

T.C.  
VAN YÜZÜNCÜ YIL ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ  
İSTATİSTİK ANABİLİM DALI

**ÖĞRENCİLERİN MATEMATİK BAŞARILARINI ETKİLEYEN  
FAKTÖRLERİN RASTGELE ORMAN, ÇOK KATMANLI ALGILAYICI VE  
RADYAL TABANLI FONKSİYON YAPAY SİNİR AĞLARI YÖNTEMLERİ  
İLE TAHMİNLEME YETENEĞİ AÇISINDAN KARŞILAŞTIRILMASI:  
TÜRKİYE ÖRNEĞİ**

DOKTORA TEZİ

HAZIRLAYAN: Özlem BEZEK GÜRE  
1. DANIŞMAN: Prof. Dr. Fevzi ERDOĞAN  
2. DANIŞMAN: Prof. Dr. Murat KAYRI

VAN-2019



T.C.  
VAN YÜZÜNCÜ YIL ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ  
İSTATİSTİK ANABİLİM DALI

**ÖĞRENCİLERİN MATEMATİK BAŞARILARINI ETKİLEYEN  
FAKTÖRLERİN RASTGELE ORMAN, ÇOK KATMANLI ALGILAYICI VE  
RADYAL TABANLI FONKSİYON YAPAY SİNİR AĞLARI YÖNTEMLERİ  
İLE TAHMİNLEME YETENEĞİ AÇISINDAN KARŞILAŞTIRILMASI:  
TÜRKİYE ÖRNEĞİ**

DOKTORA TEZİ

HAZIRLAYAN: Özlem BEZEK GÜRE

VAN-2019



## KABUL VE ONAY SAYFASI

İstatistik Anabilim Dalı'nda Prof. Dr. Fevzi ERDOĞAN-Prof. Dr. Murat KAYRI danışmanlığında, Özlem BEZEK GÜRE tarafından sunulan "ÖĞRENCİLERİN MATEMATİK BAŞARILARINI ETKİLEYEN FAKTÖRLERİN RASTGELE ORMAN, ÇOK KATMANLI ALGILAYICI VE RADYAL TABANLI FONKSİYON YAPAY SİNİR AĞLARI YÖNTEMLERİ İLE TAHMİNLEME YETENEĞİ AÇISINDAN KARŞILAŞTIRILMASI: Türkiye Örneği" isimli bu çalışma Lisansüstü Eğitim ve Öğretim Yönetmeliği'nin ilgili hükümleri gereğince 27.06.2015 tarihinde aşağıdaki jüri tarafından oy birliği / oy çokluğu ile başarılı bulunmuş ve ...Doktora... tezi olarak kabul edilmiştir.

Başkan: Prof. Dr. Sinan ÇALIK.

İmza: 

Üye: Prof.Dr. Fevzi ERDOĞAN

İmza: 

Üye: Doç.Dr. Hamit MİRİTAGİOĞLU

İmza: 

Üye: Dr. Öğr.Üyesi Sanem ŞEHRİBANOĞLU

İmza: 

Üye: Dr. Öğr.Üyesi Suna AKKOL

İmza: 

Fen Bilimleri Enstitüsü Yönetim Kurulu'nun 12.07.2019 tarih ve 209/88-1 sayılı kararı ile onaylanmıştır.

  
Doç.Dr. Serhan KARACA  
Enstitü Müdürü  
Enstitü Müdürü  
Prof.  
Enstitü



## TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atf yapıldığını bildiririm.

(İmza)

Özlem BEZEK GÜRE







## ÖZET

### ÖĞRENCİLERİN MATEMATİK BAŞARILARINI ETKİLEYEN FAKTÖRLERİN RASTGELE ORMAN, ÇOK KATMANLI ALGILAYICI VE RADYAL TABANLI FONKSİYON YAPAY SINIR AĞLARI YÖNTEMLERİ İLE TAHMİNLEME YETENEĞİ AÇISINDAN KARŞILAŞTIRILMASI: TÜRKİYE ÖRNEĞİ

BEZEK GÜRE, Özlem  
Doktora Tezi, İstatistik Anabilim Dalı  
1.Danışmanı: Prof. Dr. Fevzi ERDOĞAN  
2.Danışmanı: Prof. Dr. Murat KAYRI  
Haziran 2019, 137 sayfa

Bu tez çalışmasında, PISA 2015 verilerine göre Türkiye'deki öğrencilerin matematik başarılarını etkileyen faktörleri belirlemek için, Karar Ağaçları ailesinden Rastgele Orman ve Yapay Sinir Ağları ailesinden Çok Katmanlı Algılayıcı Yapay Sinir Ağları (MLPANN) ve Radyal Tabanlı Fonksiyon Yapay Sinir Ağları (RBFANN) yöntemleri uygulanmıştır. PISA 2015 sınavına katılan 2165'i (%49) erkek ve 2257'si (%51) kız olmak üzere, toplam 4422 öğrenciden toplanan bilgiler kullanılmıştır. PISA 2015 sınavına giren öğrencilerin matematik testinden almış oldukları puanlar bağımlı değişken; bağımlı değişken ile kuramsal olarak ilişkisi olduğu düşünülen 25 adet değişken ise bağımsız değişken olarak modele dâhil edilmiştir.

Bu çalışmada, üç yöntem, tahminleme yeteneği açısından karşılaştırılmış, model test edildiğinde; birçok performans göstergeleri açısından, Rastgele Orman yönteminin diğer iki yönteme göre daha düşük hatalar ile modeli tahminlediği görülmüştür. Bu nedenle; Rastgele Orman yönteminin, performans ölçütleri açısından daha kararlı, tutarlı olduğu ve tahminleme yeteneğinin az da olsa MLPANN ve RBFANN'ye göre daha yüksek düzeyde olduğu söylenebilir. Ayrıca; MLPANN ve RBFANN yöntemleri karşılaştırıldığında, MLPANN'nin RBFANN'ye göre daha iyi performans gösterdiği, diğer taraftan; RBFANN ve RF yöntemleri karşılaştırıldığında ise, RF yönteminin daha başarılı olduğu sonucuna varılmıştır.

**Anahtar kelimeler:** Matematik okuryazarlığı, PISA, Rastgele Orman, Yapay Sinir Ağları.



## ABSTRACT

### COMPARISON OF MATHEMATICS ACHIEVEMENT OF STUDENTS WITH RANDOM FOREST, MULTI-LAYER BASED SENSORS AND RADIAL FUNCTION NEURAL NETWORK METHODS IN TERMS OF FORECASTING ABILITY: TURKEY EXAMPLE

BEZEK GÜRE, Özlem

Ph.D. Thesis, Department of Statistics

1.Supervisor : Prof. Dr. Fevzi ERDOĞAN

2.Supervisor : Prof. Dr. Murat KAYRI

June 2019, 137 pages

In this dissertation study, in order to determine the factors affecting the Mathematics literacy of students participating in PISA 2015 test in Turkey, the methods of Random Forest from Decision Trees and Multilayer Perceptron Artificial Neural Networks (MLPANN) and Radial Basis Function Artificial Neural Networks (RBFANN) from Artificial Neural Networks (ANN) were implemented according to PISA 2015 data. The information, which was collected from a total of 4422 students, 2165 (49%) of whom were boys and 2257 (51%) of whom were girls having participated in PISA 2015 test, was used. The scores, which the students, having gone in for PISA 2015 test, got from mathematics test were included in the model as dependent variables; and 25 variables, which were thought to have connection with dependent variables institutionally, were included in the model as independent variables.

In the study, three methods were compared in terms of predictability; and when the model was tested, it was observed that Random Forest method estimated the model with fewer errors in terms of a number of performance indicators compared to the other methods. Therefore, it is possible to say that Random Forest is more consistent in terms of performance criteria; and its estimating ability is a little higher compared to MLPANN and RBFANN. Moreover, when MLPANN and RBFANN methods are compared, it is concluded that MLPANN exhibited a better performance compared to RBFANN; on the other hand, when MLPANN and RF were compared, it was found out that RF was more successful.

**Keywords:** Artificial Neural Networks, Mathematics literacy, PISA, Random Forest



## ÖN SÖZ

Doktora eğitimim boyunca, her türlü ilgi ve yardımlarını esirgemeyen değerli bilgilerini paylaşan saygıdeğer danışmanım Sayın Prof.Dr. Fevzi ERDOĞAN'a teşekkürü bir borç bilirim.

Tez çalışma sürecinin her aşamasında yol gösteren, destekleyen, değerli bilgilerinden faydalandığım, akademik yönü, çalışma azmi ve kişiliğiyle örnek aldığım saygıdeğer danışmanım Sayın Prof.Dr. Murat KAYRI'ye teşekkürü bir borç biliyor ve şükranlarımı sunuyorum.

Tez izleme komitesinde yer alan ve desteğini esirgemeyen değerli hocalarım Sayın Dr. Öğr. Üyesi Sanem ŞEHRİBANOĞLU ve Sayın Dr. Öğr. Üyesi Suna AKKOL'a teşekkürlerimi sunarım. Tez savunma jürisinde bulunan görüş ve önerileriyle teze katkıda bulunan değerli hocalarım Sayın. Prof.Dr. Sinan ÇALIK ve Doç.Dr. Hamit MİRTAĞIOĞLU'na teşekkürlerimi sunarım.

Doktora eğitimim boyunca desteğini esirgemeyen Prof.Dr. Abdulkadir LEVENT'e ve tez çalışmamda yardımlarını esirgemeyen Dr. Öğr. Üyesi İsmail KAYRI ile Öğr. Gör. Cemil MANAP'a çok teşekkür ederim. Özel yaşamımda ve çalışma hayatımda yanımda olan ve beni destekleyen arkadaşlarıma sonsuz teşekkürler...

Bugünlere gelmemde büyük paya sahip olan, bütün hayatım boyunca her daim yanımda olan çok kıymetli annem ve babam başta olmak üzere canım aileme yürekten teşekkür ederim.

Tez çalışmam süresince ve her zaman desteğiyle yanımda olan sabır ve hoşgörüsünü benden esirgemeyen değerli eşim Bayram GÜRE'ye ve varlıkları ile bana güç katan oğullarım Muhammed Zahir, Onur Eymen ve Ali Emir'e sonsuz teşekkürler. İyi ki varsınız...

2019  
Özlem BEZEK GÜRE



# İÇİNDEKİLER

	Sayfa
ÖZET.....	i
ABSTRACT.....	iii
ÖNSÖZ.....	v
İÇİNDEKİLER.....	vii
ÇİZELGELER LİSTESİ.....	xiii
ŞEKİLLER LİSTESİ.....	xv
SİMGELER VE KISALTMALAR .....	xvii
1.GİRİŞ.....	1
1.1. Tezin Amacı.....	2
1.2. Tezin Önemi .....	2
1.3. Hipotez.....	3
1.4. PISA Projesi (Programme for International Student Assessment) .....	3
1.4.1. Matematik okuryazarlığı.....	5
1.4.1.1. Matematik okuryazarlığının tanımı .....	6
1.4.2. Matematiksel süreçler ve temel matematiksel yetenekler .....	8
1.4.2.1. Matematiksel süreçler .....	8
1.4.2.2. Maddelerin matematiksel süreçle istenilen dağılımı.....	11
1.4.2.3. Matematiksel süreçlerin altında yatan temel matematiksel yetenekler.....	11
1.4.2.4. Matematik okuryazarlığının değerlendirilmesi için temel içerik konuları .....	16
1.4.2.5. Matematik okuryazarlığını değerlendirme.....	17
1.4.2.6. PISA 2015 matematik okuryazarlığı yeterli düzeylerine göre dağılımı .....	18
1.5. Veri Madenciliği .....	19
1.5.1. Karar ağaçları.....	19
1.5.1.1. Karar ağaçları oluşturma.....	21
1.5.1.2. Karar ağacı bölünme kuralları .....	22
1.5.1.2.1. Safsızlık tabanlı (impurity-based) ölçüt.....	22
1.5.1.2.2. Bilgi kazancı .....	22
1.5.1.2.3. Entropi .....	23

	Sayfa
1.5.1.2.4. Gini indeksi.....	23
1.5.1.2.5. Kazanç oranı (Gain ratio).....	24
1.5.1.3. Budama yöntemleri.....	24
1.5.1.3.1. Maliyet karmaşıklığı budaması (Cost-complexity pruning).....	24
1.5.1.3.2. Azaltılmış hata budaması (Reduced error pruning).....	26
1.5.1.3.3. Kötümser hata budaması (Pessimistic error pruning)...	27
1.5.1.3.4. En küçük hata budaması (Minimum-error pruning).....	28
1.5.1.3.5. Kritik değer budaması (Critical value pruning).....	28
1.5.1.3.6. Hataya dayalı budama (Error-based pruning).....	29
1.5.1.3.7. Optimal budama (Optimal pruning).....	29
1.5.1.4. Sınıflandırma ve regresyon karar ağaçları.....	29
1.5.1.4.1. ID3 algoritması.....	29
1.5.1.4.2. C4.5 algoritması.....	30
1.5.1.4.3. CART (Classification and regression tree) algoritması	30
1.5.1.4.4. CHAID (Chisquare-automatic-interaction-detection) algoritması.....	31
1.5.1.4.5. Exhaustive CHAID algoritması.....	31
1.5.1.4.6. QUEST (Quick-unbiased-efficient statistical tree) algoritması.....	32
1.5.1.5. Ağaç tabanlı topluluk yöntemleri.....	32
1.5.1.5.1. Boosting (hızlandırma) yöntemi.....	33
1.5.1.5.1.1. Sınıflandırma problemleri için boosting algoritması.....	34
1.5.1.5.1.2. Sınıflandırma problemleri için adaboost algoritması (Adaboost algorithm).....	35
1.5.1.5.1.3. Regresyon problemleri için boosting algoritması (Adaboost R algorithm).....	36
1.5.1.5.2. Bagging (torbalama) yöntemi.....	37
1.5.1.5.2.1. Bagging algoritması.....	38
1.5.2. Yapay sinir ağları.....	39
1.5.2.1. Biyolojik sinir sistemi.....	40
1.5.2.2. Sinir hücresi (Neuron).....	41



1.5.2.3. Yapay sinir hücresi (Artificial neuron).....	42
1.5.2.4. Yapay sinir ağları mimarisi (Artificial neural networks architecture) .....	42
1.5.2.5. Yapay sinir ağlarının modeli (Model of artificial neural networks) .....	43
1.5.2.6. Yapay sinir ağlarının sınıflandırılması (Classification of artificial neural networks) .....	44
1.5.2.6.1. YSA'ların ağ yapılarına göre sınıflandırılması (Classification of ANNs by network structures).....	44
1.5.2.6.1.1. İleri beslemeli ağlar (Feedforward neural networks) .....	45
1.5.2.6.1.2. Geri beslemeli ağlar (Back propogation networks) .....	45
1.5.2.6.1.3. Tekrarlayan yapay sinir ağları (Recurrent artificial neural networks).....	46
1.5.2.6.2. Öğrenme yöntemlerine göre sınıflandırılması .....	46
1.5.2.6.2.1. Gözetimli öğrenme (Supervised learning) 46	
1.5.2.6.2.2. Gözetimsiz öğrenme (Unsupervised learning).....	47
1.5.2.6.2.3. Takviyeli öğrenme (Reinforcement learning).....	47
1.5.2.6.3. Öğrenme algoritmalarına göre sınıflandırılması.....	48
1.5.2.6.3.1. Geri yayılım algoritması (Backpropagation algorithm).....	48
1.5.2.6.3.2. İleri beslemeli algoritma (Feed-forward algorithm).....	49
1.5.2.6.3.3. Delta-bar-delta algoritması (Delta-bar-delta algorithm).....	49
1.5.2.6.3.4. Genişletilmiş delta-bar-delta algoritması (Extended-delta-bar-delta algorithm).....	50
1.5.2.6.3.5. Hızlı yayılım algoritması (QuickProp algorithm).....	51
1.5.2.6.3.6. Genetik algoritmalar (Genetic algorithms)53	

	Sayfa
2.KAYNAK BİLDİRİŞLERİ .....	55
2.1. Pisa ile İlgili Kaynak Bildirişleri .....	55
2.2. Yöntemle ile İlgili Kaynak Bildirişleri .....	59
3.MATERYAL VE YÖNTEM.....	63
3.1. Materyal .....	63
3.1.1. Araştırma modeli .....	63
3.1.2. Evren ve örneklem .....	63
3.1.3. Veri seti.....	63
3.1.4. Verilerin tanımlanması .....	64
3.1.4.1. Bağımlı ve bağımsız değişkenler .....	64
3.1.4.2. Ölçme araçları.....	67
3.1.4.3. Performans ölçütleri.....	68
3.2. Yöntem.....	69
3.2.1. Rastgele orman yöntemi (Random Forest) .....	69
3.2.1.1. Rastgele orman yönteminin özellikleri .....	74
3.2.1.1.1. Değişken önem derecesi (Variance importance) .....	74
3.2.1.1.2. Örnekler arası yakınlık ölçüleri (Proximity measures) 76	
3.2.1.1.3. Kayıp gözlem kestirimi.....	77
3.2.1.1.4. Tutarlılık .....	78
3.2.1.1.5. Bootstrap örnekleme .....	79
3.2.1.2. Rastgele orman algoritmasının avantajları ve dezavantajları .....	79
3.2.2. Çok katmanlı algılayıcı yapay sinir ağları (Multilayer perceptron artificial neural network) .....	80
3.2.2.1. Algılayıcı Öğrenme Algoritması (Perceptron Learning Algorithm) .....	80
3.2.2.2. Geri yayılım algoritması ( Back propagation algorithm ).....	81
3.2.2.3. Çok katmanlı algılayıcı yapay sinir ağlarının yapısı (Architecture of multilayer perceptron artificial neural network).....	81
3.2.2.4. Çok katmanlı algılayıcı öğrenme algoritması (Multilayer perceptron learning algorithm) .....	83
3.2.2.5. Çok katmanlı algılayıcı yapay sinir ağlarının eğitimi (Training a multilayer perceptron).....	84

	Sayfa
3.2.3. Radyal tabanlı fonksiyon yapay sinir ağları (Radial basis function artificial neural networks) .....	85
3.2.3.1. Radyal tabanlı fonksiyon yapay sinir ağları .....	85
3.2.3.2. Radyal tabanlı fonksiyonlar (Radial basis functions) .....	85
3.2.3.3. Radyal tabanlı fonksiyon ağlarının yapısı (The structure of RBF network) .....	86
3.2.3.4. Radyal tabanlı fonksiyon ağlarının eğitimi (RBF network learning) .....	89
3.2.3.4.1. Öğrenme merkezleri (Learning RBF centers) .....	93
3.2.3.4.1.1. Eğitim setinden rastgele olarak RBFANN merkezlerinin seçimi (Selecting RBF centers randomly from training sets) .....	93
3.2.3.4.1.2. Ağırlıkları öğrenme (Learning the weights) .....	94
3.2.3.5. Geleneksel yapay sinir ağları ile radyal tabanlı yapay sinir ağlarının karşılaştırılması (Comparison between Traditional Neural Networks and Radial Basis Function Networks) .....	94
4.BULGULAR.....	97
4.1. PISA 2015 Verilerine İlişkin Uygulama.....	105
4.1.1. Veri setine rf yönteminin uygulanması.....	105
4.1.2. Veri setine mlpann yönteminin uygulanması .....	107
4.1.3. Veri setine rbfann yönteminin uygulanması .....	111
4.1.4.Üç yöntemin tahminleme performanslarının karşılaştırılması.....	115
5.TARTIŞMA VE SONUÇ .....	117
KAYNAKLAR .....	123
ÖZ GEÇMİŞ.....	137



## ÇİZELGELER LİSTESİ

Çizelge	Sayfa
Çizelge 1.1. Matematik öğelerinin işlem kategorisine göre istenen dağılımı.....	11
Çizelge 1.2. İçerik kategorisine göre matematik öğelerinin yüzdesi .....	15
Çizelge 1.3. PISA 2015 matematik okuryazarlığı yeterlik düzeylerine göre dağılımı... 18	
Çizelge 3.1. Araştırmada kullanılan ölçeklere ait anket soruları .....	66
Çizelge 4.1. Öğrencilerin sınıf değişkenine göre dağılımı .....	97
Çizelge 4.2. Öğrencilerin cinsiyet değişkenine göre dağılımı .....	97
Çizelge 4.3. Öğrencilerin anne eğitim düzeyi değişkenine göre dağılımı.....	97
Çizelge 4.4. Öğrencilerin baba eğitim düzeyi değişkenine göre dağılımı.....	98
Çizelge 4.5. Öğrencilerin “Evde çalışma masası var mı?”değişkenine göre dağılımı... 98	
Çizelge 4.6. Öğrencilerin “Evinizde kendi odanız var mı?” değişkenine göre dağılımı .....	98
Çizelge 4.7. Öğrencilerin “Evinizde sessiz çalışma yeriniz var mı?” değişkenine göre dağılımı .....	99
Çizelge 4.8. Öğrencilerin “Evinizde okul çalışmalarını için bilgisayar var mı?” değişkenine göre dağılımı .....	99
Çizelge 4.9. Öğrencilerin “Evinizde eğitim yazılımları var mı?” değişkenine göre dağılımı .....	99
Çizelge 4.10. Öğrencilerin “Evinizde internet bağlantınız var mı?” değişkenine göre dağılımı .....	100
Çizelge 4.11. Öğrencilerin “Evinizde okul çalışmalarını için yardımcı kitap var mı?” değişkenine göre dağılımı .....	100
Çizelge 4.12. Öğrencilerin “Evinizde teknik kitaplar var mı?” değişkenine göre dağılımı .....	100
Çizelge 4.13. Öğrencilerin “Okul hayatınızda hangi noktaya kadar ulaşmayı hedefliyorsunuz?” değişkenine göre dağılımı .....	101
Çizelge 4.14. Öğrencilerin “Öğretmenler beni diğer öğrencilerden daha az çağırırlar.” değişkenine göre dağılımı .....	101

<b>Çizelge</b>	<b>Sayfa</b>
Çizelge 4.15. Öğrencilerin “Öğretmenler beni diğer öğrencilerden daha az çağırırlar.” değişkenine göre dağılımı .....	102
Çizelge 4.16. Öğrencilerin “Öğretmenlerin beni daha az zeki olduğumu düşündükleri izlenimindeyim.” değişkenine göre dağılımı .....	102
Çizelge 4.17. Öğrencilerin “Öğretmenler beni diğer öğrencilere göre daha sert bir şekilde disipline eder.” değişkenine göre dağılım .....	103
Çizelge 4.18. Öğrencilerin “Öğretmenler benimle diğerlerinin önünde alay eder.” değişkenine göre dağılımı .....	103
Çizelge 4.19. Öğrencilerin “Öğretmenler başkalarının önünde bana hakaret eder.” değişkenine göre dağılımı .....	104
Çizelge 4.20. Öğrencilerin Haftalık ders sayısı değişkenine göre dağılımı .....	104
Çizelge 4.21. Öğrencilerin Türkçe başarı durumu değişkenine göre dağılımı .....	104
Çizelge 4.22. Öğrencilerin Haftalık matematik öğrenme zamanı değişkenine göre dağılımı .....	105
Çizelge 4.23. RF yöntemine göre doğru sınıflandırma oranı.....	105
Çizelge 4.24. MLPANN yöntemine göre doğru sınıflandırma oranı.....	107
Çizelge 4.25. MLPANN mimarisindeki bağımsız değişkenlerin önem düzeyleri ....	109
Çizelge 4.26. RBFANN yöntemine göre doğru sınıflandırma oranı .....	113
Çizelge 4.27. RBFANN mimarisindeki bağımsız değişkenlerin önem düzeyleri .....	114
Çizelge 4.28. MLPANN, RBFANN ve RF yöntemlerinin performansı .....	115

## ŞEKİLLER LİSTESİ

Şekil	Sayfa
Şekil 1.1. Uygulamadaki matematik okuryazarlığına ait model .....	7
Şekil 1.2. Biyolojik nöronun yapısı .....	41
Şekil 1.3. Bir kapalı devre kontrol sistemi .....	41
Şekil 1.4. Basit sinir ağı yapısı .....	42
Şekil 1.5. Yapay sinir ağlarının temel modeli .....	43
Şekil 1.6. Yapay sinir ağlarının sınıflandırılması .....	44
Şekil 1.7. İleri beslemeli ağlar .....	45
Şekil 1.8. Quickprop algoritmasının varsayımları .....	52
Şekil 3.1. RF yöntemine ait ağaç yapısı .....	70
Şekil 3.2. 10 sınıflı digit sınıflandırma için yakınlık grafiği .....	77
Şekil 3.3. Çok katmanlı bir algılayıcının düğüm yapısı ve aktivasyon .....	82
Şekil 3.4. Çok katmanlı bir algılayıcı yapay sinir ağının temel yapısı .....	82
Şekil 3.5. Radyal tabanlı ağların yapısı .....	86
Şekil 4.1. Rastgele Orman yöntemine göre değişkenlerin önem düzeyleri .....	106
Şekil 4.2. MLPANN yöntemine göre değişkenlerin normalize edilmiş önem düzeyleri .....	107
Şekil 4.3. MLPANN ağ mimarisine göre ağ yapısı .....	110
Şekil 4.4. RBFANN ağ mimarisine göre ağ yapısı .....	112
Şekil 4.5. RBFANN yöntemine göre değişkenlerin normalize edilmiş önem düzeyleri .....	113





## SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış bazı simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler	Açıklama
$\varphi(P)$	P dağılımına ait safsızlık ölçüsü
$a_i$	Ayrılık iyiliği
S	Eğitim setinin entropisi
c	Sınıf sayısı,
$p_i$	"i" sınıfına ait S'nin oranı
$T_o$	Budama yapılmadan önceki başlangıç karar ağacı
$T_k$	Son karar ağacı
$\varepsilon(T,S)$	S örnekleri üzerindeki (T) ağacının hata oranı
$ \text{leaves}(T) $	T ağacındaki yaprakların sayısı
$\text{pruned}(T,t)$	T ağacındaki t düğümünün yer değiştirilmesi ile elde edilen ağacı
$\acute{\varepsilon}(T,S)$	Binom için süreklilik düzeltmesi
l	Olasılık hata oranı tahmini
$P_{\text{apr}}$	$c_i$ değerini alan y'nin a-önsel olasılığı
$\iota$	a-önsel olasılığına verilen ağırlığı
$\mathcal{A}$	Zayıf öğrenme algoritması
T	Tamsayı ve iterasyonların özel sayısı
$\hat{g}^*(\cdot)$	Bootstrap tahmincisi
$\hat{g}_{\text{Bag}}(\cdot)$	Bagging tahmincisi
p	j,j sınıfının göreceli frekansı
$p(j/t)$	t düğümündeki j sınıfına ait nispi olasılığı
m	Değişkenlerin sayısı

$N$	Geliştirilecek ağaçların sayısı
$\theta_K$	Rastgele vektör
$\bar{r}_n$	Rastgele temelli regresyon ağaçlarından meydana gelen tahminciler topluluğu
<b>Simgeler</b>	<b>Açıklama</b>
$\Theta$	Rassal değişken
$E_\Theta$	Koşullu olarak $X$ ve $D_n$ veri seti üzerindeki rastgele parametreye ilişkin beklenti
$P_{n,t}$	$t$ düğümüne düşen gözlemlerin bölümü
$\{\mathbf{T}_\ell\}_{1 \leq \ell \leq M}$	Ormandaki ağaçlar topluluğu
$\mathbf{j}_{n,t}^*, \mathbf{z}_{n,t}^*$	$t$ düğümündeki deneysel kriterleri
$D_{\ell,n}, \ell$	Ağacın out-of bag verileri
$m_n(\cdot, \Theta_\ell)$	$\ell$ . ağacın tahminleri
$\check{\varphi}\mathcal{L}, \theta_m$	$\varphi\mathcal{L}, \theta_m$ terminal düğümlerinin kümesi
$\Delta w$	Ağırlık değişimleri
$\eta$	Öğrenme katsayısı
$\alpha$	Momentum katsayısı
$d_i$	Nörondan vermesi istenilen değer
$y_i$	Çıkış nöronundaki $i$ .ninci nörona ait çıkış terimi
$e_i$	$i$ .ninci nörona ait hata terimi
$E$	Uygunluk fonksiyonu
$w$	Ağırlık değerleri
$\alpha(\mathbf{k})$	Öğrenme katsayısı
$\delta(\mathbf{k})$	Ağırlık değişimlerinin eğim bileşeni
$\bar{\delta}(\mathbf{k})$	Ağırlıklı ortalama
$\theta$	Konveks ağırlık vektörü
$\kappa$	Sürekli öğrenme katsayısı artırma faktörü
$\varphi$	Sürekli öğrenme katsayısı küçültme faktörü
$\mu(\mathbf{k})$	Momentum katsayıları
$\kappa_a$	Sürekli öğrenme katsayısı ölçek faktörü
$\text{Exp}$	Üstel fonksiyon
$\varphi_\alpha$	Sürekli öğrenme katsayısı küçültme faktörü

$\gamma_\alpha$	Sürekli öğrenme üstel katsayı faktörü
$\kappa_\mu$	Sürekli öğrenme katsayısı ölçek faktörü;
$\varphi_\mu$	Sürekli momentum katsayısı küçültme faktörü
$\gamma_\mu$	Sürekli momentum katsayısı üstel faktörü
<b>Simgeler</b>	<b>Açıklama</b>
$E(t)$	t.ninci yinelemedeki sistem hatası
$\Delta\omega_{ij}(t)$	t.ninci yinelemedeki bir ağdaki, i.ninci ve j.ninci düğümlerdeki bağlantıların ağırlık değişimleri
$\phi$	Maksimum büyüme faktörü
$w_{ij}(t)$	t zamanındaki i.ninci düğümünden j.ninci düğüme kadar ki ağırlıkları
$\eta$	Kazancı
$\delta_{pj}$	j düğümündeki p olayı için, hata terimi
$R^2$	Belirlilik katsayısı
$\theta$	Ayarlanabilir sapma
$\omega_i$	i.ninci merkezin sinaptik ağırlığı
$\phi_i(x)$	Radyal fonksiyon
$k$	Gizli düğümlerin toplam sayısı
$\mu_i$	i.ninci düğümün merkez genişliği
$\sigma_i$	i.ninci düğümün yayılma genişliği
$E_S(F)$	Normal standart hata terimi
$E_R(F)$	Yaklaşık fonksiyonunun karmaşıklığını kısıtlayan terim
$D$	Diferansiyel operatörü
$\lambda$	Düzenlenen ağın parametresi
$G(x, x_i)$	Gaussian fonksiyonu
$\omega_i$	Ağırlık değeri
$\sigma_i$	Ağın genişliği
$\mu_i$	Ağın merkezi
$h$	Merkezlerin sayısı
$p_c$	Çaprazlama olasılığı

$p_m$	Mutasyon olasılığı
$d$	Seçilen merkezler arasındaki maksimum uzaklıkları
$E_{dist}$	Öklit uzaklığı
$\Phi$	Transformasyon matrisi
$Y$	Çıktı vektörü
<b>Kısaltmalar</b>	<b>Açıklama</b>
<b>BP</b>	Backpropagation Algorithm (Geri yayılım algoritması)
<b>CART</b>	Classification and Regression Tree (Sınıflandırma ve regresyon ağacı)
<b>CF</b>	Certainty Factor (Belirlilik faktörü)
<b>CHAID</b>	Chisquare-Automatic-Interaction-Detection (Kikare otomatik etkileşim çıkarma)
<b>CNS</b>	Central Nervous System (Merkezi sinir sistemi)
<b>CT</b>	Classification tree (Sınıflandırma Ağacı)
<b>DBD</b>	Delta-Bar-Delta algorithm (Delta-Bar-Delta algoritması)
<b>EDBD</b>	Extended-Delta-Bar-Delta algorithm (Genişletilmiş Delta-Bar-Delta algoritması)
<b>GA</b>	Genetic Algorithms (Genetik algoritmalar)
<b>ISCED</b>	International Standard Classification of Education (Uluslararası Eğitimin Standart Sınıflaması)
<b>LAD</b>	Least Absolute Deviation (En küçük mutlak sapma)
<b>LSD</b>	Least Squared Deviation (En küçük kareli sapma)
<b>MAE</b>	Mean Absolute Error (Ortalama mutlak hata)
<b>MDA</b>	Mean Decrease Accuracy (Doğruluk azalış ortalaması)
<b>MDI</b>	Mean Decrease Impurity (Safsızlık azalış ortalaması)
<b>MLPANN</b>	Multilayer Perceptron Artificial Neural Networks (Çok katmanlı algılayıcı yapay sinir ağları)

<b>OOB</b>	Out-Of-Bag (Test veri seti)
<b>PIRLS</b>	Progress in International Reading Literacy Study
<b>PISA</b>	The Programme for International Student Assessment (Uluslararası Öğrenci Değerlendirme Programı)

## **Kısaltmalar**

## **Açıklama**

<b>PNS</b>	Peripheral Nervous System (Çevresel Sinir Sistemi)
<b>QUEST</b>	Quick-Unbiased-Efficient Statistical Tree (Hızlı-Yansız-Etkili-İstatistik Ağacı)
<b>RAE</b>	Relative Absolute Error (Bağıl mutlak hata)
<b>RBF</b>	Radial Basis Function (Radyal Tabanlı Fonksiyon)
<b>RBFANN</b>	Radial Basis Function Artificial Neural Networks (Radyal tabanlı fonksiyon yapay sinir ağları)
<b>RF</b>	Random Forest (Rastgele Orman)
<b>RMSE</b>	Root Mean Square Error (Hata kareler ortalamasının kökü)
<b>RRSE</b>	Relative Root Square Error (Bağıl karesel hatanın kökü)
<b>RT</b>	Regression Tree (Regresyon Ağacı)
<b>TIMMS</b>	Trends in International Mathematics and Science Study (Uluslararası Matematik ve Fen Eğilimleri Araştırması)
<b>VIF</b>	Variance Inflation Factor (Varyans artış faktörü)
<b>YSA</b>	Yapay Sinir Ağları





## 1. GİRİŞ

Toplumların ekonomik, sosyal ve kültürel alanda gelişimlerini doğrudan etkileyen en önemli unsur eğitimidir. Eğitim; yaşam boyu devam eden bir süreçtir ve toplumun ihtiyaçlarına cevap vermek amacıyla, sürekli kendini yenilemek zorundadır. Toplumların gelişmesi, nitelikli insan yetiştirmekle mümkündür. Bilim ve teknolojiyle donanmış, evrensel değerlere sahip çıkan, nitelikli insan yetiştirmek, ancak nitelikli eğitimle mümkündür (Gündoğan, 2003; Gözübüyük-Tamer, 2013).

Gelişen ve küreselleşen dünyada, teknolojik gelişmelerin hızla ilerlemesiyle birlikte, bireylerin eğitimi önem arz etmektedir. Eğitim, yıllar boyunca tüm toplumlarda her zaman önemini korumaya devam ettiği gibi farklı bilim alanlarında çalışan bireylerin, birbirleriyle bilgi alışverişi yaparak kendilerini geliştirme fırsatını doğurmuştur (Soytürk, 2011; Aygüner, 2016).

Bir ülkenin vermiş olduğu eğitimin, nitelik ve düzeyinin ölçülebilmesi için uluslararası düzeyde yapılan sınavlar önem arz etmektedir (Azapağası İlbağı ve Akgün, 2012). Ulusal ve uluslararası düzeydeki konumunu belirlemek ve eksikliklerini görebilmek amacıyla Uluslararası Öğrenci Değerlendirme Programı (PISA), Uluslararası Okuma Becerilerinde Gelişim Projesi (PIRLS) ile Uluslararası Matematik ve Fen Eğilimleri Araştırması (TIMSS) gibi uluslararası düzeyde yapılan geniş ölçekli sınavlara ülkemizde katılmaktadır (Akyüz ve Pala, 2010; Azapağası İlbağı ve Akgün, 2012; Türkan ve ark., 2015; MEB, 2016; Özaslan, 2017).

Ülkelerin uluslararası düzeyde yapılan sınavlara katılımı, kendi eğitim sistemlerinin içinde bulunduğu durumu görmelerine, geleceğe yönelik politikalar geliştirmelerine yardımcı olacak bilgiler sunmaktadır (Akyüz ve Pala, 2010; Azapağası İlbağı ve Akgün, 2012).

Alanyazın incelendiğinde; PISA verilerinden yararlanılarak öğrencilerin başarılarını etkileyen faktörlerin belirlendiği birçok çalışma bulunmaktadır (Akyüz ve Pala, 2010; Demir ve ark., 2010; Aydın ve ark., 2012; Gürsakal, 2012; Kamaliyah ve ark., 2013; Güzeller ve Akın, 2014; Karabay ve ark., 2015; Koğar, 2015; Aksu ve Güzeller, 2016; İnal ve Turabik, 2016; Aksu ve ark., 2017; İlgün Dibek ve Demirtaşlı, 2017). Bu çalışmalarda verilerin analizinde sıklıkla klasik istatistiksel yöntemler



kullanılmaktadır. Sözkonusu verilerin analizinde mevcut çalışmada kullanılan Çok Katmanlı Algılayıcı Yapay Sinir Ağlarının (MLPANN) kullanıldığı sınırlı sayıda çalışma bulunmaktayken (Tepehan, 2011; İnal ve Turabik, 2016; Benzer ve Benzer, 2017; Toprak; 2017), Radyal Tabanlı Fonksiyon Yapay sinir ağları (RBFANN) yönteminin kullanıldığı bir çalışmaya (Bezek Güre ve ark., 2019), diğer taraftan; Rastgele Orman yönteminin kullanıldığı birkaç çalışmaya rastlanmıştır (Saarela ve ark., 2016; Aksu, 2018; Aksu ve Doğan, 2018). Sözkonusu çalışmalarda, mevcut çalışmada kullanılan yöntemlerden sadece biri yer almaktadır. Bu çalışmanın alan yazında yer alan araştırmalardan farkı, sözkonusu verilerin analizinde Çok Katmanlı Algılayıcı Yapay Sinir Ağları, Radyal Tabanlı Fonksiyon Yapay Sinir Ağları ve Rastgele Orman yönteminin birlikte kullanılmasıdır.

### **1.1. Tezin Amacı**

Bu çalışmanın amacı, Türkiye'deki 15 yaş grubu öğrencilerin matematik okuryazarlığını etkileyen faktörleri veri madenciliği yöntemleri ile incelemektir. Buradaki amaç sadece mevcut durumu ortaya koymak değil, aynı zamanda matematik okuryazarlığını etkileyen önemli faktörleri tespit edip bu konu ile ilgili eğitim politikaları ve eğitim müfredatlarının gelişimine ipuçları sunabilmektir. PISA 2015 verileri, veri madenciliği yöntemlerinden Yapay Sinir Ağları ailesinden Çok Katmanlı Algılayıcı Yapay Sinir Ağları ve Radyal Tabanlı Fonksiyon Yapay Sinir Ağları ile Karar Ağaçları ailesinden Rastgele Orman yöntemi ile incelenip neden-sonuç temelli bir modele varılacaktır. Bu yolla, neden-sonuç ilişkisini keşfetmede alternatif modeller karşılaştırılmıştır.

### **1.2. Tezin Önemi**

Ülkemiz; fen okuryazarlığı, matematik okuryazarlığı ve okuma becerileri alanlarında hem tüm ülkeler hem de OECD'ye üye ülkelerle karşılaştırıldığında ortalamanın çok altında kalmaktadır. Bu nedenle; matematik başarısını etkileyen faktörlerin belirlenip ülkemizin bu konudaki eksikliklerine dikkati çekmek önemli görülmüştür. Eğitim kalitesini yükseltmek için alınabilecek tedbirlerin belirlenmesine

yardımcı olabilmek umuduyla araştırmanın önemli olduğu düşünülmektedir. Bununla birlikte, birkaç veri madenciliği yönteminin performans açısından deneysel (ampirik) olarak karşılaştırılmasının araştırmacılara ışık tutacağı düşünülmektedir.

### 1.3. Hipotez

$H_0$ : Pisa 2015 verileri için Rastgele Orman, Çok Katmanlı Algılayıcı Yapay Sinir Ağları ve Radyal Tabanlı Fonksiyon Yapay Sinir Ağlarının tahminleme yetenekleri açısından aralarında anlamlı bir fark yoktur ( $p>0.05$ ).

$42H_1$ : Pisa 2015 verileri için Rastgele Orman, Çok Katmanlı Algılayıcı Yapay Sinir Ağları ve Radyal Tabanlı Fonksiyon Yapay Sinir Ağlarının tahminleme yetenekleri açısından aralarında anlamlı bir fark vardır ( $p<0.05$ ).

### 1.4. PISA Projesi (Programme for International Student Assessment)

Ekonomik İşbirliği ve Kalkınma Teşkilatı (Organisation for Economic Co-operation and Development - OECD) tarafından finanse edilmekte olan Uluslararası Öğrenci Değerlendirme Programı (Programme for International Student Assessment - PISA), örgün öğretime kayıtlı olan 15 yaş grubu öğrencilerin matematik okuryazarlığı, fen okuryazarlığı ve okuma becerilerinin yanı sıra; öğrencinin motivasyonu, kendisi ile ilgili düşünceleri, öğrenme biçimleri, okul ve aile ortamı ile ilgili bilgi toplamayı hedefleyen geniş ölçekli bir eğitim araştırmasıdır (Akyüz ve Pala, 2010; Kamaliyah ve ark., 2013). Bunun yanında PISA, öğrencilerin okul hayatında edinmiş oldukları temel bilgi ve becerilerin ne kadarını gerçek yaşamda kullanılabileceklerini ölçmeyi hedeflemektedir (Bauiter ve Rayou, 2007; Çelen ve ark., 2011; Aydın ve ark., 2012).

PISA, zorunlu eğitimin son basamağında olan 15 yaşındaki öğrencilerin, modern toplumlara tam katılımlarını sağlamaları için gerekli olan bilgi ve becerileri kazanma derecelerini değerlendirmektedir. PISA, öğrencilerin ülke dışında ve ülke içindeki farklı demografik özelliklere sahip alt gruplardaki bilgi ve becerilerin kazanımının izlenmesine yardımcı olmaktadır. Ayrıca; eğitim politikaları ve uygulamalarının iç yüzünü anlama imkânı sunmaktadır (Aydın ve ark., 2012; OECD, 2016a; Mutluer ve Büyükkıdık, 2017). PISA araştırması, araştırmaya katılan ülkelerin kendi eğitim

sistemlerini deęerlendirmesi yoluyla, eęitim sistemlerinin gl ve zayıf ynlerini grebilmelerine imkn saęlayan, lkeler arasında yarıřma amacı tařımayan bir arařtırmadır (Aydın ve ark., 2012; MEB, 2016).

PISA, ilk olarak 2000 yılında dzenlenmiř olup 3 yılda bir periyodik olarak yapılmaktadır. Sınava, OECD'ye ye lkeler ve dięer katılımcı lkeler katılmaktadır. Uluslararası dzeyde eęitim seviyemizi belirlemek amacıyla lkemiz, ilk defa 2003 yılında bu sınava katılmıştır (Akyz ve Pala, 2010; MEB, 2016).

PISA, temel olarak; ęrencilerin fen okuryazarlıęı, matematik okuryazarlıęı ve okuma yazma becerilerini lmeyi amalamaktadır. Arařtırmanın her periyodunda ayrı bir alana aęırlık verilmektedir. PISA'nın altıncı dngs olan 2015 uygulamasında, fen okuryazarlıęı aęırlıklı alan olarak belirlenmiřtir. Bu uygulamada; fen, matematik ve okuma yazma becerilerinin yanında, iřbirlięine dayalı problem zme de deęerlendirilmiřtir (OECD, 2016). PISA 2015 uygulamasında, fen okuryazarlıęı aęırlıklı alan olduęundan, matematik okuryazarlıęı alanında daha az sayıda soru (83 adet) kullanılmış ve daha az sayıda ęrenci bu soruları cevaplamıřtır (MEB, 2016).

PISA 2015'te anketlerin deęerlendirilmesi iin, kaęıt tabanlı deęerlendirmenin yanında, ilk defa bilgisayar tabanlı deęerlendirme kullanılmıştır. Kaęıt tabanlı deęerlendirme ya da bilgisayar tabanlı deęerlendirme lkelerin tercihine bırakılmıştır (MEB, 2016).

Yapılan arařtırmalar, Trkiye'deki matematik okuryazarlıęının dřk seviyede olduęunu gstermektedir (OECD, 2007; elen ve ark., 2011; Aydın ve ark., 2012; OECD, 2016). Matematik okuryazarlıęı alanında Trkiye ortalaması 420, OECD ortalaması 490 ve tm lkelerin ortalaması da 461'dir. Bilindięi zere, PISA'daki matematik okuryazarlıęı altı dzeyden oluřmaktadır. Birinci dzey en dřk seviyeyi, altıncı dzey ise en yksek seviyeyi gstermektedir (OECD, 2016). Ayrıca, birinci seviyenin altında kalanlar iin de bir dzey oluřturulmuřtur (below Level 1). PISA 2015 matematik okuryazarlıęı alanında ęrencilerin yeterlilik dzeylerine gre daęılımına bakıldıęında; birinci dzey ve altında, yani; alt yeterlik dzeyinde bulunan ęrenci oranları, Trkiye'de %51.3, OECD'ye ye lkelerde %23.4, tm lkelerde ise %35.8'dir. lkemizde alt yeterlilik dzeyinde bulunan ęrenci oranları; PISA 2012'de %42 iken, PISA 2015'te artarak %51,3 olarak grlmřtr. Ayrıca; PISA 2015'te, beřinci dzey ve stnde, yani; st yeterlilik dzeyinde yer alan ęrenci oranları,

Türkiye’de %2.01, OECD’ye üye ülkelerde %10.7, tüm ülkelerde ise %8.2’dir. Ülkemizde üst yeterlik düzeyinde bulunan öğrenci oranları; PISA 2012’de %5,9 iken, PISA 2015’te azalarak %2,01’ye gerilediği görülmektedir (MEB, 2016).

#### **1.4.1. Matematik okuryazarlığı**

Modern toplumlarda; matematiği anlamak, gençlerin yaşamları boyunca matematikle ilgili karşılaşacakları zorlukları aşmaları açısından önem arz etmektedir. Günümüzde; mesleki alanda karşılaşılan problemlerin büyümesiyle birlikte, sorunları tam olarak anlamadan önce, matematik, matematiksel akıl yürütme ve matematiksel araçların çok iyi düzeyde anlaşılması gerekir. Matematik; gençlerin yaşamları boyunca kişisel, mesleki, toplumsal ve bilimsel açıdan sorunlar ve zorluklarla karşılaşabileceklerinden dolayı önemlidir (Türkan ve ark., 2015; OECD, 2016). Teknolojik gelişmelere paralel bir şekilde, matematiğin de geleneksel bakış açısından farklı olarak, model kurmaya ve kuramdan uygulamaya yönelik bir matematiksel okuryazarlık anlayışının oluşması önem kazanmaktadır (Uysal ve Yenilmez, 2011).

Matematik okuryazarlığı; gençlerin karşılaşacakları problemleri anlamlı bir şekilde çözmeleri ve önemli konuları anlamaları için, matematik uygulamalarında yeterli düzeyde hazır olma derecelerini belirlemesi açısından önemlidir. Ayrıca; 15 yaşındaki öğrencilerin değerlendirilmesi yoluyla, gençlerin daha sonraki hayatlarında, matematikle ilgili karşılaşacakları çeşitli durumlara nasıl yanıt verebilecekleri konusunda erken bir uyarı sağlamaktadır (OECD, 2016).

