

**T.C.
CELAL BAYAR ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**YÜKSEK LİSANS TEZİ
YAZILIM MÜHENDİSLİĞİ ANABİLİM DALI**

**MAKİNE ÖĞRENMESİ İLE LİSE ÖĞRENCİLERİNE
MESLEKİ ALAN SEÇİM REHBERİ**

Esat Fazlullah ÇELİK

**Danışman
Dr. Öğr. Üyesi Yusuf ÖZÇEVİK**



MANİSA-2022

**Esat Fazlullah
ÇELİK**

**MAKİNE ÖĞRENMESİ İLE LİSE ÖĞRENCİLERİNE
MESLEKİ ALAN SEÇİM REHBERİ**

2022

TEZ ONAYI

Esat Fazlullah ÇELİK tarafından hazırlanan "**Makine Öğrenmesi ile Lise Öğrencilerine Mesleki Alan Seçim Rehberi**" adlı tez çalışması 12/06/2022 tarihinde aşağıdaki jüri üyeleri önünde Manisa Celal Bayar Üniversitesi Fen Bilimleri Enstitüsü **Yazılım Mühendisliği Anabilim Dalı**'nda **YÜKSEK LİSANS TEZİ** olarak savunulmuş ve **oyçokluğu / oybirliği** ile başarılı olarak kabul edilmiştir.

Danışman **Dr. Öğr. Üyesi Yusuf ÖZÇEVİK**
Manisa Celal Bayar Üniversitesi

Jüri Üyesi **Dr. Öğr. Üyesi Fatih YÜCALAR**
Manisa Celal Bayar Üniversitesi

Jüri Üyesi **Doç. Dr. Aytuğ ONAN**
İzmir Kâtip Çelebi Üniversitesi

TAAHHÜTNAME

Bu tezin Celal Bayar Üniversitesi Hasan Ferdi Turgutlu Teknoloji Fakültesi Yazılım Mühendisliği Bölümü'nde, akademik ve etik kurallara uygun olarak yazıldığını ve kullanılan tüm literatür bilgilerinin referans gösterilerek tezde yer aldığını beyan ederim.

Esat Fazlullah ÇELİK



İÇİNDEKİLER

İÇİNDEKİLER	I
SİMGELER VE KISALTMALAR DİZİNİ	III
ŞEKİLLER DİZİNİ.....	IV
TABLO DİZİNİ	V
TEŞEKKÜR.....	VI
ÖZET.....	VII
ABSTRACT.....	VIII
1. GİRİŞ	1
2. GENEL BİLGİLER	3
2.1. Literatür Taraması	3
2.2. Tezin Amacı	7
3. DENEYSEL KISIM (MATERYAL VE YÖNTEMLER).....	9
3.1. Materyal.....	9
3.2. Yöntem	20
3.2.1. Veri Ön İşleme	20
3.2.1.1. Etiket Kodlayıcı	20
3.2.1.2. Dummy Değişkenleri.....	21
3.2.1.3. Ölçekleme	21
3.2.1.4. Boyut Azaltma	21
3.2.2. Makine Öğrenmesi	23
3.2.2.1. Rasgele Orman.....	23
3.2.2.2. K-En Yakın Komşu	25
3.2.2.3. Destek Vektör Makineleri.....	26
3.2.2.4. Gradyan Arttırma Makineleri	28
3.2.2.5. Aşırı Gradyan Arttırma	29
3.2.2.6. Hafif Gradyan Arttırma Makineleri	30
3.2.2.7. CatBoost.....	32
3.2.2.8. Yapay Sinir Ağları	33
3.2.2.9. Sınıflandırma ve Regresyon Ağaçları.....	36
3.2.2.10. Doğrusal Ayrım Analizi	36
3.2.2.11. Hiyerarşik Kümeleme.....	37
3.2.3. Başarı Ölçümü.....	39
3.2.3.1. Hata Matrisi	39
3.2.3.2. Doğruluk	40
3.2.3.3. Kesinlik.....	40
3.2.3.4. Duyarlılık.....	41
3.2.3.5. F1 Skoru.....	41
3.2.3.6. Cohen Kappa Skoru	41
4. ARAŞTIRMA BULGULARI VE TARTIŞMA	43
4.1. Veri Toplama ve Ön işleme.....	43
4.2. Makine Öğrenmesi Modellerinde Parametreler ve Skorlar.....	49
4.2.1. Rasgele Orman Parametreleri ve Skorları.....	50
4.2.2. K En Yakın Komşu Parametreleri ve Skorları	51
4.2.3. Destek Vektör Makineleri Parametreleri ve Skorları.....	52
4.2.4. Gradyan Arttırma Makineleri Parametreleri ve Skorları	53
4.2.5. Aşırı Arttırma Parametreleri ve Skorları.....	54
4.2.6. Hafif Gradyan Arttırma Makineleri Parametreleri ve Skorları	56

4.2.7.	Kategorik Arttırma Parametreleri ve Skorları.....	57
4.2.8.	Yapay Sinir Ağları Parametreleri ve Skorları	58
4.2.9.	Sınıflandırma ve Regresyon Ağaçları Parametreleri ve Skorları	59
4.2.10.	Doğrusal Ayrım Analizi Parametreleri ve Skorları	60
4.3.	Hiyerarşik Kümeleme ve Dendrogram Yapıları.....	61
5.	SONUÇ VE ÖNERİLER	62
	KAYNAKLAR	69
	EKLER.....	74
	EK-A. Tüm Parametre Değerleri ile Makine Öğrenmesi Modellerinin Sonuçları	74
	EK-B. Hiyerarşik Kümeleme ile Oluşan Dendrogramlar	116
	ÖZGEÇMİŞ	122



