testing	Düzey 1	7	0	0	0	0	1	87,5%
	Düzey 2	3	0	0	1	0	1	0,0%
	Düzey 3	1	0	1	1	0	2	20,0%
	Düzey 4	1	0	0	0	1	2	0,0%
	Düzey 5	0	0	0	0	2	0	100,0%
	Düzey 6	0	0	0	0	0	5	100,0%
	Overall Percent		41,4%	0,0%	3,4%	6,9%	10,3%	37,9%

Dependent Variable: 6 Alt Grup

Classification

Sample	Observed	Predicted			Percent Correct
		Düşük düzey	Orta düzey	Üst düzey	
Training	Düşük düzey	17	4	4	68,0%
	Orta düzey	7	8	8	34,8%
	Üst düzey	1	4	17	77,3%
	Overall Percent	35,7%	22,9%	41,4%	60,0%
Testing	Düşük düzey	7	0	2	77,8%
	Orta düzey	2	6	3	54,5%
	Üst düzey	1	3	8	66,7%
	Overall Percent	31,3%	28,1%	40,6%	65,6%

Dependent Variable: 3 Alt Grup

Classification

Sample	Observed	Predicted		Percent Correct
		Alt düzey	Üst düzey	
Training	Alt düzey	31	5	86,1%
	Üst düzey	3	34	91,9%
	Overall Percent	46,6%	53,4%	89,0%
Testing	Alt düzey	13	2	86,7%
	Üst düzey	3	11	78,6%
	Overall Percent	55,2%	44,8%	82,8%

Dependent Variable: 2 Alt Grup

EK 23. Büyük örneklemede 6, 3 ve 2 alt gruba sınıflama yapmada karar ağaçlarına ait sonuçlar

Classification

Observed	Predicted						Percent Correct
	Düzye 1	Düzye 2	Düzye 3	Düzye 4	Düzye 5	Düzye 6	
Düzye 1	10214	10537	4472	893	176	0	38,8%
Düzye 2	7313	14324	8712	2184	360	0	43,5%
Düzye 3	3483	10251	11492	4365	833	0	37,8%
Düzye 4	1069	4637	8079	5805	1327	0	27,8%
Düzye 5	298	1469	3534	4187	1617	0	14,6%
Düzye 6	82	359	964	1936	1154	0	0,0%
Overall Percentage	17,8%	33,0%	29,5%	15,4%	4,3%	0,0%	34,5%

Growing Method: CHAID

Dependent Variable: 6 Alt Grup

Classification

Observed	Predicted			Percent Correct
	Düşük düzey	Orta düzey	Üst düzey	
Düşük düzey	43792	14744	649	74,0%
Orta düzey	20663	28238	2440	55,0%
Üst düzey	2422	10172	3006	19,3%
Overall Percentage	53,0%	42,1%	4,8%	59,5%

Growing Method: CHAID

Dependent Variable: 3 Alt Grup

Classification

Observed	Predicted		Percent Correct
	Alt düzey	Üst düzey	
Alt düzey	80769	8840	90,1%
Üst düzey	20279	16238	44,5%
Overall Percentage	80,1%	19,9%	76,9%

Growing Method: CHAID

Dependent Variable: 2 Alt Grup

EK 24. Orta büyüklükteki örnekleme 6, 3 ve 2 alt gruba sınıflama yapmada karar ağaçlarına ait sonuçlar

Classification

Observed	Predicted						Percent Correct
	Düzey 1	Düzey 2	Düzey 3	Düzey 4	Düzey 5	Düzey 6	
Düzey 1	608	184	98	46	39	37	60,1%
Düzey 2	420	263	165	64	61	55	25,6%
Düzey 3	228	228	231	120	89	119	22,8%
Düzey 4	128	121	168	203	152	225	20,4%
Düzey 5	65	80	141	134	217	373	21,5%
Düzey 6	38	44	103	105	167	667	59,3%
Overall Percentage	24,0%	14,9%	14,6%	10,9%	11,7%	23,9%	35,4%

Growing Method: CHAID

Dependent Variable: 6 Alt Grup

Classification

Observed	Predicted			Percent Correct
	Alt düzey	Orta düzey	Üst düzey	
Alt düzey	1480	422	138	72,5%
Orta düzey	687	751	574	37,3%
Üst düzey	256	474	1404	65,8%
Overall Percentage	39,2%	26,6%	34,2%	58,8%

Growing Method: CHAID

Dependent Variable: 3 Alt Grup

Classification

Observed	Predicted		Percent Correct
	Alt düzey	Üst düzey	
Alt düzey	2377	678	77,8%
Üst düzey	791	2340	74,7%
Overall Percentage	51,2%	48,8%	76,3%