PISA 2015 matematik çerçevesi, birkaç ana bölüme ayrılmıştır:

Birinci bölüm, “Matematiksel Okuryazarlığın Tanımlanması” adlı bölümdür. Burada; matematik okuryazarlık yapısının resmi tanımı dâhil olmak üzere, PISA matematik değerlendirmesinin teorik temelleri açıklanmaktadır.

İkinci bölüm, “Matematik Alanını Organize Etme” başlıklı üç bölümden oluşmaktadır. Bunlar;

- a) Matematiksel süreçler ve bu süreçlerin altında yatan temel matematiksel yetenekler,
- b) PISA 2015 çerçevesinde matematiksel içerik bilgisinin nasıl düzenlendiği ve 15 yaşındaki öğrencilerin değerlendirilmesi ile ilgili içerik bilgisi,
- c) Öğrencilerin matematiksel zorluklarla karşılaştıkları durumlar (OECD, 2016).

Üçüncü bölüm ise, “Matematiksel Okuryazarlığın Değerlendirilmesi” adlı bölümdür. Bu bölümde, anketin yapısı, bilgisayar tabanlı bir değerlendirme ve raporlama yeterliliğine aktarılma da dâhil olmak üzere, uygulamaya alınan yaklaşım ana hatlarıyla belirlenmektedir (OECD, 2016).

#### **1.4.1.1. Matematik okuryazarlığının tanımı**

PISA’ya göre; “Matematik okuryazarlığı, bireylerin matematiğin dünyadaki oynadığı rolü anlama, doğrulara dayanan yargılama yapabilme, yapıcı, yaratıcı, ilgili ve düşünceli birer vatandaş olarak kendi hayatlarını devam ettirebilmeleri için, ihtiyaç duydukları durumlarda, bireylerin matematiği formüle edebilme, kullanabilme ve yorumlayabilme becerisi” olarak tanımlanabilir. Başka bir deyişle; bireylerin karşılaşacağı sorunların çözümünde; olayları açıklama, tanımlama ve tahmin etmede, matematik ve matematiksel kavramları kullanarak mantık yürütme becerisi olarak tanımlanabilir (Bauiter ve Rayou, 2007; Akyüz ve Pala, 2010; Uysal ve Yenilmez, 2011; Kamaliyah ve ark., 2013; Türkan ve ark., 2015; OECD, 2016).

Matematik okuryazarlığı tanımı, matematikte aktif katılım üzerine odaklanmıştır. Yani; bireylerden, matematiksel muhakeme, olayları açıklama ve tahmin etmek amacıyla matematiksel kavramları, süreçleri, unsurları ve araçları kullanması beklenir. Ayrıca; matematik okuryazarlığı, bireylerin matematiği “formüle etme”, “kullanma” ve “yorumlama” becerisi olarak da ifade edilebilir (Uysal ve Yenilmez, 2011; OECD, 2016).

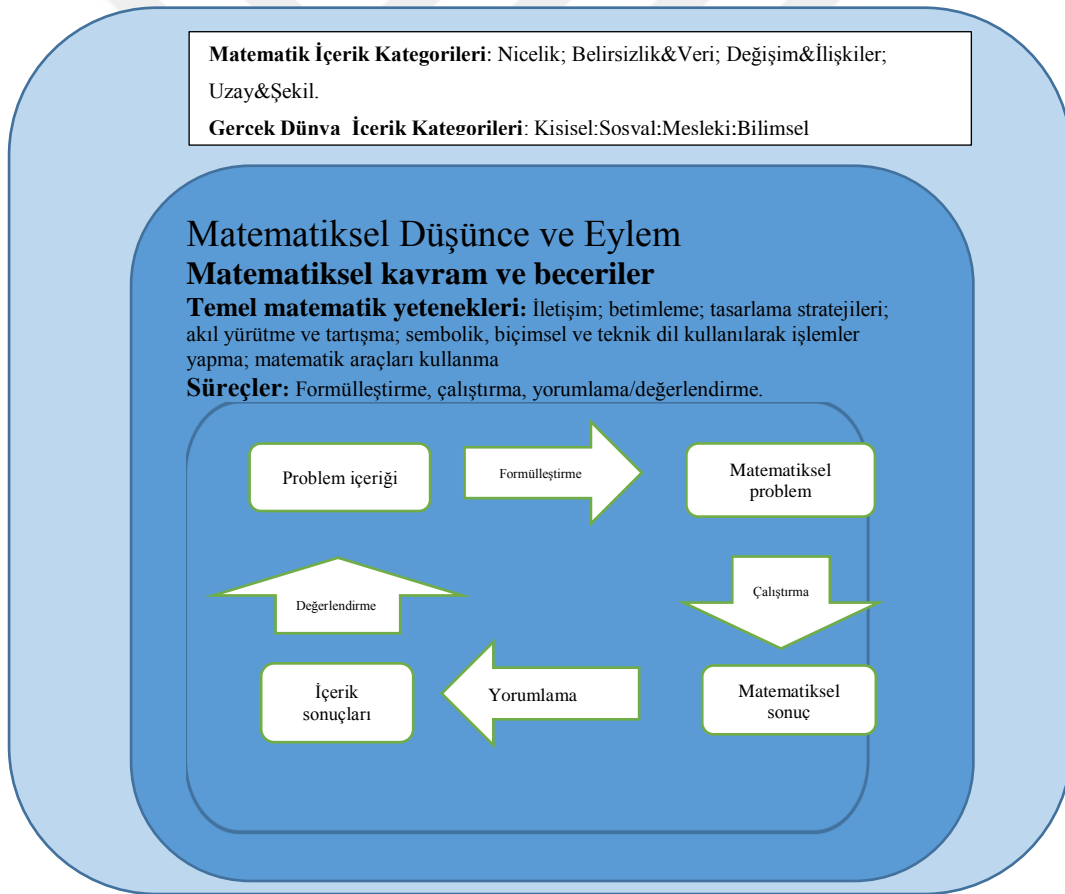
Matematik okuryazarlığı, matematiğin soyut dünyasına yönelik araştırmaları ve öğrencilerin soyut matematik kavramlarını güçlü bir şekilde anlamalarına yardımcı olmaktadır (OECD, 2016).

Matematik okuryazarlığı için doğal olarak, belirli bir yaş sınırlaması yoktur. Bununla birlikte, 15 yaşındakilere yönelik yapılan değerlendirmeler; bu öğrencilerin ilgili özellikleri, uygun içerik, dil ve bağlamları belirlenerek yapılmalıdır. 15 yaş grubu öğrenciler ile bireylerin matematik okuryazarlığı arasında, içerik konuları açısından ayırım olmalıdır. Yani; bahsi edilen yaş grubuna ait uygun içerik belirlenmelidir. Matematik okuryazarlığı, bir bireyin sahip olması gereken ya da gerekmeyen bir özellik

değildir. Ancak; matematik okuryazarlığı bireylere diğer bireylere nazaran oldukça farklılık kazandırır (OECD, 2013).

PISA matematik çerçevesi, PISA araştırması için matematik alanını ve 15 yaşındakilerin matematik okuryazarlığını değerlendirmek için bir yaklaşımı tanımlar. Yani; PISA, 15 yaşındaki öğrencilerin, gerçek dünyadaki matematiksel sorunlar ile karşılaştıklarında ustalıklarla matematiği nasıl kullanabileceklerini değerlendirir.

PISA matematik problemlerinde; içerik, kapsam ve yeterlilik olmak üzere üç önemli bileşen bulunmaktadır. İçerik, okulda öğrenilen materyallerin bir bileşenidir. Kapsam, günlük hayat ile ilgili durumlara bağlı problemlerdir. Yeterlilik ise, öğrencilerin matematik problemlerini çözmede, matematiği formüle etme, kullanma ve yorumlama becerisini göstermektedir (Ahyan ve Darmawijoyo, 2014).



Şekil 1.1. Uygulamadaki matematik okuryazarlığına ait model (OECD, 2016)

## 1.4.2. Matematiksel süreçler ve temel matematiksel yetenekler

### 1.4.2.1. Matematiksel süreçler

Matematik okuryazarlığı, bireyin matematiği formüle etme, kullanma ve yorumlama kapasitesini tanımlamaktadır. Matematiği formüle etme, kullanma ve yorumlama; bir problemin bağlamını matematik ile ilişkilendirmek ve böylece sorunu çözmek için bireylerin ne yapması gerektiğini tanımlayan matematiksel süreçleri düzenlemek için yararlı ve anlamlı bir yapı sağlar. 2015 PISA matematik anketindeki öğeler, aşağıda verilmiştir;

- Durumları matematiksel olarak formüle etme,
- Matematiksel kavramları, gerçekleri, süreçleri kullanma ve muhakeme yapma,
- Matematiksel sonuçları yorumlama, uygulama ve değerlendirme (OECD, 2017).

#### a. Durumları matematiksel olarak formüle etme

Matematik okuryazarlığı tanımında yer alan formüle etme (formulate) terimi, bireylerin matematiği kullanma fırsatlarını belirleyebilmelerini, tanıyabilmelerini ve birçok bağlam içinde kullanılmış bir formda sunulan bir problem için matematiksel yapı sağlayabilmelerini ifade eder. Matematiksel olarak durumları formüle etme sürecinde; bireyler, problemi analiz etmek, kurmak ve çözmek için temel bilgileri nereden sağlayabileceklerini belirler. Formüle etme sürecine ilişkin etkinlikler aşağıda verilmiştir (OECD, 2017).

- Gerçek dünya şartlarında yer alan bir problemin matematiksel bakış açılarını ve önemli değişkenlerini belirleme,
- Problem ya da durumlardaki matematiksel yapıyı (düzenlilikler, ilişkiler ve desenler dâhil olmak üzere) belirleme,
- Matematiksel analize uygun hale getirmek için bir durumu ya da problemi basitleştirme,

- İÇerikten derlenenleri basitleştirme ve herhangi bir matematiksel modellemenin ardında yatan kısıtlamaları ve varsayımları belirleme,
- Uygun değişkenler, semboller, diyagramlar ve standart modeller kullanarak bir durumu matematiksel olarak temsil etme,
- Uygun varsayımlar oluşturarak ve bir problemi matematiksel kavramlara göre düzenleyerek farklı bir şekilde temsil etme,
- Bir problemin içeriğe özgü dili ile sembolik ve biçimsel dili arasındaki ilişkileri anlama ve açıklama,
- Bir problemi matematiksel dile veya gösterime çevirme,
- Bilinen problemlere, matematiksel kavramlara, olgulara veya süreçlere benzeyen bir problemin bakış açılarını belirleme,
- Bağlam içinde kullanılmış bir problemin doğasında bulunan matematiksel bir ilişkiyi göstermek için teknolojiyi kullanma.

#### b. Matematiksel kavramların, olguların, süreçlerin ve muhakemenin kullanılması

Matematik okuryazarlığındaki kullanma (employ) terimi, matematiksel sonuçları elde etmek için, bireylerin matematiksel olarak formüle edilmiş problemleri çözme mantığını anlayabilmelerini, matematiksel kavramları, olguları ve süreçleri uygulayabilmelerini ifade eder. Problemleri çözme muhakemesinde bireyler; matematiksel kavramlar, olgular ve süreçleri kullanarak sonuçları elde etmek için gerekli olan matematiksel işlemleri yaparak matematiksel bir çözüm bulurlar. Örneğin; aritmetik hesaplamalar, denklem çözme, matematiksel varsayımlardan mantıksal çıkarım yapma, tablolardan ve grafiklerden matematiksel bilgiler çıkarmak ve verileri analiz etmek vb... Özellikle, matematiksel kavramları, olguları, süreçleri ve muhakemeyi kullanma süreci aşağıdaki özellikleri içerir (OECD, 2017).

- Matematiksel çözümler bulmak için stratejiler tasarlamak ve uygulamak,
- Tam veya yaklaşık çözümleri bulmaya yardımcı olmak için teknoloji de dâhil olmak üzere matematiksel araçları kullanmak,
- Çözümler ararken matematiksel gerçekleri, kuralları, algoritmaları ve yapıları uygulamak,



- Geometrik simgeler, cebirsel ifadeler, denklemler, sayılar, grafikler ve istatistiksel verileri kullanmak,
- Matematiksel çizimler, grafikler ve yapılar oluşturmak, bunlardan matematiksel bilgi elde etmek,
- Çözüm bulma sürecinde farklı gösterimleri kullanmak ve değiştirmek,
- Çözümleri bulmak için matematiksel süreçlerin uygulama sonuçlarına dayalı olarak genellemeler yapmak,
- Matematiksel parametreleri yansıtmaya, açıklama ve sonuçları doğrulamaktır.

c. Matematiksel sonuçları yorumlama, uygulama ve değerlendirme

Matematik okuryazarlığı tanımında kullanılan yorumlama (interpret) terimi, gerçek yaşam sorunları bağlamında; bireylerin matematiksel çözümleri, bulgulara ya da sonuçlara yansıtma ve bunları yorumlama yeteneklerine odaklanır. Bu süreç, matematiksel çözümlerin veya mantık yürütmenin bir problemin içeriğine dönüştürülmesini, sonuçların mantıklı olup olmadığını ve soru bağlamında anlamlı olup olmadığını belirlemeyi içermektedir. Bu sürece katılan bireyler, hem modelleme sürecini hem de bu sürecin sonuçlarını yansıtır. Spesifik olarak, matematiksel sonuçları yorumlama, uygulama ve değerlendirme süreci aşağıdaki bilgileri içerir (OECD, 2017).

- Matematiksel bir sonucu gerçek dünya bağlamı için yorumlamak,
- Gerçek bir dünya problemi bağlamında, matematiksel bir çözümün mantıklı olup olmadığını değerlendirmek,
- Sonuçların gerçek dünya etkisini anlamak, ayarlanması ya da uygulanması gereken sonuçların içeriksel kararlarını oluşturmak için bir matematiksel model ya da süreç hesaplamak,
- Akla uygun verilen problemin içeriğine göre, bir matematiksel sonucun uygun olup olmadığını açıklamak,
- Matematiksel kavramların ve matematiksel çözümlerin kapsamını ve sınırlarını anlamak,
- Bir problemi çözmek için kullanılan modelin sınırlarını belirlemek ve gözden geçirmektir.

#### 1.4.2.2. Maddelerin matematiksel süreçle istenilen dağılımı

Değerlendirmenin yapılmasındaki amaç; gerçek dünya ile matematik dünyası arasında bir ilişki kurulmasını ve ikisi arasında bir denge oluşturulmasını sağlamaktır. Ayrıca; öğrencilerin matematiksel olarak formüle edilmiş bir problem üzerinde çalışabilmelerini gerektiren süreç sırasında, yaklaşık olarak eşit ağırlığı olan bir dengeyi sağlamaktır (OECD, 2017).

Çizelge 1.1. Matematik öğelerinin işlem kategorisine göre istenen dağılımı (OECD, 2017).

İşlem Kategorisi	Öğelerin Yüzdesi
Matematiksel olarak durumları formüle etme	25
Matematiksel kavramlar, olgular, süreçler ve muhakemeyi kullanma	50
Matematiksel sonuçları yorumlama, uygulama ve değerlendirme	25
Toplam	100

#### 1.4.2.3. Matematiksel süreçlerin altında yatan temel matematiksel yetenekler

Matematiksel süreçlerin altında yatan temel yetenekler şu şekildedir:

##### a. İletişim

Matematik okuryazarlığı iletişimi içerir. Birey, bir problem durumunu anlar, problemi tanımak için uyarılır ve bazı zorlukların varlığını algılar. Bir problemi anlama, aydınlatma ve formüle etme aşaması önemli olup bu durumların zihinsel modelinin oluşturulmasını ve nesnelere, görevlerin, soruların, ifadelerin yorumlanmasını, okunmasını ve kodlanmasını sağlar. Çözüm sürecinde, ara sonuçların özetlenmesi ve gösterilmesine ihtiyaç duyulabilir (OECD, 2017).

### b. Matematikselleştirme

Matematik okuryazarlığı, bireylere, gerçek dünyada tanımlanan bir problemi tamamen matematiksel bir forma dönüştürme (Örneğin; yapılandırma, kavramsallaştırma varsayım oluşturma ve/veya bir modeli formüle etme.), asıl problemle ilgili matematiksel model ya da matematiksel sonucu değerlendirme veya yorumlama becerilerini kazandırmaktadır (OECD, 2017).

### c. Gösterim

Matematik okuryazarlığı sıklıkla matematiksel nesnelere ve durumların gösterimini içerir. Bu süreç, bir durumu yansıtmak, bir problemle etkileşimde bulunmak veya bir kişinin çalışmasını sunmak için çeşitli gösterimlerin seçilmesini, yorumlanmasını, tercüme edilmesini ve kullanılmasını gerektirebilir. Belirtilen gösterimler arasında grafikler, tablolar, diyagramlar, resimler, denklemler, formüller ve somut materyaller bulunur (OECD, 2017).

### d. Akıl yürütme ve tartışma

Bu yetenek, problemleri çözmek, düşüncelerin haklılığını ispat etmeyi sağlamak için, problem öğelerini birbirine bağlayan ve araştıran mantıksal olarak köklü düşünceleri içerir (OECD, 2017).

### e. Problemleri çözmek için stratejiler geliştirmek

Matematik okuryazarlığı, sıklıkla matematiksel olarak problem çözmek için stratejiler geliştirmeyi gerektirir. Bu süreç, bireylerin problemleri etkili bir şekilde çözmesi için formüle etmesinde, tanımında önemli olan kontrol süreçlerini içerir. Bu yetenek, görev veya bağlamdan doğan problemleri çözmek için bir plan ya da strateji

seçme ya da düzenleme olarak nitelendirilir. Bu matematiksel yetenek, problem çözme sürecinin herhangi bir aşamasında talep edilebilir (OECD, 2017).

#### f. Sembolik, biçimsel ve teknik dil ve işlemleri kullanma

Matematik okuryazarlığı; sembolik, biçimsel ve teknik dil ve işlemlerin kullanılmasını gerektirir. Matematiksel teamüller ve kurallar ile yönetilen matematiksel içerik içindeki sembolik ifadelerin kullanılmasını, işlenmesini, yorumlanmasını ve anlaşılmasını içerir (OECD, 2017).

#### g. Matematiksel araçları kullanma

Matematiksel araçlar, yaygın olarak kullanılan hesap makineleri ve bilgisayar tabanlı araçlar vb. fiziksel araçları içerir. Öğrenciler, matematiksel görevleri tamamlamalarında kendilerine yardımcı olması için bu araçları nasıl kullanacaklarını ve araçların sınırlılıklarını bilmelidirler (OECD, 2017).

#### ğ. Matematiksel içerik bilgisi

Modern dünyadaki insanlar için matematiksel içeriğin anlaşılması, anlamlı bağlamsal sorunların çözümünde kullanılan bilginin uygulanabilmesi bakımından önemlidir. Yani; kişisel, mesleki, toplumsal ve bilimsel bağlamlarda sorunları çözmek ve durumları yorumlamak için, belirli matematiksel bilgi ve anlayışları kullanmaya ihtiyaç vardır. PISA matematik okuryazarlığını değerlendirmek amacıyla, matematiksel içerik bilgisi için, bir örgütsel yapı önerilmiştir. Bu yapı, geniş problem sınıflarının altında yatan ve belirli matematiksel kavram ve süreçlerin gelişimini harekete geçiren matematiksel olgulara dayanmaktadır (OECD, 2017).

Ulusal matematik müfredatı sıklıkla, öğrencileri benzer temel matematiksel olayları ele alan bilgi ve becerilerle donatmak için tasarlanmaktadır. Bu çerçevede, on bir ülkeden gelen ulusal standartların analizlerine dayanarak, 15 yaşındaki öğrencilerin matematik okuryazarlığını değerlendirmek için uygun bazı içerik konuları listelenmektedir (OECD, 2017).

PISA 2015 matematiksel içerikte; Değişim ve İlişkiler (Change and relationships), Uzay ve şekil (Space and shape), Nicelik (Quantity) ile Belirsizlik ve veri (Uncertainty and data) konu kategorileri kullanılmıştır.

Değişim ve ilişkiler: Doğal ve tasarlanmış dünyalar, nesnelere ve koşullar arasında çok sayıda geçici ve kalıcı ilişki sergilemektedir. Değişiklikler, ilişkili nesnelere sistemler içerisinde veya elemanların birbirini etkilediği durumlarda meydana gelir. Birçok durumda, bu değişiklikler zaman içinde meydana gelir. Diğer durumlarda ise, bir nesne veya miktardaki değişiklikler başka bir nesne ya da miktarı etkilemektedir. Bu durumlardan bazıları, soyut değişimi içerirken, diğerleri sürekli değişmektedir. Bazı ilişkiler kalıcı ya da sabit bir niteliktedir. Değişim ve ilişkiler hakkında daha fazla bilgi sahibi olmak suretiyle değişikliğin temel türleri anlaşılabilir. Uygun matematiksel modelleri tanımlamak ve değişimleri tahmin etmek mümkündür. Matematiksel olarak; ilişkileri sembolik ve grafiksel olarak gösterme, yorumlamanın yanı sıra, uygun fonksiyon ve denklemlerle değişim ve ilişkilerin modellenmesi mümkündür (OECD, 2017).

Değişim ve ilişkiler, organizmaların büyümesi, müzik, mevsimlerin döngüsü, hava durumu modelleri, istihdam seviyeleri ve ekonomik koşullar gibi çeşitli durumlarda belirgindir. Değişim olaylarını tanımlama, modelleme ve yorumlamada, geleneksel matematiksel içeriklerinden fonksiyonlar ve cebirin yanında, cebirsel ifadeler, denklemler ve eşitsizlikler, tablo ve grafiksel gösterimler merkezi bir öneme sahiptir. Verilerin gösterimleri ve istatistikler kullanılarak tanımlanan ilişkilerde, sıklıkla betimleme kullanılır. Ayrıca; değişim ve ilişkilerin tanımlanması ve yorumlanması için sayı ve ölçü birimlerinin sağlam bir temelde oluşturulması şarttır (OECD, 2017).

Uzay ve şekil: Uzay ve şekil, görsel ve fiziksel dünyamızda her yerde karşılaşılan modeller, nesnelere özellikleri, nesnelere temsili, konumlar ve yönelimler; görsel bilginin şifrelenmesi ve kodlanması gibi çok çeşitli olayları kapsar. Geometri, uzay ve şekil için temel bir dayanaktır. Bununla birlikte; bu kategori, üç boyutlu görselleştirme, ölçme ve cebir gibi diğer matematiksel alanların elemanlarını kullanarak, anlam ve yöntemdeki geleneksel geometri içeriğine göre genişletilebilir (OECD, 2017).

PISA, uzay ve şekille ilgili bir takım temel kavram ve becerinin anlaşılmasının matematik okuryazarlığı için önemli olduğunu varsayar. Uzay ve şekil alanındaki

matematik okuryazarlığı, resimlerdeki bakış açısını anlama, yaratma, haritaları okuma, teknolojiyi kullanarak ya da kullanmaksızın şekilleri dönüştürme, üç boyutlu görüntüyü çeşitli açılardan yorumlama ve temsiller oluşturma gibi bir dizi aktiviteyi içerir (OECD, 2017).

**Nicelik:** Nicelik kavramı, dünyadaki nesnelerin, ilişkilerin, durumların ve varlıkların niteliklerinin nicelleştirilmesini ve bu niceliklerin çeşitli gösterimlerinin anlaşılmasını ve niceliğe dayalı parametreleri ve yorumları değerlendirmeyi içermektedir. Dünyanın niceliğiyle ilgilenmek; ölçümleri, sayıları, büyüklükleri, ölçü birimleri, göstergeleri, nisbi büyüklükleri, sayısal eğilimleri ve modelleri anlamak demektir. Nicelik, sayısal muhakemenin boyutları, sayı duyusu, sayıların çoklu gösterimleri, hesaplamada zarafet, zihinsel hesaplama, sonuçların tahmini ve akla uygunluğunun değerlendirilmesidir. Nicelik, matematik okuryazarlığının temelidir (OECD, 2017).

Nicelleştirme, dünyanın çeşitli yönlerinin uçsuz bucaksız özelliklerini tanımlamak ve ölçmek için kullanılan birincil yöntemdir. Daha sonra, durumların modellenmesi amacıyla, değişim ve ilişkilerin incelenmesine, uzay ve şeklin tanımlanmasına ve kullanılmasına, verilerin düzenlenmesine ve yorumlanmasına, belirsizliğin ölçülmesine ve değerlendirilmesine imkân sağlar (OECD, 2017).

**Belirsizlik ve veri:** Bilim, teknoloji ve günlük hayatın hemen hemen her alanında belirsizlik vardır. Belirsizlik ve veri kategorisi; süreçteki farklılıkların yerini tanımayı, bu farklılıkları anlamayı, belirsizliği kabul etmeyi, ölçmedeki hata ve olasılık ile ilgili bilgi sahibi olmayı, ayrıca; belirsizlik durumlarında ortaya çıkan sonuçları oluşturma, yorumlama ve değerlendirmeyi de içermektedir (OECD, 2017).

Bilimsel tahminlerde, anket sonuçlarında, hava durumu tahminlerinde ve ekonomik modellerin birçoğunda belirsizlik vardır. Olasılık ve istatistik alanları, belirsizlik olaylarını tanımlamak, modellemek, yorumlamak ve çıkarım yapmak için araçlar sağlar. Ayrıca; belirsizlik, cebirin özellikleri ve sayı bilgisi ile bu bağlamdaki problemlerin çözümünde kolaylık sağlar. Belirsizlik ve veri kategorisinin önemli bir yönü, verilerin yorumlanması ve sunulmasına odaklanmasıdır (OECD, 2017).

Çizelge 1.2. İçerik kategorisine göre matematik öğelerinin yüzdelerine göre dağılımı (OECD, 2017).

İçerik Kategorisi	Öğelerin Yüzdeleri
Değişim ve İlişkiler	25
Uzay ve şekil	25
Nicelik	25
Belirsizlik ve veri	25
Toplam	100

#### 1.4.2.4. Matematik okuryazarlığının değerlendirilmesi için temel içerik konuları

PISA 2015'te yer alan içerik konuları aşağıdaki şekilde tasarlanmıştır.

- Fonksiyonlar: Doğrusal fonksiyon ile sınırlanmayan fonksiyon kavramı, onların özellikleri, gösterimleri ve açıklamalarıdır. Yaygın olarak kullanılan temsiller; sözel, sembolik, tablo ve grafiksel gösterimlerdir.
- Cebirsel ifadeler: Sayıları, sembolleri, aritmetik işlemleri, kuvvetleri ve basit kökleri içeren cebirsel ifadelerle sözlü yorumlama ve kullanma.
- Denklemler ve eşitsizlikler: Doğrusal ve doğrusal olmayan denklemler ve eşitsizlikler, basit ikinci derece denklemler, analitik ve analitik olmayan çözüm yöntemleri.
- Koordinat sistemleri: Verilerin, konumunun ve ilişkilerinin gösterimi ve açıklaması.
- İki ve üç boyutlu geometrik nesnelerin içindeki ve arasındaki ilişkiler: Şekil elementleri arasındaki cebirsel bağlantılar gibi statik ilişkiler (Örneğin: Üçgenin kenarlarının uzunlukları arasındaki ilişkiyi tanımlayan Pisagor Teoremi), göreceli konum, benzerlik ve uyum, nesnelerin dönüşümü ve hareketini içeren güçlü ilişkiler, iki ve üç boyutlu nesneler arasındaki benzerlikler.
- Ölçme: Şekiller ve nesnelerin özelliklerinin ölçülmesi (Örneğin; açı ölçümleri, mesafe, uzunluk, çevre, alan, hacim vb. hesaplanması).

- Sayılar ve ölçü birimleri: Tam sayı ve rasyonel sayıların özellikleri, irrasyonel sayılar ile ilgili özellikler, zaman, para, ağırlık, sıcaklık, mesafe, alan ve hacim gibi olayları ifade eden nicelikler ve birimler dâhil olmak üzere sayı ve sayı sistemlerinin temsilleri, türetilmiş miktarlar ve sayısal açıklamaları.
- Aritmetik işlemler: Bu işlemlerin niteliği ve özellikleri (OECD, 2017).

#### 1.4.2.5. Matematik okuryazarlığını değerlendirme

##### a. Araştırma aracının yapısı

2015 yılında yapılan PISA sınavında, matematik okuryazarlığı küçük bir alanı kapsadığından, öğrencilere daha az sayıda soru sorulmuştur. Bununla birlikte, önceki döngülerdeki gibi, öge kümeleri benzer şekilde yapılandırılmış ve dönüştürülmüştür. Ülkelerin, İşbirlikçi Problem Çözme seçeneğini yerine getirip getirmediğine veya testi kâğıt üzerinde yapıp yapmadıklarına bağlı olarak, bir “kolay” ve bir “zor” olmak üzere önceki döngülerdeki altı matematik kümesindeki üç tasarımdan biri kullanılmıştır (OECD, 2017).

##### b. Yanıt biçimleri

PISA 2015' te matematik okuryazarlığını değerlendirmek için üç tip soru biçimi kullanılmıştır. Bunlar; açık yapılandırılmış soru, kapalı yapılandırılmış soru ve seçilen cevap (basit ve karmaşık çoktan seçmeli) öğeleri (OECD, 2017).



### 1.4.2.6. PISA 2015 matematik okuryazarlığı yeterlik düzeylerine göre dağılım

Çizelge 1.3. PISA 2015 matematik okuryazarlığı yeterlik düzeylerine göre dağılımı (OECD, 2017).

Düzyey	Türkiye	OECD	Tüm ülkeler	Yeterlilik Düzeyleri
6. Düzey	2,0	2,3	1,9	Bu düzeyde yer alan öğrenciler; araştırmalarından elde ettikleri bilgileri kavramlaştırma, genelleme ve kullanabilme özelliğine sahiptir. Karmaşık problemleri modelleyebilir ve birbirinden farklı bilgi kaynaklarını ilişkilendirebilir. Matematiksel düşünme ve akıl yürütme kapasitesi bakımından gelişmiş düzeydedirler. Yeni durumlarla karşılaştıklarında, yeni yaklaşımlar ve stratejiler geliştirebilir, sembolik ve formel matematik işlemleri ve ilişkilerine kendi bakış açılarını uygulayabilir. Orijinal durumların uygunluğuna bağlı olarak, elde ettikleri bulgulara, yorumlarını ve eylemlerini aktarabilir. Ayrıca; formüle edebilme ve bunlar arasındaki iletişimi sağlama becerisine sahiptir.
5. düzey	0,1	8,4	6,9	Bu düzeyde yer alan öğrenciler; karmaşık durumlarla ilgili olarak, sınırlılıkları ve belirli varsayımları tanımlayarak, model geliştirebilir ve bu modellerle çalışabilir. Karmaşık problemlerle ilgili, uygun problem çözme stratejilerini seçme, karşılaştırma ve değerlendirme yapabilir. Çalışmalarını formüle edebilme ve yorumlama- muhakeme kurma becerileri arasında iletişim kurabilme özelliğine sahiptir.
4. Düzey	5,9	18,6	13,9	Bu düzeyde yer alan öğrenciler; varsayımlar ya da sınırlılıklar gerektiren karmaşık somut durumlar için, kesin modellerle etkin olarak çalışabilir. Bunlarla gerçek problem durumları arasında doğrudan bağlantı kurabilir, sembolik de dâhil olmak üzere farklı gösterimleri seçebilir ve birleştirebilir. Öğrenciler, sınırlı aralıktaki becerilerini değerlendirebilir ve basit içerikleri kavrayarak sebeplendirebilir. Ayrıca; eylem, çıkarım ve yorumlamalara bağlı olarak çıkarımlar yapabilme ve tartışmaları oluşturabilme özelliğine sahiptir.
3. Düzey	16,3	24,8	20,1	Bu düzeyde yer alan öğrenciler; bir dizi ardışık kararlar alınmasını gerektiren durumlarda dahil olmak üzere, açık bir şekilde tanımlanmış süreçleri yürütebilir. Basit problem çözme stratejilerini uygulayabilir ve basit bir model oluşturabilir ya da seçebilir. Farklı bilgi kaynaklarına dayalı olarak gösterimleri kullanabilir, açıklayabilir ve yorumlayabilir. Ondalık sayıları, kesirleri, yüzdelikleri kullanabilir. Yorumlarını, sonuçlarını ve akıl yürütme ile ilgili elde ettiklerine çözümlerine yansıtabilir.
2. Düzey	25,3	22,5	21,9	Bu düzeyde yer alan öğrenciler; doğrudan görünen belli bir içerikteki durumları tanımlayabilme ve yorumlayabilme becerisine sahiptir. Bir kaynakla ilgili bilgi çıkarabilir ve tek bir gösterimden faydalanabilirler. Bu düzeydeki öğrenciler, problemleri çözmek için tüm sayılar da dâhil olmak üzere, temel algoritmalar, formüller, işlemler ve talimatları kullanabilir. Basit ilişkileri muhakeme edebilme ve sonuçları sınırlı bir şekilde yorumlayabilme özelliğine sahiptir.

I. Düzey	28,4	14,9	18,8	Bu düzeyde yer alan öğrenciler; konuyla ilgili tüm bilgilerin mevcut olduğu ve soruların açıkça tanımlandığı bağlamları içeren soruları yanıtlayabilirler. Açık durumlardaki doğrudan talimatlar doğrultusunda bilgileri belirleyebilme ve rutin işlemleri uygulayabilme becerisine sahiptir. Verilen uyarıları derhal takip edebilir ve eylemleri gerçekleştirebilirler.
I altı	22,9	8,5	17	

## 1.5. Veri Madenciliği

Veri madenciliği, çok büyük miktardaki veri içinden değerli bilgiyi çıkarmaktır. Veri madenciliği, anlaşılabilir ve kullanılabilir verileri belirli yöntemlerle özetleyen ve aralarındaki karmaşık ilişkileri bulmaya çalışan çok büyük veri setlerinin analizidir (Hand ve ark., 2001).

Veri madenciliği, potansiyel olarak yararlı olan gizli kalmış bilgiyi arama ve analiz etme sürecidir (Shaw ve ark., 2001). Başka bir ifadeyle; veri madenciliği, veri tabanı içindeki gizli kalmış ilişkileri, örüntüleri ve aralarındaki korelasyonları tahmin ederek, karar vericilerin güvenilir ve hızlı bir şekilde karar vermelerine yardımcı olan bir yöntemdir (Fayyad ve ark., 1996; Gargaro Gargano mu? ve Ragged, 1999; Shaw ve ark., 2001; Chen ve Liu, 2004; Larose, 2005).

Veri madenciliği, veri tabanlarının büyüklüğü göz önüne alındığında, veri tabanlarındaki bilgi keşfi için bir teknoloji olup bu teknoloji; karar vericiler için, karar verme, problem çözme, analiz, planlama, tanılama, belirleme, birleştirme, önleme, öğrenme ve yenilik konularında farklı yöntemler sunan bir alandır (Liao, 2003).

Veri madenciliği; veri tabanı teknolojisi, makine öğrenme, istatistik, desen tanıma, bilgiye erişim, yapay sinir ağları, bilgi tabanlı sistemler, yapay zekâ, yüksek performanslı hesaplama ve veri görselleştirme gibi çalışma alanına sahiptir (Han ve Kamber, 2006).

Veri madenciliği; istatistiksel analiz, Karar Ağaçları, Yapay Sinir Ağları, sonuç çıkarımı ve grafik görselleştirme gibi geniş bir sayısal yöntemler ailesini kullanır (Shaw ve ark., 2001).

Veri madenciliğinde kullanılan modeller; tahmin edici (predictive) ve tanımlayıcı (descriptive) modeller olmak üzere ikiye ayrılmaktadır. Sınıflama, regresyon ve zaman serileri tahmin edici modeller; kümeleme, birliktelik kuralları ve

ardışık zamanlı örüntü modelleri ise tanımlayıcı modellerdir (Albayrak ve Koltan Yılmaz, 2009).

### 1.5.1. Karar ağaçları

Sınıflama, makine öğrenim sürecinde denetimli bir öğrenme algoritması olarak tanımlanabilir. Veri kayıtlarının ait olduğu sınıf bilgisine dayanarak, veri nesnelere sınıf etiketleri atar. Sınıflama, donanım ve yazılımı ortak tasarlayan ve geliştiren bir veri madenciliği tekniği olup bilinmeyen veri tabanı kayıtlarından bilgi çıkarımı ve bilinmeyen veri setlerinden sınıf etiketlerinin tahmini ile ilgilenmektedir (Tan ve ark., 2006).

Sınıflandırmada, verilen veri seti, eğitim veri seti ve test veri seti olarak iki kümeye ayrılmaktadır. Test veri seti; modelin onaylanmasında kullanılırken, eğitim veri seti sınıflandırma modelinin oluşturulmasında kullanılmaktadır. Model, eğitim veri seti ve test veri setinden farklı olarak yeni üretilen veri setinin sınıflandırılması ve tahmin edilmesinde kullanılmaktadır (Gehrke ve ark., 1998; Garofalakis ve ark., 2000).

Veri tabanlarının sınıf etiketlerinin, ön bilgisinin nitelik/özelliik seçimini kolaylaştırmasından dolayı, sınıflamaya benzeyen gözetimli öğrenme algoritmaları, kümelemeye benzeyen gözetimsiz öğrenme algoritmalarına göre tercih edilmektedir. Veri madenciliği ve karar destek sistemlerinde kullanılan ortak sınıflandırma algoritmalarından bazıları şunlardır: Yapay Sinir Ağları (Lippmann, 1987), Lojistik Regresyon (Khoshgoftaar ve ark., 1999), Karar Ağaçları (Quinlan, 1993) vb. Bu sınıflandırma algoritmaları arasında karar ağacı algoritmaları, anlaşılması ve uygulanmasının kolay olmasından dolayı çok yaygın kullanıma sahiptir (Anyanwu ve Shiva, 2009).

Bir karar ağacı; iç ve yaprak düğümler ile kökten meydana gelmektedir. Ağaç yapısı bilinmeyen veri setini sınıflandırmada kullanılmaktadır. Ağacın her bir iç düğümünde, en iyi bölünme kararı, safsızlık ölçüsü kullanılarak verilir (Quinlan, 1993). Ağaç yaprakları, veri öğelerinin grubu olduğu sınıf etiketlerinden oluşur. Karar ağacı sınıflandırma tekniği; ağaç yapısı ve ağaç budaması olarak iki aşamada gerçekleştirilir. Ağaç inşası yukarıdan aşağıya doğru yapılır (Anyanwu ve Shiva, 2009).

Veri madenciliği alanında; sınıflama amaçlı olarak kullanılan karar ağaçları, kurumlarının basit olması, kolay yorumlanabilmesi, veri tabanları ile kolayca

entegrasyon sağlayabilmesinin yanında güvenilirlik oranlarının yüksek düzeyde olması nedeniyle tercih edilmektedir (Emel ve Taşkın, 2005).

Karar ağaçları, bağımsız değişkenleri kademeli bir şekilde homojen alt gruplara bölebilen lineer olmayan yöntemler olarak tanımlanabilir (Türe ve ark., 2005).

Karar ağaçları, veri setindeki yapısal modeli keşfetme ve açıklama imkânı sağlayan ağaç görünümlü yöntemlerdir. Bu yöntemler, veriyi kullanarak tahmin yapmaya ve veriyi açıklamaya yardım eder. Karar ağaçlarında, tüm girdi değişkenleri ile hedef değişkenleri arasında ilişki olmasına gerek yoktur (Alkhasawneh ve ark., 2014).

### **1.5.1.1. Karar ağaçları oluşturma**

Karar ağacı, örnek uzayının yinelemeli olarak bölümlere ayrılması olarak ifade edilen bir sınıflandırma tekniğidir. Karar ağacı, bir kök ve ağacı oluşturan düğümlerden oluşur. Kök herhangi bir gelen uca sahip olmamasına rağmen, diğer düğümler bir adet gelen uca sahiptir. Giden uca sahip düğümler; dâhili ya da test düğümü olarak, diğer düğümler ise terminal ya da karar düğümleri olarak bilinen yapraklar olarak adlandırılır. Bir karar ağacında, her dâhili düğüm girdi özelliklerinin belli bir kesikli (ayrık) fonksiyonuna göre örnek uzayını iki ya da daha çok alt uzaya böler (Rokach ve Maimon, 2005).

Karar ağacı başlatıcıları, verilen veri kümesinden bir karar ağacını otomatik olarak oluşturan algoritmalarıdır. Genel olarak amaç, genelleme hatasını en aza indirerek en uygun karar ağacını bulmaktır. Bununla birlikte; diğer hedef fonksiyonlar, düğümlerin sayısını veya ortalama derinliği en aza indirmek olarak açıklanabilir (Rokach ve Maimon, 2005).

Karar ağaçları oluşturmada, ortak bir yaklaşım olarak böl ve elde et yöntemi kullanılmaktadır. Yöntem, en iyi özelliğin seçilmesi için, ağaçların iç düğümüne bir etiket verilmesiyle yinelemeli bir şekilde, yukarıdan aşağıya doğru olan bir süreçten oluşmaktadır. Ağacın kökünü temsil eden bir özellik seçilir. İlk özelliğin seçiminden sonra, özelliğin olası her bir değeri için bir dal oluşturulur ve veri kümesi, seçili özelliğin örnek değerlerine göre alt kümelerine ayrılır. Seçim süreci, örneklerin uyumlu alt kümeleri kullanılarak düğümün her dalına yinelemeli olarak uygulanır. Örneğin; dal

ile ilgili özellik değerlerine sahip tüm örnekler, alt kümede yer alır. Aynı sınıf etiketine sahip tüm alt örnekler bir sınıfta olduğunda veya başka bir durdurma kriteri ile karşılaşıldığında, tahmin edilecek bir sınıf etiketini temsil etmek için bir yaprak düğümü oluşturulur (Otero ve ark., 2012).

Böl ve elde et yaklaşımında; özellik seçimi, erken iterasyonlarda belirlenmekte olup daha sonraki iterasyonlarda yeniden ele alınamamaktadır. Bu nedenle yaklaşım; bir karar ağacını oluşturmak için hırslı bir stratejiyi temsil eder (Otero ve ark., 2012).

### 1.5.1.2. Karar ağacı bölünme kuralları

#### 1.5.1.2.1. Safsızlık tabanlı (impurity-based) ölçüt

Safsızlık ölçüsü,  $P = (p_1, p_2, \dots, p_k)$ 'e göre dağılım gösteren,  $x$  rastgele değişken ile  $k$  adet ayrık değerler verildiğinde,  $\varphi: [0, 1]^k \rightarrow \mathbb{R}$ 'nin aşağıdaki koşullara uyan bir fonksiyonu şeklinde tanımlanır.

- $\varphi(P) \geq 0$ .
- $\varphi(P)$ , eğer  $\exists i, p_i = 1$  bileşeni ise minimumdur.
- $\varphi(P)$ , eğer  $\forall i, 1 \leq i \leq k, p_i = 1/k$  ise maksimumdur.
- $\varphi(P)$ ,  $P$ 'nin bileşenine nazaran simetriktir.
- $\varphi(P)$ , kendi aralığında düzgündür.

Olasılık vektörünün 1 bileşenine sahip olması durumunda ( $x$  değişkeni sadece bir değer alır), değişken saf olarak tanımlanır. Diğer taraftan; eğer tüm bileşenler eşitse, safsızlık seviyesi maksimuma ulaşır (Rokach ve Maimon, 2005).

Bir  $S$  eğitim seti verildiğinde,  $y$  hedef özniteliğin olasılık vektörü 1.1 numaralı eşitlikte tanımlanmıştır.

$$P_y(S) = \left( \frac{|\sigma_{y=c_1} S|}{|S|}, \dots, \dots, \frac{|\sigma_{y=c_{|dom(y)|}} S|}{|S|} \right) \quad (1.1)$$

Eş. 1.1'de;  $a_i$ , ayrık öznitelikten dolayı ayrılık iyiliği,  $v_{ij} \in \text{dom}(a_i)$  değerlerine göre  $S$ 'nin bölümlere ayrılmasından sonra hedef özniteliğin safsızlığındaki azalma olarak tanımlanır (Rokach ve Maimon, 2005).

### 1.5.1.2.2. Bilgi kazancı

Bilgi kazancı; safsızlık ölçüsü olarak entropi ölçüsünü kullanan safsızlık temelli bir ölçüttür (Quinlan, 1987; Rokach ve Maimon, 2005). Bilgi kazancı ve entropiyi hesaplayan eşitlikler aşağıda verilmiştir.

$$\text{Bilgi Kazancı } (a_i, S) = \text{Entropi } (y, S) - \sum_{v_{i,j} \in \text{dom}(a_i)} \frac{|\sigma_{a_i=v_{i,j}} S|}{|S|} \cdot \text{Entropi } (y, \sigma_{a_i=v_{i,j}} S) \quad (1.2)$$

$$\text{Entropi } (y, S) = \sum_{c_j \in \text{dom}(y)} \frac{|\sigma_{y=c_j} S|}{|S|} \cdot \log_2 \frac{|\sigma_{y=c_j} S|}{|S|} \quad (1.3)$$

Bilgi kazancı, hedef sınıflandırmasına göre eğitim örneklerini ne kadar iyi ayırdığını ölçer. Bu ölçüm, ağaç büyürken her adımdaki aday özellikleri arasından seçim yapmak için kullanılır. Bilgi kazancı, bu özelliklere göre örnekleri bölerek entropideki küçülmeyi beklemektedir (Rokach ve Maimon, 2005).

### 1.5.1.2.3. Entropi

Entropi, örneklerin homojenliğini hesaplayan bir ölçüttür. Eğer, entropi sıfır (0) ise örnekler tamamen homojen, entropi bir (1) olduğunda ise örnekler homojen değildir anlamına gelmektedir. S eğitim setinin entropisi, S veri setinin belirlenmesinde gereken ortalama bilgi miktarının ölçüsü olarak tanımlanmaktadır. Matematiksel olarak entropi aşağıda verilen eşitlik ile ifade edilebilir (Sastry ve ark., 2010).

$$E(S) = - \sum_{i=1}^c p_i \log_2 p_i \quad (1.4)$$

Bu eşitlikte; c, sınıfların sayısı, p<sub>i</sub> ise, "i" sınıfına ait S'nin oranıdır.

### 1.5.1.2.4. Gini indeksi

CART algoritmasında kullanılmakta olan, Gini indeksi, hedef öznitelik değerlerinin olasılık dağılımları arasındaki farklılıkları ölçen safsızlık temelli bir ölçüt olup aşağıdaki biçimde tanımlanmaktadır.

$$Gini(y, S) = 1 - \sum_{c_j \in dom(y)} \left( \frac{|\sigma_{y=c_j} S|}{|S|} \right)^2 \quad (1.5)$$

Dolayısıyla,  $a_i$  özneliğini seçmek için değerlendirme kriteri aşağıdaki biçimde tanımlanmaktadır.

$$Gini Kazancı (a_i, S) = Gini(y, S) - \sum_{v_{i,j} \in dom(a_i)} \frac{|\sigma_{a_i=v_{i,j}} S|}{|S|} \cdot Gini(y, \sigma_{a_i=v_{i,j}} S) \quad (1.6)$$

(Rokach ve Maimon, 2005).