SİMGELER VE KISALTMALAR DİZİNİ

ANN	Artificial Neural Network (Yapay Sinir Ağları)
BFS	Breadth First Search(Önce Genişlik Araması)
CART	Classification and Regression Trees (Sınıflandırma ve Regresyon Ağaçları)
CB	Categorical Boosting (Kategorik Arttırma
DFS	Depth First Search (Önce Derinlik Araması)
DN	Doğru Negatif
DP	Doğru Pozitif
EFB	Exclusive Feature Bundling (Özel Öznitelik Paketleme)
GBM	Gradient Boosting Machines (Gradyan Arttırma Makineleri)
GOSS	Gradient Based One Side Sampling (Gradyan Tabanlı Tek Taraflı Örneklem)
GPU	Graphics Processing Unit (Grafik İşlem Birimi)
HC	Hierarchical Clustering (Hiyerarşik Kümeleme)
IDE	Integrated Development Environment (Entegre Geliştirme Ortamı)
KNN	K-Nearest Neighbor (K-En Yakın Komşu)
LDA	Linear Discriminant Analysis (Doğrusal Ayrım Analizi)
LGBM	Light Gradient Boosting Machines (Hafif Gradyan Arttırma Makineleri)
MEB	Millî Eğitim Bakanlığı
MLP	Multi Layer Perceptron (Çoklu Katman Algılayıcı)
PCA	Principal Component Analysis (Temel Bileşenler Analizi)
RF	Random Forest (Rasgele Orman)
ROC	Receiver Operating Characteristic (Alıcı İşletim Karakteristiği)
SMO	Sequential Minimal Optimization (Sıralı Minimum Optimizasyon)
SVM	Support Vector Machines (Destek Vektör Makineleri)
XGB	Extreme Gradient Boosting (Aşırı Gradyan Arttırma)
YN	Yanlış Negatif
YP	Yanlış Pozitif

ŞEKİLLER DİZİNİ

Şekil 2.1. Literatür Taraması Akış Diyagramı.....	3
Şekil 3.1. İş Akış Diyagramı.....	9
Şekil 3.2. Bağımlı Değişkenin Gruplandırılması.....	11
Şekil 3.3. Cinsiyet Dağılımı	12
Şekil 3.4. Alan Dağılımı	12
Şekil 3.5. Giriş Yılı Dağılımı	13
Şekil 3.6. Ek Puan Hakkı Dağılımı	14
Şekil 3.7. Dokuzuncu Sınıf Derslerinin Yıllara Göre Karşılaştırılması.....	14
Şekil 3.8. Dokuzuncu Sınıf Derslerinin Boxplot Yardımı ile Değerlendirilmesi.....	15
Şekil 3.9. Onuncu Sınıf Derslerinin Yıllara Göre Karşılaştırılması.....	15
Şekil 3.10. Onuncu Sınıf Derslerinin Boxplot Yardımı ile Değerlendirilmesi.....	16
Şekil 3.11 On birinci Sınıf Derslerinin Yıllara Göre Karşılaştırılması.....	16
Şekil 3.12. On birinci Sınıf Derslerinin Boxplot Yardımı ile Değerlendirilmesi.....	17
Şekil 3.13 On ikinci Sınıf Derslerinin Yıllara Göre Karşılaştırılması.....	17
Şekil 3.14. On ikinci Sınıf Derslerinin Boxplot Yardımı ile Değerlendirilmesi.....	18
Şekil 3.15. Bölüm Değişkeni Sınıfları	18
Şekil 3.16. Grup 1 Değişkeni Sınıfları.....	19
Şekil 3.17. Grup 2 Değişkeni Sınıfları.....	19
Şekil 3.18. Grup 3 Değişkeni Sınıfları.....	19
Şekil 3.19. Yöntem Diyagramı	20
Şekil 3.20. Boyut Azaltma Metotları	22
Şekil 3.21. Algoritma Çalışma mantığı.....	23
Şekil 3.22. Rasgele Orman Çalışma Mantığı.....	24
Şekil 3.23. KNN Örneği	25
Şekil 3.24. SVM' de hiper düzlem çizimi [28]	27
Şekil 3.25. GBM Çalışma Mantığı [29]	29
Şekil 3.26. Seviye Odaklı (Level-wise) Büyüme	30
Şekil 3.27. Düğüm Odaklı (Leaf-wise) Büyüme	30
Şekil 3.28. Breadth First Search (BFS) Metodu	31
Şekil 3.29. Depth First Search (DFS) Metodu	31
Şekil 3.30. Simetrik Olmayan ve Simetrik Olan Ağaç Yapıları	33
Şekil 3.31. İnsan Beynindeki Nöron Yapısı [37]	34
Şekil 3.32. ANN Yapısı	34
Şekil 3.33. ANN Katman Yapısı	35
Şekil 3.34. Hiyerarşik Kümelemede Toplayıcı Yöntemi Örneği	38
Şekil 3.35. Dendrogram Yapısı Örneği.....	38
Şekil 3.36. Hata Matrisi	40
Şekil 4.1. Ayrıntılı İş Akışı.....	43
Şekil 0.1. Complete Yöntemi ile Oluşturulmuş Dendrogram Yapısı.....	116
Şekil 0.2. Average Yöntemi ile Oluşturulmuş Dendrogram Yapısı	117
Şekil 0.3. Single Yöntemi ile Oluşturulmuş Dendrogram Yapısı	118
Şekil 0.4. Median Yöntemi ile Oluşturulmuş Dendrogram Yapısı	119
Şekil 0.5. Ward Yöntemi ile Oluşturulmuş Dendrogram Yapısı.....	120
Şekil 0.6. Centroid Yöntemi ile Oluşturulmuş Dendrogram Yapısı	121