Growing Method: CHAID

Dependent Variable: 2 Alt Grup

EK 25. Küçük örnekleimde 6, 3 ve 2 alt gruba sınıflama yapmada karar ağaçlarına ait sonuçlar

Classification

Observed	Predicted						Percent Correct
	Düzey 1	Düzey 2	Düzey 3	Düzey 4	Düzey 5	Düzey 6	
Düzey 1	41	27	8	0	10	14	41,0%
Düzey 2	34	32	15	0	4	15	32,0%
Düzey 3	18	32	30	0	7	14	29,7%
Düzey 4	10	21	30	0	22	18	0,0%
Düzey 5	4	18	24	0	29	26	28,7%
Düzey 6	0	2	18	0	27	53	53,0%
Overall Percentage	17,7%	21,9%	20,7%	0,0%	16,4%	23,2%	30,7%

Growing Method: CHAID

Dependent Variable: 6 Alt Grup

Classification

Observed	Predicted			Percent Correct
	Düşük düzey	Orta düzey	Üst düzey	
Düşük düzey	127	57	16	63,5%
Orta düzey	56	106	40	52,5%
Üst düzey	12	78	111	55,2%
Overall Percentage	32,3%	40,0%	27,7%	57,0%

Growing Method: CHAID

Dependent Variable: 3 Alt Grup

Classification

Observed	Predicted		Percent Correct
	Alt düzey	Üst düzey	
Alt düzey	202	99	67,1%
Üst düzey	54	248	82,1%
Overall Percentage	42,5%	57,5%	74,6%

Growing Method: CHAID

Dependent Variable: 2 Alt Grup

EK 26. Çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örnekleme 6, 3 ve 2 alt gruba sınıflama yapmada karar ağaçlarına ait sonuçlar

Classification

Observed	Predicted						Percent Correct
	Düzye 1	Düzye 2	Düzye 3	Düzye 4	Düzye 5	Düzye 6	
Düzye 1	0	0	9	0	0	8	0,0%
Düzye 2	0	0	10	0	0	7	0,0%
Düzye 3	0	0	14	0	0	3	82,4%
Düzye 4	0	0	9	0	0	8	0,0%
Düzye 5	0	0	8	0	0	9	0,0%
Düzye 6	0	0	2	0	0	15	88,2%
Overall Percentage	0,0%	0,0%	51,0%	0,0%	0,0%	49,0%	28,4%

Growing Method: CHAID

Dependent Variable: 6 Alt Grup

Classification

Observed	Predicted			Percent Correct
	Düşük düzey	Orta düzey	Üst düzey	
Düşük düzey	0	19	15	0,0%
Orta düzey	0	23	11	67,6%
Üst düzey	0	10	24	70,6%
Overall Percentage	0,0%	51,0%	49,0%	46,1%

Growing Method: CHAID

Dependent Variable: 3 Alt Grup

Classification

Observed	Predicted		Percent Correct
	Alt düzey	Üst düzey	
Alt düzey	33	18	64,7%
Üst düzey	19	32	62,7%
Overall Percentage	51,0%	49,0%	63,7%

Growing Method: CHAID

Dependent Variable: 2 Alt Grup

EK 27. Çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme 6, 3 ve 2 alt gruba sınıflama yapmada karar ağaçlarına ait sonuçlar

Classification

Observed	Predicted						Percent Correct
	Düzye 1	Düzye 2	Düzye 3	Düzye 4	Düzye 5	Düzye 6	
Düzye 1	17	0	0	0	0	0	100,0%
Düzye 2	17	0	0	0	0	0	0,0%
Düzye 3	17	0	0	0	0	0	0,0%
Düzye 4	17	0	0	0	0	0	0,0%
Düzye 5	17	0	0	0	0	0	0,0%
Düzye 6	17	0	0	0	0	0	0,0%
Overall Percentage	100,0%	0,0%	0,0%	0,0%	0,0%	0,0%	16,7%

Growing Method: CHAID

Dependent Variable: 6 Alt Grup

Classification

Observed	Predicted			Percent Correct
	Düşük düzey	Orta düzey	Üst düzey	
Düşük düzey	34	0	0	100,0%
Orta düzey	34	0	0	0,0%
Üst düzey	34	0	0	0,0%
Overall Percentage	100,0%	0,0%	0,0%	33,3%

Growing Method: CHAID

Dependent Variable: 3 Alt Grup

Classification

Observed	Predicted		Percent Correct
	Alt düzey	Üst düzey	
Alt düzey	51	0	100,0%
Üst düzey	51	0	0,0%
Overall Percentage	100,0%	0,0%	50,0%