#### 1.5.1.2.5. Kazanç oranı (Gain ratio)

Kazanç oranı, bilgi kazancını aşağıda verilen eşitlikteki gibi normalleştirmektedir (Quinlan, 1993).

$$Kazanç Oranı (a_i, S) = \frac{Bilgi Kazancı(a_i, S)}{Entropi(a_i, S)} \quad (1.7)$$

Bu eşitlikte, paydanın sıfır olması halinde kazanç oranının tanımsız olduğu bilinmektedir. Aynı zamanda, payda çok küçük değere sahipse, nitelikleri destekleme yönünde eğilim gösterebilir. Böyle bir durumda, tüm nitelikler için bilgi kazancı hesaplanmalı ve sadece en az ortalama bilgi kazancı kadar iyi olan nitelikler dikkate alınarak, en iyi oran kazanımını elde eden nitelik seçilmelidir. Kazanç oranı, sınıflandırıcı karmaşıklığı özelliğinin yanı sıra doğruluk özelliğinden dolayı, basit bilgi kazancı kriterlerinden daha iyi performans gösterme eğilimindedir (Quinlan, 1988; Rokach ve Maimon, 2005).

#### 1.5.1.3. Budama yöntemleri

Aşırı uyumu engellemek ve yanlış sınıflandırma hatasını minimize etmek amacıyla, oluşturulan karar ağaçları aşırı büyük olduğunda ağaçlara budama (pruning) işlemi uygulanması gerekir (Yılmaz, 2014).

### 1.5.1.3.1. Maliyet karmaşıklığı budaması (Cost-complexity pruning)

Breiman ve ark. (1984) tarafından oluşturulmuş bir budama yöntemidir. Hata karmaşıklığı ve en zayıf bağlantı budaması olarak da bilinmektedir.  $T_0, T_1, \dots, T_k$  şeklinde oluşturulan bir dizi ağaç için iki aşamalı bir süreç olarak tanımlanmaktadır.  $T_0$ , budama yapılmadan önceki başlangıç karar ağacını ve  $T_k$  ise son karar ağacını göstermektedir (Quinlan, 1987).

Birinci aşamada, her  $T_{i+1}$  ağacı, son ağaç  $T_k$  sadece bir yaprak olana kadar  $T$ 'nin bir ya da daha çok alt yapılarının yer değiştirilmesi ile elde edilir. İkinci aşamada, ya bu ağaçlar ya da bu ağaçlardan biri seçilerek budanmış ağaç olarak değerlendirilir (Quinlan, 1987). Başka bir ifadeyle;  $T_{i+1}$  ağacı, bir önceki ağaç olan  $T_i$ ' de bulunan uygun yapraklar ile bir veya daha çok alt ağacın yer değiştirilmesiyle elde edilir. Budama yapılan alt ağaçlar, budanmış yaprak başına belirgin hata oranındaki en düşük artışı sağlayan ağaçlardır (Rokach ve Maimon, 2005).

$$\alpha = \frac{\varepsilon(\text{pruned}(T,t),S) - \varepsilon(T,S)}{|\text{leaves}(T)| - |\text{leaves}(\text{pruned}(T,t))|} \quad (1.8)$$

Burada;  $\varepsilon(T,S)$ ,  $S$  örnekleri üzerindeki ( $T$ ) ağacının hata oranını göstermektedir.  $|\text{leaves}(T)|$ ,  $T$  ağacındaki yaprakların sayısını ve  $\text{pruned}(T,t)$  ise  $T$  ağacındaki  $t$  düğümünün bir uygun yaprak ile yer değiştirilmesi ile elde edilen ağacı göstermektedir (Rokach ve Maimon, 2005).

İkinci aşamada  $T_0, T_1, \dots, T_k$  budanmış ağaçlarına ait genelleme hataları tahmin edilerek, en iyi budanmış ağaç seçilir. Eğer veri seti yeterince büyük ise, veri setinin eğitim seti ve budama seti olarak ayrılması önerilir. Ağaçlar eğitim seti kullanılarak oluşturulur ve budama seti üzerinde değerlendirilir. Diğer taraftan; veri seti yeteri kadar büyük değilse, hesaplama karmaşıklığına rağmen, çapraz doğrulama yönteminin kullanılması önerilir (Rokach ve Maimon, 2005).



Kısaca özetlemek gerekirse; bu budama yönteminde; öncelikle farklı miktarlarda bir dizi ağaç budanır, sonrasında ise bağımsız değişken veri seti ile oluşan sınıflandırma hatalarının sayısı incelenerek seçim yapılır. Budamada maliyet karmaşıklık yöntemi, hem ağacın karmaşıklık boyutunu hem de hata sayısını ele alır (Mingers, 1989).

Yöntemin çalışma prensibi şöyledir: Ağaçtaki her düğüm, birkaç yaprakla bitecek olan bir alt ağacın başlangıç noktasıdır. Budama yapılmadan önce, yapraklar sadece bir sınıfa ait örnekleri içermektedir. Budama sürecinde ise, kalan yapraklara birçok farklı sınıftan örnekler dâhil olmaktadır. Bu durumda, yapraktaki örnekler incelenerek en sık görülen sınıfa ayrılır. Bir yaprağın hata oranı, o sınıfa ait olmayan eğitim örneklerinin oranıdır. Alt ağacın budanması durumunda beklenen hata oranı; yaprağın başlangıç noktası olan düğümdür. Budanmaması durumunda ise her yapraktaki örnek sayısı ile ağırlıklandırılmış yapraklara ait hata oranlarının ortalamasıdır. Eğitim verileriyle budama her zaman hata oranında bir artışa yol açar ve bu artış alt ağacın değerinin ölçüsünü göstermektedir. Bu artış, alt ağaçtaki yaprak sayısına bölünerek, yaprak başına düşen hata miktarındaki azalmanın bir ölçüsünü verir ki buna, hata-karmaşıklık ölçüsü adı verilir (Mingers, 1989).

#### **1.5.1.3.2. Azaltılmış hata budaması (Reduced error pruning)**

Quinlan (1987), en iyi ağacı seçmek için doğrudan test verilerini kullanarak budanmış ağaç dizisi üreten bir yöntemi önermiştir (Quinlan, 1987; Mingers, 1989). Brunk ve Pazzani (1991), gürültünün olduğu alanlardaki tahmin doğruluğunu arttırmak için bu budama yönteminin oldukça etkili olduğunu kanıtlamışlardır (Furnkranz ve Widme, 1994).

Quinlan (1987), azaltılmış hata budaması yöntemini, karar ağaçları budaması için basit bir süreç olarak ifade etmiştir. İç düğümler alttan üste doğru geçiş yaparken, süreç, her bir iç düğümü, en sık kullanılan ve ağacın doğruluğunu azaltmayan sınıfla değiştirilmesi ya da değiştirilmemesi yönünde karar vermek için kontrol etmektedir. Bu durumda, düğüm budanır. Süreç, budamanın doğruluğu azalana kadar devam eder. Quinlan doğruluğu tahmin etmek için bir budama seti kullanmayı önermiştir. Süreç, verilen budama seti ile ilgili olan alt ağaçların en küçük doğruluk oranına sahip olması ile sonlanmaktadır (Rokach ve Maimon, 2005).

Yöntemin çalışma prensibi şöyledir: Bir dizi ağaç seçmekten ziyade, ağaçlardan biri seçilir. Orijinal ağaç tarafından sınıflandırılan her durumda, ayrı bir test seti seçilir. T'nin yaprağı olmayan her S alt ağacı için, ağaç dizisi içerisindeki ağaçlardan biri seçilir. Daha sonra, S'nin olası en iyi yaprak ile değiştirilmesi durumunda bile, oluşacak olan test seti üzerindeki yanlış sınıflandırma değişimi incelenir. Oluşan yeni ağacın hata sayısı eşit ya da daha az sayıda ise S benzer özellikte alt ağaç değildir, bu durumda, S'nin yaprakları değiştirilir. Bu süreç, test seti üzerindeki hata sayısını artıran yer değiştirmeler kalmayana kadar devam eder (Quinlan, 1987).

### 1.5.1.3.3. Kötümser hata budaması (Pessimistic error pruning)

Ayrı bir test veri setine ihtiyaçtan kaçınmayı amaçlayan Quinlan (1986)'nin önerdiği bir yöntemdir. Budama yapılıyorsa ve ağaç tarafından üretilen yanlış sınıflama oranları aşırı derecede iyimser ise eğitim seti aşırı büyük ağaçlar üretmektedir (Quinlan 1987; Mingers, 1989). Quinlan (1993)'nin kötümser budaması, çapraz geçerlilik veya budama ihtiyacından kaçınmak için kötümser istatistiksel korelasyon testini kullanır. Bu budamada yönteminde, eğitim seti kullanılarak tahmin edilen hata oranının yeterince güvenilir olmadığı düşünülmektedir (Rokach ve Maimon, 2005). Bundan dolayı; Quinlan, yanlış sınıflandırma oranının daha gerçekçi bir tahminini elde etmek için binom dağılımına süreklilik düzeltmesi yapmayı önermektedir (Quinlan 1987; Mingers, 1989).

Binom dağılımı için süreklilik düzeltmesi aşağıdaki eşitlik ile verilmiştir:

$$\hat{\epsilon}(T, S) = \epsilon(T, S) + \frac{|leaves(T)|}{2 \cdot |S|} \quad (1.9)$$

Bununla birlikte, yukarıdaki eşitlikteki düzeltme yine de iyimser hata oranı üretmektedir. Eğer hata oranı, referans ağacından  $\pm 1$  standart hata içerisinde ise iç düğüm olan t'nin budanması düşünülebilir (Quinlan, 1993; Rokach ve Maimon, 2005).

$$\hat{\epsilon}(\text{pruned}(T, t), S) \leq \hat{\epsilon}(T, S) + \sqrt{\frac{\hat{\epsilon}(T, S) \cdot (1 - \hat{\epsilon}(T, S))}{|S|}}$$

(1.10)

Son durumda hata oranları istatistiksel güven aralıklarına bağlıdır. Genellikle; T, kökü iç düğüm t olan bir alt ağaca başvurur. S ise t düğümünün eğitim setindeki payını belirtmektedir. Bu yöntemin istatistiksel gerekçesi biraz belirsizdir. Süreklilik düzeltmesi, ne aşırı iyimser bir yanlış sınıflandırma tahminine bağlı olarak, ne de istenildiği zaman eklenir. Yöntem bazı yönlerden eksik olmasına rağmen, yine de, bir alt düğümdeki benzer alt ağaçlar ile yanlış sınıflandırmaların sayısını karşılaştırması nedeniyle başarılı olarak kabul edilebilir. Buradaki süreklilik düzeltmesi küçük ve önemsizdir. Yöntem, bir test veri setine ihtiyaç duymaz, geçiş yapmak ve her düğüme bir kez bakmak zorunda olmasına rağmen çok hızlıdır. Ancak, bir dizi ağaç üretmez (Mingers, 1989).

#### 1.5.1.3.4. En küçük hata budaması (Minimum-error pruning)

Niblett ve Bratko (1986), bağımsız veri setini sınıflandırırken, teorik olarak minimum hata oranını vermesi gereken tek ağacı bulan bir yöntem geliştirmişlerdir (Mingers, 1989).

Yöntem, iç düğümlerin sırasıyla aşağıdan yukarıya doğru geçişini gerçekleştirir. Budamalı ve budama olmaksızın, her bir düğümdeki olasılık hata oranı tahminlerini karşılaştırır.  $\lambda$ -olasılık hata oranı tahmini, frekanslar kullanılarak basit olasılık tahmini düzeltmesidir. Eğer  $S_t$ , bir t yaprağına ulaşan örnekleri gösterirse, bu yapraktaki beklenen hata oranı aşağıdaki eşitlikle gösterilir.

$$\hat{\epsilon}(t) = 1 - \max_{c_i \in \text{dom}(y)} \frac{|\sigma_{y=c_i} S_t| + \lambda \cdot p_{apr}(y=c_i)}{|S_t| + \lambda}$$

(1.11)

Burada,  $p_{apr}$ ,  $c_i$  değerini alan  $y$ 'nin a-önsel olasılığı olup  $\lambda$  ise a-önsel olasılığına verilen ağırlığı ifade etmektedir. İç düğüme ait hata oranı, dalların hata oranının ağırlıklı ortalamasıdır. Ağırlık, her bir daldaki örneklerin oranına göre belirlenir. Hesaplama yinelemeli olarak yapraklara kadar gerçekleştirilir. Eğer bir iç düğüm budanmış ise o

zaman bir yaprak kesilir ve hata oranı son denklem kullanılarak hesaplanır. Sonuç olarak, belli bir iç düğümün budanmasından önce ve budanmasından sonraki hata oranını kıyaslayabilmek mümkündür. Eğer bir düğümün budanması hata oranının artırmıyor ise budama kabul edilmelidir (Rokach ve Maimon, 2005).

#### **1.5.1.3.5. Kritik değer budaması (Critical value pruning)**

Mingers (1987a), ağaç oluşturma aşamasında yapılan hesaplamalardan bir düğümün önemini veya gücünü tahmin etmeye dayanan bir yöntem geliştirmiştir. Bu budama yöntemi, kritik bir değer belirler ve kritik düğüm noktasına ulaşmayan düğümleri erteler. Büyük bir kritik değer seçilmesi durumunda, budamanın derecesi büyük, küçük seçilmesi durumunda küçüktür. Uygulamalarda genelde artan kritik değerler kullanılarak bir dizi budanmış ağaç üretilmektedir. Tek bir ağaç olması durumunda, maliyet karmaşıklık budamasına benzer bir yol seçilebilir (Mingers, 1989).

#### **1.5.1.3.6. Hataya dayalı budama (Error-based pruning)**

Hataya dayalı budama (EBP), test hata oranını tahmin etmede eğitim verisindeki ağacın bir düğümündeki hata oranını kullanmaktadır. EBP, hata oranının bir binom dağılımı gösterdiğini varsaymakta ve budamayı kontrol etmek amacıyla Belirlilik Faktörü'nü (Certainty factor-CF) kullanmaktadır. Belirlilik Faktörü, bir yapraktaki popülasyonun üzerinde oluşan hata olasılıklarının üst sınırını tahmin etmek için binom dağılımının güven sınırını kullanmaktadır (Hall ve ark., 2002).

#### **1.5.1.3.7. Optimal budama (Optimal pruning)**

Breiman ve ark.(1984), optimal budamanın matematiksel özelliklerini belirtmek ve doğrulamak için uygun bir terminoloji kullanarak, k adayları arasından özel olarak en iyi şekilde budanmış bir alt ağacı seçmek amacıyla bir algoritma geliştirmişlerdir (Breiman ve ark., 1984). Bohanec ve Bratko (1996) ve Almuallim (1996), farklı bir şekilde en iyi budamayı bulma konusunu incelemişlerdir. Bohanes ve ark. (1996), optimal budamayı garanti eden bir algoritma geliştirmişlerdir. Almuallim (1996) tek başına, hesaplama karmaşıklığı açısından optimal budamayı daha da geliştirmiştir.

Karar ağaçlarını sadeleştirme istekleri, gürültülü veriler ve budanmış ağaçlar için birbirlerinden farklıdır. Her ikisinde de ilk olarak, budanmamış karar ağaçlarının tamamen doğru olduğu varsayılmaktadır. Ancak gürültülü verilerden öğrenme yapılırken, ilk olarak karar ağacının yanlış olduğu ve uygun budamanın doğruluğu arttıracığı varsayılmaktadır (Almuallim, 1996; Bohanec ve Bratko, 1996; Patil ve ark., 2010).

#### **1.5.1.4. Sınıflandırma ve regresyon karar ağaçları**

##### **1.5.1.4.1. ID3 algoritması**

ID3 algoritması, Quinlan tarafından 1986 yılında geliştirilen klasik karar ağacı sınıflandırma yöntemlerinden biridir. ID3 algoritması, özellik seçim yöntemi olarak bilgi kazancını kullanmaktadır.

##### **1.5.1.4.2. C4.5 algoritması**

C4.5 algoritması, Quinlan tarafından geliştirilen ID3 algoritmasının genişletilmiş hali olup CART algoritmasına benzerdir. En uygun bölünmeyi seçmek için mümkün olan hiçbir düğüm kalmayana kadar, her bir karar düğümünü yinelemeli olarak ziyaret eden ve ikili bölme ile sınırlı olmayan bir karar ağacıdır. C4.5 algoritması, en uygun bölünmeyi seçmek için bilgi kazancı veya entropiyi kullanmaktadır (Larose, 2005).

##### **1.5.1.4.3. CART (Classification and regression tree) algoritması**

1984 yılında "CART-Sınıflandırma ve Regresyon Ağaçları", Leo Breiman, Jerome Friedman, Richard Olshen ve Charles Stone (BFOS) tarafından beraber yazılmış olup veri madenciliği, makine öğrenme, parametrik olmayan istatistikler ve yapay zekanın gelişiminde bir dönüm noktasıdır (Steinberg, 2009).

Sınıflandırma ve Regresyon Ağaçları (CART) yöntemi, hem regresyon hem de sınıflandırma problemleri için kullanılan özyinelemeli bir bölümlenme yöntemidir. En iyi kestirici için, çeşitli safsızlık veya çeşitlilik ölçümleri kullanılarak seçim yapılır. Amaç,

hedef deęişken ile ilgili olabildięince homojen olan alt gruplar oluřturabilmektir (Breiman ve ark., 1984).

Baęımlı deęişkenin kategorik olduęu durumlarda, "Sınıflandırma Aęacı" (Classification Tree - CT); sürekli olduęu durumlarda ise "Regresyon Aęacı" (Regression Tree - RT) olarak tanımlanır (Chang ve Wang, 2006; Kayri ve Boysan, 2008).

CART algoritmasında deęişkenler, kategorik veya sürekli olabilir. Baęımlı deęişkenin kategorik olduęu durumlarda, Gini, Twoing ya da Sıralı Twoing ölçüsünü kullanmaktadır. Sürekli olduęu durumlarda ise En Küçük Kareli Sapma (LSD) veya En Küçük Mutlak Sapma (LAD) seçilebilir (Alkhasawneh ve ark., 2014).

#### 1.5.1.4.4. CHAID (Chisquare-automatic-interaction-detection) algoritması

CHAID algoritması; verileri ayrıntılı homojen alt gruplara bölerek, baęımlı ve baęımsız deęişkenler arasında ve baęımsız deęişkenlerin birbirleriyle olan etkileşimlerini gösteren yapılardır (Doęan ve Özdamar, 2003).

CHAID algoritması, baęımlı ve baęımsız deęişkenler arasındaki ilişkiyi ölçmek için  $\chi^2$  test istatistięini kullanarak bu farklılıkları bulmaya çalışmaktadır (Agresti, 1990; Thomas ve Galambos, 2004). CHAID aęacı, tüm veri setiyle başlayarak, yinelemeli bir şekilde homojen alt gruplara bölünerek, iki ya da daha çok çocuk düęümün art arda oluřturulmasıyla meydana gelen bir karar aęacıdır (Çelik ve Yılmaz, 2017).

CHAID analizinde görece bir avantaj olarak; normallik, doğrusallık, varyansların homojenlięi gibi temel varsayımların yerine gelmiş olması gerekmemektedir. Veri setinin çok büyük olduęu durumlarda deęişkenler arası ilişkileri modellemek hususunda güvenilir sonuçlar vermektedir (Efe ve ark., 2000; Kayri ve Boysan, 2007). Aynı zamanda, CHAID algoritması, kayıp verileri dikkate almadan modelleme sürecini tamamlamaktadır (Agresti, 1990). Dięer bazı istatistiksel analizlere göre bir avantaj olarak, CHAID analizinde, baęımlı ve baęımsız deęişkenler; nominal,

ordinal ve aralıklı ölçek (interval) türünde olabilirler. Bağımsız değişkenlerin ölçek türünün aynı olması gerekmemektedir (Doğan ve Özdamar, 2003).

Literatürde, genel itibariyle CHAID analizine alternatif olarak sunulan Sınıflandırma ve Regresyon Ağacı (Classification and Regression Tree – CART) yöntemine kıyaslandığında, CART ikili yapıda ağaç oluştururken, CHAID iki ve ikiden fazla ağaç oluşturmaktadır (Albayrak ve Koltan Yılmaz, 2009).

CHAID başlangıçta sadece kategorik değişkenleri işlemek üzere tasarlanmış olmasına rağmen; nominal kategorik, sıralı kategorik ve sürekli bağımlı değişkenleri kullanabilen bir yöntemdir (SPSS, 1999).

#### **1.5.1.4.5. Exhaustive CHAID algoritması**

Exhaustive CHAID, Biggs tarafından CHAID algoritmasının zayıflıklarını gidermek için geliştirilmiştir. Exhaustive CHAID, benzer çiftleri tek bir çift kalıncaya kadar birleştirmeyi ve en önemli kategoriyi tahmin değişkeninin en iyi bölmesi olarak ele almayı önermiştir. Her bir tahmin değişkeni için mümkün olan tüm dağılımları daha ayrıntılı bir şekilde incelemeyi hedeflemektedir (Haciefendioğlu, 2012). CHAID algoritması, en son bölünmeyi test ettiğinden, en iyi bölmeyi bulması garanti değildir. Exhaustive CHAID, her bir tahmin değişkeni için arta kalan kategorileri sadece iki kategori kalıncaya kadar önemlilik düzeyine bakılmaksızın birleştirerek sorunu çözmeye çalışır (Alkhasawneh ve ark., 2014).

#### **1.5.1.4.6. QUEST (Quick-unbiased-efficient statistical tree) algoritması**

QUEST algoritması, veri madenciliği ve sınıflandırma problemleri için, ikili yapıda bölme yapan, bağımlı değişkenin sadece nominal yapıda olduğu karar ağacı algoritmasıdır. QUEST, tek değişkenli veya doğrusal kombinasyonlu bölmeler yapmaktadır. QUEST'in eşsiz özelliği, nitelik seçim yönteminin önyargıyı görmezden gelmesidir (Loh ve Shih, 1997; Türe ve ark., 2008; Alkhasawneh ve ark., 2014).

#### **1.5.1.5. Ağaç tabanlı topluluk yöntemleri**

Son zamanlarda arařtırmacılar tarafından, kümeleme ve sınıflama yapan çok sayıda ilgi çekici topluluk öğrenme yöntemleri kullanılmaktadır. Bunlardan en iyi bilinen iki yöntem, Boosting (Hızlandırma) ve Bagging (Torbalama) yöntemleridir. Boosting yöntemi, Freund ve Schapire tarafından, Bagging yöntemi ise Breiman tarafından önerilmiştir (Breiman 1996; Shapire ve ark., 1998; Liaw ve Wiener, 2002).

Bagging ve Boosting yöntemleri güçlü deneysel sonuçları ve teorik olarak performans garantisi dolayısıyla tercih edilmektedir (Kumari, 2012).

Bagging yöntemi, hassas eğitim örnekleri ve azalmayan (non-decreasing) öğrenme eğrisi ile kararsız ve zayıf sınıflar için kullanışlı bir yöntemdir. Boosting yöntemi ise, büyük örnek boyutları ve azalmayan öğrenme eğrileri ile basit sınıflandırıcıların sadece zayıf öğrencileri için kullanışlıdır (Kumari, 2012).

Çoklu sınıflandırıcılarından faydalanmak için kullanılan bu iki yöntem, eğitim sistemi hakkında farklı varsayımlara sahiptir. Bagging yönteminde, eğitim setindeki farklı sınıflara yol açan küçük değişiklikler nedeniyle öğrenme sisteminin kararlı olmasına gerek yoktur. Bu yöntemde, Breiman, “zayıf tahmincilerin daha da kötüye dönüşebileceğini” belirtmektedir. Öte yandan, Boosting yönteminde, zayıf tahminciler üreten öğrenme sistemlerinin kullanımı önlenemez (Quinlan, 2006).

Bagging ve Boosting yöntemleri, öğrenme sistemlerinin sınıflandırmadaki tahmin gücünü artırmak için geliştirilmiş yöntemlerdir. Her iki yöntem oylama ile birleştirilen bir dizi sınıflandırıcı oluşturur. Bagging yönteminde, veri setindeki bootstrap örneklerin tekrarlanırken, Boosting yönteminde ise eğitim örneklerinin ağırlıkları ayarlanır (Quinlan, 2006). Bu yöntemler, her bir sınıflandırıcıya ait farklı eğitim setleri elde etmek için yeniden örnekleme tekniğini kullanır (Maclin ve Opitz, 2013).

Bagging yöntemi, genel tahmini elde etmek için sonuçların basit ortalamasını alırken; Boosting yöntemi, değişik örneklemlere bir tahmin yöntemi uygulayarak elde edilen sonuçların ağırlıklandırılmış ortalamasını kullanmaktadır (Sutton, 2005).

#### **1.5.1.5.1. Boosting (hızlandırma) yöntemi**

Boosting (Hızlandırma) yöntemi, “bootstrap” topluluk yöntemi olup ilk olarak Schapire tarafından önerilmiştir. Boosting yöntemi, herhangi bir öğrenme



algoritmasının performansını geliştirmek için kullanılan genel bir yöntemdir. Bu algoritma, zayıf öğrencileri birleştirmesinden dolayı güçlü öğrenme kabiliyetine sahiptir. Yöntem, zayıf öğrenme algoritmalarının hata oranını önemli ölçüde azaltmak için kullanılabilir (Maclin ve Opitz,1997; Freud ve Schapire, 1999; Ferreira ve Figueiredo, 2012).

Boosting yöntemi, bir yöntemler ailesini kapsamaktadır. Yöntemlerin odak noktası bir dizi sınıflandırıcı üretmektir. Serinin her üyesi için kullanılan eğitim seti, serideki önceki sınıflandırıcıların performansına bağlı olarak seçilmektedir. Yöntemde; önceki sınıflandırıcılar tarafından yanlış tahmin edilen örnekler, doğru olarak tahmin edilen örneklerden daha sık seçilmektedir. Yöntem, mevcut topluluk performansının zayıf olduğu örnekleri doğru bir şekilde tahmin edebilme yeteneğine sahip topluluk elde etmek için yeni sınıflandırıcılar üretmeyi denemektedir (Maclin ve Opitz, 1997).

Boosting yöntemi, eğitim örneklerinin ağırlıklandırılmasıyla yinelemeli olarak oluşturulan sınıflandırıcıları birleştiren bir yöntemdir. Her bir adımda, önceki adımda yanlış sınıflandırılan durumlara ağırlık artışı verilerek, uygun ağırlık ile ayarlanmaktadır. Sonuç tahminleri, yinelemeli olarak üretilen tahmin sonuçlarının ağırlıklandırılmasıyla elde edilir. Boosting yöntemi, sınıflama için oluşturulmasına rağmen, zayıf öğrencilerin çalıştırılması için de uygulanabilmektedir (Sutton, 2005).

Boosting yönteminde ağaçların ardışık olduğu yani; birbirine bağlı olduğu durumlarda, önceden tahmin edicilerin hatalı tahmin ettiği noktalara fazladan ağırlık verilmektedir. Başka bir deyişle tahmin için ağırlıklandırılmış oy kullanılmaktadır (Breiman, 1996; Shapire ve ark., 1998; Liaw ve Wiener, 2002).

#### 1.5.1.5.1.1. Sınıflandırma problemleri için boosting algoritması

Girdi: Veri seti  $Z = \{z_1, z_2, \dots, z_N\}$  şeklinde olan  $z_1 = (x_1, y_1)$  ve  $x_1 \in \mathcal{X}$ veyi  $y_i \in \{-1, +1\}$ .

Çıktı :  $H: \mathcal{X} \rightarrow \{-1, +1\}$ .

1.  $Z$  örnekleri arasından,  $Z_1^*$ 'ı elde etmek için yer değiştirme olmaksızın  $L_1 < N$  olacak şekilde rastgele seçim yapılır.
2.  $Z_1^*$ 'deki zayıf öğrenciler çalıştırılarak  $H_1$  sınıfı elde edilir.

3.  $Z_2^*$ 'ı elde etmek için  $H_1$  sınıflandırıcısı tarafından hatalı sınıflanan örneklerin yarısı ile  $Z$  örnekleri arasından  $L_2 < N$  olacak şekilde seçim yapılır.
4.  $Z_2^*$ 'deki zayıf öğrenciler çalıştırılarak  $H_2$  sınıfı elde edilir.
5.  $Z_3^*$ 'ü elde etmek için  $H_1$  ve  $H_2$  sınıflandırıcıları tarafından kabul edilmeyen  $Z$  örneklemindeki tüm örnekler seçilir.
6.  $Z_3^*$ 'deki zayıf öğrenciler çalıştırılarak  $H_3$  sınıfı elde edilir.
7.  $H(x) = \text{sign}(\sum_{b=1}^3 H_b(x))$   
(1.12)

Eşitliği kullanılarak, oy çoğunluğu ile son sınıflandırıcı elde edilir. Algoritmada görüldüğü üzere; eğitim seti bölümler arasında yer değiştirme olmaksızın  $Z_1^*$ ,  $Z_2^*$  ve  $Z_3^*$  olarak rastgele üçe bölünmüştür. Verilen örneğe göre, eğer ilk iki sınıflandırıcı olan  $H_1$  ve  $H_2$  sınıfları sınıf etiketini kabul ederlerse, bu örnek geçerlidir. Aksi takdirde; örnek setinde yer alan  $H_1$  ve  $H_2$  sınıflarının kabul etmediği örnekler,  $H_3$  sınıfında kullanılır ve  $Z_3^*$  bölümünü tanımlar. Schapire'ye göre; bu öğrenme yöntemi, yinelemeli olarak kullanıldığında hata miktarını azaltmasından dolayı güçlüdür. Yani her öğrenci kendine ait hızlandırma süreci kurabilmektedir (Ferreira ve Figueiredo, 2012).

En çok kullanılan boosting algoritmaları arasında yer alan Adaboost algoritması Freud ve Schapire tarafından önerilmiştir. Farklı öğrenme algoritmalarının performansını geliştirmek için ikili ve çoklu sınıflandırma problemlerinde kullanılmaktadır. Regresyon problemlerinde  $f: x \rightarrow [0,1]$  ise Adaboost R algoritması uygulanmaktadır (Freud ve Schapire, 1995; Bertoni ve ark., 1997).

#### **1.5.1.5.1.2. Sınıflandırma problemleri için adaboost algoritması (Adaboost algorithm)**

Girdi:  $S = \{(x_1, y_1), \dots, (x_N, y_N)\}$  olarak etiketlenmiş  $N$  dizisine ait  $S$  örnekleme,

$S$  örneklemine ait  $D$  dağılımı,

$\mathcal{A}$ , Zayıf öğrenme algoritması (Weak learn)

$T$ , tamsayı ve iterasyonların özel sayısı.

Başlangıç:  $i = 1, 2, \dots, N$  için ağırlık vektörü  $w_i^1 = D(i)$ ;

$t = 1, 2, \dots, T$  için;

$$1. \ p^{(t)} = \frac{w^{(t)}}{\sum_{i=1}^N w_i^{(t)}} \text{başlayın.}$$

(1.13)

2.  $S$ 'den  $S^{(t)}$  örneklemini  $p^{(t)}$  dağılımı ile rastgele seçin.  $\mathcal{A}$  öğrenme algoritması ve  $h_t = \mathcal{A}_{S^{(t)}}$  hipotezini elde edin.  $h_t: \rightarrow [0, 1]$  olan bir hipotezi reddeden  $p^t$  dağılımı zayıf öğrenme olarak adlandırılır

$$3. \text{ Hatayı, } \varepsilon_t = \sum_{i=1}^N p_i^{(t)} |h_t(x_i) - y_i| \quad \text{hesaplayın}$$

(1.14)

$$4. \ \beta_t = \frac{\varepsilon_t}{(1-\varepsilon_t)} \quad \text{hesaplayın}$$

(1.15)

$$5. \text{ Yeni ağırlık vektörünü } w_i^{(t+1)} = w_i^{(t)} \beta^{1-|h^{(t)}(x_i)-y_i|}$$

(1.16)

olarak ayarlayın.

Çıktı hipotezi:

$$h_f(x) \begin{cases} 1 & \text{eğer, } \left( \sum_{t=1}^T \left( \log \frac{1}{\beta_t} \right) h_t(x) - \frac{1}{2} \sum_{k=1}^T \left( \log \frac{1}{\beta_t} \right) \right) \\ 0, & \text{aksi takdirde} \end{cases}$$

(1.17)

(Freud ve Schapire, 1995; Bertoni ve ark., 1997).

### 1.5.1.5.1.3. Regresyon problemleri için boosting algoritması (Adaboost R algorithm)

**Girdi:**  $S = \langle (x_1, y_1), \dots, (x_N, y_N) \rangle$  olarak etiketlenmiş  $N$  dizisine ait  $S$  örnekleme,

$S$  örnekleme ait  $D$  dağılımı,

$\mathcal{A}$ , Zayıf öğrenme algoritması (Weak learn)

$T$ , tamsayı ve iterasyonların özel sayısı

$\Delta$  bir gerçel sayı.

Başlangıç:  $i = 1, 2, \dots, N$  için ağırlık vektörü  $w_i^1 = D(i)$ ;

$t = 1, 2, \dots, T$  için;

1.  $p^{(t)} = \frac{w^{(t)}}{\sum_{i=1}^N w_i^{(t)}}$  başlayın. (1.18)

2.  $S$ 'den  $S^{(t)}$  örneklemini  $p^{(t)}$  dağılımı ile rastgele seçerek,  $\mathcal{A}$  öğrenme algoritması ve  $h_t = \mathcal{A}_{S^{(t)}}$  hipotezini elde edin

3. Hata

4.  $\varepsilon_t = \sum_{i=1}^N p_i^{(t)} H S (\|h_t(x_i) - y_i\| - \Delta)$   
(1.19)

Eğer  $\varepsilon_t > 1/2$  sonra  $T = t - 1$  ve döngü yarıda bırakılır.

5.  $\beta_t = \frac{\varepsilon_t}{(1-\varepsilon_t)}$  hesaplayın. (1.20)

6. Yeni ağırlık vektörü,

7.  $w_i^{(t+1)} = w_i^{(t)} \beta^{1-H S (\|h_t(x_i) - y_i\| - \Delta)}$  (1.21)

olarak ayarlayın.

Çıktı hipotezi:  $\alpha_t = \log \frac{1}{\beta_t}$  olduğunda;

$$h_f = \operatorname{argmax}_{y \in [0,1]^m} \sum \alpha_t H S (\Delta - \|h_t(x_i) - y_i\|) \text{ 'dir}$$

(1.22)

(Bertoni ve ark., 1997).

### 1.5.1.5.2. Bagging (torbalama) yöntemi

Bagging (Torbalama) yöntemi, bir öğrenme algoritmasının genelleme yeteneğini önemli ölçüde geliştirebilen etkili bir eğitim yöntemidir. Yöntem, makine öğrenme algoritmalarıyla birlikte kullanıldığında zaman kazandırmaktadır (Jiang ve ark., 2011).

Ayrıca; hata, standart hata ve parametrelerin güven aralıklarının tahmin edilmesinde popüler bir yöntemdir (Kumari, 2012).

Bagging yöntemi, tahminle ilgili varyansı azaltmak ve böylece tahmin sürecini geliştirmek için birçok sınıflandırma yöntemi ve regresyon yöntemiyle kullanılabilen bir tekniktir. Bagging yöntemi, hem sınıflandırma ve regresyon ağaçlarının tahmin gücünü hem de kararlılığını geliştirmekte kullanılmaktadır. Ancak; yöntemin kullanımı, ağaç tabanlı tahminlerin geliştirilmesi ile sınırlı değildir. Yöntem, birçok alanda tahminleri geliştirmek için uygulanabilmektedir (Sutton, 2005).

Bagging yöntemi, her sınıflandırıcıyı eğitim setinin rastgele yeniden dağıtımına üzerine eğiterek, topluluk için bireyler yaratmaktadır. Her sınıflandırıcının eğitim seti, yenisiyle değiştirilerek rastgele bir taslak oluşturulur. N, orijinal eğitim setinin büyüklüğüdür. Orijinal örneklerin birçoğu ortaya çıkan eğitim setinde tekrarlanabilirken, diğerleri dışarıda bırakılabilir. Topluluktaki her bir sınıflandırıcı, eğitim setinin farklı bir rastgele örnekleme ile üretilir (Maclin ve Opitz, 1997).

Bagging yönteminde ana fikir, çok gürültülü ancak hemen hemen yansız modellerde, ortalamaların alınması ve dolayısıyla varyansın azaltılmasıdır. Yöntem, karar ağaçları eğer yeterli oranda büyümüşlerse ve nispeten düşük hataya sahiplerse veri setinde yer alan karmaşık ilişkileri yakalama şansına sahiptir (Akar, 2013).

Bagging yöntemi, orijinal veri setinden bootstrap örnekleri üreten, her bir örnekten bir tahmin yapan ve ortalamaları alarak karar veren genel toplulaştırma planıdır. Problemin karmaşıklığı ve ölçeği nedeniyle tek bir adımda iyi bir model oluşturmanın imkânsız olduğu çok boyutlu veri setlerinde, kararlı olmayan tahminleri geliştirmek için etkili hesaplama yöntemlerinden biridir (Biau ve Scornet, 2016).

Bagging ya da Bootstrap örnekleme, birçok sınıflandırma yöntemini birarada kullanabilen ve tahmin varyansını azaltmak için regresyon yöntemini kullanan bir yöntemdir. Bu nedenle, tahminleme süreci geliştirilebilmektedir. Yöntem özellikle, ağaçların yüksek varyans ve düşük hata oranına sahip olduğu durumlarda daha iyi çalışmaktadır. Burada, eğitim verilerinin bootstrap örneklemlerine çeşitli tahmin yöntemleri uygulanmaktadır. Ortalamaların alınması nedeniyle varyans azaltılarak elde edilen regresyon problemlerinde ortalamaları alınarak ve sınıflandırma problemlerinde ise basit oylama yapılarak tüm tahminlerin sonuçları birleştirilmektedir (Sutton, 2005).

Bagging yönteminde, ardışık ağaçlar birbirine bağlı değildir. Ağaçların her biri bootstrap yöntemi ile orijinal veri setinden bağımsız olarak seçilmektedir. Sonuç olarak; salt çoğunluğa sahip oy alınmaktadır (Breiman 1996; Shapire ve ark., 1998; Liaw ve Wiener, 2002).

#### 1.5.1.5.2.1. Bagging algoritması

1.  $(X_1, Y_1), \dots, (X_n, Y_n)$  verilerinden yerine koyma yöntemi ile n defa rastgele  $(X_1^*, Y_1^*), \dots, (X_n^*, Y_n^*)$  bootstrap örnekleme oluşturulur.
2. Eklenti (plug-in principle) ilkesiyle  $\hat{g}^*(.)$  bootstrap tahmincisi aşağıda verilen eşitlik ile hesaplanır.

$$\hat{g}^*(.) = h_n((X_1^*, Y_1^*), \dots, (X_n^*, Y_n^*))(. ) \quad (1.23)$$

3. M, 50 ya da 100 olarak seçilir. M kez birinci ve ikinci adımlar tekrar edilir.  $\hat{g}^{*k}(.) (k = 1, \dots, M)$ . Bagging tahmincisi,

$$\hat{g}_{Bag}(. ) = M^{-1} \sum_{k=1}^M \hat{g}^{*k}(.)$$

(1.24)

Eşitliğiyle hesaplanmaktadır.

Teorik olarak ise, bagging tahmincisi;

$$\hat{g}_{Bag}(. ) = \mathbf{E}^*[\hat{g}^*(.)]'dir$$

(1.25)

(Bühlmann, 2018).

Eşitlikteki teorik miktar  $M = \infty$ 'a tekabül eder. Uygulamada M, Monte Carlo yaklaşımının doğruluğunu düzenler. Aksi durumda, bagging için parametre ayarlaması gösterilmesine gerek yoktur (Bühlmann, 2018).

#### 1.5.2. Yapay sinir ağları

Yapay Sinir Ağları (YSA), insan beynindeki biyolojik sinir ağlarından esinlenilerek ortaya çıkarılan bir bilgi işleme sistemidir (Fausett, 1994). YSA, insan beyninin çalışma prensibine dayanarak yeni bilgiler keşfedebilme, sayısız değişkenle çalışabilme gibi özelliklere sahip bilgisayar sistemleridir. Birçok bilim dalındaki araştırmacılar; desen tanıma tahmin, optimizasyon, ilişkisel bellek ve kontrol alanlarında karşılaşılan sorunları çözmek için YSA kullanmaktadır. Geleneksel yaklaşımların, bu sorunları çözmeye başarılı uygulamaları olmalarına rağmen, YSA kadar heyecan verici alternatifler sunamamaktadırlar (Jain ve Mao, 1996).

YSA; her bir işlemcinin hesaplama gücü ve hafızasının çok basit bir yapıya sahip olması nedeniyle, doğrusal olmayan cihazlara uyarlanabilme özelliğine sahiptir. Bundan dolayı; YSA, gerçek hayatta karşılaşılan birçok problemi çözmek için, doğrusal olmayan modellerin tahmin edilmesinde kullanılabilir (Nascimento, 1994).

YSA, günlük problemlere kolaylıkla uygulanmasından dolayı, son zamanlarda yaygın olarak kullanılmaktadır. Klasik istatistik yöntemlerin cevap bulamadığı, yüksek dereceli doğrusal olmayan ilişkileri belirleyebilme yeteneğine sahiptir (Cganh ve ark., 2001; Akbilgiç, 2011).

YSA, klasik istatistik yöntemlerle karşılaştırıldığında hiçbir varsayım gerektirmemesi nedeniyle tercih edilmektedir. Bu yöntemde; aykırı değer, normallik, çoklu bağlantılılık sorunu (multi-collinearity) gibi varsayımlar dikkate alınmaz (İnal ve Turabik, 2016). Bu yüzden, YSA parametrik olmayan bir yöntem olarak kabul edilebilir (Comrie, 1997).

YSA; sınıflama (classification), kümeleme (clustering), tahminleme (prediction) başarılı olan matematiksel bir modeldir (Priddy ve Keller, 2005; Hamzaçebi, 2011). YSA, bağımsız değişkenleri bağımlı değişkenler ile olan ilişkilerine bakarak doğrudan, karmaşık ve doğrusal olmayan modeller oluşturur (Güler ve Übeyli, 2003). Eksik verisi bulunan veri tabanlarında YSA, modelleme ve karar verme işlemlerinde yüksek performansa sahiptir. Bununla birlikte, farklı eğitim algoritmalarıyla modelin performansının daha da arttığı görülmektedir (Güler ve Übeyli, 2003; Öztemel, 2012).

YSA'nın çalışmasına esas teşkil eden en küçük birimler, yapay sinir hücresi ya da işlem elemanı olarak isimlendirilir (Kaynar ve Taştan 2009).

Yapay sinir ağı modellerinin uyarlanabilir parametreleri, işlemcileri birbirine bağlayan bağlantılardır. Bu, biyolojik sinir ağlarındaki "öğrenmeye" benzerdir (Nascimento,1994).

### 1.5.2.1. Biyolojik sinir sistemi

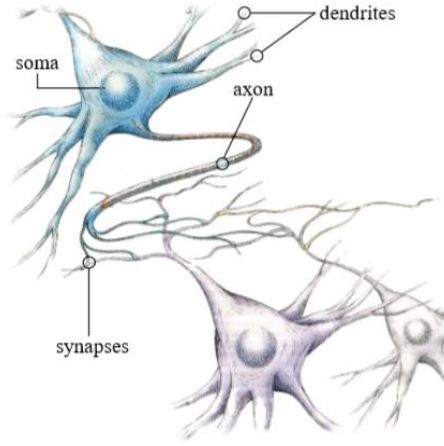
İnsan sinir sistemi, “Merkezi Sinir Sistemi” (Central Nervous System’-CNS) ve “Çevresel (Periferik) Sinir Sistemi” (Peripheral Nervous System- PNS)’nden oluşur. Merkezi sinir sistemi, beyin ve omurilik, periferik sinir sistemi ise beyin ve omurilik dışındaki sinir sisteminden oluşur (Nascimento, 1994).

İnsan vücudunda merkezi sinir sistemi üç bölümden oluşmaktadır. Bunlar: reseptörler, sinir ağı ve efektörler (dengeleyici)’dir. Sinir sistemi, girdilerin duyuşal reseptörler tarafından girişlerinin sağlandığı, geniş bir elektriksel anahtarlama ağı olarak ifade edilebilir. Bu tür reseptörler, güç çeviriciler olarak hareket eder ve vücut içinden veya dış çevreyi gözlemleyen duyu organlarından sinyaller üretir. Bilgi, periferik sinir sistemi tarafından merkezi sinir sistemine aktarılır, daha sonra analiz edilir ve işlenir. Merkezi sinir sistemi gerekirse, istenen eylemleri yürütecek olan efektörlere ve ilgili motor organlara sinyaller gönderir. Buna göre; insan sinir sistemi, bazı vücut fonksiyonlarını düzenlemek için, vücut içerisine ve dışarısına geri bildirim sağlayan, kapalı çemberli kontrol sistemi olarak tanımlanabilir (Zurada, 1992; Gumma, 2004).

Merkezi sinir sisteminin temel yapı taşı, biyolojik nöronlardır (Gumma, 2004). Biyolojik nöronlar, vücudun çeşitli bölümlerini güçlü bir şekilde birbirine bağlayan, insan beyninin bilgi işleme elemanlarıdır. Biyolojik nöronlar; dendrit, soma ve axon olmak üzere üç ana elemandan oluşmaktadır. Dendrit, somaya elektrik sinyali gönderen, birçok dalı olan hücre uzantılarıdır. Soma, nöronun merkezi bölümüdür. Temel görevi, alınan tüm sinyalleri işlemektir. Aksonun görevi ise, çıkış sinir sinyallerini somadan uzaklaştırmaktır. Çoğu nöronlar tek aksona sahip olmasına rağmen, hedef nöronların çok olduğu durumlarda, genişleyen dalları sayesinde iletişimi sağlayabilirler. Sinapslar, hedef nöronlar ile iletişimi sağlayan kimyasal sinir taşıyıcılarıdır (Sospedra, 2011).

Biyolojik sinir ağlarında bilgi, sinapslar olarak adlandırılan farklı nöronlar arasındaki temas noktalarında saklanır (Rojas, 1996).

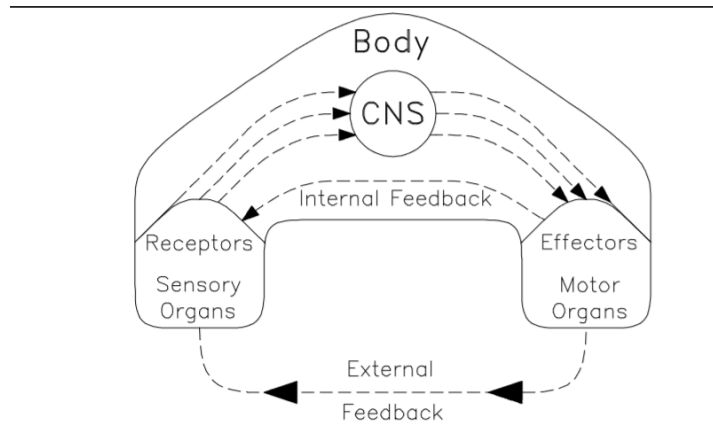




Şekil 1.2. Biyolojik nöronun yapısı (Sospedra, 2011).

### 1.5.2.2. Sinir hücresi (Neuron)

İnsan beyninde, yaklaşık olarak,  $10^{11}$  adet nöron olarak adlandırılan temel sinir hücresi bulunmaktadır. Bu nöronların her biri, yaklaşık olarak  $10^3$  ila  $10^4$  kadarı diğer nöronlara bağlıdır ve bu nedenle insan beyninde  $10^{14}$  ila  $10^{15}$  kadar bağlantı olduğu tahmin edilir. Nöron, sinir sisteminin temel yapı taşıdır ve nöronların birçoğu beyinde bulunur (Nascimento, 1994).