TABLO DİZİNİ

Tablo 4.1. Veri Setindeki Değişken Yapıları.....	45
Tablo 4.2. En Başarılı RF Sonuçları ve Parametreleri	50
Tablo 4.3. En Başarılı KNN Sonuçları ve Parametreleri	51
Tablo 4.4. En Başarılı SVM Sonuçları ve Parametreleri	52
Tablo 4.5. En Başarılı GBM Sonuçları ve Parametreleri	53
Tablo 4.6. En Başarılı XGBoost Sonuçları ve Parametreleri	55
Tablo 4.7. En Başarılı LGBM Sonuçları ve Parametreleri.....	56
Tablo 4.8. En Başarılı CatBoost Sonuçları ve Parametreleri.....	57
Tablo 4.9. En Başarılı ANN Sonuçları ve Parametreleri	58
Tablo 4.10. En Başarılı CART Sonuçları ve Parametreleri.....	60
Tablo 4.11. En Başarılı LDA Sonuçları ve Parametreleri.....	61
Tablo 5.1. Bölüm Etiketleri ile En İyi Tahmin Başarıları	62
Tablo 5.2. Grup 1 Etiketleri ile En İyi Tahmin Başarıları	63
Tablo 5.3. Grup 2 Etiketleri ile En İyi Tahmin Başarıları	64
Tablo 5.4. Grup 3 Etiketleri ile En İyi Tahmin Başarıları	65
Tablo 0.1. RF En Başarılı 50 Model.....	74
Tablo 0.2. KNN En Başarılı 50 Model.....	78
Tablo 0.3. SVM En Başarılı 50 Model	83
Tablo 0.4. GBM En Başarılı 50 Model.....	88
Tablo 0.5. XGBoost En Başarılı 50 Model	92
Tablo 0.6. LGBM En Başarılı 50 Model	97
Tablo 0.7. Catboost En Başarılı 50 Model	102
Tablo 0.8. ANN En Başarılı 50 Model	106
Tablo 0.9. CART En Başarılı 50 Model	111

TEŐEKKÖR

Yüksek lisans tezimin başından sonuna kadar her aşamasında bana destek olan, bilgi birikimi ve tecrübesi ile yol gösteren danışman hocam Sayın Dr. Öğr. Üyesi Yusuf ÖZÇEVİK'e sonsuz teşekkürlerimi sunarım.

Tezimin gerçekleşmesi için gerekli veri setini topladığım Şehzadeler Gediz Anadolu Lisesi yönetim kadrosuna bana sağladığı imkanlardan ve destekten ötürü teşekkürü borç bilirim.

Esat Fazlullah ÇELİK
Manisa, 2022



ÖZET

Yüksek Lisans Tezi

Makine Öğrenmesi ile Lise Öğrencilerine Mesleki Alan Seçim Rehberi

Esat Fazlullah ÇELİK

Manisa Celal Bayar Üniversitesi
Fen Bilimleri Enstitüsü
Yazılım Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Yusuf ÖZÇEVİK

Yapay zekâ insanların beynini taklit ederek ve geri bildirimlere göre kendini sürekli yenileyerek geliştiren bir sistemdir. Bu sistem her geçen gün insan hayatında daha büyük bir yer edinmektedir. Bunun sebebi; yazılım içeren teknolojik araçlarda yapay zekâ sistemleri bulunduğu çevre ile iletişimin üst düzeye çıkması bu sayede de geri bildirimler alabilmesi, sonuç olarak da bu araçların işlevinin artmasıdır.

Makine öğrenmesi kavramı yapay zekânın bir uygulama alanıdır ve endüstri içerisinde kullanımı yaygındır. Makine öğrenmesinin kullanılabilmesi için gereken en önemli araç anlamlı bir veridir. Makine öğrenmesi yöntemleriyle, veri üzerinde ile insan gözünün yakalayamadığı ilişkiler ve sonuçlar çıkartılabilir. Buradan çıkan sonuçlar ile de ilgili problem alanı özelinde iyileştirmeler yapılabilir.

Eğitim kurumları verinin muazzam boyutlarda bulunduğu kurumlardır. Ancak ülkemizde bu veriler henüz pek kullanılmamaktadır. Bu tezin konusu bu sebeple eğitim alanında seçilmiştir. Makine öğrenmesi yardımıyla lise öğrencilerinin 4 sene boyunca derslerde aldıkları notlar ve bir takım başka bilgileri ile seçtikleri üniversite bölümleri arasında korelasyon olabileceği düşünülmüştür. Bu motivasyonla Millî Eğitim Bakanlığı'ndan gerekli izinler alınarak önceki senelerde mezun olmuş lise öğrencilerinin bilgisi toplanmıştır. Toplam 447 gözlem birimi oluşturulmuştur. Bu öğrencilerin seçtikleri toplam bölüm sayısı 43 olarak belirlenmiştir. Gözlem birimlerinin bağımlı değişkendeki sınıf sayısına oranı düşük olduğundan dolayı benzer bölümler birleştirilerek yeni bağımlı değişkenler oluşturulmuştur. Sonuç olarak veri seti üzerinde tekrarlanan deneyler için 43, 23, 9 ve 6 sınıf içeren etiketleme yaklaşımları ele alınmaktadır. Bununla birlikte veri seti üzerinde her bir etiket için 10 makine öğrenmesi algoritması test edilmektedir. İlk etiketleme yaklaşımında %43, 2. yaklaşımda %53, 4. yaklaşımda %75 başarı oranı ile XGBoost çok başarılı sonuçlar vermektedir. 3. etiketleme yaklaşımında ise en başarılı sonucu %65 ile KNN vermektedir.

Çalışmada elde edilen sonuçlara göre veri setindeki gözlem birimleri önemli ölçüde arttırılırsa bölümlerin gruplandırılarak yeni etiketler oluşturulmasına gerek kalmayacağı ve tahminlerdeki başarıların önemli ölçüde artacağı ortaya konmaktadır.