Growing Method: CHAID

Dependent Variable: 2 Alt Grup

EK 28. Büyük örneklemede 6, 3 ve 2 alt gruba sınıflama yapmada ayırma analizine ait sonuçlar

Classification Results^a

		Predicted Group Membership						Total	
6 Alt Grup		Düzye 1	Düzye 2	Düzye 3	Düzye 4	Düzye 5	Düzye 6		
Original	Count	Düzye 1	15424	5305	3214	1100	480	769	26292
		Düzye 2	12778	7696	6844	2879	1238	1458	32893
		Düzye 3	6433	5844	7784	5072	2568	2723	30424
		Düzye 4	2307	2267	4471	4562	3266	4044	20917
		Düzye 5	632	639	1492	2136	2246	3960	11105
		Düzye 6	142	138	318	505	743	2649	4495
%		Düzye 1	58,7	20,2	12,2	4,2	1,8	2,9	100,0
		Düzye 2	38,8	23,4	20,8	8,8	3,8	4,4	100,0
		Düzye 3	21,1	19,2	25,6	16,7	8,4	9,0	100,0
		Düzye 4	11,0	10,8	21,4	21,8	15,6	19,3	100,0
		Düzye 5	5,7	5,8	13,4	19,2	20,2	35,7	100,0
		Düzye 6	3,2	3,1	7,1	11,2	16,5	58,9	100,0

a. 32,0% of original grouped cases correctly classified.

Classification Results^a

		Predicted Group Membership			Total	
3 Alt Grup		Düşük düzey	Orta düzey	Üst düzey		
Original	Count	Düşük düzey	41243	13634	4308	59185
		Orta düzey	16852	20868	13621	51341
		Üst düzey	1546	4083	9971	15600
%		Düşük düzey	69,7	23,0	7,3	100,0
		Orta düzey	32,8	40,6	26,5	100,0
		Üst düzey	9,9	26,2	63,9	100,0

a. 57,2% of original grouped cases correctly classified.

Classification Results^a

		Predicted Group Membership		Total	
2 Alt Grup		Alt düzey	Üst düzey		
Original	Count	Alt düzey	68857	20752	89609
		Üst düzey	11204	25313	36517
%		Alt düzey	76,8	23,2	100,0
		Üst düzey	30,7	69,3	100,0

a. 74,7% of original grouped cases correctly classified.

EK 29. Orta büyüklükteki örnekleme 6, 3 ve 2 alt gruba sınıflama yapmada ayırma analizine ait sonuçlar

Classification Results^a

		Predicted Group Membership						Total	
6 Alt Grup		Düzey 1	Düzey 2	Düzey 3	Düzey 4	Düzey 5	Düzey 6		
Original	Count	Düzey 1	588	217	118	48	17	24	1012
		Düzey 2	391	247	184	114	47	45	1028
		Düzey 3	215	197	253	171	90	89	1015
		Düzey 4	103	106	166	259	175	188	997
		Düzey 5	64	66	135	178	215	352	1010
		Düzey 6	34	37	84	135	181	653	1124
%		Düzey 1	58,1	21,4	11,7	4,7	1,7	2,4	100,0
		Düzey 2	38,0	24,0	17,9	11,1	4,6	4,4	100,0
		Düzey 3	21,2	19,4	24,9	16,8	8,9	8,8	100,0
		Düzey 4	10,3	10,6	16,6	26,0	17,6	18,9	100,0
		Düzey 5	6,3	6,5	13,4	17,6	21,3	34,9	100,0
		Düzey 6	3,0	3,3	7,5	12,0	16,1	58,1	100,0

a. 35,8% of original grouped cases correctly classified.

Classification Results^a

		Predicted Group Membership			Total	
3 Alt Grup		Alt düzey	Orta düzey	Üst düzey		
Original	Count	Alt düzey	1447	469	124	2040
		Orta düzey	628	861	523	2012
		Üst düzey	194	532	1408	2134
%		Alt düzey	70,9	23,0	6,1	100,0
		Orta düzey	31,2	42,8	26,0	100,0
		Üst düzey	9,1	24,9	66,0	100,0

a. 60,1% of original grouped cases correctly classified.

Classification Results^a

		Predicted Group Membership		Total	
2 Alt Grup		Alt düzey	Üst düzey		
Original	Count	Alt düzey	2451	604	3055
		Üst düzey	838	2293	3131
%		Alt düzey	80,2	19,8	100,0
		Üst düzey	26,8	73,2	100,0

a. 76,7% of original grouped cases correctly classified.