Şekil 1.3. Bir kapalı devre kontrol sistemi (Nascimento, 2011).

Nöron, beynin temel birimi olup tek başına bir analog mantıksal işlem birimidir. Nöronlar, iki ana tipten oluşur. Bunlar; lokal işlem yapan aracı nöron hücreleri ve çıkış

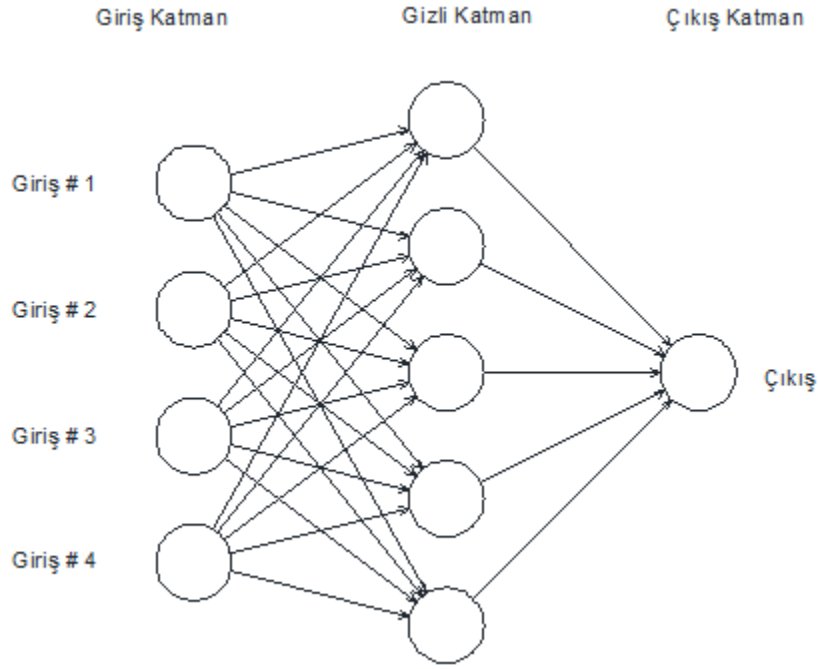
hücreleridir. Lokal işlem yapan aracı nöron hücreleri, yaklaşık olarak 100 mikrondan fazla giriş ve çıkış bağlantısına sahiptirler. Çıkış hücreleri, beynin farklı bölgelerini birbirine, kas veya duyu organları beyne bağlayan hücrelerdir (Beale ve Jackson, 1990).

### **1.5.2.3. Yapay sinir hücresi (Artificial neuron)**

Yapay sinir hücresi, biyolojik sinir hücresine dayalı olarak modellenen en temel hesaplama birimidir. Böyle bir nöron, temel olarak, her biri bir bellekle (ağırlık) ilişkilendirilmiş bir dizi girişten oluşur. Ancak; biyolojik sinir hücrelerinin doğru hesaplama gücü, harici paralel süreç işleme yeteneklerine dayanmaktadır. Birden çok sinir hücresiyle bağlantı kurması, yapay sinir ağlarının anahtar bir özelliğidir (Gumma, 2004). Yapay nöronların davranışları biyolojik nöronların davranışlarına benzemektedir (Sospedra, 2011).

### **1.5.2.4. Yapay sinir ağları mimarisi (Artificial neural networks architecture)**

Yapay sinir ağları, birbiriyle bağlantılı, ancak; basit bilgi işlem elemanları (veya yapay nöronlar) kullanarak zor problemleri çözebilen, büyük ölçüde paralel bir yapıya sahiptir. Çoğu araştırma, geri yayılma sinir ağlarına dayanmaktadır (Yeh, 1998).




Şekil 1.4. Basit sinir ağı yapısı (Cilimcovic, 2018).

Şekil 1.4. basit sinir ağı yapısını temsil etmektedir. Şekil; bir giriş, bir çıkış ve birden fazla gizli katmandan oluşur. Giriş katmanından gelen her düğüm, gizli katmandaki bir düğüme bağlanır ve gizli katmandaki her düğüm, çıkış katmanındaki bir düğüme bağlanır. Her bağlantıda genellikle bir miktar ağırlık vardır. Giriş katmanı, ağdan beslenen ham bilgiyi temsil eder. Ağın bu bölümü asla değerlerini değiştirmeyerek, ağdaki her bir girişi kopyalar ve gizli katmandaki düğümlere gönderir. Gizli katman, giriş katmanından gelen verileri alarak, bunları ağırlıklandırır ve elde edilen yeni değeri çıkış katmanına gönderir. Aynı zamanda; gizli katman ve çıkış katmanı arasındaki bağlantı noktasından bir miktar ağırlıkla değiştirebilir. Çıkış katmanı aşamasında, gizli katmandan alınan bilgi işlenerek bir çıktı üretilir. Bu çıktı, aktivasyon fonksiyonu tarafından işlenir (Cilimcovic, 2018).

#### 1.5.2.5. Yapay sinir ağlarının modeli (Model of artificial neural networks)

Bir nöron modeli oluşturmak için, son yıllarda, dikkate değer çalışmalar yapılmaktadır. Sinirle ilgili bağlantılar büyük ölçüde insan beynine benzemektedir. Basit bir YSA modeli, Şekil 1.5' te gösterildiği gibidir.

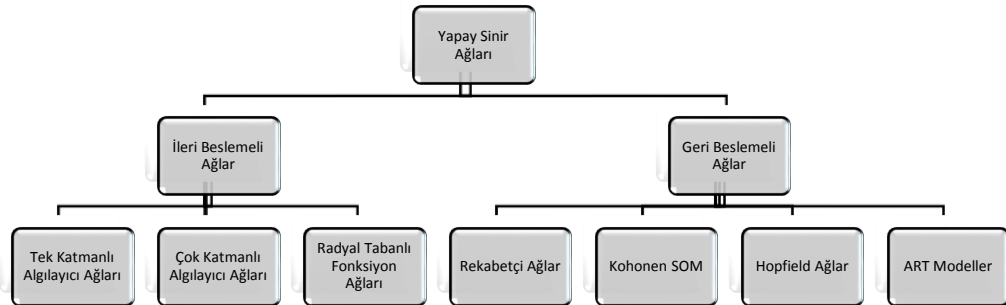


Şekil 1.5. Yapay sinir ağlarının temel modeli (Mehta ve ark., 2007).

### 1.5.2.6. Yapay sinir ağlarının sınıflandırılması (Classification of artificial neural networks)

#### 1.5.2.6.1. YSA'ların ağ yapılarına göre sınıflandırılması (Classification of ANNs by network structures)

YSA, yapay sinir hücrelerinin çeşitli şekillerde bağlanmasından meydana gelir ve katmanlar şeklinde düzenlenir. Yapılarına göre yapay sinir ağları; ileri beslemeli yapay sinir ağları (Feedforward Neural Networks) ve geri beslemeli yapay sinir ağları (Back Propagation Networks) şeklinde 2 grupta incelenmektedir.




Şekil 1.6. Yapay sinir ağlarının sınıflandırılması (Jain ve Mao, 1996).

### 1.5.2.6.1.1. İleri beslemeli ağlar (Feedforward neural networks)

İleri beslemeli topolojiye sahip yapay sinir ağlarında; bilgi akışı, girişten çıkışa doğru geri dönüşsüz, sadece tek yönde ilerlemeye müsaade etmektedir. Bu ağlarda; katman sayısı, bireysel yapay sinir ağlarında kullanılan transfer fonksiyonunun türü veya bireysel yapay sinir ağları arasındaki bağlantı sayısı üzerinde herhangi bir sınırlama yoktur. En basit ileri beslemeli yapay sinir ağı sadece doğrusal ayrılabilir problemleri öğrenebilme yeteneğine sahip tek bir algılayıcıdır (Krenker ve ark., 2011).

İleri beslemeli YSA'da, bir katmandaki hücrelerin çıkışları bir sonraki katmana ağırlıklandırılmak suretiyle girdi olarak verilir. Giriş katmanına alınan bilgiler, değişikliğe uğramadan gizli katmanda yer alan hücrelere iletilir (Rojas, 1996, Ataseven, 2016).



Şekil 1.7. İleri beslemeli ağlar (Hamzaçebi ve Kutay, 2004).

Şekil 1.7'de görüldüğü üzere, ileri beslemeli ağlarda, giriş katmanında  $n$  adet, gizli katmanda  $p$  adet ve çıkış katmanında  $m$  adet nöron bulunmaktadır. Her bir katmandaki nöronlar arasındaki bağlantıların ağırlıklarının düzenlenmesi ile ağın eğitimi gerçekleştirilir (Hamzaçebi ve Kutay, 2004).

### 1.5.2.6.1.2. Geri beslemeli ağlar (Back propogation networks)

Geri beslemeli ağlarda, bilgi akışı çıkıştan girişe doğru olup ağ yapısında geri besleme olanağı mevcuttur (Ulusoy, 2010). Geri beslemeli ağlarda, genellikle

gözetimsiz öğrenme kuralları uygulanmaktadır (Ataseven, 2016). Bu ağlar, örüntü tanımadaki mükemmel performansı ve klasik istatistiksel tekniklerin yerine çok sayıda değişken içeren doğrusal olmayan ilişkilerin modellenmesi nedeniyle araştırmacılar tarafından ilgi görmektedir. Bir geri yayılma sinir ağı modelinin geliştirilmesi temel olarak birkaç aşama içerir. İlk olarak, sinir ağı modeli için giriş parametreleri olarak kullanılacak değişkenlerin tanımlanması gerekmektedir. Giriş parametrelerinin sayısını en aza indirmek için, bazen modeldeki en önemli değişkenleri tanımlamak için istatistiksel yöntemler kullanılır. Bir sonraki aşama, sinir ağını eğitmek ve test etmek için kullanılacak verilerin toplanmasından ibarettir. Bu, giriş modellerini ve beklenen (hedef çıktı) çözümü içeren bir veri seti gerektirir. Eğitim seti, sinir ağının bitmiş uygulamada karşılaşması muhtemel olan problemin farklı özelliklerini içeren verilerin temsili bir örneğini sağlamalıdır. Büyük bir eğitim seti, doğrusal olmayan fonksiyonun düşük hızda örnekleme yapma riskini azaltır ancak eğitim süresini artırır (Goh, 1995).

#### **1.5.2.6.1.3. Tekrarlayan yapay sinir ağları (Recurrent artificial neural networks)**

Tekrarlayan topolojiye sahip yapay sinir ağları, backloops (geri döngü) ile ilgili bir sınırlama olmaksızın ileri beslemeli yapay sinir ağlarına benzemektedir. Bu durumda; bilgi akışı, artık sadece bir yönde iletilmeyip ayrıca geriye doğru da iletilir. Tekrarlayan yapay sinir ağları, herhangi bir girdi dizisini işlemek için dâhili belleğini kullanabilir. Tekrarlayan yapay sinir ağının en temel topolojisi, her temel yapı bloğunun (yapay nöron) tüm diğer temel yapı taşlarına doğrudan doğruya bağlandığı tam tekrarlı yapay sinir ağlarıdır. Diğer tekrarlayan yapay sinir ağlarına, Hopfield, Elman, Jordan, çift yönlü ve sadece özel durumları tekrarlayan yapay sinir ağları örnek gösterilebilir (Krenker ve ark., 2011).

#### **1.5.2.6.2. Öğrenme yöntemlerine göre sınıflandırılması**

##### **1.5.2.6.2.1. Gözetimli öğrenme (Supervised learning)**

Gözetimli öğrenme, YSA'ya bir dizi eğitim örneği sunan ve harici bir öğretmene ihtiyaç duyan bir tür öğrenme biçimi olarak ifade edilebilir. Her örnek, girdi modeli ve

ağ tarafından üretilecek olan istenen çıktı modelini içerir. Ağ, gerçek çıkışı belirler ve eğitim örneğinden istenen çıktıyla karşılaştırır. Ağdan gelen çıktı, eğitim örneğinde belirtilen istenen çıktıdan farklıysa, ağ ağırlıkları değiştirir. Gözetimli öğrenme yöntemlerinden en popüler olanı geri yayılım yöntemidir (Negnevitsky, 2005).

Gözetimli öğrenmede, her bir model için doğru hedef çıktı değerlerinin (y) bilindiği varsayılır. Öğrenme (eğitim) süreci, istenilen çıktı modelini oluşturmak için YSA'nın ağırlıklarının en uygun şekilde ayarlanması için bir çeşit geri besleme içerir (Gumma, 2004).

#### **1.5.2.6.2.2. Gözetimsiz öğrenme (Unsupervised learning)**

Gözetimsiz öğrenmede; ortamdaki çıktıların ne olması gerektiği veya doğru olup olmadığı ile ilgili herhangi bir geri bildirim bilgisi sağlayacak öğretmene ihtiyaç duyulmamaktadır. Ağ, giriş verileri içindeki model özelliklerini, doğruluğunu, korelasyonunu veya girdi verileri içindeki uygun kategorilere nasıl sınıflandırabileceğini kendisi için keşfetmelidir. Ayrıca; bu özellikleri keşfederken, ağın kendi parametrelerinde değişime uğrayan çıktıları için kodlarını okumalıdır. Bu sürece kendini organize etme denir (Gumma, 2004; Negnevitsky, 2005).

Gözetimsiz öğrenme; beynin nöro-biyolojik organizasyonu takip etme eğilimindedir. Denetlenmeyen öğrenme algoritmaları, hızlı öğrenmeyi amaçlar. Aslında, kendi kendini organize eden sinir ağları, geri yayılım ağlarından çok daha hızlı öğrenirler ve böylece gerçek zamanda kullanılabilirler (Negnevitsky, 2005).

Gözetimsiz öğrenme; eğitim veri kümesindeki her bir girdi modeli ile ilişkili doğru bir cevap gerektirmemektedir. Verilerdeki temel yapıyı veya veri modelleri arasındaki ilişkileri araştırır ve bu ilişkilere bakarak modelleri düzenler (Jain ve Mao, 1996).

#### **1.5.2.6.2.3. Takviyeli öğrenme (Reinforcement learning)**

Takviyeli öğrenme, ortamdaki bazı geri bildirimler alması sebebiyle, gözetimli öğrenmenin bir biçimi olarak kabul edilebilir. Burada söz konusu geri bildirim, öğretici olmaktan ziyade sadece değerlendircidir (Gumma, 2004).

### 1.5.2.6.3. Öğrenme algoritmalarına göre sınıflandırılması

#### 1.5.2.6.3.1. Geri yayılım algoritması (Backpropagation algorithm)

Geri yayılım algoritmasının ardındaki fikir oldukça basittir. Sinir ağı çıkışı istenen çıktıya göre değerlendirilir. Sonuçlar tatmin edici değilse; bağlantı, katmanlar arasındaki ağırlıklar ile düzeltilir ve hata yeterince küçük olana kadar tekrarlanır (Çilimcovic, 2018).

Geriye yayılım ağlarında kullanılan algoritma aşağıda verilen eşitliklerle gösterilmiştir.  $\Delta w$ , ağırlık değişimleri;  $\eta$  öğrenme katsayısı;  $\alpha$  ise momentum katsayısını göstermektedir (Üstün ve Yıldız, 2009).

$$E(k) = \frac{1}{2}e^2(k), \quad E_{ort} = \frac{1}{K} \sum_{k=1}^K E(k) \quad (1.26)$$

$$e(k) = y_d(k) - y_a(k) \quad (1.27)$$

$$\Delta w_{st}(k) = \alpha_{st} \Delta_{st}(k-1) + \eta_{st} \left[ -\frac{\partial E}{\partial w_{st}} \right] \quad (1.28)$$

$$\Delta w_{rs}(k) = \alpha_{rs} \Delta_{rs}(k-1) + \eta_{rs} \left[ -\frac{\partial E}{\partial w_{rs}} \right] \quad (1.29)$$

$$\Delta w_{pr}(k) = \alpha_{pr} \Delta_{pr}(k-1) + \eta_{pr} \left[ -\frac{\partial E}{\partial w_{pr}} \right] \quad (1.30)$$

$$w_{st}(k+1) = w_{st}(k) + \Delta w_{st}(k) \quad (1.31)$$

$$w_{rs}(k+1) = w_{rs}(k) + \Delta w_{rs}(k) \quad (1.32)$$

$$w_{pr}(k+1) = w_{pr}(k) + \Delta w_{pr}(k) \quad (1.33)$$

Eğitim k kez tekrarlandığında, nöronun vermesi istenilen değer  $d_i$ , çıkış katmanında yer alan i'inci nöronun değeri  $y_i$  olmak üzere i'ninci nörona ait hata terimi aşağıda verilen eşitlikte verilmiştir.

$$e_i = d_i - y_i(k) \quad (1.34)$$

Yapay Sinir Ağlarında, çıkış katmanında yer alan her nörona ait hata sinyallerinin kareler toplamından meydana gelmiş olan bir uygunluk fonksiyonu bulunmaktadır (Karadeniz ve ark., 2001).



Uygunluk fonksiyonu;

$$E = \frac{1}{2} \sum_1 e_i^2(k) = \frac{1}{2} \sum_1 (d_i - y_i(k))^2 \quad (1.35)$$

eşitliği ile gösterilmektedir (Karadeniz ve ark., 2001).

### 1.5.2.6.3.2. İleri beslemeli algoritma (Feed-forward algorithm)

İleri besleme algoritmasında girişten çıkışa doğru tek yönlü bir ilerleme söz konusudur. Her bir girdi verisi ikilisi için ağırlık değerleri Eş. 1.36' da verilmiştir. Etkinlik fonksiyonlarına bağlı olarak, sırasıyla (1.37), (1.38) ve (1.39)'daki eşitlikler kullanılarak, en son adımda ağırlık gerçek çıkış değeri,  $y_a = y_t$  eşitliği ile hesaplanır (Üstün ve Yıldız, 2009).

$$x_p = \{x_1, x_2\}, y_p = x_p \quad (1.36)$$

$$x_y = \sum_{p=0}^P y_p \cdot w_{pr} \text{ ve } y_r = y_n(x_r) \quad (1.37)$$

$$x_s = \sum_{r=0}^R y_r \cdot w_{rs} \text{ ve } y_s = y_n(x_s) \quad (1.38)$$

$$x_t = \sum_{s=0}^S y_s \cdot w_{st} \text{ ve } y_t = y_n(x_t) \quad (1.39)$$

### 1.5.2.6.3.3. Delta-bar-delta algoritması (Delta-bar-delta algorithm)

Delta-Bar-Delta algoritması (DBD), ayrılma olmaksızın güncellemelerin ne kadar büyük olacağını belirlemek için önsel bilgilerden türetilen ağırlıkları kullanan bir algoritmadır. Bu algoritma, tipik olarak belirli bir ağırlığın gradyanı hakkında bazı tarihsel bilgileri kullanır (Otair ve Salameh, 2016).

Bu algoritma; YSA'lardaki ağırlıkların yakınsama hızını geliştirmek için kullanılan, keşifsel bir yaklaşımdır. Ağırlıklar, aşağıdaki eşitlik ile güncelleştirilir (Sadeghkhanı ve ark., 2013).

$$w(k+1) = w(k) + \alpha(k)\delta(k) \quad (1.40)$$

Burada;  $\alpha(k)$ , her bir bağlantı için atanan öğrenme katsayısıdır.  $\delta(k)$ , her bir bağlantının öğrenme katsayılarının artırılması ve azaltılması için kullanılan ağırlık değişimlerinin eğim bileşenidir.  $\bar{\delta}(k)$  ise ağırlıklı ortalama olup aşağıdaki eşitlik ile hesaplanmaktadır.

$$\bar{\delta}(k) = (1 - \theta)\delta(k) + \theta\delta(k - 1) \quad (1.41)$$

$\theta$ , konveks ağırlık vektörüdür. Öğrenme katsayısı değişimi ise;

$$\Delta\alpha(k) = \begin{cases} \kappa & \bar{\delta}(k - 1)\bar{\delta}(k) > 0 \\ -\varphi\alpha(k)\bar{\delta}(k - 1)\bar{\delta}(k) & \bar{\delta}(k - 1)\bar{\delta}(k) < 0 \\ 0, & \text{aksi taktirde} \end{cases} \quad (1.42)$$

Eşitliğiyle hesaplanmaktadır.  $\kappa$ , sürekli öğrenme katsayısı artırma faktörü;  $\varphi$  ise sürekli öğrenme katsayısı küçültme faktörüdür (Sadeghkhanı ve ark., 2013).

#### 1.5.2.6.3.4. Genişletilmiş delta-bar-delta algoritması (Extended-delta-bar-delta algorithm)

Genişletilmiş Delta-Bar-Delta algoritması (EDBD), Delta-Bar-Delta algoritmasının genişletilmiş halidir. Yapay Sinir Ağlarının eğitim zamanının azaltılması esasına dayanmaktadır (Sadeghkhanı ve ark., 2013). EDBD algoritması, DBD tabanlı ağların, momentum terimlerinin sezgisel olarak ayarlanmasında uygulanır. Momentum, ağırlık değişimlerine eklenen ve önceki ağırlık değişimleri ile orantılı olan bir terimdir. Bu algoritma, pozitif öğrenme eğilimlerini güçlendirmek ve salınımları azaltmak için tasarlanmıştır (Otair ve Salameh, 2016).

GDBD algoritmasında, ağırlıklar;

$$w(k + 1) = w(k) + \Delta w(k)$$

(1.43)

Eşitliği ile gösterilir. Ağırlık değişimleri ise,

$$\Delta w(k+1) = \alpha(k)\delta(k) + \mu(k)\Delta w(k) \quad (1.44)$$

Eşitliğiyle hesaplanmaktadır. Burada;  $\alpha(k)$ , öğrenme katsayısı ve  $\mu(k)$  momentum katsayılarıdır.

Öğrenme katsayıları değişimi şu şekilde yazılabilir;

$$\Delta\alpha(k) = \begin{cases} \kappa_\alpha \exp(-\gamma_\alpha |\bar{\delta}(k)|) & \text{if } \bar{\delta}(k-1)\bar{\delta}(k) > 0 \\ -\varphi_\alpha \alpha(k) & \text{if } \bar{\delta}(k-1)\bar{\delta}(k) < 0 \\ 0, & \text{aksi taktirde} \end{cases} \quad (1.45)$$

Burada;  $\kappa_\alpha$ , sürekli öğrenme katsayısı ölçek faktörü;  $\exp$ , üstel fonksiyon;  $\varphi_\alpha$ , sürekli öğrenme katsayısı küçültme faktörü ve  $\gamma_\alpha$  ise sürekli öğrenme üstel katsayı faktörünü göstermektedir (Sadeghkhanı ve ark., 2013).

Momentum katsayısı değişimi şu şekilde yazılabilir:

$$\Delta\mu(k) = \begin{cases} \kappa_\mu \exp(-\gamma_\mu |\bar{\delta}(k)|) & \text{if } \bar{\delta}(k-1)\bar{\delta}(k) > 0 \\ -\varphi_\mu \mu(k) & \text{if } \bar{\delta}(k-1)\bar{\delta}(k) < 0 \\ 0, & \text{aksi taktirde} \end{cases} \quad (1.46)$$

$\kappa_\mu$ , sürekli öğrenme katsayısı ölçek faktörü;  $\exp$ , üstel fonksiyon;  $\varphi_\mu$ , sürekli momentum katsayısı küçültme faktörü ve  $\gamma_\mu$  ise sürekli momentum katsayısı üstel faktörünü göstermektedir (Sadeghkhanı ve ark., 2013).

#### 1.5.2.6.3.5. Hızlı yayılım algoritması (QuickProp algorithm)

Quickprop, yakınsama oranı çok hızlı olan en popüler hızlı öğrenme algoritmalarından biridir. Bununla birlikte, yerel bir minimumda kolayca tuzağa düşürülür ve böylece küresel minimuma yaklaşamaz. Quickprop algoritması, Backpropagation (BP) algoritmasının yakınsamasını arttırmak için geliştirilmiştir. Bu

algoritma, BP'nin gradyan fonksiyonunu kullanmak yerine, ilk olarak mevcut ağırlıkları güncellemek için genel hatanın birinci mertebeden türevini alır. Minimum konumu tahmin etmek için ağırlık uzayındaki hata yüzeyi eğiminin ardışık değerlerini kullanır. Ardından ağırlıkları doğrudan bu minimum seviyeye doğru hareket edecek şekilde değiştirir. Quickprop algoritması, hata yüzeyinin, içbükey (konkav) ve yerel olarak ikinci dereceden olması şeklinde iki temel varsayıma sahiptir (Cheung ve ark., 2012).




Fig. 1. The assumptions of the Quickprop algorithm

Şekil 1.8. Quickprop algoritmasının varsayımları (Cheung ve ark., 2012).

Ağırlık güncelleme algoritması aşağıdaki eşitlikte verilmiştir:

$$\Delta\omega_{ij}(t) = \frac{E'(t)}{E'(t-1) - E'(t)} \Delta\omega_{ij}(t-1) \quad (1.47)$$

Burada;  $\Delta\omega_{ij}(t)$ , t'ninci yinelemedeki bir ağırdaki i'ninci ve j'ninci düğümlerdeki bağlantıların ağırlık değişimleridir.  $E(t)$ , t.ninci yinelemedeki sistem hatasıdır.

$$E'(t) = \partial E(t) / \partial \omega_{ij}(t) \quad (1.48)$$

Quickprop algoritmasında  $E'(t-1)$  ve  $E'(t)$  arasındaki fark çok küçük olduğunda, ağırlık düzensiz davranacaktır. Bundan sakınmak için  $\phi$  maksimum büyüme faktörü geliştirilmiştir.

$$\Delta\omega_{ij}(t) = \max\left(\phi, \frac{E'(t)}{E'(t-1)-E'(t)}\Delta\omega_{ij}(t-1)\right) \quad (1.49)$$

Burada;  $\phi$ 'nin değeri, quickpropun performansını önemli düzeyde etkileyebilir. Eğer,  $\phi$  küçükse küresel minimum yakınsaması  $\phi\Delta\omega_{ij}(t-1)$  ile sınırlı ve küçük; eğer büyükse ağ kararsız ve yakınsama başarısız olabilir. Quickprop algoritmasının hata yüzeyi ile ilgili, gradyan sınırlaması ve yerel minimum problemi olmak üzere iki ana sakıncası bulunmaktadır (Cheung ve ark., 2012).

#### 1.5.2.6.3.6. Genetik algoritmalar (Genetic algorithms)

Genetik algoritmalar (GA), biyolojik evrim üzerine kurulu bir stokastik arama algoritmaları sınıfıdır (Negnevitsky, 2005). GA, yaygın olarak; optimizasyon problemlerinde kullanılan bir rastgele arama tekniğidir. Bu algoritma, özellikle parametre sayısının büyük ve analitik çözümlerinin zor olduğu durumlarda, karmaşık optimizasyon problemleri için kullanışlıdır. GA, bir alan üzerinde global olarak en uygun çözümü bulmak için, yardımcı olabilen bir yöntemdir (Lam ve ark., 2003).

GA teknikleri, sağlam bir teorik temele sahiptir. GA, Holland tarafından geliştirilen, Şema Teoremine dayanmaktadır (Holland, 1975). Şema, sıfır ve yıldızlardan oluşmaktadır. Her yıldız sadece 1 veya 0 değerini alabilmektedir (Negnevitsky, 2005).

GA algoritmasının aşamaları aşağıdaki gibidir (Davis, 1991; Mitchell, 1996; Negnevitsky, 2005).

1. Problemlerle değişken alanı sabit bir uzunluktaki bir kromozom olarak temsil edilir. Çaprazlama olasılığı  $p_c$  ve mutasyon olasılığı  $p_m$  olan N adet kromozom seçilir.
2. Problem alanındaki bireysel kromozomun performansını veya etkisini ölçmek için bir uygunluk fonksiyonu tanımlanır (Uygunluk fonksiyonu, çoğaltma sırasında eşlenecek olan kromozomları seçmek için temel oluşturur).
3. N boyutlu başlangıç kromozom popülasyonunu rastgele oluşturulur

$$x_1, x_2, x_3, \dots, x_N$$

4. Her bir bireysel kromozomların uygunluğu hesaplanır.

$$f(x_1), f(x_2), f(x_3), \dots \dots f(x_N)$$

5. Mevcut populyasyondan eşleştirmek için bir çift kromozom seçilir. Eşli kromozomlar, onların uygunluğu ile ilgili bir olasılıkla seçilir. Yüksek uygunluğa sahip kromozomlar seçim için daha yüksek olasılığa sahiptir.
6. Çaprazlama ve mutasyon gibi genetik işlemler uygulayarak bir çift yavru kromozom yaratılır.
7. Yeni populyasyondaki yaratılan yavru kromozomları yer değiştirilir.
8. Yeni kromozomların boyutu ilk başlangıç hacmi olan N'e ulaşana kadar 5.adım tekrarlanır.
9. Yeni yavru kromozom ile ilk başlangıç kromozomlarını yer değiştirilir.
10. 4. adıma gidilir. Tatmin edici sonuç elde edene kadar süreç tekrarlanır.

Genetik algoritmalar, populyasyondaki ortalama uygunluğun sürekli olarak geliştirilmesini sağlar. Birkaç kuşaktan sonra algoritma, populyasyonu optimal bir çözüme yaklaştırır (Negnevitsky, 2005).

## 2. KAYNAK BİLDİRİŞLERİ

### 2.1. Pisa ile İlgili Kaynak Bildirişleri

Ekonomik İşbirliği ve Kalkınma Teşkilatı (Organization of Economic Cooperation and Development – OECD) tarafından düzenlenen Uluslararası Öğrenci Değerlendirme Programı (The Programme for International Student Assessment – PISA), eğitimin yeni işlevini ölçmek ve değerlendirmek amacıyla yapılan bir araştırmadır (MEB, 2016).

Toprak (2017), PISA 2012'deki öğrencilerin matematik başarılarını sınıflandırmak için Yapay Sinir Ağları, Karar Ağaçları ve Diskriminant Analizi yöntemlerini kullanarak; yöntemlerin sınıflandırma performansını karşılaştırmıştır. Örneklem büyüklükleri esas alındığında, en yüksek sınıflandırma performansının Yapay Sinir Ağlarında olduğunu belirlemiştir. Ayrıca örneklem büyüklüğü küçüldükçe, karar ağaçlarındaki performansın küçüldüğünü, aksine Diskriminant Analizindeki performansın yükseldiğini tespit etmiştir.

Mutluer ve Büyükkıdık (2017), PISA 2012 verilerini kullanarak, matematik okuryazarlığını etkileyen faktörleri Lojistik Regresyon yöntemiyle inceledikleri çalışmalarında; anne eğitim düzeyi, baba eğitim düzeyi, matematikten zevk alma, matematik öz algılama/hızlı öğrenme, azim- çabuk pes etme bağımsız değişkenlerinin istatistiksel olarak önemli olduklarını belirlemişlerdir.

İnal ve Turabik (2016), PISA 2012'ye katılan 15 yaş grubu Türk öğrencilerin matematik başarılarını etkileyen faktörlerin belirlenmesi amacıyla yaptıkları çalışmada; öğrencilerin matematik başarısının yordayıcılık düzeyini belirlemede Yapay Sinir Ağlarını kullanmışlardır.

Şahin ve Yıldırım (2016), PISA 2012 verilerini kullanarak, matematiksel davranış ve matematik okuryazarlığını etkilediği düşünülen değişkenleri “Çok Gruplu Hibrit Modelleme” inceledikleri çalışmalarında, matematik okuryazarlığı değişkenini en iyi açıklayan bağımsız değişkenin matematik özyeterliliği değişkeni olduğunu belirlemişlerdir.

Yavuz ve ark. (2017), Türk ve Vietnamlı öğrencilerin, matematik okuryazarlığını açıklayan, dürtüsel ve güdüsel özellikleri belirlemek amacıyla bir çalışma yapmışlardır. Bu çalışmada, ölçme değişmezliğini test etmek için Çoklu Grup Doğrulayıcı Faktör Analizi kullanmışlardır. Ayrıca, öğrencilerin matematik okuryazarlığı etkileyen değişkenler arasındaki ilişkileri belirlemek için de Karar Ağaçlarından CHAID algoritmasını uygulamışlardır.

Aksu ve Güzeller (2016), matematik okuryazarlığı bakımından başarılı ve başarısız öğrencileri; derse ilgi, tutum, motivasyon, algı, öz yeterlik, kaygı ve çalışma disiplini değişkenlerine göre sınıflandırmak amacıyla karar ağacı algoritmalarından CHAID algoritmasını kullanmışlardır.

Aygüner (2016), “Sekizinci sınıf öğrencilerinin görsel matematik okuryazarlığı öz yeterlik algıları ile gerçek performanslarının karşılaştırılması” adlı çalışmasında, öğrencilerin görsel matematik okuryazarlığı öz yeterlik algı ölçeğinden aldıkları puanlar ile görsel matematik okuryazarlığı gerçek performans testinden aldıkları puanlar arasında ilişki olmadığı bulgusuna ulaşmıştır.

Güzeller ve Akın (2014), 40 ülkenin PISA 2006 verilerini kullanarak, bilgi ve iletişim tekniklerinin bazı alt ölçeklerinin matematik başarısı üzerindeki etkisini belirlemeye çalışmışlardır.

Özaslan (2017), “Türkiye’deki Öğrenci Başarılarının PISA 2003-2012 Matematik Okuryazarlığı Testlerinde Yer Alan Farklı Soru Türlerine Göre Değerlendirilmesi” adlı çalışmasında, PISA 2003 ve 2012 uygulamalarına ait matematik okuryazarlığı test maddelerini, soru türlerine göre; çoktan seçmeli, karmaşık çoktan seçmeli ve yapılandırılmış yanıtı madde şeklinde sınıflandırmıştır. Analiz sonucunda, soru türlerine göre öğrencilerin başarılarının farklılaştığı görülmüştür.

Azapağası İlbağı (2012), PISA 2003 matematik okuryazarlığına ait sorular üzerinde, öğrencilerin matematik okuryazarlığı ve tutumlarını incelemiştir. Öğrencilerin büyük çoğunluğunun, matematik okuryazarlığına ilişkin üst yeterlilik düzeyindeki değerlendirme sorularına istenilen cevapları veremediğini, alt ve orta düzey sorularına ise öğrencilerin sadece yarısının istenilen düzeyde cevap verdiğini tespit etmiştir.

Azapağası İlbağı ve Akgün (2012), PISA 2003 öğrenci anketini kullanarak, 15 yaş grubu öğrencilerinin, matematik dersi ile ilgili tutumlarını incelemişlerdir.



İlgün Dibek (2015), PISA 2012 verilerini kullanarak, matematik okuryazarlığını etkileyen öğrenme ve öğretme süreci ile ilgili değişkenleri belirlemek amacıyla, Yapısal Eşitlik Modelini kullanmıştır.

Akyüz ve Pala (2010), Türkiye, Finlandiya ve Yunanistan'ın PISA 2003 matematik okuryazarlığı ile ilgili verilerini kullanarak; öğrencilerin matematik okuryazarlıklarını ve problem çözme becerilerini etkileyen faktörleri, Açıklayıcı Faktör Analizi ve Doğrulayıcı Faktör Analizi ile incelemiştir. Ayrıca, bu ülkeler için Yapısal Eşitlik Modelleri kurarak karşılaştırma yapmışlardır.

Akarsu (2009), PISA 2003 uygulamasında başarılı ülkelerden biri olan Finlandiya ile Türkiye'nin matematik başarılarını karşılaştırmak için, öz-yeterlik, içe ve dışa yönelik motivasyon faktörlerini değerlendiren bir modeli oluşturmuş, bu model ile ülkelerin benzerlik ve farklılıklarını belirlemek için Temel Bileşenler Analizini ve Çoklu Grup Yapısal Eşitlik Modellemesi Analizini kullanmışlardır.

Satıcı (2008), PISA 2003 sonuçlarına göre Türkiye ve Hong Kong-Çin arasında matematik okuryazarlığını etkileyen faktörleri, Açıklayıcı Faktör Analizi, Doğrulayıcı Faktör Analizi ve Yapısal Eşitlik Modeli kullanarak araştırmıştır. Matematik okuryazarlığını en büyük derecede etkileyen faktörün, okula ait olma değişkeni olduğunu belirlemiştir.

İlgün Dibek ve Demirtaşlı (2017), "Öğrenme ve Öğretme Süreci Değişkenleri ile PISA 2012 Matematik Okuryazarlığı Arasındaki İlişkiler" isimli çalışmada, matematik okuryazarlığı ile öğrenci-öğretmen ilişkisi arasında negatif yönde ilişki ve disiplin ortamı ile ise pozitif yönde ilişki olduğunu belirtmişlerdir.

İş (2003), matematik başarıları çok farklı olan Japonya, Norveç ve Brezilya üzerinde matematik okuryazarlığını etkileyen bağımsız örtük değişkenlerin, kültürler arası karşılaştırmasını yapmıştır. Çalışmada, matematik okuryazarlığında, en güçlü etkisi olan bağımsız örtük değişken; Brezilya'da teknoloji ve kaynak kullanımı, Japonya'da aile ile olan iletişim, Norveç'te ise anadile yönelik tutumlar olarak bulunmuştur.

İş Güzel (2006), PISA 2003 verilerini kullanarak, öğrencilerin matematik okuryazarlığını etkileyen faktörleri kültürler arası karşılaştırdığı çalışmada, Hiyerarşik Lineer Modelleme analizi yapmıştır. Araştırmada; üst sınıflarda bulunan, evlerinde daha fazla eğitim kaynağı bulunan, matematikte kendini yeterli görme

yeterlilikleri yüksek olan, matematikte kaygı veya sıkıntı düzeyleri düşük olan, matematikte özgüven düzeyleri yüksek olan, ezberleme ve tekrar stratejilerini daha az tercih eden ve matematik derslerinde daha pozitif sınıf ortamı bulunan öğrencilerin matematik okuryazarlığında daha başarılı olduğu sonucuna varılmıştır.

Okatan (2017), PISA 2012 uygulamasına katılan beş bin öğrencinin, matematik başarısını etkileyen değişkenleri incelemiş, matematik başarısını etkileyen en önemli değişkenin ESCS (ekonomik, sosyal ve kültürel statü) indeksi olduğunu belirlemiştir.

Aydın ve ark. (2012), Türkiye ve beş farklı ülkenin PISA 2012'deki matematik başarısını etkileyen sosyoekonomik ve sosyokültürel değişkenleri karşılaştırmalı olarak incelemiştir.

Benzer bir şekilde; Ziya (2008), PISA 2006 verilerini kullanarak, Türkiye'deki öğrencilerin matematik başarısını etkileyen faktörleri incelediği çalışmasında, matematik başarısını etkileyen en güçlü faktörün ESCS indeksi olduğunu belirtmiştir. Ayrıca; araştırma sonucunda, öğrencilerin matematik puanlarının anne/babanın meslek kategorilerine ve eğitim seviyelerine göre farklılık gösterdiği görülmüştür.

Karabay (2013); 2003, 2006, 2009 yıllarında yapılan PISA uygulamalarına göre, 15 yaşındaki öğrencilerin, okuma becerileri, matematik ve fen okuryazarlığını etkileyen okul içi ve okul dışı özelliklerini incelemiştir. Aile özelliklerinin, okul özelliklerinden daha anlamlı olduğunu bulmuştur. Ayrıca; aile özellikleri değişkenleri olan; öğrencilerin evlerindeki kitap sayısı, kendine ait bir odanın bulunması, evde bilgisayara sahip olması ve anne babanın eğitim düzeyi gibi değişkenlerin ve okul özellikleri değişkeni olan okuldaki eğitim kaynaklarının kalitesi değişkeninin de üç uygulama döneminde anlamlı olduğunu belirlemiştir.

Karabay ve ark. (2015), PISA 2003, 2006 ve 2009 uygulamalarına katılan öğrencilerin matematik okuryazarlığı puanları ile ilişkili olan değişkenlerin belirlenmesi amacıyla yaptıkları çalışmalarında; her üç uygulama döneminde de sınıf, cinsiyet, baba eğitim düzeyi, evdeki olanaklar, okulun bulunduğu yer ve okulun seçiciliği değişkenlerinin önemli olduğu sonucuna ulaşmışlardır.

Koçar (2015), "PISA 2012 Matematik Okuryazarlığını Etkileyen Faktörlerin Aracılık Modeli ile İncelenmesi" adlı çalışmasında; cinsiyet, ekonomik, sosyal ve kültürel durum indeksi ve matematik öğrenmek için harcanan zaman değişkenlerinin, matematik okuryazarlığı üzerinde önemli bir etkisi olduğunu belirtmiştir.

## 2.2. Yöntemle İlgili Kaynak Bildirişleri

Kayri (2015), Çok Katmanlı Algılayıcı Yapay Sinir Ağları ile Radyal Tabanlı Yapay Sinir Ağları yöntemlerinin tahminleme performanslarını karşılaştırdığı çalışmada, üniversite öğrencilerinin başarılarını etkileyen faktörleri araştırmış ve tahminleme yeteneği bakımından Çok Katmanlı Algılayıcı Yapay Sinir Ağları yönteminin daha iyi performans gösterdiğini tespit etmiştir.

Zare ve ark. (2013), Çok Katmanlı Algılayıcı Yapay Sinir Ağları ve Radyal Tabanlı Yapay Sinir Ağları yöntemlerinin, Vaz Havzasındaki (İran) heyelan duyarlılığını tahmin etmedeki performanslarını karşılaştırdıkları çalışmada, her iki yöntemin performansının benzer olduğunu belirtmişlerdir.

Bayram ve ark. (2013), inşaat maliyetini tahmin etmek için; Çok Katmanlı Algılayıcı Yapay Sinir Ağları, Radyal Tabanlı Yapay Sinir Ağları yöntemleri ile Çevre ve Şehircilik Bakanlığınca yayınlanan "Birim alan maliyet yöntemi" olarak bilinen UACM (unit area cost method) yöntemlerini kullanmışlardır. Tahminleme performansı açısından Çok Katmanlı Algılayıcı Yapay Sinir Ağları ile Radyal Tabanlı Yapay Sinir Ağlarının, UACM yönteminden daha başarılı tahminleme yaptığını; ayrıca Radyal Tabanlı Yapay Sinir Ağlarının Çok Katmanlı Algılayıcı Yapay Sinir Ağları yönteminden daha başarılı olduğu sonucuna varmışlardır.

Memarian ve Kumar Balasundram (2012), Çok Katmanlı Algılayıcı Yapay Sinir Ağları ve Radyal Tabanlı Yapay Sinir Ağları yöntemlerini, bir tropikal havzadaki çökme yükünü tahmin etmek için kullanmış, tahminleme performansı bakımından, Çok Katmanlı Algılayıcı Yapay Sinir Ağları yönteminin biraz daha iyi sonuç verdiğini belirtmişlerdir.

Kumar ve Yadav (2011), Çok Katmanlı Algılayıcı Yapay Sinir Ağları ve Radyal Tabanlı Yapay Sinir Ağları yöntemlerini, diferansiyel denklemlerin çözümünde kullanmış, Radyal Tabanlı Yapay Sinir Ağları yönteminin daha doğru çözümler bulduğunu belirtmişlerdir.

Oludolapo ve ark. (2012), Çok Katmanlı Algılayıcı Yapay Sinir Ağları ve Radyal Tabanlı Yapay Sinir Ağları yöntemlerini, Kuzey Afrika'nın enerji tüketiminin tahmin edilmesinde kullanmış, tahminleme performansı bakımından, Radyal Tabanlı

Yapay Sinir Ağlarının Çok Katmanlı Algılayıcı Yapay Sinir Ağları yönteminden daha başarılı olduğu sonucuna varmışlardır.

Sug (2009), eğitim veri seti üzerinde Çok Katmanlı Algılayıcı Yapay Sinir Ağları ve Radyal Tabanlı Yapay Sinir Ağlarının sınıflama performanslarını karşılaştırdığı çalışmada; Çok Katmanlı Algılayıcı Yapay Sinir Ağlarının büyük veri setlerinde, Radyal Tabanlı Yapay Sinir Ağlarının ise küçük veri setlerinde daha başarılı olduğunu belirlemiştir.

Jayawardena ve ark. (1997), Çok Katmanlı Algılayıcı Yapay Sinir Ağları ve Radyal Tabanlı Yapay Sinir Ağları yöntemlerini, sel baskınlarının tahmin edilmesinde kullanmış, tahminleme performansı açısından, Radyal Tabanlı Yapay Sinir Ağları yönteminin daha başarılı olduğunu belirtmişlerdir.

Guo ve ark. (2017), Çok Katmanlı Algılayıcı Yapay Sinir Ağları ve Rastgele Orman yöntemini, polimid nanokompozit filmlerin yalıtkan kaybını tahmin etmek için kullanmışlardır. Çalışmada, Rastgele Orman ve Çok Katmanlı Algılayıcı yöntemleri birleştirilerek RF-MLP modeli oluşturulmuş, modelin nano yalıtkan materyallerin özelliklerinin tahmin edilmesinde, hızlı ve güvenilir olduğu belirtilmiştir.

Raczko ve Zagajewski (2017), hava kaynaklı hiperspektral APEX görüntüler ile ağaç türlerinin sınıflandırılması amacıyla, Yapay Sinir Ağları, Rastgele Orman ve Destek Vektör Makineleri yöntemlerini kullanmış, yöntemlerin doğru sınıflama performanslarını sırasıyla; Yapay Sinir Ağları, Destek Vektör Makineleri ve Rastgele Orman olarak bulmuşlardır.

Nitze ve ark. (2012), denetlenen ürün tiplerinin sınıflandırılmasında Yapay Sinir Ağları, Rastgele Orman, Destek Vektör Makineleri ve En Çok Olabilirlik yöntemlerini kullanmışlardır. Doğru sınıflama ve sağlamlık açısından, Radyal Taban ve polinomial çekirdek fonksiyonu kullanan Destek Vektör Makinesinin, Yapay Sinir Ağları ve Rastgele Orman yöntemlerine göre daha iyi sonuçlar, En Çok Olabilirlik yönteminin ise, en kötü sonuçlar verdiğini belirtmişlerdir.

Shah ve ark. (2017), Çevrimdışı İmzaların Adli Analizinde imza doğrulaması için, Çok Katmanlı Algılayıcı Yapay Sinir Ağları ve Rastgele Orman yöntemlerini kullanmış, sınıflama performansı bakımından, Rastgele Orman yönteminin daha başarılı olduğunu belirtmişlerdir.

Eriksson ve Varatharajah (2016), borsada bir günlük tahminler için Yapay Sinir Ağları ve Rastgele Orman yöntemlerinin tahminleme performanslarını karşılaştırmış, Yapay Sinir Ağlarının daha iyi performans gösterdiğini belirtmişlerdir.

Becerra ve ark. (2013), Çok Katmanlı Algılayıcı Yapay Sinir Ağları ve Rastgele Orman yöntemlerini, Ataksi SCA2'li hastaların EOG sinyallerinde yer alan düzensiz kayıtların sınıflandırılması için kullanmış, her iki yöntemin sınıflama performansının benzer olduğunu belirtmişlerdir.

Marin ve ark. (2013), Akdeniz akarsularında yerli türlerin zenginliğini tahmin etmek için Yapay Sinir Ağları ve Rastgele Orman yöntemlerinin performanslarını karşılaştırdıkları çalışmalarında, her iki yöntemin benzer sonuçlar gösterdiğini belirtmişlerdir.

Shichkin ve ark. (2018), inceledikleri bölgedeki anormal derecede yüksek konsantrasyonlara sahip olan bir kimyasal elementli kromun üst toprak tabakasındaki uzaysal dağılımını tahmin etmek için Çok Katmanlı Algılayıcı Yapay Sinir Ağları, Rastgele Orman ve Random Perceptron Forest yöntemlerini karşılaştırdıkları çalışmalarında Rastgele Orman yönteminin daha iyi performans gösterdiğini belirtmişlerdir.