Anahtar Kelimeler: Yapay zekâ, Makine öğrenmesi, Eğitim, XGBoost, KNN

2022, 122 sayfa

ABSTRACT

M.Sc. Thesis

Machine Learning-based Profession Field Selection Guide for High School Students

Esat Fazlullah ÇELİK

**Celal Bayar University
Graduate School of Applied and Natural Sciences
Department of Software Engineering**

Supervisor: Asst. Prof. Dr. Yusuf ÖZÇEVİK

Artificial intelligence is a system that develops by imitating people's brain and constantly renewing itself thanks to the feedback mechanism. This system is gaining a bigger place in human life day by day. The reason can be stated as when there are artificial intelligence systems in technological tools that contains software, communication with the environment is maximized with receiving feedback, and as a result, the functionality of these tools is increased.

The concept of machine learning is an application area of artificial intelligence and is widely used in the industry. The most important tool that required to use machine learning is meaningful data. With this data, relationships, and results that the human eye cannot catch can be captured. With the results obtained from here, improvements can be made for the problem domain.

Educational institutions are institutions where data is available in enormous sizes. However, these data are not used much in our country yet. For this reason, the subject of this thesis was chosen in the field of education. With the help of machine learning, it has been thought that there may be a correlation between the grades that high school students have taken in courses for 4 years with some other information and the university departments they have chosen. With this motivation, the necessary permissions were obtained from the Ministry of National Education and the information of high school students who graduated in previous years were collected. A total of 447 observation units were established. The total number of departments chosen by these students was determined as 43. Since the ratio of observation units to the number of classes in the dependent variable is low, new dependent variables were created by combining similar departments. As a result, there are 4 different labeling strategies containing 43, 23, 9 and 6 classes for different experiments conducted in the study. Moreover, 10 machine learning algorithms were tested for each labeling strategy on the data set. XGBoost gives very successful results with a success rate of 43% in the first labeling strategy, 53% in the second labeling strategy, and 75% in the fourth labeling strategy. In the third labeling strategy, KNN gives the most successful result with 65%.

In summary, it can be inferred from the study that if the observation units in the data set are increased significantly, there will be no need to create new labels by grouping the departments and the success in the predictions will increase significantly.

Keywords: Artificial intelligence, Machine learning, Education, XGBoost, KNN

2021, 122 pages



1. GİRİŞ

Yapay zekâ, birtakım sonuçlara ulaşmak için insan beynini taklit eden ve sonucunda edindiği deneyimler sayesinde kendisini yineleyen ve geliştiren sistemlerdir. Günümüz endüstrisinde bu sistemlerin kullanılmaya başlandığı birçok alan mevcuttur [1]. Bu alanlara askeri, medikal, üretim, lojistik, ulaşım, haberleşme, kontrol sistemleri, akıllı bina teknolojileri, otomotiv ve güvenlik sistemleri örnek olarak verilebilir [2]. Günlük hayatta kullanımına ise sesli yapay asistanlar, dil çevirileri, öneri sistemleri, navigasyon ve e-ticaret hizmetleri örnek gösterilebilir. Ülkemizde de kullanım alanları mevcut olduğu gibi bu alanların artırılması hedeflenmektedir. Bu hedef çerçevesinde Türkiye'nin ilk Ulusal Yapay Zekâ Stratejisi Temmuz 2021'de resmi gazete yayımlanarak yürürlüğe girmiştir. 2021-2025 yıllarını kapsayan bu stratejide amaç yapay zekâ alanının gayri safi yurt içi hasılaya katkısının artırılması, bu alanda çalışan ve okuyan kalifiye insan açığının giderilmesidir. Bu amaçlar doğrultusunda Türkiye'nin uluslararası Yapay Zekâ endeksli sıralamalarda ilk 20 ülke arasına girmesi hedeflenmektedir [3].

Makine öğrenmesi yapay zekânın tam olarak bir alt dalı olmasa da birbirleriyle korelasyon halindedirler. Makine öğrenmesi ile yapılan işlemler bir nebze de olsa insan beyninin işleyişini taklit ederek akıllı sistemler oluşturulmasına yardımcı olduğu için yapay zekânın uygulamasıdır denebilir [4]. Böylelikle makine öğrenmesi yapay zekânın bir uygulama alanı olarak düşünülürse yüzlerce alanda kullanımı her geçen gün artmaktadır. Eğitim alanında ise endüstride kullanıldığı kadar yaygın şekilde kullanılmasa da bununla ilgili çalışmalar yapılmaktadır.

İnsan beyni bir noktaya kadar sayılara ve harflere bakarak bundan anlamlı sonuçlar çıkartabilir. Ancak yan yana veya alt alta gibi sırasal düzende yer alan ver miktarı arttıkça insan beyni yetersiz kalmaktadır. Tam da bu noktada makine öğrenmesi devreye girmektedir. Esasen makine öğrenmesinin temel amacı elde bulunan ve çıplak gözle anlamlandırılmayan verileri bilgisayar yardımı ile anlamlı bir şekilde kullanıp yaşanan bir soruna çözüm bulmak veya bir konuda iyileştirmeler yapmaktır [5]. İki temel dala ayrılan makine öğrenmesinde ilk dal olan denetimli öğrenme, eldeki veride bulunan girdi ve çıktılara bakarak bir model oluşturmakta ve hali hazırda bulunan veya yeni elde edilen diğer girdilere bakarak çıktıların tahmin edilmesidir. İkinci makine öğrenmesi dalı ise denetimsiz öğrenmedir. Bu makine

öğrenmesi biçiminde ise çıktı bulunmamaktadır ve girdiler farklı teknikler ile bir araya getirilerek gruplandırılmaktadır. Sonuç olarak; Makine Öğrenmesinin kullanılabilmesi için gereken en önemli araç kullanılabilecek ve anlamlandırılabilir bir veri setidir. Eğitim hususunda ise veri seti bulunabilirliği çok yüksektir ve bu sayede iki Makine Öğrenmesi dalı verimli bir şekilde kullanılabilir.