EK 30. Küçük örneklemede 6, 3 ve 2 alt gruba sınıflama yapmada ayırma analizine ait sonuçlar

Classification Results^a

		Predicted Group Membership						Total	
6 Alt Grup		Düzye 1	Düzye 2	Düzye 3	Düzye 4	Düzye 5	Düzye 6		
Original	Count	Düzye 1	58	22	11	3	3	3	100
		Düzye 2	34	32	18	10	4	2	100
		Düzye 3	17	18	31	17	12	6	101
		Düzye 4	12	12	18	23	18	18	101
		Düzye 5	6	5	12	13	37	28	101
		Düzye 6	6	1	0	7	22	64	100
%		Düzye 1	58,0	22,0	11,0	3,0	3,0	3,0	100,0
		Düzye 2	34,0	32,0	18,0	10,0	4,0	2,0	100,0
		Düzye 3	16,8	17,8	30,7	16,8	11,9	5,9	100,0
		Düzye 4	11,9	11,9	17,8	22,8	17,8	17,8	100,0
		Düzye 5	5,9	5,0	11,9	12,9	36,6	27,7	100,0
		Düzye 6	6,0	1,0	,0	7,0	22,0	64,0	100,0

a. 40,6% of original grouped cases correctly classified.

Classification Results^a

		Predicted Group Membership			Total	
3 Alt Grup		Düşük düzey	Orta düzey	Üst düzey		
Original	Count	Düşük düzey	144	40	16	200
		Orta düzey	49	99	54	202
		Üst düzey	17	39	145	201
%		Düşük düzey	72,0	20,0	8,0	100,0
		Orta düzey	24,3	49,0	26,7	100,0
		Üst düzey	8,5	19,4	72,1	100,0

a. 64,3% of original grouped cases correctly classified.

Classification Results^a

		Predicted Group Membership		Total	
2 Alt Grup		Alt düzey	Üst düzey		
Original	Count	Alt düzey	240	61	301
		Üst düzey	76	226	302
%		Alt düzey	79,7	20,3	100,0
		Üst düzey	25,2	74,8	100,0

a. 77,3% of original grouped cases correctly classified.

EK 31. Çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmış örnekleme 6, 3 ve 2 alt gruba sınıflama yapmada ayırma analizine ait sonuçlar

Classification Results^a

		6 Alt Grup	Predicted Group Membership						Total
			Düzye 1	Düzye 2	Düzye 3	Düzye 4	Düzye 5	Düzye 6	
Original	Count	Düzye 1	10	0	2	3	1	1	17
		Düzye 2	2	12	1	1	1	0	17
		Düzye 3	4	0	9	2	2	0	17
		Düzye 4	0	1	2	12	2	0	17
		Düzye 5	1	2	1	3	9	1	17
		Düzye 6	0	0	0	0	1	16	17
%		Düzye 1	58,8	,0	11,8	17,6	5,9	5,9	100,0
		Düzye 2	11,8	70,6	5,9	5,9	5,9	,0	100,0
		Düzye 3	23,5	,0	52,9	11,8	11,8	,0	100,0
		Düzye 4	,0	5,9	11,8	70,6	11,8	,0	100,0
		Düzye 5	5,9	11,8	5,9	17,6	52,9	5,9	100,0
		Düzye 6	,0	,0	,0	,0	5,9	94,1	100,0

a. 66,7% of original grouped cases correctly classified.

Classification Results^a

		3 Alt Grup	Predicted Group Membership			Total
			Düşük düzey	Orta düzey	Üst düzey	
Original	Count	Düşük düzey	25	5	4	34
		Orta düzey	7	25	2	34
		Üst düzey	3	5	26	34
%		Düşük düzey	73,5	14,7	11,8	100,0
		Orta düzey	20,6	73,5	5,9	100,0
		Üst düzey	8,8	14,7	76,5	100,0

a. 74,5% of original grouped cases correctly classified.

Classification Results^a

		2 Alt Grup	Predicted Group Membership		Total
			Alt düzey	Üst düzey	
Original	Count	Alt düzey	42	9	51
		Üst düzey	9	42	51
%		Alt düzey	82,4	17,6	100,0
		Üst düzey	17,6	82,4	100,0

a. 82,4% of original grouped cases correctly classified.