Sug (2010), Rastgele Orman ve Radyal Tabanlı Yapay Sinir Ağları yöntemlerini, ozon günlerini tahmin etmek amacıyla kullanmış, çalışmada; tahminleme performansı açısından, Radyal Tabanlı Yapay Sinir Ağları yöntemini daha başarılı bulunmuştur.

Kayri ve Çokluk Bökeoğlu (2016), üniversite öğrencilerinin akademik erteleme davranışını etkileyen faktörleri belirlemek amacıyla, Radyal Tabanlı yapay sinir ağlarını kullanmışlardır. Çalışmada, yapay sinir ağlarının tahminleme yeteneği ile eğitim verileri için yansız ve güçlü bir yöntem olduğu ifade edilmiştir.

Seyman ve Taşpınar (2009), Çok Katmanlı Algılayıcı Yapay Sinir Ağlarını, yüksek hızlı veri iletimi uygulamalarında, yüksek hızlarda ve kaliteli veri iletimine olanak sağlayan OFDM (Orthogonal Frequency Division Multiplexing-Dikgen Frekans Bölmeli Çoğullama Tekniği) sistemlerinde kanal dengelemesi yapmak amacıyla kullanmışlardır.

Güler ve Übeyli (2005) çalışmalarında, diyabet hastalığını teşhis etmek için, Çok Katmanlı Algılayıcı Yapay Sinir Ağlarını kullanmışlardır. Çalışmada, yapay sinir

ağlarının eğitiminde; Geri Yayılım, Delta-Bar-Delta, Genişletilmiş Delta-Bar-Delta ve Hızlı Yayılım olmak üzere dört algoritma kullanmışlardır. Bu çalışmada, diyabet hastalığını teşhis etmede en başarılı algoritma, Hızlı Yayılım algoritması olarak bulunmuştur.

Tektaş ve Karataş (2004), finans alanında yapay sinir ağlarının uygulanabilirliğini araştırmışlardır. Bu çalışmada, İMKB’de kayıtlı yedi şirketin hisse senedi fiyatlarını tahmin etmek için Çok Katmanlı Algılayıcı Yapay Sinir Ağlarını kullanmışlardır.

Korkem (2013), kanser veri seti üzerinde Rastgele Orman ve Naive Bayes yöntemlerinin, hem ikili hem de çoklu sınıflama performansını karşılaştırmıştır. İki yöntem arasındaki fark anlamlı bulunmamıştır.

Yılmaz (2014), çalışmasında kayıp verili veri setlerinde Rastgele Orman ve K En Yakın Komşu Algoritmasını karşılaştırmış, iki algoritma arasında anlamlı bir fark bulunmadığını tespit etmiştir. Yüksek ilişkiye sahip veri setlerinde, Rastgele Orman yönteminin kullanılmasını önermiştir.

Ayas (2014), mikroskopik imgelerde tüberküloz bakterisini sınıflandırmada, Destek Vektör Makineleri, Yapay Sinir Ağları ve Rastgele Orman yöntemlerini kullanmıştır. Rastgele Orman yönteminin, diğer yöntemlere göre daha iyi performans gösterdiğini belirlemiştir.

Akbilgiç (2011), çalışmasında Radyal Tabanlı Fonksiyon Ağlarının sınıflama ve tahminlemedeki eksikliklerini gidermek üzere, Hibrit Radyal Tabanlı Fonksiyon Ağları modelini oluşturmuş, oluşturduğu modeli, İMKB Ulusal 100 endeksinin yönünün belirlenmesi üzerinde uygulamıştır.

Çuhadar (2013), turizm talebini tahmin etmek için, Çok Katmanlı Algılayıcı Yapay Sinir Ağları, Radyal Tabanlı Yapay Sinir Ağları ve Zaman Gecikmeli Yapay Sinir Ağları (Time Delay Neural Networks-TDNN) yöntemlerini kullanmış, bu üç yöntemin tahminleme performanslarını karşılaştırmıştır. Çalışmada, tahminleme performansı en yüksek olan yöntem, Çok Katmanlı Algılayıcı Yapay Sinir Ağları olarak bulunmuştur.



### **3. MATERYAL VE YÖNTEM**

#### **3.1. Materyal**

##### **3.1.1. Araştırma modeli**

Bu araştırma, tarama modellerinden ilişkisel tarama modeli ile yapılmış bir çalışmadır. İlişkisel tarama modeli, birden çok değişken arasındaki etkileşimi neden-sonuç temelli olarak inceleyen bir araştırma yöntemidir (Karasar, 2006).

##### **3.1.2. Evren ve örneklem**

PISA, 2015 yılında, ilk defa bilgisayar tabanlı değerlendirme ile değerlendirilmiştir. PISA 2015'e, 35'i OECD ülkesi olmak üzere, toplam 72 ülke katılmıştır. PISA 2015 uygulamasına, katılımcı ülkelerde okuyan 15 yaş grubu 29 milyon öğrenciyi temsilen, yaklaşık 540 bin öğrenci örneklem grubunu oluşturmaktadır (MEB, 2016). PISA 2015, ülkemizde 15 yaş grubu örgün öğretimde okuyan öğrencilere bilgisayar tabanlı olarak uygulanmıştır. İstatistiki Bölge Sınıflaması düzey 1'e göre 12 bölge esas alınarak; 61 ilden 187 okul tabakalı seçkisiz yöntemle seçilmiştir. Bu okullarda öğrenim gören öğrenciler arasından, rastgele seçilen 5895 öğrenci uygulamaya katılmıştır (MEB, 2016).

##### **3.1.3. Veri seti**

Bu çalışmada; veri toplama aracı olarak, PISA 2015 Türkiye örneğine ait öğrenci anketi, ölçekler ve matematik okuryazarlığı testinden alınan puanlar kullanılmıştır. PISA 2015 uygulamasına ait bu veri dosyası, PISA resmi web sayfası olan, [www.pisa.oecd.org](http://www.pisa.oecd.org) adresinden elde edilmiştir. Bu veriler, herkesin kullanımına açık olduğundan, verileri kullanmak için özel izin talep edilmemiştir. PISA 2015 verileri, ilgili veri tabanından indirilerek çalışma kapsamına uygun bir şekilde biçimlendirilmiştir. Veri setinde başlangıçta, 5895 bireye ait veriler var iken, eksik ve



yanlış veriler silinmiştir. Dolayısıyla; PISA 2015 sınavına katılan 2165’i (%49) erkek ve 2257’i (%51) kız olmak üzere, toplam 4422 öğrenciden toplanan bilgiler kullanılmıştır.

### 3.1.4.Verilerin tanımlanması

#### 3.1.4.1.Bağımlı ve bağımsız değişkenler

PISA 2015 çalışmasında, öğrenci düzeyinde matematik okuryazarlığı bilişsel alan yeterliği bakımından on farklı olası değer (PV1MATH-PV10MATH) kestirilmiştir. Çalışmada bağımlı değişken olarak; öğrenci düzeyinde matematik okuryazarlığı bilişsel alan yeterliği bakımından on farklı olası (PV1MATH-PV10MATH) değerlerin ortalaması alınmıştır. Ortalama puanlar, PISA 2015 matematik yeterlilik düzeylerinin eşik değerlerine göre gruplandırılmış, daha sonra da, yeterlilik düzeyleri düşük-orta-yüksek olarak üç düzeyli kategorik hale dönüştürülmüştür. Bu durumda, modelde yer alan yordanan değişken kategorik bir veri yapısı sunmaktadır. Bilindiği üzere, istatistiksel süreçlerde, modelde yer alan değişkenlerin veri tipi önemli görülmekte, bu veri yapısına uygun analizlerin tercih edilmesi gerekmektedir (Kayri, 2015). Modelde yer alan bağımsız değişkenlerin bir kısmı sürekli (interval – scale), bir kısmı sıralı (ordinal) ve bir kısmı da sınıflamalı (nominal) bir yapıdadır.

Bağımsız değişkenler; öğrencilerin okuduğu sınıf, cinsiyet, yaş, anne eğitim düzeyi, baba eğitim düzeyi ve okul hayatında ulaşılması hedeflenen nokta değişkenleri, haftalık ders sayısı, haftalık matematik öğrenmeye ayrılan zaman ve Türkçe yeterlilik düzeylerine göre düşük-orta-yüksek olarak, üç düzeyli kategorik hale getirilen Türkçe başarı puanları kullanılmıştır. Ayrıca; sosyoekonomik göstergeler olarak; “Evinizde çalışmak için bir masanız var mı?”, “Evinizde kendi odanız var mı?”, “Evinizde sessiz çalışma yeriniz var mı?”, “Evinizde okul çalışmalarını için bilgisayar var mı?”, “Evinizde eğitim yazılımları var mı?”, “Evinizde internet bağlantınız var mı?”, “Evinizde okul çalışmalarını için yardımcı kitap var mı?”, “Evinizde teknik kitaplar var mı?” soruları da analize bağımsız değişken olarak alınmıştır. Bunun yanı sıra; öğretmenlerin öğrenciyle ilişkisini gösteren, “Öğretmenler beni diğer öğrencilerden daha az çağırırlar”, “Öğretmenler beni diğer öğrencilerden daha çok zorlar”, “Öğretmenlerin benim daha az

zeki olduğumu düşündükleri izlenimindeyim”, “Öğretmenler beni diğer öğrencilere göre daha sert bir şekilde disipline eder”, “Öğretmenler benimle diğerlerinin önünde alay eder”, “Öğretmenler başkalarının önünde bana hakaret eden sözler söyler” vb. sorular bağımsız değişkenler olarak analize alınmıştır. Ayrıca; bağımsız değişkenler olarak, öğrencinin kaygısını ölçen, ST118Q01NA, ST118Q02NA, ST118Q03NA, ST118Q04NA, ST118Q05NA soruları, öğrencinin motivasyonunu ölçen ST119Q01NA, ST119Q02NA, ST119Q03NA, ST119Q04NA ve ST119Q05NA soruları ile öğrencinin bilgi kuramına ilişkin inancını ölçen ST131Q01NA, ST131Q03NA, ST131Q04NA, ST131Q06NA, ST131Q08NA ve ST131Q011NA soruları olmak üzere toplam 16 adet soru da kullanılmış olup bu sorulara verilen yanıtlar 4'lü likert ölçeğine göre puanlanmıştır. Anket soruları aşağıdaki çizelgede verilmiştir.

Çizelge 3.1. Araştırmada kullanılan ölçeklere ait anket soruları.

SORU KODLARI	ANKET SORULARI	Kesinlikle katılmıyorum	Katılmıyorum	Katılıyorum	Kesinlikle katılıyorum
ST118	Öğrencinin hayatına ilişkin görüşlerini ölçen sorular				
ST118Q01NA	Bu sınavın benim için zor olacağı konusunda endişeliyim.				
ST118Q02NA	Okulda kötü notlar alacağımdan endişeleniyorum.				
ST118Q03NA	Sınava çok iyi hazırlanmış olsam da endişeli hissedirim.				
ST118Q04NA	Sınav sırasında çok gerginim.				
ST118Q05NA	Okulda bir soruyu çözemediğimde sinirlenirim.				
ST119	Öğrencinin hayatına ilişkin görüşlerini ölçen sorular				
ST119Q01NA	Okulda en iyi dereceyi almak isterim.				
ST119Q02NA	Mezun olduktan sonra mevcut fırsatlardan en iyisini seçmek isterim.				
ST119Q03NA	Her ne olursa olsun en iyi olmayı isterim.				
ST119Q04NA	Kendimi hırslı bir insan olarak görüyorum.				
ST119Q05NA	Sınıfımda en iyi öğrencilerden biri olmak isterim.				
ST131	Öğrencinin bilime bakışını ölçen sorular				
ST131Q01NA	Bir şeyin doğru olup olmadığını bilmenin en iyi yolu deney yapmaktır.				
ST131Q03NA	Temel bilimlerdeki fikirler ara sıra değişmektedir.				
ST131Q04NA	Birçok farklı deneyim sonucu iyi cevaplar ortaya çıkar.				
ST131Q06NA	Bulgularımızdan emin olmak için bir kaç kez deneme yapmak iyidir.				
ST131Q08NA	Bilim adamları bazen doğru düşündükleri fikirlerini değiştirirler.				
ST131Q11NA	Bilim kitaplarındaki bilgiler bazen değişir.				

Cinsiyet: Öğrencilerin cinsiyetine göre oluşturulmuştur.

Yaş: 15 ve 16 yaş şeklinde gruplandırılmıştır.

Uluslararası Eğitimin Standart Sınıflaması (International Standard Classification of Education - ISCED), tekdüze ve uluslararası kabul görmüş tanımlar temelinde ülkeler arasında karşılaştırmaları kolaylaştırmak amacıyla UNESCO tarafından geliştirilmiştir.

Anne Eğitim Düzeyi: Annenin eğitim düzeyi, ISCED düzeyine göre kategorilere ayrılmıştır.

Baba Eğitim Düzeyi: Baba eğitim düzeyi, ISCED düzeyine göre kategorilere ayrılmıştır.

Okul Hayatında Ulaşılması Hedeflenen Nokta: Okul hayatında ulaşılması hedeflenen nokta değişkeni, ISCED düzeyine göre kategorilere ayrılmıştır.

### 3.1.4.2. Ölçme araçları

Araştırmada, öncelikle matematik okuryazarlığını etkileyebileceği düşünülen değişkenler kuramsal çerçeveye bağlı kalınarak seçilmiştir. Araştırma kapsamında; Öğrenci Kaygı Ölçeği (Anxiety) Öğrenci Motivasyon Ölçeği (Motivation) ve Bilgi Kuramına İlişkin İnanç Ölçeği (Epistemological beliefs) kullanılmıştır.

Öğrenci Kaygı Ölçeği, beş maddeden oluşan tek faktörlü bir yapıya sahip olup öğrenci tutumları dördümlü skala (“1- Kesinlikle katılıyorum”, “2- Katılıyorum”, “3- Katılmıyorum”, “4- Kesinlikle katılmıyorum”) ile derecelendirilmiştir. Bu ölçekten alınabilecek en düşük puan beş, en yüksek puan ise 20 olarak hesaplanır. Ölçekten elde edilecek düşük puan, düşük kaygıya; yüksek puan ise yüksek düzeydeki kaygıya işaret etmektedir. Ölçeğe ait Cronbach Alfa güvenilirlik katsayısı 0.83 olarak bulunmuştur.

Araştırma kapsamında kullanılan Öğrenci Motivasyon Ölçeği, beş maddeden oluşan tek faktörlü bir yapıya sahiptir. Bu ölçekte, öğrencilerin tutumları dördümlü skala (“1- Kesinlikle katılmıyorum”, “2- Katılmıyorum”, “3- Katılıyorum” ve “4- Kesinlikle katılıyorum”) ile derecelendirilmiş olup; düşük puan, düşük motivasyonu; yüksek puan yüksek motivasyonu göstermektedir. Bu ölçekten alınabilecek en düşük puan beş, en yüksek puan ise 20 olarak hesaplanır. Ölçeğe ait Cronbach Alfa güvenilirlik katsayısı 0.84 olarak bulunmuştur.

Çalışma kapsamında kullanılan Bilgi Kuramına İlişkin İnanç Ölçeği altı maddeden oluşmakta ve tek faktörlü bir yapı sunmaktadır. Kullanılan diğer ölçeklerde olduğu gibi, öğrenci tutumları dördümlü skala ile derecelendirilmiştir. Bu ölçekten alınabilecek en düşük puan altı, en yüksek puan ise 24 olarak hesaplanır. Ölçekten elde edilecek düşük puan, düşük inancı; yüksek puan ise yüksek inancı göstermektedir. Ölçeğe ait Cronbach Alfa güvenilirlik katsayısı 0.92 olarak bulunmuştur.

Çalışma kapsamında, kullanılan ölçeklerin yanı sıra, öğrencilere ait bazı demografik ve kişisel bilgiler de kullanılmıştır. Söz konusu yordanan değişken üzerinde

etkisi araştırılan 25 adet bağımsız değişken, frekans ve yüzde dağılımlarıyla birlikte çalışmanın Bulgular Bölümü'nde (Çizelge 4.1'de) verilmiştir.

### 3.1.4.3. Performans ölçütleri

Hata Kareler Ortalamasının Kökü (RMSE), Ortalama Mutlak Hata (MAE), Bağıl Mutlak Hata (RAE), Bağıl Karesel Hatanın Kökü (RRSE) ve gözlenen değer ile tahmin değeri arasındaki ilişkiyi gösteren korelasyon katsayısı ağ yapısını değerlendirmede kullanılan performans ölçütleri olup aşağıda verilen eşitliklerle ifade edilmektedir (Kayri, 2015; Kayri ve ark., 2017).

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_i - O_i)^2} \quad (3.1)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |P_i - O_i| \quad (3.2)$$

$$RAE = \frac{\sum_{j=1}^n P_{ij} - O_i}{\sum_{j=1}^n |O_j - \bar{O}|} \quad (3.3)$$

$$RRSE = \sqrt{\frac{\sum_{i=1}^N (P_i - O_i)^2}{\sum_{j=1}^n (|O_j - \bar{O}|)^2}} \quad (3.4)$$

Burada;  $P_i$  (Predicted Value) tahmin edilen değeri,  $O_i$  (Observed value) ise gözlenen değerleri göstermektedir. RMSE ve MAE değerlerinin sifıra yakın olması gerekir (Kayri, 2015).

PISA 2015 veri seti MLPANN, RBFANN ve RF ile analiz edilmeden önce, modelde kullanılan değişkenler arasında çoklu bağlantılılık (Multicollinearity) probleminin olup olmadığı test edildi. Çoklu bağlantılılık testinde Varyans Artış Faktörü (VIF) ve çoklu bağlantılılığa ait Tolerans (Tolerance) değerleri dikkate alınır. VIF değerinin 10'dan büyük veya Tolerans değerinin 0.1'den küçük olması halinde değişkenler arasında çoklu bağlantılılık sorununun olduğu anlaşılır. (Keller, El-Sheikh Granger ve Buckhalt, 2012). Yapılan bu çalışmada, VIF değerlerinin 1.088 ile 4.201 arasında değiştiği ve Tolerans değerlerinin 0.238 ile 0.901 arasında değiştiği gözlenmiştir. Dolayısı ile modeldeki değişkenler arasında çoklu bağlantılılık sorununun olmadığı anlaşılmıştır.

## 3.2. Yöntem

### 3.2.1. Rastgele orman yöntemi (Random Forest)

Rastgele Orman yöntemi (RF), Leo Brieman tarafından 2000’li yıllarda rastgele seçilen veriye ait alt uzaylarda büyüyen karar ağaçlarına bir öngörü topluluğu oluşturmak için tasarlanan bir yöntemdir. Breiman'ın fikirleri, Amit ve Geman'ın (1997) geometrik özellik seçimi, Ho'nun rastgele altuzay yöntemi (1998) ve Dietterich'in (2000) rastgele bölünmüş seçim yaklaşımıyla ilgili çalışmalarından kararlı bir şekilde etkilenmiştir (Biau, 2012).

RF yöntemi; karar ağaçları ile kümeleme ve bootstrap (önyükleme) fikirlerini birleştiren; tek ve çok yönlü olarak regresyon problemlerinin yanı sıra iki sınıflı ve çok sınıflı sınıflama problemlerinde kullanılan güçlü bir nonparametrik (parametrik olmayan) istatistiksel yöntemdir (Geneur ve ark., 2017).

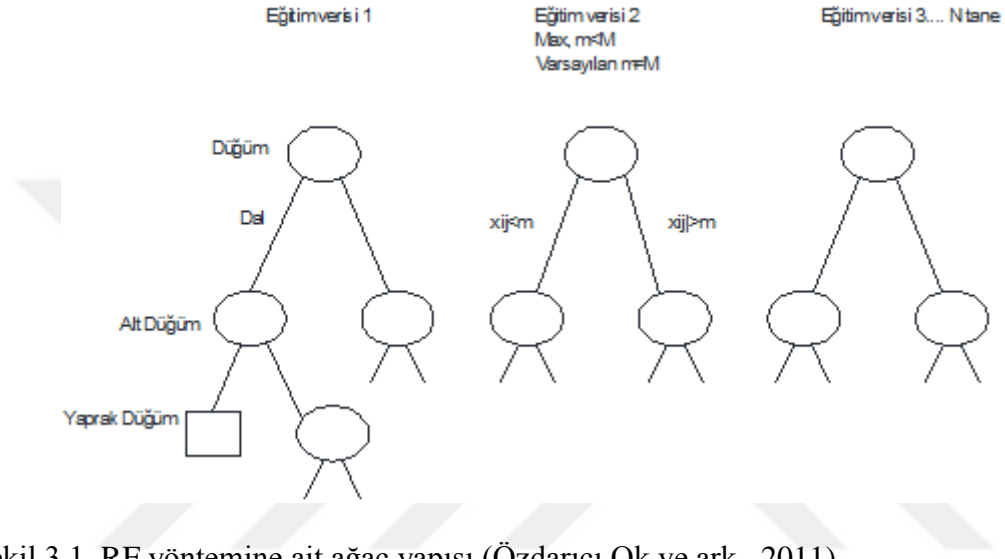
RF, genel amaçlı sınıflandırma ve regresyon yöntemi olarak oldukça başarılı bir yöntemdir. Bu yöntem, çeşitli rastgele karar ağaçlarını bir araya getirip onların ortalamalarını alarak tahminlerini birleştirmektedir (Biau ve Scornet, 2016). Rastgele Orman yöntemi; bağımsız değişken sayısının fazla olduğu büyük veri setlerinde ve kayıp gözlemlerin (missing data) çok olduğu durumlarda tahmin performansı yüksektir. Bu yöntem, bağımsız değişkenlerin önem düzeylerini ölçmektedir (Bilgen, 2014).

RF yöntemi; Diskriminant Analizi, Destek Vektör Makineleri ve Yapay Sinir Ağları da dâhil olmak üzere diğer birçok sınıflama yöntemleriyle karşılaştırıldığında çok daha iyi performans göstermektedir (Breiman, 2001; Liaw ve Wiener, 2002).

RF, çeşitli tahmin problemlerine ve parametre sayısının az olduğu durumlara uygulanabilen, tahmin performansı yüksek bir yöntemdir (Biau ve Scornet, 2016; Geneur ve ark., 2017). Yöntem kullanımının basit olmasının yanı sıra; genellikle doğruluğu, küçük örnek boyutları ve yüksek boyutlu özellik alanları ile başa çıkabilme yeteneği ile tanınır. Aynı zamanda, kolayca paralelleştirilebilme özelliğinden ötürü gerçek hayat problemlerine uygulanabilme potansiyeline sahiptir (Biau ve Scornet, 2016).

RF yöntemi; hava kalite tahminlerinde, ekoloji, üç boyutlu nesnelere tanıma, biyoinformatik, kemoinformatik, ekonometri alanları da dahil olmak üzere çeşitli uygulamalı problemlerin çözümünde kullanılmaktadır (Biau ve Scornet, 2016).

RF yöntemine artan ilgi ve talebe rağmen yöntemin istatistiksel özellikleri ve matematiksel gücü ile ilgili az sayıda bilgi bulunmaktadır (Biau,2012; Biau ve Scornet, 2016).



Şekil 3.1. RF yöntemine ait ağaç yapısı (Özdarıcı Ok ve ark., 2011).

RF, her bir ağacın, ormandaki tüm ağaçlar ile benzer dağılım gösterdiği ve bağımsız olarak örneklenen bir rastgele vektörün değerlerine bağlı olarak tahmin ağaçlarını birleştiren bir yöntemdir. Ormandaki genelleme hatası, ormandaki ağaç sayısı arttıkça sınıra yakınsar. Ormandaki ağaç sınıflandırıcılarının genelleme hatası, ormandaki bireysel ağaçların gücüne ve ağaçlar arasındaki korelasyona bağlıdır (Breiman, 2001).

RF yöntemi, Bagging yönteminin özel bir örneğidir. Yöntemin, diğer gözetimli öğrenme yöntemlerine göre, daha iyi bir doğruluk elde ettiği gösterilmiştir (Breiman, 2001; Svetnik ve ark., 2003). Ayrıca; bu yöntem, her bir aday kestiricisi için değişken önemi ölçümlerini sağlamaktadır (Breiman, 2001; Liaw ve Wiener, 2002; Archer ve Kimes, 2008).

RF yönteminde, çalışılmak istenilen sayıda ağaçla çalışılabilir. Ayrıca; mevcut algoritmalar arasında doğrulukta eşsiz olup aşırı uyuma karşı dayanıklı ve çok hızlıdır (Breiman ve Cutler, 2011).

RF yönteminde, budama ya da durdurma kuralı geçerli değildir (Breiman 2001; Archer ve Kimes, 2008). Quinlan (1993)'e göre budamanın olmaması, RF yönteminin diğer karar ağacı yöntemlerine göre en büyük avantajlarından biridir (Quinlan, 1993). Budama yöntemlerinin seçimi ile ilgili araştırmalar, budama yöntemi seçiminin ağaç tabanlı sınıflandırıcıların performansında herhangi bir katkısı olmadığını göstermektedir (Pal, 1989; Pal ve Mather 2003; Pal, 2007).

RF yöntemi; veri setindeki farklı bir bootstrap örneği kullanılarak her bir ağacın oluşturulmasının yanında, sınıflandırma veya regresyon ağaçları oluşturulmasına göre değişim göstermektedir. Standart ağaçlarda her bir düğümde, tüm değişkenler arasında en iyi bölünme kullanılarak bölünme gerçekleştirilmektedir. Rastgele Orman yönteminde ise her bir düğüm, tüm düğümler arasından rastgele seçilen tahmincilerin içinden en iyi bölünmeyi sağlayan yordayıcılar kullanılarak oluşturulmaktadır (Liaw ve Wiener, 2002).

RF yönteminde, birden fazla ağaçtan oluşan karar ormanında örnekleme seçilen her bir ağaç hem bootstrap örnekleme yöntemi hem de rastgele ve yerine koyma yöntemi kullanılarak seçilmektedir. Bundan dolayı; Breiman'a göre, Rastgele Orman yönteminin rastgelelik oranı, Bagging (Torbalama) yöntemine nazaran daha fazladır. Ayrıca; RF yönteminde tüm değişkenler arasından rastgele olarak seçilen daha az sayıda değişken kullanılmaktayken, Bagging yönteminde, veri setinde yer alan tüm değişkenler kullanılmaktadır (Akman, 2010; Akar, 2013).

RF, düğümü dallara ayırmak için, her düğümde rassal olarak seçilen değişkenlerin içinden en iyi olanını kullanır. Orijinal veri seti içinden yinelemeli olarak veri setleri üretilir ve rastgelelik özelliği kullanılmasıyla ağaçlar geliştirilir (Breiman 2001; Archer ve Kimes, 2008; Akar ve Güngör, 2012). Bundan dolayı; RF yöntemi, CART algoritmasını kullanmaktadır (Breiman 2001; Archer ve Kimes, 2008).

CART algoritmasında; her bir düğümdeki dallar, veri setindeki en geniş sınıfi diğer sınıflardan ikili olacak şekilde ayıran GINI indeksine göre oluşturulur. GINI indeksi, sınıf homojenliği hakkında bilgi veren bir ölçü olup indeks küçükse sınıfın homojen, büyükse sınıfın heterojen olduğunu göstermektedir (Akar ve Güngör, 2012).

GINI katsayısı;  $n$  sınıftan örnekler içeren veri seti  $D$  ve  $p_j$  sınıfının göreceli frekansı,  $p(j/t)$  ise  $t$  düğümündeki  $j$  sınıfına ait nispi olasılığı göstermek üzere,



$$Gini(t) = 1 - \sum_j [p(j|t)]^2 \quad (3.5)$$

Eşitliği ile hesaplanmaktadır (Akar ve ark., 2010).

RF algoritmasını uygulayabilmek için, her bir düğümde kullanılacak değişkenlerin sayısı (m) ve geliştirilecek ağaçların sayısı N kullanıcı tarafından belirlenmelidir (Akar ve Güngör, 2012).

RF yönteminde, model kurulma aşamasında, modeli test etmek için orijinal veri setinin mi yoksa ayrı bir test veri setinin mi kullanılacağına karar verilmelidir. Orijinal veri seti kullanılacaksa, bu veri setinin 2/3'ü eğitim verisi (önyükleme örnekleri-inBag), diğerleri ise test verisi (Out of Bag(OOB)) olarak ayrılmalıdır. Ayrı veri seti kullanılması veya orijinal veri setinden test verisi ayrılması durumunda ise ayrılan bu verilerin 2/3'ü eğitim veri seti olarak, kalanları ise test verisi olarak kullanılır (Akman, 2010; Atasever, 2011). Bu önyükleme örneklerinden budama yapmaya gerek olmadan ağaçlar geliştirilir (Akar ve Güngör, 2012). Geliştirilen ağaçlar test veri seti (OOB) ile test edilerek hata oranı belirlenir. Tüm ağaçların ortalaması alınarak, modele ait ortalama hata oranı tespit edilir. Hata oranı en az olan ağaç en yüksek ağırlık ile en yüksek hata oranına sahip ağaç ise en düşük ağırlık ile ağırlıklandırılır (Atasever, 2011).

RF sınıflandırıcısı;  $\theta_K$  rastgele vektör, x ise girdi verisini göstermek üzere  $\{h(x, \theta_K) \mid k=1, \dots, K\}$  şeklinde gösterilmektedir. Kazanan sınıfın belirlenmesi için geliştirilen her bir karar ağacına oy verilerek en çok oyu kazanan sınıf belirlenir. Yapılan işlemlere Rastgele Orman denir (Akar ve ark., 2010).

RF yönteminde; karar ağaçlarının her biri, bootstrap tekniği kullanılarak orijinal veri setinden seçilen örneklem ve değişkenler arasından rastgele seçilen değişkenlerin belirlenmesi ile oluşturulur (Akman, 2010).

RF,  $\Theta$  rassal değişkenin çıktıları  $\theta_1, \theta_2, \dots, \theta_m$  olan,  $\{r_n(x, \theta_m, D_n), m \geq 1\}$  şeklinde tanımlanan rastgele temelli regresyon ağaçlarından meydana gelen tahminciler topluluğu olarak kabul edilir. Bu rastgele ağaçlar, kümelenmiş regresyon tahminleri ile birleştirilir. Buna ait eşitlik aşağıda gösterilmiştir.

$$\bar{r}_n(\mathbf{X}, D_n) = \mathbb{E}_\theta [r_n(\mathbf{X}, \theta, D_n)] \quad (3.6)$$

Eşitliğinde;  $E_{\Theta}$ , koşullu olarak  $\mathbf{X}$  ve veri seti  $D_n$  üzerindeki rastgele parametreye ilişkin beklentiyi belirtir.  $\Theta$  rastgele değişkeni, bireysel ağaçların oluşturulmasında ardışık bölmelerin nasıl yapılacağını, örneğin; ayrılacak koordinatın seçimi ve bölünme pozisyonunu belirlemek için kullanılmaktadır. Akılda tutulan modelde, değişkenin  $\mathbf{X}$ 'ten bağımsız olduğu ve eğitim örneğinin  $D_n$  olduğu varsayılır. Bu, özellikle eğitim setindeki herhangi bir önyükleme veya yeniden örnekleme adımının kabul edilmemesinde olduğunu göstermektedir (Biau, 2012).

Rastgele orman algoritması, sınıflama ve regresyon problemleri için aşağıdaki gibidir:

1. Orijinal verilerden  $n$  adet bootstrap örnekleri seçilir. Bunların  $1/3$ 'ü test  $2/3$ 'ü ise eğitim verileri olarak kullanılır.
2. Her bir önyükleme örnekleri için budanmamış sınıflama ve regresyon ağaçları büyütülür. Bunun için; eğitim (inBag) veri setinde bulunan tüm değişkenler arasından en iyi bölünmeyi sağlayanı seçmek yerine, önce  $m$  adet rastgele örnek seçilir ve onlar arasından en iyi bölünmeyi sağlayacak olan belirlenir.
3.  $n$  adet karar ağaçlarının tahminleri toplanarak yeni veri seti tahmin edilir. Örneğin; regresyon için ortalama, sınıflama için oy çoğunluğu dikkate alınarak yeni veri seti tahmin edilir (Liaw ve Wiener, 2002).

Eğitim verilerine dayanarak hata oranına ilişkin tahmin, aşağıdaki şekilde elde edilebilir.

1. Her bir bootstrap yinelemesinde, bootstrap örneğiyle büyüyen ağaç kullanılarak bootstrap örneği olmayan veriler tahmin edilir ("out-of-bag-OOB" veya test verileri).
2. OOB tahminleri toplanır (Ortalama olarak, her veri noktasının yaklaşık %36'sı OOB verileri olup bu tahminler toplanacaktır). Hata oranı hesaplanır ve hata oranının OOB tahmini olarak adlandırılır (Liaw ve Wiener, 2002).

Ormandaki hata oranı iki şeye bağlıdır:

1. Ormandaki ağaçlar arasında korelasyon yoktur. Korelasyon artarsa ormandaki hata oranı artar.

2. Ormandaki bireysel ağaçlar güçlüdür. Düşük hata oranına sahip ağaç güçlü bir sınıflandırıcıya sahiptir. Bireysel ağaçların gücünün artırılması ormanın hata oranını düşürür (Breiman ve Cutler, 2011).

### 3.2.1.1. Rastgele orman yönteminin özellikleri

- a. Mevcut algoritmalar arasında doğruluğu eşsizdir.
- b. Büyük veri tabanlarında verimli çalışır.
- c. Değişken silinmeden binlerce girdi değişkenini işleyebilir.
- d. Sınıflamada hangi değişkenlerin önemli olduğunu tahmin eder.
- e. Ormandaki ağaçların yapım sürecinde genelleme hatasının yansız tahminini üretir.
- f. Kayıp verileri tahmin etmek için etkin bir yöntem olup kayıp verilerin oranının yüksek olduğu durumlarda doğruluğunu korur.
- g. Dengesiz veri kümesine sahip sınıflarda hatayı dengeleyen yöntemler vardır.
- h. Üretilen ormanlar, diğer verilerde kullanmak için saklanabilir.
- i. Değişkenler ve sınıflama arasındaki ilişki ile ilgili bilgi veren prototipler hesaplanır.
- j. Kümeleme, aykırı değerlerin yerleşimlerdeki farklılıkları tespit etmek için durum çiftleri arasındaki yakınlıkları hesaplar.
- k. Yukarıda belirtilen özellikler aykırı değer, veri görünümleri, denetimsiz kümelemeye yol açan işaretlenmemiş veriler genişletilebilir.
- l. Değişkenler arasındaki etkileşimleri belirlemek için deneysel bir yöntem sunar (Breiman ve Cutler, 2011).

#### 3.2.1.1.1. Değişken önem derecesi (Variance importance)

Makine öğrenme yöntemlerinde temel amaç, yalnızca en doğru modeli bulmak değil, aynı zamanda bağımsız değişkenlerin hangisinin en önemli olduğunu belirlemektir. Bu bağlamda, RF yöntemi, bağımsız değişkenin önemini değerlendirmek için çeşitli yöntemler sunar ve modelin yorumlanabilirliğini artırır (Louppe, 2014).

Değişken önemini tanımlamak oldukça zordur. Çünkü bir değişkenin önemi, diğer değişkenlerle olan karmaşık etkileşimlerinden kaynaklı olabilir. Rastgele Orman algoritması; bir değişkenin önemini, diğer tüm değişkenlerin değişmeden bırakıldığı ve o değişkene ait (OOB) verilerinin değiştirilmesi durumunda, tahmin hatasının ne kadar arttığına bakarak belirlemektedir (Liaw ve Wiener, 2002).

RF yönteminde; regresyon ya da sınıflandırma problemlerinde, değişkenlerin önem derecesini belirlemek için iki ölçü kullanılmaktadır. İlk olarak; Safsızlık Azalış Ortalaması (Mean decrease impurity - MDI) hesaplanır. Safsızlık Azalış Ortalaması, tüm ağaçların ortalaması alınarak, değişkenlerdeki bölünmeler nedeniyle, safsızlık miktarındaki toplam azalmaya dayanmaktadır. İkinci olarak; Doğruluk Azalış Ortalaması (Mean Decrease Accuracy - MDA) hesaplanır. Doğruluk Azalış Ortalaması, ilk olarak Breiman (2001) tarafından tanımlanmış olup eğer değişken önemli değilse, değerleri yeniden düzenlemenin tahmin doğruluğunu düşürmemesi gerektiği fikrinden doğmuştur (Biau ve Scornet, 2016).

Veri seti  $X = (X(1), \dots, X(p))$ . M ağaçlarının toplanmasıyla oluşan bir orman için,  $X(j)$  değişkeninin Safsızlık Azalış Ortalamasını gösteren eşitlik aşağıda verilmiştir.

$$\widehat{MDI}(X^{(j)}) = \frac{1}{M} \sum_{\ell=1}^M \sum_{\substack{t \in T_{\ell} \\ j_{n,t}^* = j}} p_{n,t} L_{reg,n}(j_{n,t}^*, z_{n,t}^*) \quad (3.7)$$

Burada;  $p_{n,t}$ , t düğümüne düşen gözlemlerin bölümü;  $\{T_{\ell}\}_{1 \leq \ell \leq M}$  ormandaki ağaçlar topluluğunu göstermektedir.  $j_{n,t}^*, z_{n,t}^*$  bölünmeleri ise t düğümündeki deneysel kriterleri maksimize etmektedir.

$X(j)$  'in Doğruluk Azalış Ortalaması değeri ise tüm ağaçlar üzerindeki yer değiştirme öncesi ve sonrası torba dışı (out-of-bag) hata tahminindeki farkın ortalaması alınarak elde edilir.  $X(j)$  bir değişken,  $D_{\ell,n}$ ,  $\ell$ . ağacın out-of bag verileri ile  $D_{\ell,n}^j$   $X(j)$  değerlerinin aynı olduğu veri seti rastgele değiştirilir.  $m_n(\cdot, \theta_{\ell})$   $\ell$ . ağacın tahminlerini temsil etmektedir.

$$\widehat{MDA}(X^{(j)}) = \frac{1}{M} \sum_{\ell=1}^M \left[ R_n[m_n(\cdot, \theta_{\ell}), D_{\ell,n}^j] - R_n[m_n(\cdot, \theta_{\ell}), D_{\ell,n}] \right] \quad (3.8)$$

Burada;  $R_n, \mathcal{D} = \mathcal{D}_{\ell,n}$  ya da  $\mathcal{D} = D_{\ell,n}^j$  olarak tanımlanır.

$$[R_n[m_n(\cdot, \theta_\ell)]] = \frac{1}{|D|} \sum_{i:(x_i, y_i) \in D} (Y_i - m_n(X_i; \theta_\ell))^2 \quad (3.9)$$

(Biau ve Scornet, 2016).

### 3.2.1.1.2. Örnekler arası yakınlık ölçüleri (Proximity measures)


RF yöntemi tarafından üretilen (i,j) elemanlarına ait yakınlık matrisi (proximity matrix), aynı terminal düğümüne düşen i ve j elemanlarının küçük bir parçasıdır. Bu durum, benzer gözlemlerin benzemeyenlerden daha çok aynı düğümde olması anlamına gelmektedir. Yakınlık matrisi, veri yapısını belirlemek ya da Rastgele Orman ile gözetimsiz öğrenme için kullanılmaktadır (Liaw ve Wiener, 2002).

Breiman (2002) tarafından önerilen, ağaç tabanlı topluluk yöntemlerine yardımcı olan başka bir yöntem, iki örnek noktası arasındaki yakınlığı ölçen yakınlık ölçüsüdür.  $(x_1, y_1)$  ve  $(x_2, y_2)$  arasındaki yakınlık, ormandaki ağaçların sayısına göre standartlaştırılan, her bir karar ağacında aynı t yaprağına ulaşan örnek sayısı olarak tanımlanır. Yani;

$$\text{proximity}(x_1, x_2) = \frac{1}{M} \sum_{m=1}^M \sum_{t \in \varphi_{\mathcal{L}, \theta_m}} 1(x_1, x_2 \in \mathcal{X}_t) \quad (3.10)$$

Burada;  $\varphi_{\mathcal{L}, \theta_m}$ ,  $\varphi_{\mathcal{L}, \theta_m}$  terminal düğümlerinin kümesini göstermektedir (Louppe, 2014).

Yakınlık ölçüsü, veriler yüksek boyutlu veya karışık girdi değişkenleri içerse bile, örneklerin rastgele ormanın merkezine ne kadar yakın olduğunu göstermektedir (Hastie ve ark., 2005; Louppe, 2014). Yakınlık 1'e yakın olduğunda, örnekler aynı yapraklara yayıldığından, orman benzerdir. Diğer taraftan; yakınlık sıfır ise, örnekler farklı yapraklarda bulunuyor ve yapı olarak diğerlerinden farklıdır demektir. Yakınlık ölçüsü, ormandaki ağaçların hem sayısına hem de yoğunluğuna (derinliğine) bağlıdır. Ağaçlar sık olduğunda, aynı yapraklarda ortaya çıkma olasılığı, ağaçların daha yoğun olmasına nazaran daha yüksektir. Bu durum, ölçünün yayılmasını etkiler (Louppe, 2014).



Şekil 3.2. 10 sınıflı digit sınıflandırma için yakınlık grafiği (Louppe, 2014).

Yakınlık matrisi,  $n \times n$  boyutlu simetrik bir matristir. Ağaçlar oluşturulurken tüm veriler ağaca, yukarıdan aşağıya doğru yerleştirilir. Burada  $n$ , veri setindeki tüm gözlemleri ifade etmektedir (Akman, 2010; Yılmaz, 2014). İki gözlem arasındaki yakınlık (ormandaki ağaçlarda egemen olan oran), ağaçların aynı düğümde sonlandığı zamandaki oranını göstermektedir. Eğer gözlemler, her zaman aynı düğümde olursa yakınlık bir, eğer asla aynı düğümde olmayacaklarsa yakınlık sıfır olacaktır. Öklid uzayına çok uzak düşen gözlemler, yani; alakasız veya zayıf gözlemler oldukça büyük yakınlığa; bağımlı değişken tahmin etmek için önemli değişkenler ise göreceli olarak önemsiz yakınlığa sahip olmaktadır (Cutler ve ark., 2011).

### 3.2.1.1.3. Kayıp gözlem kestirimi

Gerçek hayattaki veriler uygulamadaki kısıtlamalar, fiziksel veya özel nedenlerden dolayı kusurlu, hatalı veya eksiktir. Özellikle, çoğu makine öğrenme algoritması, çoğu zaman kayıp veri içeren veri setleri için uygun değildir, çünkü tüm girdi değişkenleri için tüm değerlerin bilindiğini varsaymaktadır (Louppe, 2014).

RF yönteminin güçlü yanlarından biri de kayıp verileri işleyebilmesidir. Breiman (2003), kayıp verileri tahmin etmek için ormandaki gözlem çiftleri arasındaki yakınlığı ölçen yakınlık matrisinden yararlanmaktadır (Biau ve Scornet, 2016).

Kayıp veri ataması yinelemeli bir süreç olup ilk ormanda, ortanca değer kullanılarak yakınlıklar hesaplanır. Kayıp verisi bulunan değişkenin sürekli veya

kategorik olmasına göre farklı şekilde atama işlemi gerçekleştirilmektedir. Değişken sürekli ise kayıp verisi bulunmayan verilerin ortanca değeri atanırken, değişken kategorik ise yakınlık değeri en uzak olana göre atama işlemi gerçekleştirilir. Daha sonra, Rastgele Orman modeli kurularak yakınlık matrisi oluşturulur. Sürekli değişkenler için yakınlık ile ağırlıklandırılmış ortalama; kategorik değişkenler için ise yakınlık ile ağırlıklandırılmış oy kullanılır. Yeni orman, yeni yakınlıklar ve hesaplamalar yapılarak inşa edilir. Genellikle 5 ya da 6 iterasyonda tutarlı sonuçlar elde edilir (Cutler ve ark., 2011; Yılmaz, 2014).

Bu yöntemde, yakınlığa dayalı en yakın komşuluk yöntemi kullanıldığından kayıp değerlerin rastgele dağıldığı durumlarda kullanılması uygundur (Cutler ve ark., 2011).

#### **3.2.1.1.4. Tutarlılık**

Uygulamadaki yaygın kullanımlarına, mükemmel performansa ve göreceli olarak algoritmik sadeliğe rağmen, RF yöntemini yönlendiren matematiksel mekanizmalar hala iyi anlaşılmamıştır. Breiman ve ark. (1984), tarafından tek karar ağaçlarının hem regresyon hem de sınıflandırmada tutarlı olduğu kanıtlanmıştır. Rastgele ağaçlar topluluklarını inceleyen ilk çalışmalardan biri Zhao tarafından yapılmıştır (Zhao, 2000). Sınıflandırmada yazar, PERT'nin (zayıf) tutarlı olduğunu, ancak ağaçların yapımının erken durması durumunda güçlü bir tutarlılık sağladığını ileri sürmektedir. Biau (2012) çalışmasında, gerçek RF algoritmasının tutarlılığına incelemiş ve RF yönteminin performansının sadece bağımlı değişken sayısına bağlı olduğunu belirtmiştir. İkili sınıflamada Biau ve ark. (2008), bir toplulukta eğer randomize taban modellerinin olması durumunda ve çoğunluk veya zayıf oylama topluluklarında tutarlı olduğunu kanıtlamışlardır. Scornet ve ark. (2014) çalışmasında, orijinal RF algoritması için ilk olarak tutarlılığı incelemişlerdir. Özellikle; güçlü tutarlılığı, regresyon katkılı modellerde, Bootstrap örnekleme yerine alt örneklemin varsayıldığı durumlarda elde etmişlerdir (Loupe, 2014).

RF yönteminin tutarlılığı için, Breiman (2001; 2004) ve Lin ve Jeon (2006) tarafından yapılan çalışmalarda, RF ve uyarlanabilir en yakın komşu yöntemleri

arasında bir bağlantı kurmuşlardır. Meinshausen (2006), Quantile Regresyon yönteminde, Rastgele Ormanların tutarlılığını kanıtlamıştır (Biau ve ark., 2008).

Biau ve ark. (2008), Tam Rastgele Orman ve Ölçek Değişmez Rastgele Orman sınıflandırıcılarının tutarlılığını ispatlamışlardır (Biau ve ark., 2008).

### **3.2.1.1.5. Bootstrap örnekleme**

RF yöntemi, birçok sınıflandırma ağacından oluşmakta ve tüm ağaçların tahminlerini birleştirmektedir. Bu algoritma, veri setinde birçok bootstrap örnekleminin seçimi ile başlar. Tipik bir bootstrap örnekleme, en az orijinal gözlemlerin yaklaşık olarak %63'ünü oluşturmaktadır. Orijinal veri kümesindeki Bootstrap örneklemede bulunmayan gözlemlere out-of-bag gözlemleri denir. Bir sınıflandırma ağacı, her bir bootstrap örnekleme uygun iken her bir düğümdeki küçük sayıda rastgele seçilen değişkenler sadece ikili bölünmeye uygundur. Ağaçlar tamamen büyür ve her biri OOB verilerini tahmin etmek için kullanılır. Bir gözlemin öngörülen sınıfı, gözlemlerin OOB tahminlerinin oy çoğunluğu ile hesaplanır (Cutler ve ark., 2007).