Geçmişten günümüze eğitim sürekli olarak değişmekte ve kendini geliştirmektedir. Eskiden öğretmenler dersi tahtada anlatırken öğrenciler ise önlerindeki kitaba ve deftere gömülmüş bir şekilde dinlerdi. Ancak gelişen teknoloji ile beraber eğitim içerisine birçok araç girdi. Bu araçlar eğitimi öğretmen ve öğrenci arasındaki tek yönlü bir süreçten kurtarmakla kalmayıp aynı zamanda elde edilen veriler sayesinde eğitim, makine öğrenmesi içerisinde değerlendirilebilecek ve geliştirmeler yapılabilecek hale gelmiştir [6].

Eğitimde Makine Öğrenmesinin kullanılmaya başlandığı alanlar mevcut olmakla beraber bu alanların neredeyse tamamı özel şirketler içerisinde kullanılmaktadır. Bu kullanımlara örnek olarak mobil ve web tabanlı birçok eğitim platformu gösterilebilir [7]. 2024 yılında dünya genelinde öğrenme araçlarının %47'sinin yapay zekâ destekli olacağı öngörülmüştür [8]. Ülkemizde ise Millî Eğitim Bakanlığının 2023 hedefleri doğrultusunda yapay zekânın dolayısıyla da Makine Öğrenmesinin eğitim sisteminin kalitesini arttırmak amacıyla kullanılması amaçlanmaktadır [9].

Özetle makine öğrenmesi teknolojisi ile eğitimin birçok noktasında geliştirmeler yapıp genel eğitim kalitesi yükseltilebilir. Geliştirmelerin yapılabileceği noktaları açmak gerekirse; öğrencilerin verileri ile öğretmenlerin performansı geliştirilebilir, öğrencilerin performansları tahmin edilebilir, öğrenciler test edilebilir ve notları adilce ve önyargı olmadan verilebilir, kişiye özel öğrenmeler geliştirilebilir, öğrencilerin ve öğretmenlerin ihtiyaç uygunluklarına göre birbirleri ile en verimli şekilde gruplandırmalar yapılabilir [10]. Sonuç olarak eğitim, Makine Öğrenmesinin rahatça uygulanabileceği bir alandır ve yapıldığında elde edilen kazanımlar sayesinde diğer alanların da kalitesi yükselecek ve refah seviyesi artacaktır.

2. GENEL BİLGİLER

Bu kısımda ilk olarak eğitim ile ilgili literatür taraması Şekil 2.1’de gösterildiği haliyle verilecektir. Sonrasında eğitimde yapay zekâya değinilip, eğitimde makine öğrenmesi konularına önce genel bir açıdan daha sonra da hazırlanan teze benzerlikleri açısından yaklaşılabacaktır. Son olarak tezin amacı ve de motivasyonu belirtilecektir.



Şekil 2.1. Literatür Taraması Akış Diyagramı

2.1. Literatür Taraması

Eğitim sisteminin 4 ana sac ayağı bulunmaktadır. Teknoloji her ne kadar gelişse de eğitim bu ayaklar sayesinde verilmektedir. Bu ayaklar; öğrenci, öğretmen, eğitimin verildiği alan ve de eğitimin müfredatıdır. Bu sac ayakları birbirleri ile olan ilişkilerini güçlendirdikçe eğitimin genel kalitesi de artış göstermektedir. Kaliteyi arttırmada en etkili ayağın ise öğretmen olduğu düşünülmektedir [11]. Öğretmenlerin ise yararlanabileceği, dolayısıyla eğitim kalitesinin artacağı, bilgisayarlar aracılığıyla kullanabilecekleri yöntemler mevcuttur. Ancak bu yöntemler içerisinde yapay zekânın dolayısıyla makine öğrenmesinin aktif bir şekilde kullanıldığı söylenemez. Bu yöntemler genelde kolay bir şekilde veri ulaşımını sağlamak amacıyla kullanılır [12]. Eğitimin kalitesini daha üst noktalara çıkarmak için yapay zekâ ve makine öğrenmesi de bu yöntemlerin içine aktif olarak katılmalıdır.

Giriş kısmında da bahsedildiği gibi makine öğrenmesi aracılığıyla eğitimin birçok farklı alanında geliştirmeler yapılabilir. Bu alanlar gruplandırılarak makine öğrenmesinin eğitime entegre edilmesi 4 ana başlık altında incelenebilir. Bu başlıklar; öğrencilerin performanslarının tahmini, öğrencileri test etme ve değerlendirme, öğrencilerin okul bırakma oranlarını düşürme ve son olarak öğretmenlere ve diğer personellere yardımcı olma şeklinde sıralanabilir. İlk başlık makine öğrenmesine çok uygun bir başlık olarak görülmektedir. Bu alanda makine öğrenmesi kullanılarak her bir öğrencinin öğrenme kapasiteleri ve performansları takip edilebilir. Ayrıca zayıf

taraflar bulunarak bunlar geliştirilmeye çalışılabilir. İkinci başlık iki parçada ele alınacak olunursa, öğrenciler test edilerek her bir öğrencinin öğrenmede zorluk yaşadığı ve yaşamadığı yerler tespit edilerek özelleştirilmiş eğitim öğrencilere sunulabilir. Her bir öğrencinin öğrenme tarzını bilmek öğretmene büyük avantaj sağlayacaktır. Öğrencileri değerlendirme alt başlığında ise amaç, insan ön yargısını ortadan kaldırmaktır. Üçüncü başlık olan okul bırakma oranlarını düşürmede amaç, eğitimi bırakma riski taşıyan öğrencilerin erkenden tespit edilmesi ve hızlı müdahaleye zemin hazırlanmasıdır. Bırakma oranları yükseldikçe okulların hem başarı hem de finansal metrikleri artmış olacaktır. Son ana başlık olan öğretim personeline yardımcı olmada amaç eğitimde öğretmenin ve müdüriyetin elini rahatlatmaktır. Böylelikle eğitmenler gereksiz iş yükünden kurtulup eğitimin kalitesinin yükselişine daha çok katkı sağlayacaklardır. Bu 4 başlıkta makine öğrenmesi eğitimde uygulandığı takdirde eğitimin genel yapısı değişecek ve kalitesi hiç olmadığı kadar yükselecektir [6].