EK 32. Çok küçük ve varyans-kovaryans matrislerinde homojenliği sağlanmamış örnekleme 6, 3 ve 2 alt gruba sınıflama yapmada ayırma analizine ait sonuçlar

Classification Results^a

		6 Alt Grup	Predicted Group Membership						Total
			Düzye 1	Düzye 2	Düzye 3	Düzye 4	Düzye 5	Düzye 6	
Original	Count	Düzye 1	11	0	4	1	0	1	17
		Düzye 2	1	4	4	2	6	0	17
		Düzye 3	3	1	9	1	1	2	17
		Düzye 4	1	1	0	12	0	3	17
		Düzye 5	1	2	0	2	9	3	17
		Düzye 6	1	1	0	1	3	11	17
%		Düzye 1	64,7	,0	23,5	5,9	,0	5,9	100,0
		Düzye 2	5,9	23,5	23,5	11,8	35,3	,0	100,0
		Düzye 3	17,6	5,9	52,9	5,9	5,9	11,8	100,0
		Düzye 4	5,9	5,9	,0	70,6	,0	17,6	100,0
		Düzye 5	5,9	11,8	,0	11,8	52,9	17,6	100,0
		Düzye 6	5,9	5,9	,0	5,9	17,6	64,7	100,0

a. 54,9% of original grouped cases correctly classified.

Classification Results^a

		3 Alt Grup	Predicted Group Membership			Total
			Düşük düzey	Orta düzey	Üst düzey	
Original	Count	Düşük düzey	22	7	5	34
		Orta düzey	10	15	9	34
		Üst düzey	7	5	22	34
%		Düşük düzey	64,7	20,6	14,7	100,0
		Orta düzey	29,4	44,1	26,5	100,0
		Üst düzey	20,6	14,7	64,7	100,0

a. 57,8% of original grouped cases correctly classified.

Classification Results^a

		2 Alt Grup	Predicted Group Membership		Total
			Alt düzey	Üst düzey	
Original	Count	Alt düzey	39	12	51
		Üst düzey	13	38	51
%		Alt düzey	76,5	23,5	100,0
		Üst düzey	25,5	74,5	100,0

a. 75,5% of original grouped cases correctly classified.

EK 33. Etik Komisyon İzin Muafiyet Formu

Form: 40

Tez Çalışması Etik Komisyon İzin Muafiyeti Formu

06 / 03 / 2017

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

Tez Başlığı / Konusu: YAPAY SINIR AĞI, KARAR AĞAÇLARI VE AYIRMA ANALİZİ YÖNTEMLERİ İLE PISA 2012 MATEMATİK BAŞARILARININ SINIFLANDIRILMA PERFORMANSLARININ KARŞILAŞTIRILMASI

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 Komisyondan/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.



Emre TOPRAK
(Öğrencinin Adı Soyadı, İmza)

Öğrenci Bilgileri

Adı Soyadı	Emre TOPRAK
Öğrenci No	N11142189
Anabilim Dalı	Eğitim Bilimleri
Programı	Eğitimde Ölçme ve Değerlendirme
Statüsü	<input type="checkbox"/> Yüksek Lisans <input checked="" type="checkbox"/> Doktora <input type="checkbox"/> Bütünleşik Dr.

Danışman Görüşü ve Onayı

"YAPAY SINIR AĞI, KARAR AĞAÇLARI VE AYIRMA ANALİZİ YÖNTEMLERİ İLE PISA 2012 MATEMATİK BAŞARILARININ SINIFLANDIRILMA PERFORMANSLARININ KARŞILAŞTIRILMASI" başlıklı tez çalışmasında OECD tarafından yapılan PISA uygulamasından alınan ve kamuoyuyla paylaşılan veriler kullanıldığı için etik izne gerek yoktur.


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

ÖZGEÇMİŞ

Kişisel Bilgiler

<i>Adı Soyadı</i>	Emre TOPRAK
<i>Doğum Yeri</i>	Ankara
<i>Doğum Tarihi</i>	25.02.1984

Eğitim Durumu

<i>Lise</i>	Ayrancı Lisesi, Ankara	2002
<i>Lisans</i>	Hacettepe Üniversitesi, Ankara	2007
<i>Yüksek Lisans</i>	Erciyes Üniversitesi, Kayseri	2011
<i>Yabancı Dil</i>	İngilizce: Okuma (İyi), Yazma (İyi), Konuşma (Orta)	

İş Deneyimi

<i>Projeler</i>	"Üniversite Öğrencilerinin Mesleki Değer Algılarının Sıralama Yargılarıyla Ölçeklenmesi ", BAP Araştırma Projesi, SBA-2015-5934, Araştırmacı.	2015-2016
<i>Çalıştığı Kurumlar</i>	Erciyes Üniversitesi Eğitim Fakültesi	2007-Halen

İletişim

<i>e-Posta Adresi</i>	etoprak@erciyes.edu.tr emretoprak@gmail.com
-----------------------	--

<i>Jüri Tarihi</i>	13.02.2017
--------------------	------------