### **3.2.1.2. Rastgele orman algoritmasının avantajları ve dezavantajları**

RF yönteminin diğer istatistiksel yöntemlerle karşılaştırıldığında, çok yüksek sınıflandırma doğruluğu, değişken önemini belirleyen yeni bir yöntem olması, yordayıcı değişkenler arasındaki karmaşık etkileşimleri modelleme becerisi, regresyon, sınıflandırma, sağkalım analizi ve denetimsiz öğrenmeyi içeren çeşitli istatistiksel veri analizi yöntemleriyle çalışabilme olanağı ve kayıp verileri kullanabilme yeteneği olması gibi avantajları bulunmaktadır (Cutler ve ark., 2007). Ayrıca; aşırı uyumu engelleme, çok boyutlu veri setlerinde hızlı işlem yapabilme, kayıp verili setlerde yüksek doğruluk oranı özelliklerine sahiptir (Guo ve ark., 2017). Buna ek olarak; bu yöntem ile iki yönlü olarak örnekler arasındaki yakınlık ölçülebilir (Prajwala, 2015).

Dezavantajları ise, farklı düzeylerde kategorik verisi bulunan veri setlerinde, RF yöntemi düzeyi çok olan özellik lehine eğilimlidir. Eğer, çıktı için benzer özellik içeren ilişkili gruplar içeriyorsa, küçük gruplar büyük gruplara göre daha avantajlıdır (Prajwala, 2015).



### 3.2.2. Çok katmanlı algılayıcı yapay sinir ağları (Multilayer perceptron artificial neural network)

Çok Katmanlı Algılayıcı Yapay Sinir Ağları (MLPANN), örüntü tanıma, ses ve sınıflandırma problemleri gibi birçok alandaki sınıflandırma ve regresyon uygulamalarında yaygın olarak kullanılmaktadır. Özellikle, her nöron için kullanılan aktivasyon fonksiyon tipinin yapısının tercihi açısından, bu ağların yakınsaması üzerinde büyük bir etkiye sahiptir (Ramchoun ve ark., 2017).

MLPANN genellikle; sınıflama, tahminleme, tanıma ve yorumlama konularında yüksek performansa sahiptir (Öztemel, 2012). Eğitim aşamasında, girdiler (input) ve olası çıktılar (output) birlikte gösterildiği bu model, YSA'da en sık kullanılan modeldir (Seyman ve Taşpınar 2009).

MLPANN yönteminde; bir giriş katmanı, bir çıkış katmanı, bir de giriş ve çıkış arasında bir ya da birkaç gizli katman bulunmaktadır. Katmanlardaki işlem birimi birbirine bağlıdır (Hamzaçebi, 2011; Gönül ve ark., 2015). MLPANN'lerde giriş katmanı ile çözümlenecek olan bilgiler sisteme alınır, çıkış katmanı ile işlenen bilgi dışarıya verilir (Kaynar ve Taştan, 2009).

MLPANN'nin eğitimi için geri yayılım algoritması kullanılır. Bu algorithmada hatalar, geriye doğru çıkıştan girişe doğru azaltılmaya çalışılır (Seyman ve Taşpınar, 2009). MLPANN'lerde, ağdan beklenen sonuç ile elde edilen sonuç arasındaki hatayı asgariye indirmek amaçlanmaktadır. Bu ağlarda, ağ mimarisini belirleyerek ağı tahmin amaçlı olarak da kullanmak mümkündür (Kaynar ve ark., 2010; Çuhadar, 2013 ).

#### 3.2.2.1. Algılayıcı Öğrenme Algoritması (Perceptron Learning Algorithm)

1. Ağırlıklar ve eşik değeri başlatılır.  
 $w_i(t)$  ( $0 \leq i \leq n$ ), t zamanda i'ninci girdi değerlerinin ağırlığı ve  $\theta$ 'yı ise çıktı düğümündeki eşik değeri olarak belirlenir.  $w_0$ 'ı  $-\theta$ , yanılmayı ve  $x_0$  'ı ise her zaman 1 olarak alıp başlanır.
2. Küçük rastgele değerler için  $w_0$  'la başlayın ve böylece tüm ağırlıkları ve eşik değeri tanımlanır. Arzulanan girdi  $x_0, x_1, x_2, \dots, x_n$  ve arzulanan çıktı  $d(t)$  olarak tanıtılır.

3. Asıl çıktıyı aşağıda verilen eşitlik ile hesaplanır.

$$y(t) = f_h[\sum_{i=0}^n w_i(t)x_i(t)]$$

(3.11)

4. Ağırlıklar ayarlanır.

Ağın doğru kararı vermesi durumunda, ağırlıklar değişmemektedir. Ayrıca; ağırlıklar, geçersiz cevaba katkıda bulunmayan girdi satırlarında ayarlanmaz, çünkü her ağırlık,  $x_i$  sıfır olduğunda o satırdaki girişin değeriyle ayarlanmıştır (Beale ve Jackson, 1990).

### 3.2.2.2. Geri yayılım algoritması ( Back propagation algorithm )

Geri yayılım algoritması aşağıda özetlenmiştir.


1. Ağ ağırlıkları başlatılır.
2. Ağ için, eğitim verisinden ilk giriş vektörü sunulur.
3. Bir çıkış elde etmek için giriş vektörü ağ üzerinden yayılır.
4. Gerçek çıktı ile istenen (hedef) çıktı karşılaştırılarak bir hata sinyali hesaplanır.
5. Hata sinyali ağ boyunca geriye doğru yayılır.
6. Genel hatayı en aza indirmek için ağırlıklar ayarlanır.
7. Genel hata yeterli derecede küçük olana kadar, sonraki giriş vektörü ile 2-7 arasındaki adımları tekrarlanır (Gardner ve Dorling, 1998).

### 3.2.2.3. Çok katmanlı algılayıcı yapay sinir ağlarının yapısı (Architecture of multilayer perceptron artificial neural network)

Çok katmanlı algılayıcının temel yapısı, tek nöron veya düğüm şeklindedir. Bu yöntemde; bir düğüm,  $x_1, \dots, x_n$  gibi bir dizi değer alır ve daha sonra girdi değerleri  $w_1, \dots, w_n$  olan bir dizi ağırlık ile çarpılarak sonuç değerleri toplanır. Bu ağırlıklı girdi toplamına, düğüm eşiği olarak bilinen bir sabit  $\theta$  değeri eklenir. Düğümün çıktısı,

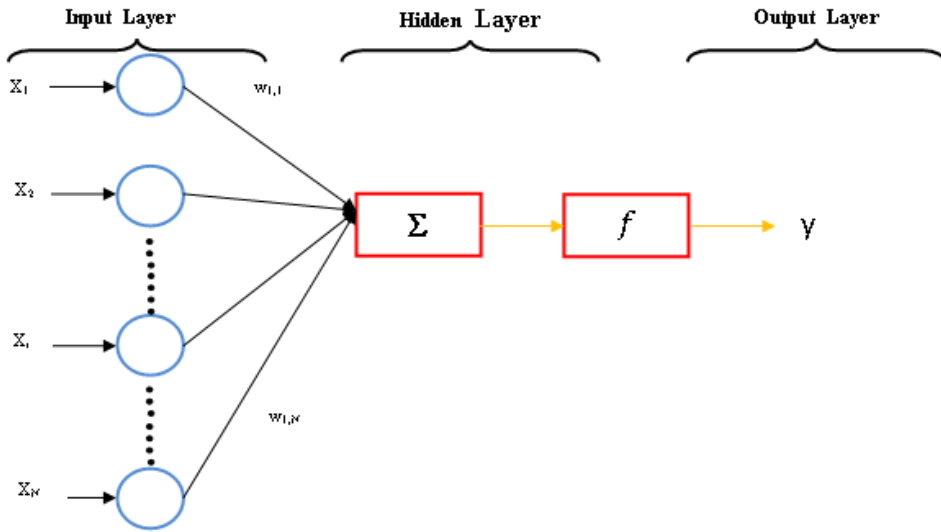
toplamin doğrusal olmayan bir fonksiyonu değerlendirilerek elde edilir.  $f$ 'nin düğüm aktivasyon fonksiyonu aşağıda verilen eşitlikle gösterilmiştir (Gibson ve ark., 1989).

$$f(x) = (1 - e^{-x}) / (1 + e^{-x}) \quad (3.12)$$



Şekil 3.3. Çok katmanlı bir algılayıcının düğüm yapısı ve aktivasyon fonksiyonu (Gibson ve ark., 1989).

Çok katmanlı bir algılayıcı, şekil 3.2'de gösterildiği gibi tabakalar halinde düzenlenmiş bir dizi düğümden meydana gelmektedir. Bu yöntemde; çok boyutlu bir giriş, ilk katmandaki her bir düğüme geçer. Yani; ilk katmandaki düğümlerin çıktıları, daha sonra ikinci katmandaki düğümlere girdi olur ve böylece süreç devam eder. Bu nedenle; ağın çıktıları, son tabakada yer alan düğümlerin çıktılarıdır. Burada, izleyen katmandaki her düğümden bir düğüme ağırlıklı bağlantılar var iken, aynı katmandaki düğümler arasında hiçbir bağlantı yoktur (Gibson ve ark., 1989).



Şekil 3.4. Çok katmanlı bir algılayıcı yapay sinir ağının temel yapısı (Kayri, 2015)

#### 3.2.2.4. Çok katmanlı algılayıcı öğrenme algoritması (Multilayer perceptron learning algorithm)

Çok katmanlı algılayıcı için aşağıda verilen algoritma, geri yayılım eğitim kuralını uygulamaktadır (Beale ve Jackson, 1990).

1. Ağırlıklar ve eşik değerler küçük rastgele değerler olacak şekilde başlatılır.
2. Girdi ve istenen çıktı sunulur. Girdi değerleri  $X_p = x_0, x_1, x_2, \dots, x_{n-1}$  ve hedef çıktı değerleri  $T_p = t_0, t_1, t_2, \dots, t_{m-1}$ ; n, girdi düğümlerinin sayısı; m ise çıktı düğümlerinin sayısıdır.  $w_0$ 'ı - $\theta$ , sapma ve  $x_0$  'ı her zaman 1 olacak şekilde ayarlanır. Model birliği için  $X_p$  ve  $T_p$  ilişkilendirilecek modelleri temsil etmektedir. Sınıflandırma için  $T_p$ ,  $X_p$  'nin bulunduğu sınıfa karşılık gelen bir ögenin ayarlanmış olması dışında sıfırlanır.
3. Asıl çıktılar hesaplanır. Her tabaka için;

$$y_{pj} = f[\sum_{i=0}^{n-1} w_i x_i] \quad (3.13)$$

Hesaplanır ve sonraki katmana girdi olarak geçilir. Burada;  $o_{pj}$  değerleri, son tabakaya ait sonuçlardır.

4. Ağırlıklar ayarlanır.

Çıkış katmanından başlanır ve geriye doğru çalışılır.

$$w_{ij}(t + 1) = w_{ij}(t) + \eta \delta_{pj} o_{pj} \quad (3.14)$$

Bu eşitlikte;  $w_{ij}(t)$ , t zamanındaki i'ninci düğümden j'ninci düğüme kadar ki ağırlıkları;  $\eta$ , kazancı,  $\delta_{pj}$  ise j düğümündeki p olayı için, hata terimini göstermektedir.

Çıktı birimleri için,

$$\delta_{pj} = k o_{pj} (1 - o_{pj}) (t_{pj} - o_{pj})$$

(3.15)

Gizli birimler için,

$$\delta_{pj} = k o_{pj} (1 - o_{pj}) \sum_k \delta_{pk} w_{jk}$$

(3.16)

Eşitlikleri kullanılmaktadır (Beale ve Jackson, 1990).

### 3.2.2.5. Çok katmanlı algılayıcı yapay sinir ağlarının eğitimi (Training a multilayer perceptron)

Çok katmanlı algılayıcının eğitimi, bireysel ağırlıkların belirlendiği bir süreçtir. Öyle ki ağdaki ilişkiler, doğru karar verilerek modellenmektedir. Burada, verilen model için, herhangi bir ağırlık kombinasyonuna ait ağ hatası belirlenebilir (Gardner ve Dorling, 1998).

Çok katmanlı algılayıcılar, eğitim yoluyla öğrenbilme becerisine sahiptir. Eğitimde, bir dizi girdi ve ilişkili çıktı vektöründen oluşan eğitim verisi kullanılmaktadır. Eğitim sürecinde, çok katmanlı algılayıcı, aralıksız olarak eğitim verisi ile birlikte sunulur (Gardner ve Dorling, 1998).

Ağı eğitmek için, bağlantıların ağırlıkları, öğrenilen bilgiye göre değiştirilir. Ağ, her bir girdi modelinin çıktısını, bu model için bir hedef çıktı ile karşılaştırarak öğrenir. Ardından hatayı hesaplar ve hata işlevini ağ boyunca geriye doğru yayar. Ağ eğitildikten sonra çalıştırmak için, girdi parametrelerinin değerleri ağa sunulur. Ağ daha sonra, eğitim sürecinde geliştirilen mevcut ağırlık değerlerini ve eşik değerlerini kullanarak, düğüm çıktıları hesaplar. Ağın çalıştırılması işlemi son derece hızlıdır, çünkü sistem, ağ düğümü değerlerini sadece bir kez hesaplar. Eğitimli bir ağın doğruluğunu test etmek için, belirleme katsayısı  $R^2$  kullanılmaktadır. Katsayı, bağımsız değişkenlerin, ölçülen bağımlı değişkeni veya değişkenleri ne kadar iyi açıklayabildiğinin bir ölçütüdür.  $R^2$  değeri ne kadar yüksekse, açıklayıcı değişkenler modeli o kadar iyi açıklar (Yeh, 1998).

### 3.2.3. Radyal tabanlı fonksiyon yapay sinir ağıları (Radial basis function artificial neural networks)

#### 3.2.3.1. Radyal tabanlı fonksiyon yapay sinir ağıları

İleri beslemeli yapay sinir ağıları, modelleme ve doğrusal olmayan sistemlerin kontrol edilmesi gibi pek çok alanda yaygın olarak kullanılmaktadır. İleri beslemeli yapay sinir ağlarından biri, Radyal Tabanlı Fonksiyon Yapay Sinir Ağları (RBFANN)'dir (Pislaru ve Shebani, 2014).

RBFANN, bağımlı ve bağımsız değişkenler arasındaki ilişkiyi tahmin etmek için kullanılan bir yöntemdir. Genel olarak Yapay Sinir Ağları; parametre kestirimi, sınıflandırma, optimizasyon gibi birçok istatistiksel işlemlerde, mevcut verinin yapısını öğrenmede güçlü bir yöntem olarak kabul edilmektedir. RBFANN, tahmin değişkenleri arasındaki karmaşık ilişkileri ortaya çıkarma ve çıkarımlar yapma özelliğine sahiptir (Hastie ve ark., 2009; Kayri, 2015; Kayri ve Çokluk, 2016).

RBFANN, ağ mimarisinin basit olması, geleneksel geri yayımlı sinir ağlarından daha hızlı olması ve durağan olmayan girdilerle ilişkili karmaşık problemlere daha dayanıklı olmasından dolayı avantaja sahiptir (Chen ve ark., 2014; Kayri, 2015). Ayrıca; kolay dizayn edilme, iyi genelleme yapma, gürültülü verilerde yüksek tolerans gösterme ve online öğrenme kabiliyeti bulunmaktadır (Yu ve ark., 2011; Santos ve ark., 2013). Bu ağlar, bağımlı ve bağımsız değişkenler arasındaki doğrusal olmayan ilişkileri ortaya çıkarmasından ötürü de önemlidir (Mustafa ve ark., 2012; Kayri, 2015). RBFANN, bağımlı değişken ve bağımsız değişkenler arasındaki ilişkileri araştırmak için sağlamlığından dolayı yaygın olarak tercih edilmektedir (Kayri ve Çokluk, 2016). RBFANN, güçlü performansı ve güzel teorik özellikleri nedeniyle makine öğreniminde dikkati çekmiştir. Herhangi bir RBFANN ağ algoritmasının kilit noktası, kapasite kontrolü özelliğine sahip olmasıdır (Que ve Belkin, 2016).

### 3.2.3.2. Radyal tabanlı fonksiyonlar (Radial basis functions)

Birçok sayıda fonksiyon, Radyal tabanlı fonksiyon (RTF) ağlarında kullanılır. Bunlardan bazıları şunlardır:

$$\phi(r) = e^{-r^2/2\sigma^2}, \quad \text{Gaussian} \quad (3.17)$$

$$\phi(r) = \frac{1}{(\sigma^2+r^2)^\alpha}, \quad \alpha > 0$$

(3.18)

$$\phi(r) = (\sigma^2 + r^2)^\beta, \quad 0 < \beta < 1$$

(3.19)

$$\phi(r) = r, \quad \text{lineer}$$

(3.20)

$$\phi(r) = \frac{1}{1+e^{(r/\sigma^2)-\theta}}, \quad \text{lojistik fonksiyon} \quad (3.21)$$


$$\phi(r) = r^2 \ln(r), \quad \text{thin-platespline}$$

(3.22)

Burada;  $r > 0$  veri noktası  $\vec{x}$  ile  $\vec{c}$  merkezi arasındaki uzaklığı temsil eder.  $\sigma$ , interpolasyon fonksiyonunun pürüzsüzlüğünü kontrol etmektedir.  $\theta$ , ise ayarlanabilir sapmayı göstermektedir. RTF ağlarında sıklıkla Gaussian fonksiyonu kullanılmaktadır (Wu ve ark., 2012).

### 3.2.3.3. Radyal tabanlı fonksiyon ağlarının yapısı (The structure of RBF network)

RTF ağının yapısı; bir gizli, bir giriş katmanı ile bir doğrusal olmayan RTF aktivasyon fonksiyonu ve doğrusal bir çıkış katmanından oluşmaktadır. Buna ait şekil aşağıda gösterilmiştir (Chen ve ark., 2014).



Şekil 3.5. Radyal tabanlı ağların yapısı (Chen ve ark., 2014).

Gizli katmanın girdileri,  $x = [x_1, x_2, \dots, x_n]^T$  olan giriş vektörünün kombinasyonlarıdır. Gelen vektörler, her bir gizli düğümdeki radyal tabanlı fonksiyonlar üzerinden eşleştirilir. Çıkış katmanı, son çıktının üretilmesi için, gizli düğümlerin çıktılarını doğrusal olarak birleştiren bir  $y$  vektörünü verir. Ağın çıkışını belirlemek için aşağıda belirtilen eşitlik kullanılır;

$$y = f(x) = \sum_{i=1}^k \omega_i \phi_i(x) \quad (3.23)$$

Burada  $\omega_i$ ,  $i$ 'nci merkezin sinaptik ağırlığı,  $\phi_i(x)$ , radyal fonksiyonu,  $k$  ise gizli düğümlerin toplam sayısını göstermektedir. Radyal fonksiyon, önceden tanımlanan merkez vektörü ve verilen girdi vektörü arasındaki uzaklığı tanımlayan çok boyutlu bir fonksiyondur (Chen ve ark., 2014). Radyal fonksiyonlar; bir merkez noktasından uzaklıklarla ilgili olarak artan ve azalan değerleri olan fonksiyonların özel bir sınıfıdır (Santos ve ark., 2013).

Normal Gaussian fonksiyonlarında genellikle aşağıda verilen radyal tabanlı fonksiyonlar kullanılmaktadır:

$$\phi_i(x) = \exp\left(-\frac{\|x-\mu_i\|^2}{2\sigma_i^2}\right) \quad (3.24)$$



Burada  $\mu_i$  ve  $\sigma_i$  sırasıyla  $i$ 'nci düğümün merkez ve yayılma genişliğini göstermektedir (Chen ve ark., 2014).

Gaussian fonksiyonu kullanılarak ağın çıkışını gösteren eşitlik şu şekilde hesaplanır;

$$y = f(x) = \sum_{i=1}^k \omega_i \exp\left(\frac{-\|x-\mu_i\|^2}{2\sigma_i^2}\right)$$

(3.25)

$$\lim_{\|x\| \rightarrow \infty} \rho[x - \mu_i] = 0$$

(3.26)

Burada, Gaussian temel fonksiyonu merkez vektör olarak kabul edilebilir. Yani; yeteri kadar gizli nörona sahip bir RTF ağının, geniş bir hassas değer aralığıyla herhangi bir sürekli fonksiyona yaklaşabileceği anlamına gelir (Chen ve ark., 2014).

Gaussian fonksiyonu kullanmanın, çoklu girdi değişkenleri için basit gösterim, radyal simetri, daha iyi pürüzsüzlük ve yüksek d düzeyde çözümleme gibi avantajları bulunmaktadır (Chen ve ark., 2014).

$s = \{(x_i, y_i) \in R_n \times R \mid i = 1, 2, \dots, N\}$  olan bir örnek seti olduğunu varsayarsak;

Normal standart hata terimi,  $E_S(F)$ :

$$E_S(F) = \frac{1}{2} \sum_{i=1}^N (y_i - F(x_i))^2 \quad (3.27)$$

Standart hata terimine göre yaklaşık fonksiyonunun (approximation function) karmaşıklığını kısıtlayan  $E_R(F)$  terimi eklenmiştir.

$$E_R(F) = \frac{1}{2} \|DF\|^2 \quad (3.28)$$

Burada; D, diferansiyel operatörü'dür. Düzenlenen ağın toplam hata terimi ise, şöyle tanımlanır:

$$E(F) = E_S(F) + \lambda E_R(F) \quad (3.29)$$

İlk terim yaklaşık fonksiyonun değerini kontrol etmekte kullanılır. İkinci terim ise yaklaşık fonksiyonun pürüzsüzlük derecesini kontrol eden düzenleme terimidir.  $\lambda$ , düzenlenen ağın parametresidir. Yukarıdaki düzenleme probleminin çözümü aşağıdaki gibi olabilir.

$$F(x) = \sum_{i=1}^N \omega_i G(x, x_i) \quad (3.30)$$

$G(x, x_i)$ , Gaussian fonksiyonu ve  $\omega_i$ , ağırlık değeridir.  $\|DF\|$ 'nin büyük değerleri sonucu oluşan eğrilik, yüksek bir faktör kullanılması ile sönmektedir.

$$G(x, x_i) = \exp\left(-\frac{1}{2\sigma^2} \|x - x_i\|^2\right) \quad (3.31)$$

(Chen ve ark., 2014)

#### 3.2.3.4. Radyal tabanlı fonksiyon ağlarının eğitimi (RBF network learning)

Radyal Tabanlı Fonksiyon Yapay Sinir Ağları için, çoğu öğrenme algoritmaları ya bir ön bilgi kullanımı ya da geçmiş deneyimler kullanılarak önceden belirlenen ağ yapısı ile başlamaktadır. Ağ sonucu, genellikle, yetersiz ya da gereksiz karmaşıktır. Uygun ağ yapısı sadece deneme yanılma yöntemiyle elde edilebilir (Billings ve Zheng, 1994).

Normal olarak, RBFANN'nin eğitim ve tasarımı üç bölümde gerçekleşmektedir. Bunlar:  $\sigma_i$  genişliğini hesaplamak,  $\mu_i$  merkezini ve  $\omega_i$  ağırlıklarını ayarlamaktır. Genişlik, merkezlerin yayılmalarına göre sabitlenir (Chen ve ark., 2014; Kayri, 2015).

$$\phi_i = e^{\left(\frac{h}{d^2} \|x - \mu_i\|^2\right)}, i=1,2,\dots,h$$

(3.32)

Burada;  $h$ , merkezlerin sayısını,  $d$  ise seçilen merkezler arasındaki maksimum uzaklıkları göstermektedir. Böylece;

$$\sigma = \frac{d}{\sqrt{2h}}$$

(3.33)

Fonksiyon tabanı (The Base Function); RBFANN'nin en küçük genişliği ile  $d$ 'nin en küçük değerine bağlı olup onun daha seçici olmasını sağlar (Chen ve ark., 2014; Kayri, 2015).

Radyal Tabanlı Yapay Sinir Ağları  $J_1 - J_2 - J_3$  şeklinde üç katmana sahip ileri beslemeli ağlardır. Gizli katmandaki her bir düğüm, doğrusal olmayan aktivasyon fonksiyonu olarak  $\phi(r)$  ile gösterilen radyal tabanlı fonksiyonu kullanır. Gizli katman girdinin doğrusal olmayan dönüşümünü gerçekleştirir. Çıkış katmanı ise doğrusal olmayan bir alanı yeni bir alana eşleyen doğrusal bir birleştiricidir. Genellikle, benzer radyal tabanlı fonksiyon, tüm düğümlere uygulanır. Yani; RTF düğümleri,  $i$ 'ninci düğümün merkezi ya da modeli  $c_i$  olan doğrusal olmayan,  $\phi_i(\vec{x}) = \phi(\vec{x} - \vec{c}_i)$   $i = 1, \dots, J_2$  bir özelliğe sahiptir. Burada,  $\phi_i(\vec{x})$  radyal tabanlı fonksiyondur. Çıkış katmanındaki nöronların sapmaları, sabit aktivasyon fonksiyonu  $\phi_0(r) = 1$  olan, gizli katmandaki ek nöronlar tarafından modellenilebilir. RTF ağı, doğrusal optimizasyon yöntemi kullanarak ortalama karesel hata (Mean square error - MSE) ile ağırlıkları ayarlayarak uygun çözümler başarabilir (Wu ve ark., 2012).

Genellikle radyal tabanlı ağlara ait ağların çıkışı,  $(\vec{x})$  girdisi için;

$$y_i(\vec{x}) = \sum_{k=1}^h w_{ki} \phi(\|\vec{x} - \vec{c}_k\|), i = 1, \dots, J_3$$

(3.34)

$y_i(\vec{x})$ ,  $i$ 'ninci çıkışı,  $w_{ki}$ ,  $i$ 'ninci çıktı birimi ile  $k$ 'ninci gizli birimler arası ağırlık bağlantıları,  $\|\cdot\|$ , öklit normunu simgelemektedir. RTF  $\phi(\cdot)$  gaussian fonksiyonu olarak seçilir. RTF ağları genellikle Gaussian RTF ağları olarak tanınır (Wu ve ark., 2012).

$N$  desen çiftler kümesi  $\{(\vec{x}_p, \vec{y}_p) | p = 1, \dots, N\}$  için, matris formu aşağıdaki gibi ifade edilebilir.

$$Y = W^T \phi \quad (3.35)$$

$W = [\vec{w}_1, \dots, \vec{w}_{J_3}]_{J_2 \times J_3}$  matrisi,  $\vec{w}_i = (w_{1i}, \dots, w_{J_2i})^T$ ,  
 $\Phi = [\vec{\phi}_1, \dots, \vec{\phi}_N]_{J_2 \times N}$  matrisi,  $\phi_p = (\phi_{p,1}, \dots, \phi_{p,J_2})^T$  p.ninci örnek için gizli katmanın çıktısıdır. Yani;  $\phi_{p,k} = \phi(\|\vec{x}_p - \vec{c}_k\|)$ ,  $Y = [\vec{y}_1, \vec{y}_2, \dots, \vec{y}_N]_{J_3 \times N}$  matrisi ve  $\vec{y}_p = (y_{p,1}, \dots, y_{p,J_3})^T$  dir.

Bir RBFANN; bir giriş katmanı, bir gizli katman ve çıkış katmanı olmak üzere üç katmandan oluşur (Kaynar ve ark., 2010). RBFANN, gizli ve çıkış katmanı arasında doğrusal ilişki, gizli ve giriş katmanları arasında ise doğrusal olmayan ilişki kurmaktadır (Chaldha ve ark., 2014).

RBFANN'lerde, giriş katmanından alınan bilgiler değiştirilmeden gizli katmana iletilir (Akbilgiç, 2011; Çuhadar, 2013). Bu ağlarda; gizli katman, doğrusal olmayan radyal tabanlı aktivasyon fonksiyonu ile desteklenirken, çıkış katmanı doğrusal bir forma sahiptir. Araştırmalarda giriş katmanı bağımsız değişkenlerden oluşmaktadır. Modele ait tüm mantıksal ve matematiksel süreç gizli katmanda meydana gelir. Y bağımlı değişkeninin tahmini, çıkış katmanında sonuçlanmaktadır (Kayri ve Çokluk, 2016).

RBFANN, N boyutlu uzaydaki verileri her kategori bir merkezi göstermek üzere farklı sınıflara veya kategorilere ayırmaktadır (Çuhadar, 2013). RBFANN, merkez, genişlik ve ağırlıklar olmak üzere üç önemli parametreden oluşur. RBFANN'nin performansı, bu parametrelerin uygun seçimine bağlıdır. Genellikle parametrelerin değerleri bilinmemekte ve ağırlık öğrenme süreci sırasında bulunabilmektedir. Bu nedenle, temel problem, RBFANN merkezlerinin uygun seçilmesidir. Bu problemin çözümünde; genellikle kümeleme algoritması (clustering algorithm) kullanılmaktadır (Pislaru ve Shebani, 2014).

Genişliği seçmek için en yaygın olarak kullanılan yöntem, hesaplanmasının kolay ve güvenilir olmasından dolayı, Öklit uzaklık ölçüsüdür. X ve C vektörü arasındaki en kısa uzaklık, Öklit uzaklığıdır (Pislaru ve Shebani, 2014).

$$E_{dist} = \sqrt{\sum_{i=1}^n X_i - c_j}$$

(3.36)

Burada,  $n$  vektör boyutu ve  $E_{dist}$  öklit uzaklığını göstermektedir. RBFANN'de öğrenme algoritmalarının amacı, eğitim hataları (training error) olarak adlandırılan aşağıda verilen hata fonksiyonunu minimize etmektir (Neruda ve Kudova, 2005).

$$E = \frac{1}{2} \sum_{t=1}^k \sum_{j=1}^p e_j^2(t)$$

(3.37)

Eğitilen ağın performansının önemli bir ölçüsü, genelleme hatası (generalization error)'dir. Hata, eğitim süresince ağı temsil etmeyen bir örnek seti üzerinde hesaplanır (Neruda ve Kudova, 2005).

RBFANN'nin amacı, Gaussian gibi doğrusal bir radyal çekirdek kombinasyonu kullanarak hedef fonksiyona yaklaşmaktır. Girdi verisi  $(x_i, y_i)$  olan her veri noktası için, merkez ve uygun katsayıların seçilmesi neticesinde tam olarak uygunluk sağlanabilir. RBFANN, aşırı uyum (overfitting) durumlarında, girdi verilerindeki en önemli olan küçük merkezlerin setini seçerek ve/veya katsayıları cezalandırarak düzenli hale getirmeye ihtiyaç duyar (Que ve Belkin, 2016).

RBFANN'nin eğitiminde gözetimsiz öğrenme ve gözetimli öğrenme birlikte kullanılmaktadır. Doğrusal dönüşüm için, gözetimli öğrenme; doğrusal olmayan dönüşüm için ise gözetimsiz öğrenme kullanılmaktadır (Jayawardena ve ark., 1997; Bayram ve ark., 2016).

Gözetimli bir eğitim sürecinde, girdi-çıkı eğitim durumlarındaki çiftlerden birkaçı, girdi çıktı eşleme fonksiyonunu öğrenmek için sinir ağı modeline sunulmaktadır. Yani; girdi verisi dikkate alındığında, sinir ağı modelinin bağlantı ağırlıkları, tahmin edilen çıktı ile hedef çıktıya uyacak şekilde yinelemeli olarak ayarlanır. Öğrenme sürecini, RBFANN'nin yapısı ve ağırlıkları belirler. Sinir ağı modelinin mimarisini ve ağırlıklarını ayarlamak için farklı eğitim (öğrenme) algoritmaları vardır (Wu, 1998).

Çıkış katmanının eğitimi, gözetimli öğrenme metodu ile yapılmaktadır. Eğitim, ağ çıkışı ve hedef çıktı arasındaki fark ile orantılı olarak güncellenen sinaptik ağırlıkların kullanıldığı Back Propagation (Geri Yayılım) algoritmasındakine benzerdir.

Öte yandan; gizli tabakanın eğitiminde, gözetimsiz öğrenme metodu uygulanmaktadır. Bu metot, her bir düğüm için uygun  $\mu_i$  ve  $\sigma_i$  ile radyal tabanlı fonksiyonlarının belirlenmesini içerir. Söz konusu parametreler sadece girdilere bağlı olup çıktılardan bağımsızdır (Jayawardena ve ark., 1997).

Radyal tabanlı yapay sinir ağlarının eğitimi aşağıdaki gibidir.

1. Girdi vektörü ( $x$ ), eğitim veri setine giriş katmanı olarak uygulanır.
2. Gizli katmanın çıktısı hesaplanır.
3. Ağın çıktı vektörü hesaplanır ve arzu edilen çıktı ile karşılaştırılır. Farkı azaltmak için ağırlık vektörü ayarlanır.
4. Eğitim setindeki her bir vektör için 1 ile 3. Adımlar tekrarlanır.
5. Hata eğilimi sıfır olana kadar 1 ile 4. Adımlar tekrarlanır (Pislaru ve Shebani, 2014).

RTF ağlarında öğrenme, Hata Kareler Ortalaması (Mean Square Error - MSE) fonksiyonunun en aza indirilmesidir ve aşağıda verilen eşitlik ile gösterilebilir.

$$E = \frac{1}{N} \sum_{i=1}^N \left\| \vec{y}_p - W^T \vec{\phi}_p \right\|^2 = \frac{1}{N} \|Y - W^T \Phi\|_F^2 \quad (3.38)$$

Burada;  $Y = [\vec{y}_1, \vec{y}_2, \dots, \dots, \vec{y}_N]$  eğitim setindeki  $i$ 'nci örneğe ait hedef çıktısı ve  $\|\cdot\|_F^2$ ,  $\|A\|_F^2 = \text{tr}(A^T A)$  olarak tanımlanan Frobenius modelidir (Wu ve ark., 2012).

RBFANN'de öğrenme, RTF merkezlerinin ve ağırlıklarının belirlenmesini gerektirir. RBFANN'nin uygulamasında en önemli şey, RTF merkezlerinin seçilmesidir. Merkezler, kümeleme veya bir öğrenme süreci ile rastgele bir alt kümeye veya eğitim örneklerinin tümüne yerleştirilebilir. Ayrıca; tüm veri noktaları, başlangıçta merkez olarak kullanılabilir. Daha sonra  $k$  En Yakın Komşuluk sınıflandırma şeması (K Nearest Neighbors – Classification) kullanılarak merkezler seçime bağlı olarak kaldırabilir. Gaussian gibi bazı RBFANN'de,  $\sigma$  pürüzsüzlük parametresini belirlemek de gereklidir. Mevcut RBFANN öğrenme algoritmaları temel olarak Gaussian RBFANN için türetilmiştir ve diğer RBFANN'ler kullanıldığında buna göre modifiye edilebilir (Wu ve ark., 2012).

#### 3.2.3.4.1. Öğrenme merkezleri (Learning RBF centers)

RBFANN eğitimi, genellikle, iki aşamalı bir strateji kullanılarak gerçekleştirilir: ilk aşamada uygun  $c_i$  merkezleri ve bunların standart sapmaları, yani; genişlikleri veya yarıçapları ve ikinci aşamada ise ağırlıklar belirlenir. Merkezlerin sayısına, eğitim süresince otomatik olarak karar verilir. Genellikle, genişliğin değeri yakın (komşu) girdi vektörlerinin arasındaki uzaklıktan daha küçüktür. Ancak; genişlik, iki uç girdi vektörü arasındaki uzaklıktan daha küçük başlayabilir (Demuth ve Beale, 1998; Wu, 1998).

#### **3.2.3.4.1.1. Eğitim setinden rastgele olarak RBFANN merkezlerinin seçimi (Selecting RBF centers randomly from training sets)**

RBFANN merkezlerini belirlemek için basit bir yöntem; eğitim setinin öğrenme problemini temsil ettiği durumda, eğitim setinden girdi modelinin bir alt örneğini rastgele seçmektir. Her bir RBFANN merkezi, girdi modeline tamamen yerleştirilir. Değiştirilemeyen boyuttaki bir büyük eğitim setinden rastgele merkez seçimine dayanan eğitim yönteminde, yalancı ters (pseudo-inverse) yönteminin kullanımının nispeten duysuz olduğu görülmüştür. Bundan dolayı yöntem, düzenleme yöntemi olarak uygulanabilir. Ancak; eğitim seti yeterince büyük değilse ya da eğitim seti öğrenme problemini temsil etmediği durumlarda; RBFANN merkezlerinin rastgele seçimi istenmeyen performansa yol açabilir. Bu durumda istenen performans elde edilene kadar başka rastgele merkezler seçilebilir (Wu ve ark., 2012).

RBFANN merkezlerini belirlemek için ayrıca, Kümeleme Analizi de kullanılmaktadır. Bu yöntemle; eğitim setinde, RBFANN merkezleri olarak kullanılan örnekler uygun kümelere gruplandırılır. Kümelerin sayısı kümeleme algoritmalarına göre otomatik olarak belirlenebilir. Kümeleme algoritmalarının performansı, RBFANN'nin öğrenme etkinliğinde önemlidir (Wu ve ark., 2012).

#### **3.2.3.4.1.2. Ağırlıkları öğrenme (Learning the weights)**

Merkezler seçildikten sonra, gizli ve çıktı tabakaları birbirine bağlayan ağırlıklar Pseudo-Inverse En Küçük Kareler yöntemiyle hesaplanır. Ağırlık vektörünün genel şekli aşağıda verilmiştir.

$$W_{k \times 1} = (\Phi_{k \times m}^T \Phi_{m \times k}^T + \lambda I_{k \times k})^{-1} \Phi^T Y_{m \times 1} \quad (3.39)$$

Eğer maliyet fonksiyonunda düzenleme yoksa ağırlık vektörü aşağıdaki şekilde azalır.

$$W = (\Phi^T \Phi)^{-1} \Phi^T Y \quad (3.40)$$

Burada;  $\Phi_m \equiv \Phi_j(X_i) \equiv \Phi_j(r \| X_i - C_j \|)$ ,  $i$ 'ninci girdi vektörü olarak değerlendirilen  $X_i$  vektörünün  $j$ 'ninci transfer fonksiyonu'dur.  $r$ , genişlik;  $k$ , gizli birimlerin sayısını,  $m$  ise eğitim olaylarının sayısını belirtmektedir.  $\Phi$ , transformasyon matrisini;  $Y$ , çıktı vektörünü ve  $W$  ağırlık vektörünü göstermektedir (Wu, 1998).

### 3.2.3.5. Geleneksel yapay sinir ağları ile radyal tabanlı yapay sinir ağlarının karşılaştırılması (Comparison between Traditional Neural Networks and Radial Basis Function Networks)

Benzer topolojiye sahip olmalarından ötürü, genellikle, RBFANN'nin MLPANN'ye ait olduğu düşünülmektedir. RBFANN'nin, artan girdi boyutları ile MLPANN'ye uygulanabildiği ispatlanmıştır. Topolojilerinin benzer olmasının dışında RBFANN ve MLPANN farklı davranışlar göstermektedir. İlk olarak; RBFANN, üç katmandan daha fazla mimariye sahip olabilen MLPANN'den daha basittir, bu nedenle eğitim süreci genel olarak MLPANN'den daha hızlıdır. İkinci olarak; RBFANN, yerel yakınlaştırma ağları olarak hareket eder, çünkü ağ çıktıları belirli yerel alıcı alanlarda belirtilen gizli birimler tarafından belirlenir. MLPANN'de ise, ağ çıktılarına tüm nöronlar tarafından karar verildiğinden dolayı, küresel olarak çalışmaktadır. Üçüncü olarak, RBFANN için başlangıç durumlarını doğru ayarlamak önemlidir. MLPANN'de ise başlangıçta rastgele oluşturulmuş parametreler kullanılır. Son ve en önemlisi, RBFANN ve MLPANN'nin sınıflandırma mekanizmaları farklıdır. MLPANN'lerde ayırma için isteğe bağlı olarak şekillendirilmiş hiper yüzeyler kullanılırken, RTF kümelerinde ise hiper küreler kullanılmaktadır (Wilamowski ve Jaeger, 1996; Xie ve ark., 2011).







#### 4. BULGULAR

Bağımsız değişkenlere ait tanımlayıcı istatistikler frekans ve yüzdeleriyle birlikte aşağıda yer alan çizelgelerde verilmiştir.

Çizelge 4.1. Öğrencilerin sınıf değişkenine göre dağılımı.

Bağımsız Değişkenler	Kategoriler	Frekans	%
Sınıf	7.sınıf	14	0.3
	8.sınıf	68	1.5
	9.sınıf	876	19.8
	10.sınıf	3325	75.2
	11.sınıf	133	3.0
	12.sınıf	6	0.1

Çizelge 4.1’de araştırmaya katılan öğrencilerin sınıf değişkenine göre dağılımları incelendiğinde; %0.3’ünün 7.sınıf, %1.5’unun 8.sınıf, %19.8’inin 9.sınıf, %75.2’sinin 10.sınıf, %3’ünün 11.sınıf ve %0.1’inin 12.sınıfta okumakta olduğu görülmektedir.

Çizelge 4.2. Öğrencilerin cinsiyet değişkenine göre dağılımı.

Bağımsız	Kategoriler	Frekans	%
Cinsiyet	Kız	2257	51
	Erkek	2165	49

Çizelge 4.2’de araştırmaya katılan öğrencilerin cinsiyet değişkenine göre dağılımları incelendiğinde; %51’inin kız ve %49’unun erkek öğrenci olduğu görülmektedir.

Çizelge 4.3. Öğrencilerin anne eğitim düzeyi değişkenine göre dağılımı.

Bağımsız	Kategoriler	Frekans	%
Anne Eğitim Düzeyi	Lise	656	14.8
	Mesleki/Teknik Lise	612	13.8
	Ortaokul	877	19.8
	İlkokul	1700	38.4

Çizelge 4.3'te araştırmaya katılan öğrencilerin anne eğitim düzeylerine göre dağılımları incelendiğinde; %14.8'inin lise, %13.8'inin mesleki/teknik lise,%19.8'inin ortaokul, %38.4'ünün ilkokul ve %13'ünün ilkokulu bitirmemiş olduğu görülmektedir.

Çizelge 4.4. Öğrencilerin baba eğitim düzeyi değişkenine göre dağılımı.

Bağımsız	Kategoriler	Frekans	%
Baba Eğitim Düzeyi	Lise	719	16.3
	Mesleki/Teknik Lise	872	19.7
	Ortaokul	1204	27.2
	İlkokul	1380	31.2
	İlkokul bitirmemiş	247	5.2

Çizelge 4.4'de araştırmaya katılan öğrencilerin baba eğitim düzeylerine göre dağılımları incelendiğinde; %16.3'ünün lise, %19.7'sinin mesleki/teknik lise, %27.2'sinin ortaokul, %31.2'sinin ilkokul ve %5.2'sinin ilkokulu bitirmemiş olduğu görülmektedir.

Çizelge 4.5. Öğrencilerin “Evde çalışma masası var mı?” değişkenine göre dağılımı.

Bağımsız Değişkenler	Kategoriler	Frekans	%
Evde çalışma masası var mı?	Evet	3795	85.8
	Hayır	627	14.2

Çizelge 4.5'te araştırmaya katılan öğrencilerin “Evde çalışma masası var mı?” değişkenine göre dağılımları incelendiğinde; öğrencilerin %85.8'inin evet, %14.2'sinin hayır cevabı verdikleri görülmektedir.

Çizelge 4.6. Öğrencilerin “Evinizde kendi odanız var mı?” değişkenine göre dağılımı.

Bağımsız Değişkenler	Kategoriler	Frekans	%
Evinizde kendi odanız var mı?	Evet	3210	72.6
	Hayır	1212	27.4

Çizelge 4.6’da araştırmaya katılan öğrencilerin “Evinizde kendi odanız var mı?” değişkenine göre dağılımları incelendiğinde; öğrencilerin %72.6’sının evet, %27.4’ünün hayır cevabını verdikleri görülmektedir.

Çizelge 4.7. Öğrencilerin “Evinizde sessiz çalışma yeriniz var mı?” değişkenine göre dağılımı.

Bağımsız Değişkenler	Kategoriler	Frekans	%
Evinizde sessiz çalışma yeriniz var mı?	Evet	3738	84.5
	Hayır	684	15.5

Çizelge 4.7’de araştırmaya katılan öğrencilerin “Evinizde sessiz çalışma yeriniz var mı?” değişkenine göre dağılımları incelendiğinde; öğrencilerin %84.5’inin evet, %15.5’inin hayır cevabını verdikleri görülmektedir.

Çizelge 4.8. Öğrencilerin “Evinizde okul çalışmalarını için bilgisayar var mı?” değişkenine göre dağılımı.

Bağımsız Değişkenler	Kategoriler	Frekans	%
Evinizde okul çalışmalarını için bilgisayar var mı?	Evet	3058	69.2
	Hayır	1364	30.8

Çizelge 4.8’de araştırmaya katılan öğrencilerin “evinizde okul çalışmalarını için bilgisayar var mı?” değişkenine göre dağılımları incelendiğinde; öğrencilerin %69.2’sinin evet, %30.8’nin hayır cevabını verdikleri görülmektedir.

Çizelge 4.9. Öğrencilerin “Evinizde eğitim yazılımları var mı?” değişkenine göre dağılımı.

Bağımsız Değişkenler	Kategoriler	Frekans	%
Evinizde eğitim yazılımları var mı?	Evet	1840	41.6
	Hayır	2582	58.4

Çizelge 4.9’da araştırmaya katılan öğrencilerin “Evinizde eğitim yazılımları var mı?” değişkenine göre dağılımları incelendiğinde; öğrencilerin %41.6’sının evet, %58.4’ünün hayır cevabını verdikleri görülmektedir.

Çizelge 4.10. Öğrencilerin “Evinizde internet bağlantınız var mı?” değişkenine göre dağılımı.

Bağımsız Değişkenler	Kategoriler	Frekans	%
Evinizde internet	Evet	2827	63.9
bağlantınız var mı?	Hayır	1595	36.1

Çizelge 4.10’da araştırmaya katılan öğrencilerin “Evinizde internet bağlantınız var mı?” değişkenine göre dağılımları incelendiğinde; öğrencilerin %63.9’unun evet, %36.1’ünün hayır cevabını verdikleri görülmektedir.

Çizelge 4.11. Öğrencilerin “Evinizde okul çalışmaları için yardımcı kitap var mı?” değişkenine göre dağılımı.

Bağımsız Değişkenler	Kategoriler	Frekans	%
Evinizde okul çalışmaları	Evet	3741	84.6
için yardımcı kitap var mı?	Hayır	681	15.4

Çizelge 4.11’de araştırmaya katılan öğrencilerin “Evinizde okul çalışmaları için yardımcı kitap var mı?” değişkenine göre dağılımları incelendiğinde; öğrencilerin %84.6’sının evet, %15.4’ünün hayır cevabını verdikleri görülmektedir.

Çizelge 4.12. Öğrencilerin “Evinizde teknik kitaplar var mı?” değişkenine göre dağılımı.

Bağımsız Değişkenler	Kategoriler	Frekans	%
Evinizde teknik kitaplar var	Evet	1867	42.2
mı?	Hayır	2555	57.8

Çizelge 4.12’de araştırmaya katılan öğrencilerin “Evinizde teknik kitaplar var mı?” değişkenine göre dağılımları incelendiğinde; öğrencilerin %42.2’sinin evet, %57.8’inin hayır cevabını verdikleri görülmektedir.

Çizelge 4.13. Öğrencilerin “Okul hayatınızda hangi noktaya kadar ulaşmayı hedefliyorsunuz?” değişkenine göre dağılımı.