2018 yılında yazılmış olan bir makalede makine öğrenmesi kullanılarak öğrencilerin bir derste ne kadar başarılı olacağını tahmin etmek ve bu tahmin sonucunda başarısız olmaya yakın öğrencileri takibe almak amaç olarak belirtilmektedir. Makine öğrenmesini kullanabilmek için gereken anlamlı veri seti olarak ise, tahmin edilecek derse içerik olarak yakın olan ve o dersin ön şartı olarak alınması gereken derslerin notları kullanılmaktadır. Makalenin teorik hedefi de amacına uygun olarak çıkan sonuca göre başarısız olma ihtimali yüksek gözükten öğrencilere özel program setleri ve ders notlarının temin edilmesi olarak belirlenmiştir. Materyal olarak kullanılan veri seti 200 “C++” dersi alan öğrenciden oluşmaktadır. Her bir öğrencinin önceki dönemde “C++” dersine benzeyen ve ön şartlı olan derslerinin dönem sonu notları ve yeni döneme kadarki genel not ortalamaları alınmaktadır. Metot olarak ise bir ders dönemi boyunca öğrenciler 3 kez değerlendirmeye sokulmakta, makine öğrenmesi ile yapılan ilk değerlendirmede çıkan sonuca göre riskli bölgedeki öğrenciler ile özel ilgilenilmekte ve bir süre sonra öğrencilerin makine öğrenmesi ile gerçekleştirilen 2. değerlendirmelerinde iki değerlendirme arasında yapılan sınav da modele katılmaktadır. 3. yani son değerlendirmede de 2 ile 3 arasında yapılan sınav modele katılmakta ve öğrencilerin makine öğrenmesi yardımıyla 3 aşamalı başarıları değerlendirilmektedir. Başarı kıstasları 3 kat şeklinde “C1-ortalama üstü”, “C2-ortalama”, “C3-ortalama altı” olarak belirlenmiştir. Bu kıstaslar belirlenirken denetimsiz bir makine öğrenmesi modeli olan

K-Means Kümeleme yönteminden faydalanılmaktadır. Bu yöntemle öğrencileri bağımlı “y” değişkenine gerek olmadan gruplandırarak grafikler üzerinden okumalar yapılmaktadır. Sonuç olarak 1. değerlendirme sonucunda oluşturulan grafik ile 2. değerlendirme sonucu oluşturulan grafikte değişimler meydana gelmekte ve ilk değerlendirmede C3 kümesinde yer alan öğrencilerin %42’si bir sonraki değerlendirmede C2’ye geçmektedir. Son değerlendirme sonucu oluşan grafik ile bir önceki değerlendirme sonucundaki grafiğe bakıldığında ise C3 kümesinde kalan öğrencilerin %18’inin daha C2’ye geçtiği gözlemlenebilmektedir. Son olarak final değerlendirmesinde, öğrenciler ile hiçbir şekilde özel olarak ilgilenilmeden yapılan 1. değerlendirme sonucundaki grafikte C3 kümesinde yer alan öğrencilerin %32’sinin, bu öğrenciler ile özel ilgilenildikten sonra yapılan son değerlendirme grafiğinde C2 ve C1 kümelerine geçtikleri görülmektedir. Bu sonuçlar ile makale sonlandırılmaktadır [13].

2021 yılında yazılmış bir makalede bir önceki makaledeki gibi makine öğrenmesini kullanılarak öğrencilerin bir dersten başarılı olup olmayacağı ölçülmektedir. Ancak önceki makaleden farklı olarak veri setinde “y” değişkeni olarak da adlandırılan etiketler mevcut olduğundan denetimli makine öğrenmesi modelleri üzerinden gidilmektedir. Öğrencinin başarısının tespit edileceği Bilgisayar Bilimi dersinin önceki dönemdeki ön şartlı dersi ve de ders İngilizce olarak işlendiği için onunla ilişkili görülen İngilizce dersi de “x” değişkenleri yani bağımsız değişkenler olarak alınmaktadır. Veri setinde yer alan diğer bağımsız değişkenler ise öğrencilerin bir takım kişisel bilgileridir. Cinsiyet, bölüm, çalışmak için internet kullanma sıklığı, aile üyelerinin eğitimi, işinin olup olmaması ve evli olup olmaması gibi bilgiler veri setinde yer almaktadır. Bunun sonucunda 2. dönemdeki Bilgisayar Bilimleri dersinden 0-60 arasında alanlara “Zayıf” etiketi, 60-100 arasında “İyi” etiketi vererek temel olarak sınıflandırma modellerine uyacak 161 öğrencinin bilgilerinden bir veri seti oluşturulmuştur. Sonuçları değerlendirmek için kesinlik, duyarlılık, ikisinin harmonik ortalaması olan f-ölçümü, doğruluk, hata ve Receiver Operating Characteristic (ROC) indeksi kullanılmaktadır. Yapay Sinir Ağları, Karar Ağaçları, Lineer Regresyon ve Naive Bayes algoritmaları veri seti üzerinde denenmiş ve en iyi ROC indeksi sonucunu 0.807 ile ve en iyi doğruluğu %77.04 ile Yapay Sinir Ağları vermektedir. Bu sonuçlar ile makale sonlanmaktadır [14].