Bağımsız Değişkenler	Kategoriler	Frekans	%
	Ortaokul	70	1.6
Okul hayatınızda hangi noktaya kadar ulaşmayı hedefliyorsunuz	Mesleki/Teknik Lise	623	14.1
	Lise	303	6.9
	Yüksekokul	236	5.3
	Üniversite/Ylisans/Doktora	3190	72.1

Çizelge 4.13’te araştırmaya katılan öğrencilerin “Okul hayatınızda hangi noktaya kadar ulaşmayı hedefliyorsunuz?” değişkenine göre dağılımları incelendiğinde; öğrencilerin %1.6’sının ortaokul, %14.1’inin mesleki/teknik lise, %6.9’unun lise, %5.3’ünün yüksekokul ve %72.1’inin üniversite/ylisans/doktora cevabını verdikleri görülmektedir.

Çizelge 4.14. Öğrencilerin “Öğretmenler beni diğer öğrencilerden daha az çağırırlar” değişkenine göre dağılımı.

Bağımsız Değişkenler	Kategoriler	Frekans	%
	Asla ya da neredeyse hiç	1561	35.3
Öğretmenler beni diğer öğrencilerden daha az çağırırlar	hiç		
	Yılda birkaç kez	880	19.9
	Ayda birkaç kez	895	20.2
	Haftada bir veya daha fazla	1086	24.6

Çizelge 4.14’te araştırmaya katılan öğrencilerin “Öğretmenler beni diğer öğrencilerden daha az çağırırlar” değişkenine göre dağılımları incelendiğinde; öğrencilerin %35.3’ünün asla ya da neredeyse hiç, %19.9’unun yılda birkaç kez, %20.2’sinin ayda birkaç kez ve %24.6’sının haftada bir veya daha fazla cevabını verdikleri görülmektedir.

Çizelge 4.15. Öğrencilerin “Öğretmenler beni diğer öğrencilerden daha çok zorlar” değişkenine göre dağılımı.

Bağımsız Değişkenler	Kategoriler	Frekans	%
Öğretmenler beni diğer öğrencilerden daha çok zorladı.	Asla ya da neredeyse hiç	2485	56.2
	Yılda birkaç kez	943	21.3
	Ayda birkaç kez	660	14.9
	Haftada bir veya daha fazla	335	7.6

Çizelge 4.15’te araştırmaya katılan öğrencilerin “Öğretmenler beni diğer öğrencilerden daha çok zorlar” değişkenine göre dağılımları incelendiğinde; öğrencilerin %56.2’sinin asla ya da neredeyse hiç, %21.3’unun yılda birkaç kez, %14.9’unun ayda birkaç kez ve %7.6’sının haftada bir veya daha fazla cevabını verdikleri görülmektedir.

Çizelge 4.16. Öğrencilerin “Öğretmenlerin beni daha az zeki olduğumu düşündükleri izlenimindeyim” değişkenine göre dağılımı.

Bağımsız Değişkenler	Kategoriler	Frekans	%
Öğretmenlerin beni daha az zeki olduğumu düşündükleri izlenimindeyim	Asla ya da neredeyse hiç	2639	59.7
	Yılda birkaç kez	701	15.9
	Ayda birkaç kez	622	14.1
	Haftada bir veya daha fazla	460	10.4

Çizelge 4.16’ da araştırmaya katılan öğrencilerin “Öğretmenlerin beni daha az zeki olduğumu düşündükleri izlenimindeyim” değişkenine göre dağılımları incelendiğinde; öğrencilerin %59.7’sinin asla ya da neredeyse hiç, %15.9’unun yılda birkaç kez, %14.1’inin ayda birkaç kez ve %10.4’ünün haftada bir veya daha fazla cevabını verdikleri görülmektedir.



Çizelge 4.17. Öğrencilerin “Öğretmenler beni diğer öğrencilere göre daha sert bir şekilde disipline eder” değişkenine göre dağılımı.

Bağımsız Değişkenler	Kategoriler	Frekans	%
Öğretmenler beni diğer öğrencilere göre daha sert bir şekilde disipline eder	Asla ya da neredeyse hiç	3058	69.2
	Yılda birkaç kez	692	15.6
	Ayda birkaç kez	354	8.0
	Haftada bir veya daha fazla	318	7.2

araştırmaya katılan öğrencilerin “Öğretmenler beni diğer öğrencilere göre daha sert bir şekilde disipline eder” değişkenine göre dağılımları incelendiğinde; öğrencilerin %69.2’sinin asla ya da neredeyse hiç, %15.6’sının yılda birkaç kez, %8.0’ının ayda birkaç kez ve %7.2’sinin haftada bir veya daha fazla cevabını verdikleri görülmektedir.

Çizelge 4.18. Öğrencilerin “Öğretmenler benimle diğerlerinin önünde alay eder” değişkenine göre dağılımı.

Bağımsız Değişkenler	Kategoriler	Frekans	%
Öğretmenler benimle diğerlerinin önünde alay eder	Asla ya da neredeyse hiç	3319	75.1
	Yılda birkaç kez	588	13.3
	Ayda birkaç kez	281	6.4
	Haftada bir veya daha fazla	234	5.3

Çizelge 4.18’de araştırmaya katılan öğrencilerin “Öğretmenler benimle diğerlerinin önünde alay eder” değişkenine göre dağılımları incelendiğinde; öğrencilerin %75.1’inin asla ya da neredeyse hiç, %13.3’ünün yılda birkaç kez, %6.4’ünün ayda birkaç kez ve %5.3’ünün haftada bir veya daha fazla cevabını verdikleri görülmektedir.

Çizelge 4.19. Öğrencilerin “Öğretmenler başkalarının önünde bana hakaret eder” değişkenine göre dağılımı.

Bağımsız Değişkenler	Kategoriler	Frekans	%
Öğretmenler başkalarının önünde bana hakaret eder	Asla ya da neredeyse hiç	3203	72.4
	Yılda birkaç kez	654	14.8
	Ayda birkaç kez	294	6.6
	Haftada bir veya daha fazla	271	6.1

Çizelge 4.19’da araştırmaya katılan öğrencilerin “Öğretmenler başkalarının önünde bana hakaret eder” değişkenine göre dağılımları incelendiğinde; öğrencilerin %72.4’ünün asla ya da neredeyse hiç, %14.8’inin yılda birkaç kez, %6.6’sının ayda birkaç kez ve %6.1’inin haftada bir veya daha fazla cevabını verdikleri görülmektedir.

Çizelge 4.20. Öğrencilerin haftalık ders sayısı değişkenine göre dağılımı.

Bağımsız Değişkenler	Kategoriler	Frekans	%
Haftalık ders sayısı	Az	890	20.1
	Orta	3517	79.5
	Çok	15	0.3

Çizelge 4.20’de araştırmaya katılan öğrencilerin haftalık ders sayısı değişkenlerine göre dağılımları incelendiğinde; öğrencilerin %20.1’inin az, %79.5’inin orta ve %0.3’ünün çok ders aldıkları görülmektedir.

Çizelge 4.21. Öğrencilerin Türkçe başarı durumu değişkenine göre dağılımı.

Bağımsız Değişkenler	Kategoriler	Frekans	%
Türkçe başarı durumu	Düşük	3177	71.8
	Orta	1232	27.9
	Yüksek	13	0.3

Çizelge 4.21’de araştırmaya katılan öğrencilerin Türkçe başarı durumlarına göre dağılımları incelendiğinde; öğrencilerin %71.8’inin düşük, %27.9’unun orta ve %0.3’ünün yüksek başarı durumuna sahip oldukları görülmektedir.

Çizelge 4.22. Öğrencilerin haftalık matematik öğrenme zamanı değişkenine göre dağılımı

Bağımsız Değişkenler	Kategoriler	Frekans	%
Haftalık matematik öğrenme zamanı	Az	989	22.4
	Orta	3342	75.6
	Çok	91	2.1

Ç

izelge 4.22’de araştırmaya katılan öğrencilerin haftalık matematik öğrenme zamanına göre dağılımları incelendiğinde; öğrencilerin %22.4’sinin az, %75.6’sının orta ve %2.1’inin çok ders aldıkları görülmektedir.

#### 4.1. PISA 2015 Verilerine İlişkin Uygulama

##### 4.1.1. Veri setine rf yönteminin uygulanması


Analizlerin uygulanmasında Weka, SPSS Modeler ve SPSS 21 programları kullanılmıştır. Analiz sadece bir kez değil, birçok kez denenmiştir. Her denemede yöntemlerin farklı performans gösterdiği görülmüştür.

Veri setine ilk olarak; Rastgele Orman yöntemi uygulanmıştır. RF yöntemine ait doğru sınıflandırma oranı Çizelge 4.23’te gösterilmiştir.

Çizelge 4.23. RF yöntemine göre doğru sınıflandırma oranı.

Modelleme Yöntemi	RF
Bağımlı değişken	Matematik başarı durumu
Bağımsız değişken sayısı	25
Doğru sınıflama oranı	%81.2
Yanlış sınıflama oranı	%18.8

RF yönteminde, bağımlı değişken üzerinde etkili olan bağımsız değişkenlerin önem düzeyi şekil 4.1’de gösterilmektedir.



Şekil 4.1.Rastgele Orman yöntemine göre değişkenlerin önem düzeyleri

Şekil 4.1 incelendiğinde, bağımlı değişkeni etkileyen en önemli değişkenin kaygı değişkeni olduğu, diğer önemli değişkenlerin ise sırasıyla; Türkçe başarı durumu, anne eğitim düzeyi, motivasyon, öğrencinin bilgi kuramına inancı, öğretmen ilgisi, baba eğitim düzeyi değişkenlerinin olduğu görülmektedir.

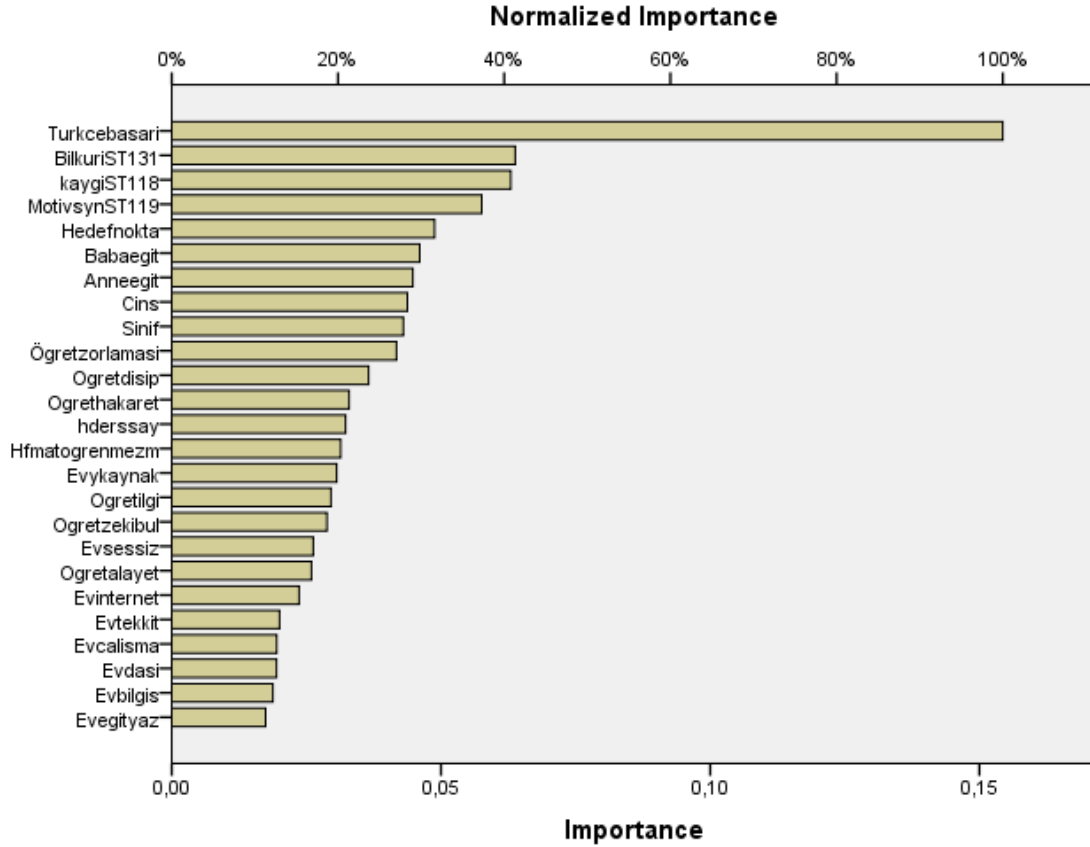
#### 4.1.2. Veri setine mlpann yönteminin uygulanması

Daha sonra veri setine MLPANN yöntemi uygulanmıştır. MLPANN analizinde, tahminlere ait doğru sınıflama oranı Çizelge 4.24'te gösterilmektedir.

Çizelge 4.24. MLPANN yöntemine göre doğru sınıflandırma oranı.

Modelleme Yöntemi	MLPANN
Bağımlı değişken	Matematik başarı durumu
Bağımsız değişken sayısı	25
Doğru sınıflama oranı	%86.7
Yanlış sınıflama oranı	%13.3

MLPANN mimarisinde, bağımlı değişken üzerinde etkili olan bağımsız değişkenlerin önem düzeyi şekil 4.2'de gösterilmektedir.



Şekil 4.2. MLPANN yöntemine göre değişkenlerin normalize edilmiş önem düzeyleri


Şekil 4.2. incelendiğinde bağımlı değişkeni etkileyen en önemli bağımsız değişkenin, öğrencilerin Türkçe başarı düzeyi olduğu, diğer önemli değişkenlerin ise

sırasıyla; öğrencinin bilgi kuramına inancı, kaygı, motivasyon, okul hayatında hedeflenen nokta değişkenlerinin olduğu görülmektedir. Modelde yer alan Türkçe dersindeki başarı düzeyinin Matematik okuryazarlık düzeyi ile pozitif yönlü istatistiksel olarak anlamlı bir ilişki ( $r = 0.647$ ,  $p < 0.01$ ) içerisinde olması şaşırtıcı karşılanmıştır. Modelde yer alan diğer değişkenlerin bağımlı değişken üzerinde yüksek düzeyde etkili olmadığı söylenebilir. Modelde yer alan tüm bağımsız değişkenlerin görece önem düzeyi Çizelge 4.25'te gösterilmiştir.

Çizelge 4.25.MLPANN mimarisindeki bağımsız değişkenlerin önem düzeyleri.

Yordayıcılar	Önem	Standartlaştırılmış Önem
Türkçe başarı durumu	.154	100.0%
Bilgi kuramına ilişkin inanç	.064	41.3%
Kaygı	.063	40.8%
Motivasyon	.058	37.3%
Okul hayatınızda hangi noktaya kadar gelmeyi hedefliyorsunuz?	.049	31.6%
Baba eğitim düzeyi	.046	29.8%
Anne eğitim düzeyi	.045	29.0%
Cinsiyet	.044	28.3%
Sınıf	.043	27.9%
Öğretmenler beni diğer öğrencilerden daha çok zorlar.	.042	27.0%
Öğretmenler beni diğer öğrencilere göre daha sert bir şekilde disipline eder.	.037	23.7%
Öğretmenler başkalarının önünde bana hakaret eder.	.033	21.3%
Haftalık ders sayısı	.032	20.9%
Haftalık matematik öğrenmeye ayrılan zaman	.031	20.3%
Evinizde okul çalışmalarını için yardımcı kitap var mı?	.031	19.8%
Öğretmenler beni diğer öğrencilerden daha az çağırırlar.	.030	19.2%
Öğretmenlerin beni daha az zeki bulurlar.	.029	18.7%
Evinizde sessiz çalışma yeriniz var mı?	.026	17.0%
Öğretmenler benimle diğerlerinin önünde alay eder.	.026	16.8%
Evinizde internet bağlantınız var mı?	.024	15.3%
Evinizde teknik kitaplar var mı?	.020	13.0%
Evinizde çalışmak için bir masanız var mı?	.020	12.6%
Evinizde kendi odanız var mı?	.019	12.6%
Evinizde okul çalışmalarını için bilgisayar var mı?	.019	12.2%
Evinizde eğitim yazılımları var mı?	.017	11.3%

Çizelge 4.25'e bakıldığında bağımlı değişkeni etkileyen en önemli değişkenin %100 standartlaştırılmış önem ile Türkçe başarı durumu olduğu, ardından %41.3 ile öğrencinin bilgi kuramına ilişkin inancı, %40.8 ile kaygı, %37.3 ile motivasyon ve %31.6 ile okul hayatında hedeflenen nokta değişkenleri olduğu görülmektedir.



Şekil 4.3. MLPANN ağ mimarisine göre ağ yapısı.

Çalışma kapsamında, MLPANN mimarisindeki gizli katman sayısı deneysel olarak birçok kez çalıştırılmış ve Şekil 4.3.'te gösterildiği gibi ideal mimari yapının iki adet gizli katmanda elde edildiği görülmüştür. Birinci gizli katmanda 11 adet nöron, ikinci katmanda ise 11 adet nöron bulunmaktadır. Yapılan analizler sonucunda, gizli katman aktivasyon fonksiyonunun hiperbolik tanjant (hyperbolic tangent), çıktı katman aktivasyon fonksiyonunun ise softmax olduğu görülmüştür.

#### 4.1.3. Veri setine rbfann yönteminin uygulanması



Son olarak; çalışma kapsamında veri setine, Radyal Tabanlı Yapay Sinir Ağları uygulanmıştır. Yapılan analizler sonucunda, gizli katman aktivasyon fonksiyonunun softmax, çıktı katman aktivasyon fonksiyonunun ise identity olduğu belirlenmiştir. RBFANN'ye ait ağ yapısı Şekil 4.4.'te verilmiştir.






RBFANN analizinde tahminlere ait doğru sınıflama oranı Çizelge 4.26'da gösterilmektedir.

Çizelge 4.26. RBFANN yöntemine göre doğru sınıflandırma oranı.

Modelleme Yöntemi	RBFANN
Bağımlı değişken	Matematik başarı durumu
Bağımsız değişken sayısı	25
Doğru sınıflama oranı	% 82.2
Yanlış sınıflama oranı	% 17.8



Şekil 4.5. RBFANN yöntemine göre değişkenlerin normalize edilmiş önem düzeyleri

Şekil 4.5. incelendiğinde, bağımlı değişkeni etkileyen en önemli bağımsız değişkenin öğrencilerin Türkçe başarı düzeyi olduğu, diğer önemli değişkenlerin ise sırasıyla; okul hayatında hedeflenen nokta değişkeni, baba eğitim düzeyi, anne eğitim

düzeyi değişkenlerinin olduğu görülmektedir. Modelde yer alan diğer değişkenlerin bağımlı değişken üzerinde yüksek düzeyde etkili olmadığı söylenebilir. Modelde yer alan tüm bağımsız değişkenlerin görece önem düzeyleri Çizelge 4.27’de gösterilmiştir.

Çizelge 4.27.RBFANN mimarisindeki bağımsız değişkenlerin önem düzeyleri.

Yordayıcılar	Önem	Standartlaştırılmış Önem
Türkçe basari durumu	.266	100.0%
Okul hayatınızda hangi noktaya kadar gelmeyi hedefliyorsunuz	.058	21.8%
Baba eğitim düzeyi	.052	19.5%
Anne eğitim düzeyi	.050	18.7%
Sınıf	.042	15.8%
Öğretmenler beni diğer öğrencilerden daha çok zorladı.	.040	15.2%
Haftalık matematik öğrenmeye ayrılan zaman	.037	13.9%
Evinizde internet bağlantınız var mı?	.037	13.8%
Evinizde okul çalışmalarını için bilgisayar var mı?	.035	13.2%
Öğretmenlerin beni daha az zeki olduğumu düşündükleri izlenimindeyim	.035	13.1%
Haftalık ders sayısı	.034	12.8%
Evinizde teknik kitaplar var mı?	.034	12.8%
Öğretmenler başkalarının önünde bana hakaret eden şeyler söyledi	.029	11.0%
Öğretmenler benimle diğerlerinin önünde alay etti.	.029	10.8%
Öğretmenler beni diğer öğrencilere göre daha sert bir şekilde disipline etti.	.028	10.4%
Öğretmenler beni diğer öğrencilerden daha az çağırırlar.	.026	9.6%
Evinizde kendi odanız var mı?	.025	9.4%
Bilgi kuramına ilişkin inanç	.024	9.0%
Motivasyon	.020	7.7%
Evinizde okul çalışmalarını için yardımcı kitap var mı?	.020	7.4%
Evinizde çalışmak için bir masanız var mı?	.019	7.1%
Evinizde sessiz çalışma yeriniz var mı?	.018	6.7%
Evinizde eğitim yazılımları var mı?	.017	6.3%
Kaygı	.014	5.3%
Cinsiyet	.012	4.6%

Çizelge 4.27'e bakıldığında bağımlı değişkeni etkileyen en önemli değişkenin %100 standartlaştırılmış önem ile Türkçe başarı durumu olduğu, ardından %21.8 ile okul hayatında hedeflenen nokta, %19.5 ile baba eğitim düzeyi ve %18.7 ile anne eğitim düzeyi değişkenlerinin olduğu görülmektedir.

#### 4.1.4.Üç yöntemin tahminleme performanslarının karşılaştırılması

Çalışmada. RF, MLPANN ve RBFANN yöntemlerinin tahminleme yeteneklerini karşılaştırmak için doğru sınıflandırma yüzdesi, korelasyon, Hata Kareler Ortalamasının Kökü (RMSE), Ortalama Mutlak Hata (MAE), Bağıl Mutlak Hata (RAE) ve Bağıl Karesel Hatanın Kökü (RRSE) kullanılmıştır. Araştırma kapsamında, modeli test eden MLPANN, RBFANN ve RF yöntemlerinin doğru tahminleme açısından performans göstergeleri Çizelge 4.28'da sunulmuştur.

Çizelge 4.28. MLPANN, RBFANN ve RF yöntemlerinin performansı.

Yöntem	Doğru Sınıflandırma Oranı%	Korelasyon	RMSE	MAE	RAE	RRSE
MLPANN	86.7	0.638909	0.3927	0.2449	0.6831	0.9005
RBFANN	85.2	0.55998	1.301983	1.78607	4.982449	2.986678
RF	81.2	0.676193	0.3217	0.2064	0.5756	0.7377

Çizelge 4.28. incelendiğinde, MLPANN ve RBFANN'nın RF'ya göre daha yüksek düzeyde doğru sınıflandırma oranına sahip olduğu görülmüştür (MLPANN Doğru Sınıflandırma Oranı = %86.7, RBFANN Doğru Sınıflandırma Oranı = %85.2, RF Doğru Sınıflandırma Oranı = %81.2). Geriye kalan göstergeler incelendiğinde, RF'nin MLPANN ve RBFANN'dan daha yüksek performans sergilediği söylenebilir. Korelasyon katsayısı açısından RF'nin MLPANN ve RBFANN' den daha yüksek düzeyde performans sergilediği ve hata ölçütleri bakımından da RF'nin lehine bir durum sergilediği görülmüştür. Tüm bu gerekçelerden dolayı, RF'nin tahminlemeye çalıştığı model, MLPANN ve RBFANN'den daha iyi olarak kabul edilebilir. Ayrıca;

MLPANN ve RBFANN yöntemleri karşılaştırıldığında, MLPANN yönteminin, RBFANN yönteminden daha yüksek düzeyde doğru sınıflandırma yaptığı ve daha az hata oranına sahip olduğu görülmüştür. Yani; MLPANN yönteminin RBFANN yöntemine göre daha iyi performans gösterdiği söylenebilir. Diğer taraftan; RBFANN ve RF yöntemleri karşılaştırıldığında ise, RBFANN'nin RF'ye göre az bir fark ile daha iyi doğru sınıflandırma oranına sahip olduğu, ancak; diğer göstergeler açısından RF'nin gerisinde kaldığı görülmektedir.



## 5. TARTIŞMA VE SONUÇ

Bu çalışmanın amacı; veri madenciliği yöntemlerinden, Çok Katmanlı Algılayıcı Yapay Sinir Ağları, Radyal Tabanlı Fonksiyon Yapay Sinir Ağları ve Rastgele Orman yöntemlerini kullanarak, PISA 2015 matematik okuryazarlığını etkileyen faktörleri belirlemek ve her üç yöntemin tahminleme yeteneklerini karşılaştırmaktır. Yapılan analizler sonucunda; Rastgele Orman yönteminin, performans ölçütleri açısından daha iyi sonuç verdiği ve tahminleme yeteneğinin az da olsa MLPANN ve RBFANN'ye göre daha yüksek düzeyde olduğu görülmüştür. Ayrıca; MLPANN ve RBFANN yöntemleri karşılaştırıldığında, MLPANN'nin RBFANN'ye göre daha iyi performans gösterdiği tespit edilmiştir. Diğer taraftan; RBFANN ve RF yöntemleri karşılaştırıldığında ise, RF yönteminin daha başarılı olduğu görülmüştür. Bununla birlikte, Rastgele Orman yöntemi ile modele ait neden-sonuç ilişkisinin sağlam ve tutarlı olabileceği kanaatine varılmıştır.

Alanyazın incelendiğinde, PISA verileri kullanılarak yapılan çok sayıda çalışma olmasına rağmen, mevcut çalışmada kullanılan yöntemlerin kullanıldığı sınırlı sayıda çalışmanın olduğu görülmektedir (Tepehan, 2011; İnal ve Turabik, 2016; Saarela ve ark., 2016; Benzer ve Benzer, 2017; Toprak, 2017; Aksu, 2018; Aksu ve Doğan, 2018; Bezek Güre ve ark., 2019). Aksu (2018) ile Aksu ve Doğan (2018), PISA 2015 verilerini kullanarak öğrencilerin fen okuryazarlığını sınıflamak için Decision Stump, Hoeffding Tree, J.48, Lojistik Model, RepTree, Rastgele Orman, Random Tree ve Ridge Lojistik Regresyon yöntemlerini kullanmış, en iyi sonuçları Rastgele Orman yöntemiyle elde etmiştir. Saarela ve ark. (2016), Finlandiyalı öğrencilerin matematik başarılarını tahmin etmek için Lineer Diskriminant Analizi, Destek Vektör Makineleri ve Rastgele Orman yöntemlerini karşılaştırdığı çalışmada tahminleme performansı bakımından Destek Vektör Makineleri yönteminin daha iyi tahminleme yaptığını belirlemişlerdir.

Toprak (2017) tarafından PISA 2012 verileri kullanılarak matematik başarılarını etkileyen faktörleri belirlemek için Çok Katmanlı Algılayıcı Yapay Sinir Ağları, Karar Ağaçlarından CHAID algoritması ve Doğrusal Ayırma analizi kullanılmıştır. Çalışmada, alt gruplara ayırmada sınıflama performansı açısından MLPANN'nin daha

başarılı olduğu belirlenmiştir. Tepehan (2011), PISA 2006 verileri üzerinde matematik başarılarını tahminlemek için Çok Katmanlı Algılayıcı Yapay Sinir Ağları ve Lojistik Regresyon yöntemlerinin performanslarını karşılaştırdığı çalışmada, Çok Katmanlı Algılayıcı Yapay Sinir Ağlarının daha iyi performans gösterdiğini tespit etmiştir. Benzer ve Benzer (2017), OECD ülkelerine ait mevcut PISA test sonuçlarını, Çok Katmanlı Algılayıcı Yapay Sinir Ağları ve Regresyon Analizi ile değerlendirmiş, Çok Katmanlı Algılayıcı Yapay Sinir Ağlarının daha iyi sonuç verdiğini belirlemişlerdir. İnal ve Turabik (2016) ise PISA 2012'ye katılan öğrencilerin başarılarını etkileyen faktörleri belirlemek için Çok Katmanlı Algılayıcı Yapay Sinir Ağları yöntemini kullanmış, en önemli değişkenleri sırasıyla fen bilimleri başarıları, okuma başarıları, matematiğe yönelik tutum, matematiğe yönelik ilgi değişkenleri olarak belirlemişlerdir.

Alanyazında, eğitim alanında mevcut çalışmada kullanılan yöntemlerin birlikte kullanıldığı çalışmaya rastlanmazken, eğitim alanı dışında sökonusu yöntemlerin birlikte karşılaştırıldığı çok az sayıda çalışmanın olduğu görülmektedir (Maroco ve ark., 2011). Çalışmamızdaki sonuçlara paralel olarak; Maroco ve ark. (2011) tarafından yapılan çalışmada bu yöntemler kullanılmış, RF yönteminin diğer iki yönteme nazaran daha başarılı performans sağladığı tespit edilmiştir. Diğer taraftan; sözkonusu yöntemlerin ikili olarak birbirleriyle karşılaştırıldığı çok sayıda çalışma mevcuttur. Alanyazın incelendiğinde, birçok alanda MLPANN ve RF yöntemlerinin karşılaştırıldığı çok sayıda çalışmanın olduğu bilinmektedir (Maroco ve ark., 2011; Becerra ve ark., 2013; Marin ve ark., 2013; Ayas, 2014; Fern'andez-Delgado ve ark., 2014; Eriksson ve Varatharajah, 2016; Guo ve ark., 2017; Kayri ve ark., 2017; Nawar ve Mouazen, 2017; Raczko ve Zagajewski, 2017; Shah ve ark., 2017; Bansal ve ark., 2018; Shichkin ve ark., 2018). Birçok araştırmada, yapılan bu çalışmanın bulgularıyla paralel olarak, RF yönteminin MLPANN yöntemine göre daha yüksek düzeyde performans gösterdiği görülmektedir (Çuhadar, 2013; Ayas, 2014; Fern'andez-Delgado ve ark., 2014; Nawar ve Mouazen, 2017; Raczko ve Zagajewski, 2017; Shah ve ark., 2017; Bansal ve ark., 2018; Shichkin ve ark., 2018). Çalışmamızdaki sonuçların tersine, MLPANN'nin RF'ye göre daha başarılı olduğu çalışmalar da bulunmaktadır (Eriksson ve Varatharajah, 2016; Kayri ve ark., 2017; Raczko ve Zagajewski, 2017; Shah ve ark., 2017). RF ve RBFANN yöntemlerinin karşılaştıran çalışmalara bakıldığında ise her iki yöntemin performansını karşılaştıran çok az sayıda çalışmaya rastlanmıştır. Sug (2010),



çalışmamızdaki bulguların aksine; RBFANN yöntemini RF yöntemine göre daha başarılı bulmuştur.

Diğer taraftan; alanyazında MLPANN ve RBFANN yöntemlerinin performansını karşılaştıran birçok çalışmanın da olduğu bilinmektedir (Jayawardena ve ark., 1997; Sug, 2009; Kumar ve Yadav 2011; Özbayoğlu ve Bozer, 2012; Memarian ve Kumar Balasundram, 2012; Oludolapo ve ark., 2012; Bayram ve ark., 2013; Çuhadar, 2013; Zare ve ark., 2013; Kayri, 2015). Bu çalışmaların bazılarında MLPANN daha başarılı bulunurken, bazılarında RBFANN daha başarılı bulunmuştur. Çalışmamızdaki sonuçlara benzer olarak; MLPANN yönteminin RBFANN yöntemine göre daha başarılı olduğunu bildiren çalışmalar mevcuttur (Senthil Kumar ve ark., 2005; Kashaninejad ve ark., 2009; Sug, 2009; Memarian ve Kumar Balasundram, 2012; Santos ve ark., 2013; Özbayoğlu ve Bozer, 2012; Kayri, 2015). Diğer taraftan, çalışmadaki sonuçlarımızın tersine, RBFANN yönteminin daha başarılı olduğunu belirten çalışmalarında olduğu bilinmektedir (Finan ve ark., 1996; Jayawardena ve ark., 1997; Park ve ark., 2004; Dash ve ark., 2010; Zayandehroodi ve ark., 2010; Kumar ve Yadav, 2011; Oludolapo ve ark., 2012; Bayram ve ark., 2013).

Mevcut çalışmada, RF yönteminin diğer yöntemlere nazaran daha iyi performans göstermesinden ötürü, sözkonusu yöntemin önemli bulunduğu değişkenler bu bölümde tartışılacaktır.

Sözkonusu çalışmada; MLPANN ve RBFANN'ye ait modelde, bağımlı değişken üzerinde etkili olan en önemli bağımsız değişken öğrencilerin Türkçe başarı durumu iken, RF modelinde öğrencilerin kaygı düzeyinin olduğu görülmüştür. Alanyazında, öğrencilerin matematik başarıları üzerinde kaygı düzeyinin sıklıkla etkili olduğu görülmüştür (Delice ve ark., 2009; Şentürk, 2010; Yücel ve Koç, 2011; Aksu ve Güzeller, 2016; İnal ve Turabik, 2016).

RF yönteminin kaygı değişkeninden sonra ikinci olarak önemli bulunduğu bağımsız değişken, Türkçe başarı durumu değişkenidir. Çalışmamıza paralel olarak; İnal ve Turabik (2016), Türkçe dil başarısının matematik başarıları üzerinde önemli bir etkiye sahip olduğunu belirtmektedir.

Araştırma kapsamında. RF'nin “öğrencilerin kaygı düzeyi” ile “Türkçe dersi başarıları” değişkenlerinden sonra önemli bulunduğu bağımsız değişkenler sırasıyla; anne

eđitim düzeyi ve öğrencilerin motivasyon düzeyleridir. Birçok arařtırmada, yapılan bu çalışmanın bulgularına paralel olarak, öğrencilerin anne eğitim düzeylerinin öğrenci başarısı üzerinde olumlu yönde etkisinin olduğu bildirilmiştir (Dursun ve Dede, 2004; Gürsakal, 2009; Savaş ve ark., 2010; Karabay, 2013; Karabay ve ark., 2015). Çalışmamızda, anne eğitim düzeyi baba eğitim düzeyine göre daha önemli bulunmuşken, Anıl (2009) ise, çalışmamızdaki bulgunun tersine, öğrencilerin başarısında baba eğitim düzeyinin anne eğitim düzeyine göre daha etkili olduğunu belirtmiştir. Diğer taraftan; mevcut çalışmada önemli görülen diğer bir deęişken motivasyon deęişkenidir. Birçok araştırma, öğrencilerin motivasyon düzeyi ile akademik başarısı arasında pozitif yönlü istatistiksel olarak anlamlı bir ilişki olduğunu göstermekte olup bu durum bireyin matematik okuryazarlığı için de geçerli bir durumdur (Üredi ve Üredi, 2005; Aksu ve Güzeller, 2016; İnal ve Turabik, 2016).

RF ‘nin önemli bulduğu diğer bir bağımsız deęişken, öğrencinin bilgi kuramına ilişkin inanç (bilgi felsefesi) deęişkenidir. Birçok çalışmada, bu deęişkenin başarı üzerindeki etkisi sıklıkla araştırılmıştır (Deryakulu, 2004; Deryakulu ve Büyüköztürk, 2005; Erođlu ve Güven, 2006; Özkan, 2008; Ünal Çoban ve Ergin, 2008; Koç-Erdamar ve Bangir-Alpan, 2011; Aydın ve Geçici, 2017). Çalışmamızdaki sonuçlara paralel olarak; Aydın ve Geçici (2017), öğrencilerin bilgi kuramına ilişkin inançları ile matematik dersi başarısı arasında istatistiksel olarak anlamlı bir ilişki olduğunu ( $p<0.01$ ) belirtmektedir. Ancak; Dursun ve Dede (2004) ile Dursun Sürmeli ve Ünver (2017) ise, bu deęişken ile matematik başarısı arasında istatistiksel olarak anlamlı bir ilişki olmadığını belirlemişlerdir.

RF’ye göre, öğrencilerin matematik okuryazarlığı üzerinde “öğretmenin ilgisi” anlamlı bir bağımsız deęişken olarak tespit edilmiştir. Akyüz (2006) ile Akyüz ve Pala (2010), Türk ve Yunan öğretmenlerin öğrencilerine olan ilgileri ile matematik okuryazarlığı arasında negatif yönlü istatistiksel olarak anlamlı bir ilişki bulmuş, Finlandiyalı öğretmenler için ise istatistiksel olarak anlamlı bir ilişki bulamamışlardır. Benzer bir arařtırmada, İlgün Dibek ve Demirtaşlı (2017), Türkiye’deki öğrencilerin matematik başarısı ile “öğretmenin ilgisi” arasında negatif yönlü istatistiksel olarak anlamlı bir ilişki tespit etmişlerdir. Yılmaz (2006) ise, öğretmen ilgisi ile matematik başarısı arasında pozitif yönlü istatistiksel olarak anlamlı bir ilişki bulmuştur.

RF'nin önemli bulduğu başka bir değişken, baba eğitim düzeyi olup çalışmamızın bulgularına paralel olarak, öğrencilerin baba eğitim düzeylerinin öğrenci başarısı üzerinde olumlu yönde etkisinin olduğu bildirilmiştir (Anıl 2009; Karabay ve ark., 2015).

RF'nin önemli olarak belirlediği başka bir değişken olan, disiplinli sınıf ortamı değişkeninin, birçok çalışmada matematik başarısını olumlu yönde etkilediği belirtilmektedir (Küçükahmet, 1999; Aydın. 2001; Dursun ve Dede, 2004; Akyüz, 2006; Akyüz ve Pala, 2010; İlgün Dibek ve Demirtaşlı, 2017).

Mevcut çalışmada, RF'nin önemli olarak gördüğü başka bir değişken, öğretmenlerin öğrencilerin matematiksel zekâ düzeylerini az görmeleri değişkenidir. Matematik öğretmenlerine göre, öğrencilerin matematiksel zekâsı, matematik başarıları üzerinde önemli bir etkiye sahiptir (Dursun ve Dede, 2004).

Bu çalışma kapsamında yapılan öneriler aşağıda sıralanmıştır:

- Yöntemlerin performansı farklı denemelerde değişiklik gösterdiğinden dolayı deneme sayılarının artırılması yoluna gidilebilir.
- Çalışmada kullanılan değişkenlerden farklı değişkenler kullanılarak, söz konusu yöntemlerin tahminleme performansları karşılaştırılabilir.
- Daha farklı örneklemeler üzerinde, çalışmada kullanılan yöntemlerin performans karşılaştırılması yapılabilir.
- Klasik istatistiksel yöntemlerle bu çalışmada kullanılan yöntemlerin performans karşılaştırılması yapılabilir.
- Araştırma kapsamında; matematik başarısını etkileyen en önemli değişkenler sırasıyla; kaygı, Türkçe başarı durumu, motivasyon ve disiplinli sınıf ortamı değişkenleri olarak bulunmuştur. Bu nedenle, öğrencilerdeki matematik kaygısının nedenleri belirlenmeli, öğrencilere okuma alışkanlığı kazandırılmaya çalışılmalı, disiplinli sınıf ortamları oluşturulmalı ve öğrencinin motivasyonunu artırıcı tedbirler alınmalıdır.

Son olarak; bu çalışmanın, eğitsel araştırmalar sürecinde, veri madenciliği yöntemlerinin kullanımına örneklik teşkil etmesi ve öğrencilerin matematik yeterliliği üzerinde etkisi tespit edilen faktörlerin Milli Eğitim sistemine ışık tutacağı ümit edilmektedir.



## KAYNAKLAR

- Agresti, A., 1990. *Categorical Data Analysis*. John Wiley & Sons, New York.
- Ahyan, S., Darmawijoyo, Z., 2014. Developing mathematics problems based on pisa level of change and relationships content. *IndoMS-JME*, 5 (1): 47-56.
- Akar Ö., Güngör O., Akar A., 2010. Rastgele orman sınıflandırıcısı ile arazi kullanım alanlarının belirlenmesi, *III. Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu*, 11-13 Ekim 2010, Gebze. 142-152.
- Akar, Ö., Güngör, O., 2012. Rastgele orman algoritması kullanılarak çok bantlı görüntülerin sınıflandırılması. *TMMOB Harita ve Kadastro Mühendisleri Odası Jeodezi ve Jeoinformasyon Dergisi*, 1 (2): 139-146
- Akarsu, S., 2009. *Öz-Yeterlik, Motivasyon ve Pisa 2003 Matematik Okuryazarlığı Üzerine Uluslararası Bir Karşılaştırma: Türkiye ve Finlandiya* (yüksek lisans tezi, basılmamış). AİBÜ, Sosyal Bilimler Enstitüsü, Bolu.
- Akbilgiç, O., 2011. *Hibrit Radyal Tabanlı Fonksiyon Ağları İle Değişken Seçimi Ve Tahminleme: Menkul Kıymet Yatırım Kararlarına İlişkin Bir Uygulama* (doktora tezi, basılmamış). İÜ, Sosyal Bilimler Enstitüsü, İstanbul.
- Akman, M., 2010. *Veri Madenciliğine Genel Bakış Ve Random Forests Yönteminin İncelenmesi: Sağlık Alanında Bir Uygulama*, (yüksek lisans tezi, basılmamış). AÜ Sağlık Bilimleri Enstitüsü, Ankara.
- Aksu, G., 2018. *PISA Başarısını Tahmin Etmede Kullanılan Veri Madenciliği Yöntemlerinin İncelenmesi*, (doktora tezi, basılmamış). Hü, Eğitim Bilimleri Enstitüsü, Ankara.
- Aksu, G., Doğan, N., 2018. Veri madenciliğinde kullanılan öğrenme yöntemlerinin farklı koşullar altında karşılaştırılması. *Ankara Üniversitesi Eğitim Bilimleri Fakültesi Dergisi*, 51 (3): 71-100
- Aksu, G., Güzeller C.O., 2016. Pisa 2012 Matematik okuryazarlığı puanlarının karar ağacı yöntemiyle sınıflandırılması: Türkiye Örnekleme. *Eğitim ve Bilim Dergisi*, 41 (185): 101-122.
- Akyüz, G., Pala M.N., 2010. Pisa 2003 sonuçlarına göre öğrenci ve sınıf özelliklerinin matematik okuryazarlığına ve problem çözme becerilerine etkisi. *İlköğretim Online*, 9 (2): 668-678.
- Albayrak, A.S., Koltan Yılmaz, Ş., 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
- Almuallim, H., 1996. An efficient algorithm for optimal pruning of decision trees. *Artificial Intelligence*, 83(2): 347-362.
- Amit, Y., Geman, D., 1997. Shape quantization and recognition with randomized trees. *Neural Computation*, 9:1545–1588.
- Aml, D., 2009. Uluslararası öğrenci başarılarını değerlendirme programı (Pisa)'nda, Türkiye'deki öğrencilerin fen bilimleri başarılarını etkileyen faktörler. *Eğitim ve Bilim Dergisi*, 34 (152): 87-100.
- Anyanwu, M., Shiva, S., 2009. Comparative analysis of serial decision tree classification algorithms. *International Journal of Computer Science and Security (IJCSS)* 3 (3): 230-240.
- Archer, K.J., Kimes, R.V., 2008. Empirical characterization of random forest variable importance measures. *Computational Statistics & Data Analysis* 52 : 2249–2260

- Ataseven, B., 2016. Yapay Sinir Ağları İle Öngörü Modellemesi. *Öneri Dergisi*, **12** (46): 101-115.
- Atasever, Ü.H., 2011. *Uydu Görüntülerinin Sınıflandırılmasında Hızlandırma (Boosting), Destek Vektör Makineleri, Rastgele Orman (Random Forest) Ve Regresyon Ağaçları Yöntemlerinin Kullanılması* (yüksek lisans tezi basılmamış) EÜ Fen Bilimleri Enstitüsü, Kayseri.
- Ayas, S., 2014. *Mikroskopik İmgelerde Tüberküloz Bakterisinin Rastgele Ormanlar Yöntemiyle Sınıflandırılması* (yüksek lisans tezi, basılmamış). KTÜ Fen Bilimleri Enstitüsü, Trabzon.
- Aydın, A., Sarıer, Y., Uysal, Ş.,2012. Sosyoekonomik ve sosyokültürel değişkenler açısından pısa matematik sonuçlarının karşılaştırılması. *Eğitim ve Bilim*, **37**: 164.
- Aydın, B., 2001. *İlköğretim Okullarında Sınıf Disiplininin Sağlanması* (doktora tezi, basılmamış). AİBÜ, Sosyal Bilimler Enstitüsü, Bolu.
- Aydın, M., Geçici, M.E., 2017. 6. Sınıf öğrencilerinin epistemolojik inançlarının bazı değişkenler açısından incelenmesi. *Ahi Evran Üniversitesi Kırşehir Eğitim Fakültesi Dergisi (KEFAD)*, **18** (1): 213-229.
- Aygüner, E., 2016. *Sekizinci Sınıf Öğrencilerinin Görsel Matematik Okuryazarlığı Öz Yeterlik Alguları İle Gerçek Performanslarının Karşılaştırılması* (yüksek lisans tezi, basılmamış). OGÜ Eğitim Bilimleri Enstitüsü, Eskişehir.
- Azapağası İlbağı E., Akgün L., 2012. Pisa 2003 öğrenci anketine göre 15 yaş grubu öğrencilerinin tutumlarının incelenmesi. *Western Anatolia Journal of Educational Science*, **3** (6): 67-90
- Azapağası İlbağı, E., 2012. *Pisa 2003 Matematik Okuryazarlığı Soruları Bağlamında 15 Yaş Grubu Öğrencilerinin Matematik Okuryazarlığı ve Tutumlarının İncelenmesi* (doktora tezi, basılmamış). ATAUNİ, Eğitim Bilimleri Enstitüsü Erzurum.
- Bansal, D., Chhikara, R.,Khanna, K., Gupta, P., 2018. Comparative analysis of various machine learning algorithms for detecting dementia. *Procedia Computer Science*, **132**, 1497–1502.
- Bautier, E., Rayou, P.(2007). What PISA really evaluates: literacy or students' universes of reference? *J Educ Change*, **8**: 359–364.
- Bayram, S, Ocal, M.E., Laptalı Oral, E. Atis, C.D., 2013. Comparison of multi layer perceptron (mlp) and radial basis function (rbf) for construction cost estimation: The case of Turkey. *Journal Of Civil Engineering and Management*, **22** (4): 480–490.
- Beale, R., Jackson, T., 1990. *Neural Computing: An Introduction*. Taylor & Francis Group, New York.
- Becerra, R., Joya, G., García, R., Velázquez, L., Rodríguez, R., Pino, C., 2013. Saccadic points classification using multilayer perceptron and random forest classifiers in EOG recordings of patients with Ataxia SCA2. *International Work-Conference on Artificial Neural Networks*. 12-14 June 2013, Tenerife, 115-123.
- Benzer, S., Benzer, R., 2017. Examination of international Pisa test results with artificial neural networks and regression methods. *Savunma Bilimleri Dergisi*, **16** (2): 1-13.
- Bertoni, A., Campadelli, P., Parodi, M., 1997. *A Boosting algorithm for regression*
- Bezek Güre, Ö., Kayri, M., Erdoğan, F., 2019. Predicting factors affecting PISA 2015 mathematics literacy via radial basis function artificial neural network. *Journal of Engineering and Technology*, **3** (1) : 1-11
- Biau, G., Devroye, L. Lugosi, G., 2008. Consistency of random forests and other averaging classifiers. *The Journal of Machine Learning Research*, **9**:2015–2033.