2018 yılında yazılmış bir başka makalede amaç yine öğrenciler üzerinde performans tahmini yapmak olarak kararlaştırılmıştır. Diğer makalelerden farklı olarak bağımlı değişken yüksek, orta ve düşük olmak üzere 3 sınıf şeklinde belirlenmektedir. Yani normal sınıflandırma olan ikili sınıflandırma yerine multi sınıflandırma kullanılmaktadır. Ayrıca veri setinde bağımsız değişkenler olarak el kaldırma, kaynakları ziyaret etme ve duyuru görüntüleme gibi farklı değişkenler kullanılmaktadır. Random Forest ve Chi-squared’ den faydalanılarak 43 “x” değişkeni ağırlık ve önem sıralamalarına göre sıralanmaktadır. Sonrasında hem modele en çok etki eden 3 değişken ile hem de bütün değişkenler ile makine öğrenmesi modelleri oluşturulmaktadır. Algoritma olarak Yapay Sinir Ağları, Karar Ağaçları, Rasgele Orman, MLP Sınıflandırması, Destek Vektör Makineleri, Gaussian Bayes ve K-En Yakın Komşu kullanılmaktadır. Bütün değişkenlerin kullanılması sonucunda %95 başarı oranı ile, 3 değişkene indirilmesi sonucunda ise %85 başarı oranı ile en yüksek sonucu Yapay Sinir Ağlarının verdiği tespit edilmiştir. 3 değişken sonucunu daha düşük olmasına rağmen korunmasının sebebi 3 boyutlu grafikler yardımı ile anlatımı kolaylaştırmak olarak belirtilmiş ve makale sonlandırılmıştır [15].

2021 yılında yazılmış bu makalede amaç, lise öğrencilerinin final notlarını tahmin ederek üniversitelerin ilk senesinde bırakma veya dondurma riskini azaltmak olarak belirtilmektedir. Veri seti 395 lise öğrencisinin bilgilerinden oluşturulmaktadır. Veri setinde G3 adı verilen son sene ortalamasını makine öğrenmesi yardımıyla tahmin edebilmek için 3 sene süren lise eğitim sistemindeki ilk ve ikinci yılların ortalaması alınmaktadır. Ayrıca yine çalışma süresi, yaşı, ailenin eğitim seviyesi gibi birçok kişisel bilgi de veri setinde bağımsız değişken olarak bulunmaktadır. Makine öğrenmesine geçilmeden önce bağımsız değişkenlerin ilişki ısı haritası çıkartılmış ve incelenmiştir. Doğal olarak ilk 2 senedeki notlar son senedeki notlar ile büyük ölçüde pozitif yönde korelasyon sağlarken, çalışma süresinin ilginç bir şekilde negatif korelasyon sağladığı saptanmıştır. Ardından veri seti %30 test seti olarak bölünmüş ve üstünde sadece Lineer Regresyon algoritması denenmiştir. Ortalama Mutlak Hata 1.282333 bulunmuş, bu oran başarılı kabul edilmiş ve makale sonlandırılmıştır [16].

2020’ de yazılmış bu makalede ise amaç liseye geçişte öğrencilere alan rehberi görevi görme amacı taşıyarak yazılmıştır. Türkiye’ de lisenin sonraki senelerinde seçilen sayısal, eşit ağırlık ve sözel alanları makalenin yazıldığı ülke olan Bangladeş’te

liseye geiřte verildiđi iin byle bir ama belirlenmiřtir. Bu alanların isimleri ise Bangladeř'te bilim, iř alıřmaları ve beřer bilimler olarak kabul gemektedir. Trkiye'deki duruma benzer řekilde orada da ebeveynler đrencinin yeteneđine ok bakmaksızın bilim grubunu tercih etmeye yatkın olmaktadırlar. Ve de đrenciler yař olarak kk oldukları iin bu karar alma mekanizması ebeveynlerin elinde kalmaktadır. Makalenin motivasyonu, bunu nleyip đrencilere en uygun alanları semede yardımcı olmak olarak belirtilmektedir. Bu motivasyon ile veri seti 360 đrenciden oluřmaktadır. Bađımlı deđiřken olarak bakılacak alan deđiřkeninde %44'n İř alıřmaları, %40'ını Bilim ve %16'sını Beřer Bilimler řeklinde yer almaktadır. Bađımsız deđiřkenler ise 12 soruluk bir anket zerinden oluřmaktadır. Liseye gemeden nceki devamlılıkları, hobileri ve đrencinin tercih ettiđi alan gibi sorular da ankette bulunmaktadır. Veri seti %70'e %30 eđitim/test olarak blndkten sonra 3 makine đrenmesi modeline sokulmaktadır. Bunlar Rasgele Orman, Naive Bayes ve Sequential Minimal Optimization (SMO) adı verilen bir model olarak belirlenmiřtir. Trke karřılıđı Sıralı Minimum Optimizasyon olan SMO, gcn Destek Vektr Makinelerinden almakta ancak ikinci derece programlama yeteneđi sayesinde Destek Vektr Makinelerine gre 1000 kat daha hızlı iřlem yapabilmekte ve byk veri setlerinde hafızayı daha az kullanabilmektedir. Kullanılan 3 modelin sonuları dođruluk, hassaslık, kesinlik ve f1-skoru metrikleri zerinden incelenmektedir. En yksek metrik sonularını %84 ile Rasgele Orman vermekte ardından ise %82 ile Naive Bayes gelmektedir. Bu sonulardan sonra uzun sreli hedef olarak đrencilerin bu alanları seimini kolaylařtıracak bir uygulama geliřtirme belirlenmiřtir. Bu hedefle birlikte makale sonlandırılmıřtır [17].