- Biau, G., 2012. Analysis of a Random Forest, *Journal of Machine Learning Research*, **13** (2012) 1063-1095.
- Biau, G., Scornet, E., 2016. A random forest guided tour. *An Official Journal of the Spanish Society of Statistics and Operations Research*, **25** (2). Doi: 10.1007/s11749-016-0481-7
- Bilgen, İ., 2014. *İnsan ve HIV-1 Proteinleri Arasındaki Etkileşimlerin Rastgele Orman Yöntemi ve Birlikte Öğrenme Yaklaşımı ile Tahmin Edilmesi*, (yüksek lisans tezi, basılmamış). İTÜ, Fen Bilimleri Enstitüsü, İstanbul.
- Billings, S.A., Zheng, G.L., 1994. Radial basis function network configuration using genetic algorithms. research report. ACSE Research Report 521. <http://eprints.whiterose.ac.uk/79776/1/acse%20research%20report%20521.pdf>  
Erişim tarihi: 18.06.2018.
- Bohanec, M., Bratko, I., 1994. Trading accuracy for simplicity in decision trees. *Machine Learning*, **15**: 223-250.
- Breiman, L., 1996. Bagging predictors. *Machine Learning*, **24** (2):123–140.
- Breiman, L., 2001. Random forests. *Mach Learn*, **45**:5–32
- Breiman, L., 2003. *Setting up, using, and understanding random forests V3.1*. [https://www.stat.berkeley.edu/~breiman/Using\\_random\\_forests\\_V3.1.pdf](https://www.stat.berkeley.edu/~breiman/Using_random_forests_V3.1.pdf).  
Erişim tarihi: 08.02.2018.
- Breiman, L., 2004. Consistency for a simple model of random forests. *Technical Report 670*, Statistics Department,
- Briemann, L., Friedman, J., Olshen, R., Stone, C., 1984. CART: Classification and Regression Trees, Chap. 11. *Classification Algorithms and Regression Trees* Chapman and Hall/CRC Boca Raton London. 368.
- Bühlmann, P., 2018. *Bagging, Boosting and Ensemble Methods*. Papers / Humboldt-Universität Berlin, Center for Applied Statistics and Economics (CASE), No. 2004,312018
- Cganh, F.J., Liang, J.M., Chen, Y.C., 2001. Flood forecasting using radial basis function neural networks. *IEEE Transaction on Systems, Man, and Cybernetics Part C: Applications and Reviews*, **31** (4): 530-535.
- Chadha, A.N., Nirmal, J.N., Zaveri, M.A., 2014. A Comparison of multi-layer perceptron and radial basis function neural network in the voice conversion framework. *2014 International Conference on Advances in Computing, Communications and Informatics (ICACCI)*. 24 - 27 September, Delhi, India.
- 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.
- Chen, J., Zhao, P., Liang, H., Mei, T., 2014. Motion planning for autonomous vehicle based on radial basis function neural network in unstructured environment. *Sensors*, **14**: 17548–17566.
- Chen, S.Y., Liu, X., 2004. The contribution of data mining to information science. *Journal of Information Science*, **30**(6): 550–558© CILIP, DOI: 10.1177/0165551504047928.
- Cheung, C.C., Ng, S.C., Lui A.K., 2012. Improving the Quickprop algorithm. *WCCI 2012 IEEE World Congress on Computational Intelligence.*, June 10-15 2012, Brisbane, Australia.
- Cilimkovic, M., 2018. Neural Networks and Back Propagation Algorithm,

- Comrie, A. C., 1997. Comparing neural networks and regression models for ozone forecasting. *Journal of the Air & Waste Management Association*, **47**: 653-663
- Cutler, D.R., T.C. Edwards, K.H. Beard, A. Cutler, K.T., Hess, J.C. Gibson, J.J. Lawler., 2007. Random forests for classification in ecology. *Ecology*, **88** (11):2783-2792.
- Çelen. F.K., Çelik., Seferoğlu. S.S., 2011. Türk eğitim sistemi ve Pisa sonuçları. **Akademik Bilişim'11 - XIII. Akademik Bilişim Konferansı Bildirileri**. 2 - 4 Şubat 2011, Malatya. 765-773.
- Çelik, S., Yılmaz, O., 2017. Comparison of different data mining algorithms for prediction of body weight from several morphological measurements in dogs. *The Journal of Animal & Plant Sciences*, **27**(1): 57-64.
- Çuhadar, M., 2013. Türkiye'ye yönelik dış turizm talebinin MLP, RBF ve TDNN yapay sinir ağı mimarileri ile modellenmesi ve tahmini: Karşılaştırmalı bir analiz. *Journal of Yasar University*, **8** (31) 5274-5295.
- Dash, R.N., Subudhi, B., Das, S., 2010. A comparison between MLP NN and RBF NN techniques for the detection of stator inter-turn fault of an induction motor. **2010 International Conference on Industrial Electronics, Control and Robotics**. 27-29 Dec. 2010, Orissa, India.
- Davis, L., 1991. *Handbook on Genetic Algorithms*. Van Nostrand Reinhold, New York.
- Delice, A., Ertekin, E., Aydın, E., Dilmaç, B., 2009. Öğretmen adaylarının matematik kaygısı ile bilimsel inançları arasındaki ilişkinin incelenmesi. *Uluslararası İnsan Bilimleri Dergisi*, **6** (1), 361-375.
- Demir, İ., Depren, Ö., Kılıç, S., 2010. Measuring the efficiency of secondary schools in different regions in turkey using data envelopment analysis. *The International Journal of Research in Teacher Education*, **1**(1):52-64
- Deryakulu, D., 2004. Üniversite öğrencilerinin öğrenme ve ders çalışma stratejileri ile epistemolojik inançları arasındaki ilişki. *Kuram ve Uygulamada Eğitim Yönetimi*, **38**: 230-249.
- Deryakulu, D., Büyüköztürk, Ş., 2005. Epistemolojik inanç ölçeğinin faktör yapısının yeniden incelenmesi: cinsiyet ve öğrenim görülen program türüne göre epistemolojik inançların karşılaştırılması. *Eurasian Journal of Educational Research*, **18**: 57-70.
- Doğan, N., Özdamar, K., 2003. Chaid analizi ve aile planlaması ile ilgili bir uygulama. *Türkiye Klinikleri Tıp Bilimleri Dergisi*, **23** (5): 392-397.
- Dursun Sürmeli, Z., Ünver, G., 2017. Öz-düzenleyici öğrenme stratejileri, epistemolojik inançlar ve akademik benlik kavramı ile matematik başarısı arasındaki ilişki. *Turkish Journal of Computer and Mathematics Education*, **8** (1), 83-102.
- Dursun, Ş., Dede, Y., 2004. Öğrencilerin matematikte başarısını etkileyen faktörler: matematik öğretmenlerinin görüşleri bakımından. *Gazi Eğitim Fakültesi Dergisi*, **24** (2) : 217-230.
- Efe, E., Bek, Y., Şahin, M., 2000. *SPSS'te Çözümleri ile İstatistik Yöntemler II*. Kahramanmaraş: Kahramanmaraş Sütçü İmam Üniversitesi Rektörlüğü, yayın no:10.
- Emel, G.G., Taşkın, Ç., 2005. Veri madenciliğinde karar ağaçları ve bir satış analizi uygulaması. *Eskişehir Osmangazi Üniversitesi Sosyal Bilimler Dergisi*, **6**(2): 221-239.
- Eriksson, V., Varatharajah, T., 2016. A comparative study on artificial neural networks and random forests for stock market prediction. *KTH Royal Institute of Technology School of Computer Science and Communication*.



- Erođlu, S.E., Güven, K., 2006. Üniversite öğrencilerinin epistemolojik inançlarının bazı değişkenler açısından incelenmesi. *Selçuk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, **16**: 295-312.
- Fausett, L., 1994. *Fundamentals of Neural Networks: Architectures, Algorithms and Applications*, Prentice Hall.
- Fayyad, U., Piatetsky-Shapiro, G., Smyth, P., 1996. from data mining to knowledge discovery in databases. *American Association for Artificial Intelligence*, **17**(3): 37-54.
- Fernández-Delgado, M., Cernadas, E., Barro, S., 2014. Do we Need Hundreds of Classifiers to Solve Real World Classification Problems? *Journal of Machine Learning Research*, **15** : 3133-3181.
- Ferreira, A., Figueiredo, M., 2012. Boosting Algorithms: A review of methods, theory, and applications. Chap. 8. *Boosting Algorithms: A Review of Methods, Theory, and Applications*. Springer, Lisbon, Portugal. 35-85.
- Finan, R.A., Sapeluk, A.T., Dampert, R.I., 1996. Comparison of multilayer and radial basis function neural networks for text-dependent speaker recognition. **Proceedings of International Conference on Neural Networks (ICNN'96)**. 3-6 June 1996. Washington, DC, USA,
- Fürnkranz, J., Widmer, G., 1994. Incremental reduced error pruning. *Machine Learning, Proceedings of the Eleventh International Conference*. July 10-13 1994, New Brunswick, NJ, USA.
- Gardner, M. W., Dorling, S. R., 1998. Artificial Neural Networks (The Multilayer Perceptron). *A Review of Applications in the Atmospheric Sciences, Atmospheric Environment*, **32** (14/15): 2627—2636.
- Gargano, M.L., Raggad, B.G., 1999. Data mining—A Powerful Information Creating Tool. *OCLC Systems & Services*(15): 81—90.
- Garofalakis, M., Hyun, D., Rastogi, R., Shim, K., 2000. Efficient algorithms for constructing decision trees with constraints. **Proceedings of the Sixth ACM SIGKDD International conference on Knowledge discovery and data mining**. pp. 335 – 339
- Gehrke, J., Ramakrishnan, R., Ganti, V., 1998. RainForest - a framework for fast decision tree construction of large datasets. *Proceedings of the 24th VLDB conference*. New York, USA. 416- 427.
- Geneur, R., Poggi, J.M., Tuleao Malot, C., Villa-Vialaneix, N., 2017. Random Forest for Big Data, *Big Data Research*, **9** : 28-46.
- Gibson, G.J., Siu, S., Cowan, C.F.N., 1989. Multilayer perceptron structures applied to adaptive equalisers for data communications. *International Conference on Acoustics, Speech, and Signal Processing*, 23-26 May 1989, Glasgow, UK.
- Goh, A.T.C., 1995. Back-propagation neural networks for modeling complex systems, *Artificial Intelligence in Engineering*, **9**: 143-151.
- Gönül Y., Ulu Ş., Bucak A., Bilir A., 2015. Yapay sinir ağları ve klinik araştırmalarda kullanımı. *Genel Tıp Dergisi*, **25**:104-111.
- Gözübüyük-Tamer, M., 2013. Yaşam boyu öğrenme için ulusal yeterlilikler çerçevesi: Avrupa ve Türkiye örneği. *Uluslararası Eğitim Programları ve Öğretim Çalışmaları Dergisi*, **3** (5), 43-54.
- Gumma, S., 2004. *A Radial Basis Function Neuro Controller for Permenent Magnet Stepper Motor* (yüksek lisans tezi basılmamış) Master of Science in Electrical Engineering. Cleveland State University, India.

- Guo, H., Zhao, J.Y., Yin, J.H., 2017. Random forest and multilayer perceptron for predicting for dielectric loss of polyimide nanocomposite films. *This journal is © The Royal Society of Chemistry*, **7**: 30999-31008.
- Güler İ., Übeyli E.D., 2005. Çok katmanlı perseptron sinir ağları ile diyabet hastalığının teşhisi. *Gazi Üniv. Müh. Mim. Fak. Dergisi*, **21** (2): 319-326.
- Güler, İ., Übeyli, E.D., 2003. Detection of ophthalmic artery stenosis by least-mean squares backpropagation neural network. *Computers in Biology and Medicine*, **33** (4): 333-343.
- Gündoğan, N., 2003. Avrupa Birliği'ne üye ülkelerde bir istihdam politikası aracı olarak yaşam boyu öğrenme ve bazı örnek program ve uygulamalar. *Kamu-İş İş Hukuku ve İktisat Dergisi*, **7** (2): 2-15.
- Gürsakal, S., 2009. PISA 2009 öğrenci başarı düzeylerini etkileyen faktörlerin değerlendirilmesi. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, **17** (1): 441-452.
- Güzeller, C.O., Akın, A., 2014. Relationship between ICT variables and mathematics achievement based on PISA 2006 database: International evidence. *The Turkish Online Journal of Educational Technology*, **13** (1): 184-192.
- Hacıfendioglu, Ş., 2012. *Makine Öğrenmesi Yöntemleri ile Glokom Hastalığının Teşhisi*, (yüksek lisans tezi). SÜ, Fen Bilimleri Enstitüsü, Konya.
- Hall, L. O., Collins, R., Bowyer, K.W., Banfield, R., 2002. Error-based pruning of decision trees grown on very large data sets can work!. *International Conference on Tools for Artificial Intelligence*, 233-238.
- Hamzaçebi, C., Kutay, F., 2004. Yapay sinir ağları ile Türkiye elektrik enerjisi tüketiminin 2010 yılına kadar tahmini. *Gazi Üniversitesi Mühendislik ve Mimarlık Dergisi*, **19** (3): 227-233.
- Hamzaçebi, C., 2011. *Yapay sinir ağları*, Bursa: Ekin.
- Han, J., Kamber, M., 2006. *Data Mining: Concepts and Techniques*. Second Edition, Morgan Kaufmann Publications, San Francisco, USA.703.
- Hand, D.J., Mannila, H., Smyth, P., 2001. *Principles of Data Mining* MIT Press, Cambridge, Massachusetts London England. 546.
- Hastie, T., Tibshirani, R., Friedman, J., 2009. *The Elements of Statistical Learning*. New York, NY, USA: Springer.
- Ho, T.K.. 1998. The random subspace method for constructing decision forests. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **20**:832-844.
- Holland, J.H., 1975. *Adaptation in Natural and Artificial Systems*. University of Michigan Press, Ann Arbor.
- Hrycej, T., 1997. *Neurocontrol: Toward an Industrial Control Methodology*. NY: JohnWiley and Sons, Inc.
- İlgün Dibek, M., 2015. *PISA 2012 Matematik Okuryazarlığı ile Öğrenme Ve Öğretme Süreci Değişkenleri Arasındaki İlişkiler* (yüksek lisans tezi, basılmamış). AÜ, Eğitim Bilimleri Enstitüsü, Ankara.
- İlgün Dibek, M., Demirtaşlı, R.N., 2017. Öğrenme ve öğretme süreci değişkenleri ile PISA 2012 matematik okuryazarlığı arasındaki ilişkiler. *İlköğretim Online*, **16** (3) :1137-1152.
- İnal H., Turabik T., 2016. Matematik başarısını etkileyen bazı faktörlerin yordama gücünün yapay sinir ağları ile belirlenmesi. *Uşak Üniversitesi Eğitim Araştırmaları Dergisi*, **3** (1), 23-50.

- İş Güzel, Ç., 2006. *A Cross-Cultural Comparison of The Impact of Human and Physical Resource Allocations on Students' Mathematical Literacy Skills in The Programme For International Student Assessment (PISA) 2003* (doktora tezi, basılmamış). ODTÜ, Fen Bilimleri Enstitüsü, Ankara.
- İş, Ç., 2003. *Uluslararası Öğrenci Başarı Belirleme Programına Göre (Pisa) , Matematik Okuryazarlığını Belirleyen Faktörlerin Kültürler Arası Karşılaştırılması* (yüksek lisans tezi, basılmamış). ODTÜ, Fen Bilimleri Enstitüsü, Ankara.
- Jain K.A., Mao, J., 1996. Artificial Neural Network; A Tutorial, 0018-
- Jayawardena, A. W., Fernando, D. A. K., Zhou, M. C., 1997. Comparison of multilayer perceptron and radial basis function networks as tools for flood forecasting, destructive water: water-caused natural disasters, their abatement and control. *Proceedings of the CQ Conference held at Anaheim*. California, June 1996, 173-181.
- Jiang, T., Li, J. , Zheng, Y., Sun, C., 2011. Improved bagging algorithm for pattern recognition in uhf signals of partial discharges. *Energies*, **4**:1087-1101.
- Kamaliyah K., Zulkardi Z., Darmawijoyo D., 2013. Developing the sixth level of Pisa-like mathematics problems for secondary school students. *Journal on Mathematics Education*, **4** (1), 9-28.
- Karabay, E., 2013. *Aile ve Okul Özelliklerinin Pisa Okuma Becerileri, Matematik ve Fen Okuryazarlığını Yordama Gücünün Yıllara Göre İncelenmesi*(yüksek lisans tezi, basılmamış). GÜ, Eğitim Bilimleri Enstitüsü, Ankara.
- Karabay, E., Yıldırım, A., Güler, G., 2015. Yıllara göre Pisa matematik okuryazarlığının öğrenci ve okul özellikleri ile ilişkisinin aşamalı doğrusal modeller ile analizi. *Mehmet Akif Ersoy Üniversitesi Eğitim Fakültesi Dergisi*, **36**: 137-151.
- Karadeniz, M., Yüncü, S., Aydemir M.T., 2001. Asenkron motorlarda stator direncinin yapay sinir ağları ile tahmini. *TMMOB Elektrik Mühendisliği Elektrik-Elektronik-Bilgisayar ve Biyomedikal Mühendisliği Kongresi Bildirileri*, 9-21 Eylül 2001, Kocaeli.
- Kashaninejad, M., Dehghani, A.A., Kashiri, M., 2009. Modeling of wheat soaking using two artificial neural networks (MLP and RBF). *Journal of Food Engineering*, **91** (2009): 602–607.
- Kaynar, O., Taştan, S., 2009. Zaman serisi analizinde MLP yapay sinir ağları ve Arıma modelinin karşılaştırılması. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, **33**:161-172.
- Kaynar, O., Taştan, S., Demirkoparan, F., 2010. Ham petrol fiyatlarının yapay sinir ağları ile tahmini. *Ege Akademik Bakış*, **10** (2): 559-573.
- Kayri M., Çokluk Bökeoğlu Ö., 2016. Examining Factors of academic procrastination tendency of university students by using artificial neural network. *International Journal of Computer Trends and Technology*, **34** (1): 1-8.
- Kayri, M., 2015. An intelligent approach to educational data: performance comparison of the multilayer perceptron and the radial basis function artificial neural networks. *Educational Sciences: Theory & Practice*, **15** (5): 1247-1255.
- Kayri, M., Boysan, M., 2008. Bilişsel yatkınlık ile depresyon düzeyleri ilişkisinin sınıflandırma ve regresyon ağacı analizi ile incelenmesi. *Hacettepe Üniversitesi Eğitim Fakültesi Dergisi (H. U. Journal of Education)***34**: 168-177.
- Kayri, M., Kayri, İ., Gençoğlu, M.T., 2017. The performance comparison of multiple linear regression, random forest and artificial neural network by using photovoltaic

- and atmospheric data. *2017 14th International Conference on Engineering of Modern Electric Systems (EMES)*. 1-2 June 2017, Oradea, Romania. 1-4.
- Khoshgoftaar, T.M., Allen, E.B., 1999. Logistic regression modeling of software quality. *International Journal of Reliability, Quality and Safety Engineering*, 6(4): 303-317.
- Koç-Erdamar, G., Bangir-Alpan, G., 2011. Öğretmen adaylarının epistemolojik inançları. *e- Journal of New Word Sciences Academy*, 6 (4): 2689-2698.
- Koğar, H., 2015. PISA 2012 matematik okuryazarlığını etkileyen faktörlerin aracılık modeli ile incelenmesi. *Eğitim ve Bilim dergisi*, 40 (179): 45-55.
- Korkem, E., 2013. *Mikroarray Gen Ekspresyon Veri Setlerinde Random Forest Ve Naive Bayes Sınıflama Yöntemleri Yaklaşımı İncelenmesi*(yüksek lisans tezi, basılmamış). HÜ, Sağlık Bilimleri Enstitüsü, Ankara.
- Krenker A., Beşter J., Kos,A., 2011. Introduction to the Artificial Neural Networks. Methodological Advances and Biomedical Applications.
- Kumar, M., Yadav, N., 2011. Multilayer perceptrons and radial basis function neural network methods for the solution of differential equations: A survey. *Computers and Mathematics with Applications*, 62 (10): 3796-3811.
- Kumari, G.T.P., 2012. A study of bagging and boosting approaches to develop meta-classifier. *IRACST – Engineering Science and Technology: An International Journal (ESTIJ)*, 2(5): 850-855.
- Küçükahmet, L., 1999. *Öğretimde Planlama ve Değerlendirme*. Alkım Yayınevi, İstanbul:
- Larose, D.T., 2005. *Discovering Knowledge in Data*. A John Wiley & Sons, Inc., Publication, New Jersey. 317.
- Leung, F.H.F., Lam, H.K., Ling, S.H., Tam, P.K.S., 2003. Tuning of the structure and parameters of neural networks using an improved Genetic Algorithm. *IEEE Transactions on Neural Networks*, 14 (1): 79-88.
- Liao, S., 2003. Knowledge management technologies and applications—literature review from 1995 to 2002. *Expert Systems With Applications* 2 (25): 155–164.
- Liaw, A., Wiener,M., 2002. Classification and regression by randomforest, *R News*, 2(3): 18-22.
- Lin, Y., Jeon, Y., 2006. Random forests and adaptive nearest neighbors. *Journal of the American Statistical Association*, 101:578–590.
- Lippmann, R., 1987. An Introduction to computing with neural nets. *IEEE ASSP Magazine*, 22:4-22.
- Loh, W.Y., Shih, Y.S., 1997. Split selection methods for classification trees. *Statistica Sinica*, 7 (4): 815–840.
- Louppe, G., 2014. *Understanding Random Forests from Theory to Practice*. (PhD dissertation). University of Liège Faculty of Applied Sciences Department of Electrical Engineering & Computer Science, Liege.
- Maclin,R., Opitz, D., 1997. An empirical evaluation of bagging and boosting, Appears in *The Fourteenth National conference on Artificial Intelligence*, Providence, Rhode Island. 546-551.
- Marin, E.J. O., Martínez-Capel, F., Vezza, P. (2013). A comparison of Artificial Neural Networks and Random Forests to predict native fish species richness in Mediterranean rivers. *Knowledge and Management of Aquatic Ecosystems*, 409, 07.

- Maroco, J., Silva, D., Rodrigues, A., Guerreiro, M., Santana, I., Mendonça, A., 2011. Data mining methods in the prediction of Dementia: A real-data comparison of the accuracy, sensitivity and specificity of linear discriminant analysis, logistic regression, neural networks, support vector machines, classification trees and random forest. *BMC Research Notes*, **4**:299.
- Mehta, J., Mehta, A.H., Manjunath T.C., Ardil C., 2007. A Multi-layer artificial neural network architecture design for load forecasting in power systems, *International Journal of Applied Mathematics and Computer Sciences*, **4** (4): 1-31.
- Meinshausen, N., 2006. Quantile regression forests. *Journal of Machine Learning Research* **7**: 983–999.
- Memarian, H., Kumar Balasundram, S., 2012. Comparison between multi-layer perceptron and radial basis function networks for sediment load estimation in a tropical watershed. *Journal of Water Resource and Protection*, **4** :870-876.
- Milli Eğitim Bakanlığı (MEB), 2016. PISA 2009 projesi ulusal ön raporu. MEB Eğitimi Araştırma ve Geliştirme Dairesi Başkanlığı. [http://odsgm.meb.gov.tr/test/analizler/docs/PISA/PISA2015\\_Ulusal\\_Rapor.pdf](http://odsgm.meb.gov.tr/test/analizler/docs/PISA/PISA2015_Ulusal_Rapor.pdf) Erişim tarihi: 15.09.2017.
- Mingers, J., 1987a. Expert systems—rule induction with statistical data. *Journal of the Operational Research Society*, **38**: 39-47.
- Mingers, J., 1989. An Empirical comparison of pruning methods for decision tree induction, *Machine Learning*, **4**: 227-243.
- Mitchell, M., 1996. *An Introduction to Genetic Algorithms*. MIT Press, Cambridge, MA.
- Mustafa, M. R., Rezaur, R. B., Rahardjo, H., Isa, M. H., 2012. Prediction of pore-water pressure using radial basis function neural network. *Engineering Geology*, **135** (136):40–47.
- Mutluer, C., Büyükkıdık, S., (2017). PISA 2012 verilerine göre matematik okuryazarlığının lojistik regresyon ile kestirilmesi. *Marmara Üniversitesi Atatürk Eğitim Fakültesi Eğitim Bilimleri Dergisi*, **46**: 97-112.
- Nascimento, C.L. Jr., 1994. *Artificial Neural Networks in Control and Optimization*. (PhD. Dissertation). The University of Manchester for the degree of Doctor of Philosophy in the Faculty of Technology, Manchester.
- Nawar, S., Mouazen, A.M. 2017. Comparison between random forests, artificial neural networks and gradient boosted machines methods of on-line Vis-NIR spectroscopy measurements of soil total nitrogen and total carbon. *Sensors*, **17**(10):2428.
- Negnevitsky, M., 2005. *Artificial Intelligence A Guide to Intelligent Systems* Second Edition. Addison-Wesley.
- Neruda, R., Kudova, P., 2005. Learning methods for radial basis function networks. *Future Generation Computer Systems*, **21** (7): 1131-1142
- Niblett, T., 1986. *Constructing decision trees in noisy domains*. Editor: I. Bratko and N. Lavrac). Progress in machine learning. Sigma Press. England.
- Nitze, I., Schulthess, U., Asche, H., 2012. Comparison of Machine Learning Algorithms Random Forest, Artificial Neural Network And Support Vector Machine To Maximum Likelihood For Supervised Crop Type Classification. *Proceedings of the 4th GEOBIA*. 7-9 May, Rio de Janeiro - Brazil. 35-40.
- OECD, 2007. PISA 2006. <https://www.oecd.org/pisa/data/42025182.pdf> Erişim tarihi: 27.10.2017.
- OECD, 2013. PISA 2012 mathematics framework. Pisa 2015 assessment and analytical framework: science, reading, mathematic and financial literacy. Paris: OECD

- Publishing. <http://www.oecd.org/publications/pisa-2015-assessment-and-analytical-framework-9789264281820-en.htm> Erişim tarihi: 17.10.2017.
- OECD, 2016. PISA 2015 mathematics framework. Pisa 2015 assessment and analytical framework: science, reading, mathematic and financial literacy. Paris: OECD Publishing. <http://www.oecd.org/publications/pisa-2015-assessment-and-analytical-framework-9789264281820-en.htm> Erişim tarihi: 15.10.2017.
- OECD, 2016a. PISA 2015 results in focus. Paris: OECD Publishing. . [https://www.oecd-ilibrary.org/education/pisa-2015-results-in-focus\\_aa9237e6-en](https://www.oecd-ilibrary.org/education/pisa-2015-results-in-focus_aa9237e6-en)Erişim tarihi: 14.10.2017.
- OECD, 2017. PISA 2015 mathematics framework. Pisa 2015 assessment and analytical framework: science, reading, mathematic and financial literacy. Paris: OECD Publishing. <https://www.oecd-ilibrary.org/docserver/9789264281820-5-en.pdf?expires=1551263445&id=id&accname=guest&checksum=68103F2481FBCB83BC914AB2675855B6> Erişim tarihi: 16.10.2017.
- Okatan, Ö., 2017. *Uluslararası Öğrenci Başarılarını Değerlendirme Programı'na (Pisa) göre Öğrencilerin Matematik Başarıları İle İlişkili Değişkenlerin İncelenmesi* (yüksek lisans tezi, basılmamış). MAEÜ, Eğitim Bilimleri Enstitüsü, Burdur.
- Oludolapo, O., Jimoh, A., Kholopane, P., 2012. Comparing performance of MLP and RBF neural network models for predicting South Africa's energy consumption. *Journal of Energy in Southern Africa*, **23** (3): 40-46.
- Otaïr, M.A., Salameh, W.A., 2016. An enhanced version of Delta-Bar-Delta Algorithm. *The International Conference on Information Technology*, 4-6 April 2005, US & Canada.
- Otero, F.E.B., Freitas, A.A., Johnson, C.G., 2012. Inducing decision trees with an ant colony optimization algorithm. *Applied Soft Computing*, **12**( 11):3615–3626.
- Özaslan, N., 2017. *Türkiye'deki Öğrenci Başarılarının PISA 2003-2012 Matematik Okuryazarlığı Testlerinde Yer Alan Farklı Soru Türlerine Göre Değerlendirilmesi* (yüksek lisans tezi, basılmamış). GÜ, Eğitim Bilimleri Enstitüsü, Gaziantep.
- Özbayoğlu, A.M. ve Bozer, R., 2012. Estimation of the burned area in forest fires using computational intelligence techniques. *Procedia Computer Science*, **12** ( 2012 ): 282 –287.
- Özdarıcı Ok, A., Akar, Ö., Güngör, O., 2011. Rastgele orman sınıflandırma yöntemi yardımıyla tarım alanlarındaki ürün çeşitliliğinin sınıflandırılması. *TUFUAB VI.Teknik Sempozyumu*. 23-26 Şubat 2011, Antalya.
- Özkan, Ş., 2008. *İlköğretim Öğrencilerinin Fen Başarıları ile İlgili Bir Modelleme Çalışması: Epistemolojik İnançlar, Öğrenme Yaklaşımları ve Öz-Düzenleme Becerileri Arasındaki İlişkiler* (doktora tezi, basılmamış). ODTÜ, Fen Bilimleri Enstitüsü, Ankara.
- Öztemel, E., 2012. *Yapay Sinir Ağları*, Papatya Yayıncılık, İstanbul.
- Pal, M., 2005. Random forest classifier for remote sensing classification. *International Journal of Remote Sensing*, **26** (1): 217–222.
- Pal, M., 2007. Random forest classifier for remote sensing classification. *International Journal of Remote Sensing*, **26** (1): 217–222.
- Pal, M., Mather, P.M., 2003. Support vector classifiers for land cover classification. *Map India Conference 2003*. 28–31 January, New Delhi.
- Park, J.W., Harley, R.G., Venayagamorthy, G.K., 2004. Indirect adaptive control for synchronous Generator: comparison of MLP/RBF neural networks approach with

- Lyapunov stability analysis. *IEEE Transactions on Neural Networks*, **15** (2): 460 – 464.
- Patil, D.D., Wadhai, V.M, Gokhale, J.A., 2010. evaluation of decision tree pruning algorithms for complexity and classification accuracy. *International Journal of Computer Applications*, **11** (2): 23-30.
- Pislaru, C., Shebani, A., 2014. Identification of nonlinear systems using radial basis function neural network. *International Journal of Computer, Information, Systems and Control Engineering*, **8** (9): 1528-1532.
- Prajwala, T. R., 2015. A comparative study on decision tree and random forest using r tool. *International Journal of Advanced Research in Computer and Communication Engineering*, **4** (1): 196-199.
- Priddy, K. L., Keller, P. E., 2005. *Artificial neural networks: An introduction*, Washington: SPIE Press.
- Que, Q., Belkin, M., 2016. Back to the future: radial basis function networks revisited. *Appearing in Proceedings of the 19th International Conference on Artificial Intelligence and Statistics (AISTATS) 2016*. May 9-11, 2016, Cadiz, Spain.
- Quinlan, J. R., 1986. Induction of decision trees. *Machine Learning*, **1**: 81-106.
- Quinlan, J. R., 1993. *C4.5: Programs for Machine Learning*. Morgan Kaufmann, San Mateo, California, USA.301.
- Quinlan, J.R., 1987. Simplifying decision trees. *International Journal of Machine Studies*, **27** (3): 221-234.
- Quinlan, J.R., 1988. Decision trees and multivalued attributes. J. Richards, ed., *Machine Intelligence*, **11**: 305-318.
- Quinlan, J.R., 1993. *C4.5: Programs for Machine Learning*. San Mateo, CA: Morgan Kaufmann.
- Raczko, E., Zagajewski, B. (2017). Comparison of support vector machine, random forest and neural network classifiers for tree species classification on airborne hyperspectral APEX images. *European Journal of Remote Sensing*, **50** (1): 144-154.
- Ramchoun, H., Janati Idrissi, M.A., Ghanou, Y., Ettaouil, M., 2017. Multilayer perceptron: architecture optimization and training with mixed activation functions. *BDCA'17*, March 29-30, 2017, Tetouan.
- Rojas, R., 1996. *Neural Networks-A Systematic Introduction*. Berlin: Springer-Verlag.
- Rokach, L., Maimon, O., 2005. *Data Mining and Knowledge Discovery Handbook*. Springer New York Dordrecht Heidelberg London.1285.
- Saarela, M., Yener, B., Zaki, M.J., Karkkainen, T., 2016. Predicting Math Performance from Raw Large-Scale Educational Assessments Data: A *Machine Learning Approach*. *33rd International Conference on Machine Learning*, MLR Workshop and Conference Proceedings; 48, s: 1-8.
- Sadeghkhani, I, Ketabi, A., Feuillet, R., 2013. Delta-Bar-Delta and directed random search algorithms application to reduce transformer switching overvoltages, *International Journal on Electrical Engineering and Informatics*, **9** (2): 217-229.
- Samancı, O., Ocakçı, E., 2017. Hayat boyu öğrenme. *Bayburt Eğitim Fakültesi Dergisi*, **12** (24): 711-722.
- Santos, R.B., Rupp M., Bonzi S.J., Fileti AM.F., 2013. Comparison between multilayer feedforward neural networks and a radial basis function network to detect and locate leaks in pipelines transporting gas. *Chemical Engineering Transactions*, **32**: 1375-1380.



- Sastry PM, Krishnan R, Ram ,B.V.S., 2010. Classification and identification of teluguh and written characters extracted from palm leaves using decision tree approach. *ARNP Journal of Engineering and Applied Sciences*, **5** (3): 22-32.
- Satıcı, K., 2008. *Pisa 2003 Sonuçlarına göre Matematik Okuryazarlığını Etkileyen Faktörler: Türkiye ve Hong Kong-Çin* (yüksek lisans tezi, basılmamış). BÜ, Fen Bilimleri Enstitüsü, Balıkesir.
- Savaş, E., Taş. S., Duru, A., 2010. Factors affecting students' achievement in mathematics. *Inonu University Journal of The Faculty of Education*, **11** (1): 113-132.
- Scornet, E., Biau, G., Vert, J.P., 2014. Consistency of random forests. *The Annals of Statistics*, **43** (4): 1716–1741.
- Senthil Kumar, A. R., Sudheer, K. P., Jain, S. K., Agarwal, P. K., (2005). Rainfall-runoff modelling using artificial neural networks: comparison of network types. *Hydrological Processes*, **19**: 1277–1291.
- Seyman M N., Taşpınar N., 2009. Çok katmanlı yapay sinir ağları kullanarak ofdm sistemlerinde kanal dengeleme. *5.Uluslararası İleri Teknolojiler Sempozyumu (IATS'09)*. 13–15 Mayıs 2009, Karabük, Türkiye.
- Shah, A.S., Shah, M., Fayaz, M., Wahid, F., Khalid Khan H., Shah, A., 2017. Forensic Analysis of Offline Signatures Using Multilayer Perceptron and Random Forest. *International Journal of Database Theory and Application*, **10** (1): 139-148
- Shapire, R. Freund Y., Bartlett P ., Lee W., 1998. Boosting the margin: A new explanation for the effectiveness of voting methods. *Annals of Statistics*, **26** (5):1651–1686,
- Shaw, M.J., Subramaniam, C., Tan, G.W., Welge M.E., 2001. Knowledge management and data mining for marketing. *Decision Support Systems*, **1** (31):127–137.
- Shichkin, A.V., Buevich, A.G., Sergeev, A.P., Comparison of artificial neural network, random forest and random perceptron forest for forecasting the spatial impurity distribution. AIP Conference Proceedings **1982**, 30 July 2018, 020005-1- 020005-7.
- Sospedra, J.T., 2011. *Ensembles of Artificial Neural Network; Analysis and Development of Design Method* (Ph.D. Thesis). Universitat Jaume, Castellon.
- Soytürk, İ. (2011). *Sınıf Öğretmeni Adaylarının Matematik Okuryazarlığı Öz-yeterlikleri ve Matematiksel Problem Çözmeye Yönelik İnanışlarının Araştırılması* (yüksek lisans tezi, basılmamış). İÜ, Sosyal Bilimler Enstitüsü, İstanbul.
- SPSS, 1999. *AnswerTree Algorithm Summary*, Printed in the U.S.A © Copyright 1999 SPSS Inc. ATALGWP-0599.
- Steinberg, D., 2009. A tour of advanced data mining methodologies: the CART decision tree. *International Conference Data Mining / DMIN'09* |. Island, Florida. 3-7.
- Sug, H., 2009. Performance Comparison of RBF networks and MLPs for Classification. *Proceedings of the 9th WSEAS International Conference on Applied Informatics And Communications (AIC '09)*.20 - 22August, 2009 Moscow, Russia. 450-454.
- Sug, H., 2010. A comparison of RBF networks and random forest in forecasting ozone day. *International Journal of Mathematics and Computers in Simulation*, **4** (3): 59-66.
- Sutton, D.C., 2005. Classification and regression trees, bagging and boosting. *Handbook of Statistics*, **24** :303-329.
- Svetnik,V., Liaw,A., Tong,C., Culberson,J.C., Sheridan, R.P., Feuston, B.P., 2003. Randomforest: a classification and regression tool for compound classification and QSAR modeling. *J. Chem. Inform. Comput*, **43**(6):1947-58.



- Şahin, M.G., Yıldırım, Y., 2016. PISA 2012 Türkiye örnekleminde matematiksel davranış ve matematik okuryazarlığını etkileyen değişkenlerin çok gruplu hibrit modelleme ile incelenmesi. *Eğitim ve Bilim Dergisi* **41** (187): 181-198
- Şentürk, B., 2010. *İlköğretim Beşinci Sınıf Öğrencilerinin Genel Başarıları, Matematik Başarıları, Matematik Dersine Yönelik Tutumları Ve Matematik Kaygıları Arasındaki İlişki* (yüksek lisans tezi, basılmamış). AKÜ, Sosyal Bilimler Enstitüsü, Afyon.
- Tan, P., Steinbach, M., Kumar, V., 2006. Introduction to Data. Pearson Addison-Wesley Publisher, Boston. 165.  
<https://www-users.cs.umn.edu/~kumar001/dmbook/sol.pdf> Erişim tarihi: 18.05.2018.
- Tektaş, A., Karataş, A., 2004. Yapay sinir ağları ve finans alanına uygulanması: Hisse senedi fiyat tahminlemesi. *Atatürk Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, **18** (3-4) : 397-421.
- Tepehan, T., 2011. *Türk Öğrencilerinin PISA Başarılarının Yordanmasında Yapay Sinir Ağı ve Lojistik Regresyon Modeli Performanslarının Karşılaştırılması* (doktora tezi, basılmamış). HÜ, Sosyal Bilimler Enstitüsü, Ankara.
- Thomas, E.H., Galambos, N., 2004. What satisfies students? Mining student-opinion data with regression and decision tree analysis. *Research in Higher Education*, **45**(3):251-269.
- Toprak, E., 2017. *Yapay Sinir Ağı, Karar Ağaçları Ve Ayırma Analizi Yöntemleri İle Pisa 2012 Matematik Başarılarının Sınıflandırılma Performanslarının Karşılaştırılması* (doktora tezi, basılmamış). HÜ, Eğitim Bilimleri Enstitüsü, Ankara.
- Türe, M., Tokatlı, F., Kurt, İ., 2008. 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** (2009) 2017–2026.
- Türkan, A., Üner S.S., Alcı, B., 2015. 2012 PISA Matematik testi puanlarının bazı değişkenler açısından incelenmesi. *Ege Eğitim Dergisi*, **16** (2): 358-372.
- Ulusoy, T., 2010. İMKB endeks öngörüsü için ileri beslemeli ağ mimarisine sahip yapay sinir ağı modellemesi. *International Journal of Economic and Administrative Studies*, **3** (5) :21-40.
- Uysal E., Yenilmez K., 2011. Sekizinci sınıf öğrencilerinin matematik okuryazarlığı düzeyi. *Eskişehir Osmangazi Üniversitesi Sosyal Bilimler Dergisi*, **12** (2), 1-15.
- Ünal Çoban, G., Ergin, Ö., 2008. İlköğretim öğrencilerinin bilimsel bilgiye yönelik görüşlerini belirleme ölçeği. *İlköğretim Online*, **7** (3), 706-716.
- Üredi, I., Üredi, L., 2005. İlköğretim 8. Sınıf öğrencilerinin öz-düzenleme stratejileri ve motivasyonel inançlarının matematik başarısını yordama gücü. *Mersin Üniversitesi Eğitim Fakültesi Dergisi*, **1** (2): 250-260.
- Üstün, O., Yıldız, İ., 2009. Geri-yayımlı öğrenme algoritmasındaki öğrenme parametrelerinin genetik algoritma ile belirlenmesi. *SDU International Technologic Science* **1** (2): 61-73.
- Walker, A., 1980. Activity and Selectivity in the Field, Chap. 8. *Interactions Between Herbicides and the Soil* (Editor: R. J. Hance). Academic Press, London. 349.
- Wilamowski, B. M., Jaeger, R. C., 1996. Implementation of RBF type networks by MLP networks. *IEEE International Conference on Neural Networks.*, June 3-6, 1996, Washington DC. 1670-1675.

- Wu, Y., Wang,H., Zhang, B., Du, K.L., 2012. Using radial basis function networks for function approximation and classification. *International Scholarly Research Network ISRN Applied Mathematics*, 2012: 1-34.
- Wu, Y.J., 1998. *Exchange Rate Forecasting: an Application of Radial Basis Function Neural Networks* (doktora tezi, basılmamış). Iowa State University, North Zeeb Road, USA.
- Xie,T., Yu, H., Wilamowski, B., 2011. Comparison between traditional neural networks and radial basis function networks. *2011 IEEE International Symposium on Industrial Electronics*. 27-30 June 2011, Gdansk, Poland.
- Yavuz H. Ç, İlgün Dibek, M., Yalçın S., 2017. Türk ve Vietnamlı öğrencilerin PISA 2012 matematik okuryazarlığı ile dürtü ve güdülenme özellikleri arasındaki ilişkiler. *İlköğretim Online*, **16** (1) :178-196.
- Yeh, I.C., 1998. Modeling of strength of high-performance concrete using artificial neural networks. *Cement and Concrete Research*, **28** (12): 1797–1808. 1998.
- Yılmaz, E.T., 2006. *Uluslar Arası Öğrenci Başarı Değerlendirme Programı (PISA)'nda Türkiye'deki Öğrencilerin Matematik Başarılarını Etkileyen Faktörler* (yüksek lisans tezi, basılmamış). HÜ, Sosyal Bilimler Enstitüsü, Ankara.
- Yılmaz, H., 2014. *Random Forests Yönteminde Kayıp Veri Probleminin İncelenmesi ve Sağlık Alanında bir Uygulama* (yüksek lisans tezi, basılmamış). OGÜ, Sağlık Bilimleri Enstitüsü, Eskişehir.
- Yu H., Xie T., Paszezynski S., Wilamowski B. M., 2011. advantages of radial basis function networks for dynamics system design. *IEEE Transactions on Industrial Electronics*, **58**(12), 5438-5450.
- Yücel, Z., Koç, M., 2011. The relationship between the prediction level of elementary school students' math achievement by their math attitudes and gender. *Elementary Education Online*, **10** (1), 133-143.
- Zare, M., Pourghasemi, H.R., Vafakhah, M., Pradhan, B., 2013. Landslide susceptibility mapping at Vaz Watershed (Iran) using an Artificial Neural Network Model: a Comparison between Multilayer Perceptron (Mlp) and Radial Basic Function (Rbf) Algorithms. *Arab J Geosci*, **6**:2873–2888.
- Zayandehroodi, H., Mohamed, A., Shareef, H., Mohammadjafari, M., 2010. Performance comparison of mlp and rbf neural networks for fault location in distribution networks with dgs. *2010 IEEE International Conference on Power and Energy (PECon2010)*, Nov 29 - Dec 1, 2010, Kuala Lumpur, Malaysia
- Zhao, G., 2000. *A new perspective on classification*. (PhD thesis). Utah State University, Department of Mathematics and Statistics. Brigham City.
- Ziya, E., 2008. *Uluslararası öğrenci başarı değerlendirme programına (Pisa 2006) göre Türkiye'deki öğrencilerin matematik başarılarını etkileyen bazı faktörler* (yüksek lisans tezi, basılmamış). HÜ, Sosyal Bilimler Enstitüsü, Ankara.
- Zurada, Jacek M., 1992. *Introduction to Artificial Neural System*. West Publishing Company, St.

## ÖZ GEÇMİŞ

03.01.1973 tarihinde Batman'da doğdu. İlk, orta ve lise eğitimini Ankara'da tamamladı. Hacettepe Üniversitesi Sağlık Hizmetleri Meslek Yüksekokulu Tıbbi Dokümantasyon ve Sekreterlik Programını 1993 yılında bitirdi. Ardından aynı yıl; Anadolu Üniversitesi Fen Fakültesi İstatistik Bölümünü kazanarak, 1997 yılında bu bölümden mezun oldu. 1996-1997 yılları arasında, Anadolu Üniversitesi Eğitim Fakültesinde Formasyon Eğitimi aldı. 2009-2011 yılları arasında Fırat Üniversitesi Tıp Fakültesi Biyoistatistik Anabilim dalında yüksek lisans eğitimini tamamladı. 2015 yılında Van Yüzüncü Yıl Üniversitesi Fen Bilimleri Enstitüsü İstatistik Anabilim Dalı Doktora Programında öğrenim görmeye başladı. Halen, Batman Üniversitesi Sağlık Hizmetleri Meslek Yüksekokulu'nda Öğretim Görevlisi olarak çalışmaya devam etmektedir. Evli ve 3 çocuk annesidir.

T.C  
VAN YÜZÜNCÜ YIL ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ  
LİSANSÜSTÜ TEZ ORJİNALLİK RAPORU

Tarih: 22.05.2019

Tez Başlığı / Konusu:

PISA 2015 VERİLERİ KULLANILARAK ÖĞRENCİLERİN MATEMATİK BAŞARILARINI  
ETKİLEYEN FAKTÖRLERİN RANDOM FOREST, ÇOK KATMANLI ALGIRIYICI,  
ve RADYAL TABANLI YAPAY SINIR AĞLARININ TEMELİNİN TAHMİNİNE İZLENİMİ

Yukarıda başlığı/konusu belirlenen tez çalışmamın Kapak sayfası, Giriş, Ana bölümler ve Sonuç bölümlerinden oluşan toplam 134 sayfalık kısmına ilişkin, 22.05.2019 tarihinde şahsım/tez danışmanım tarafından intihal tespit programından aşağıda belirtilen filtreleme uygulanarak alınmış olan orijinallik raporuna göre, tezim benzerlik oranı % 10 (10) dir.

Uygulanan filtreler aşağıda verilmiştir:

- Kabul ve onay sayfası hariç,
- Teşekkür hariç,
- İçindekiler hariç,
- Simge ve kısaltmalar hariç,
- Gereç ve yöntemler hariç,
- Kaynakça hariç,
- Alıntılar hariç,
- Tezden çıkan yayınlar hariç,
- 7 kelimeden daha az örtüşme içeren metin kısımları hariç (Limit inatch size to 7 words)

Van Yüzüncü Yıl Üniversitesi Lisansüstü Tez Orijinallik Raporu Alınması ve Kullanılmasına İlişkin Yönergeyi inceledim ve bu yönergede belirtilen azami benzerlik oranlarına göre tez 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 bilgilerinize arz ederim.

22.05.2019  
Tarih ve İmza

Adı Soyadı: Ötlen Bezek GÜRE

Öğrenci No: .....

Anabilim Dalı: İstatistik

Programı: .....

Statüsü: Y. Lisans  Doktora

DANIŞMAN ONAYI  
UYGUNDUR

Prof. Dr. Feri İrdogan

(Unvan, Ad Soyad, İmza)

ENSTİTÜ ONAYI  
UYGUNDUR

Doç. Dr. Serhat KARACA  
Enstitü Müdür Yrd.  
(Unvan, Ad Soyad, İmza)  
Prof. Dr. Suat Gensör  
Enstitü Müdürü