2.2. Tezin Amacı


Bu tezin amacı, lise son sınıftaki đrencilerin onlara en uygun blmleri semelerine yardımcı olmaktır. Diđer bir ifadeyle, nceki lise mezunlarının ders notları ve yerleřtikleri niversite programlarının makine đrenmesi ile bilgisayar ortamında iřlenmesi ve sonucunda ortaya ıkan model ile řu an son senelerinde okuyan ve blm semede kararsız kalmıř lise đrencilerine en uygun blm semelerine bir nebze yardımcı olmaktır. Kendilerine uygun blmler seen đrenciler niversite hayatlarında daha bařarılı olacak ve kendi alanlarında aranan niteliklere sahip olarak iř dnyasına atılacaklardır. Daha geniř perspektiften bakmak gerekirse de bu ama dođrultusunda hem đrencilerin kendilerine en uygun blm semedeki

kararsızlıkları giderilecek olup, hem de eğitim sisteminde makine öğrenmesinin artırılmasına yönelik bir kapı aralanmış olacaktır. Böylece, daha önce makine öğrenmesinde hiç kullanılmamış olan bu veriler, makine öğrenmesi aracılığıyla kullanılarak ve işlenerek, sistemin gelişmesinde bir ön ayak olma görevi üstlenecektir. Sistemin gelişmesi ile de öğrencilere sağlanan eğitim kalitesinin ve gelecek nesillerin eğitim düzeyinin artması öngörülmektedir.



3. DENEYSEL KISIM (MATERYAL VE YÖNTEMLER)

Bu bölümde anlatılacak materyal ve yöntemler, Şekil 3.1'deki iş akışına göre ilerlemektedir.




Şekil 3.1. İş Akış Diyagramı

3.1. Materyal

Makine öğrenmesinde kullanılan en önemli materyal veri setinin bizzat kendisidir. Bu tezin amacı, öğrencilere mesleki alan seçiminde rehber olmak olduğu için veri seti de mesleki alanlarını geçmişte seçmiş ve genel olarak bu alanlarda başarılı olmuş mezunlardır. Bu sebeple Millî Eğitim Bakanlığı'ndan gerekli izinler alınarak mezun öğrencilerin gerekli bilgileri doküman incelenmesi yöntemi ile toplanmıştır. Elde edilen veri setinde bazı eski öğrencilerin notları alınmasına karşın üniversiteye ilk senede yerleşmedikleri için okulda kazandıkları bölümlerin bilgileri bulunmamaktadır. Üniversiteyi kazanan öğrenciler ile lise boyunca aldıkları ders notları birleştirildikten sonra açıkta kalan öğrenciler için okuldaki yetkili ile beraber kazandıkları bölümlere dair internette aramalar yapılmıştır. Bulunabilenler veri setine yerleştirilmiş, geri kalanlar ise veri eksikliği dolayısıyla veri setinden silinmiştir. Veri setinden ayrıca 6 sene boyunca toplam sadece 1 ve 2 kişinin kazandığı ve gruplandırma yapıldığında herhangi gruplardan birine yerleştirilemeyen birkaç öğrenci de aynı şekilde veri setinden çıkartılmıştır. Bunun sebebi, makine öğrenmesi için veri seti eğitim ve test olarak bölündüğünde oluşabilecek model bozukluklarının engellenmesidir. Son olarak modelde gereksiz yer kaplayabilecek önemsiz dersler de veri setinden çıkartılmıştır. Bu derslere Beden Eğitimi, Görsel Sanatlar/Müzik, Din


Kültürü, Sağlık Bilgisi dersleridir. Bu derslerdeki notların öğrencinin mesleki alan seçimine etki etmeyeceği düşünülmektedir. Ayrıca bu derslerde seneler boyunca not olarak 95'ten aşağı alan pek olmadığı görülmektedir. Böylelikle modelin yükü azaltılmaktadır. Bütün bu elle yapılan işlemler sonucunda nihai veri seti 447 öğrencinin bilgilerinden oluşmaktadır.

Veri setinde yer alan 447 öğrencinin 44 derse ait notları, alanları, liseye giriş yılları, ek puandan yararlanma durumları ve cinsiyetleri bağımsız değişken olarak yer almaktadır. Bağımlı değişken olarak ise 4 farklı değişken kullanılmaktadır. Bunları ilki öğrencilerin üniversitede kazandıkları bölümlerdir. Ancak 447 öğrencide 43 bölüm olduğu için makine öğrenmesinin performansı düşünülerek bu bölümler 3 defa gruplandırılmış ve yeniden makine öğrenmesine sokulmuştur. Bu gruplandırmalar üniversite bölümlerinin birbirlerine yakınlıklarına göre yapılmıştır. Şekil 3.2'de görüldüğü üzere Bölüm “y” değişkeninde 43 sınıf varken, Grup 1’de 23, Grup 2’de 9, Grup 3’te ise 6 sınıf bulunmaktadır. 3. grubun daha ilerisine gidilememektedir çünkü bu 6 gruptan ilerisi sayısal ve eşit ağırlık alanlarına fazla yakınsamaktadır. Bu yakınsama ile veri sızıntısı gerçekleşmektedir. Veri sızıntısı problemi, veri setinde girdi olarak tanımlanan bazı değişkenlerin bağımlı değişken ile yüksek korelasyonun bulunması sorunudur. Test kümesinde çok yüksek tahmin başarıları elde edilmesini sebep olur. Ancak, çıkan bu yüksek sonuçlar makine öğrenmesi algoritmalarının bağımsız değişkenler arasında ilişkileri tespit etmesinden değil sızıntıyı gerçekleştiren değişkenlerin sonucuna doğrudan bakmasından kaynaklanır. Bu da elde edilen sonuçların gerçekçiliğini kaybetmesine neden olur. Bu veri seti üzerinde örnek vermek gerekirse, öğrencilerin sayısal mı sözel mi seçtikleri bulmak için makine öğrenmesine aynı değişkenler sokulursa veri sızıntısı gerçekleşmiş olmaktadır. Çünkü, 11 ve 12. sınıf derslerinde sayısal seçenlerin almadığı dolayısıyla 0 olarak veri setine girilmiş dersler bulunmaktadır. Eşit ağırlık için de aynısı geçerlidir. Bu şekilde veri seti makine öğrenmesi algoritmalarına sokulduğunda coğrafya ve tarih gibi derslerden 0 alanları otomatik olarak sayısal; fizik, kimya ve biyoloji derslerinden 0 alanları ise otomatik olarak eşit ağırlık olarak etiketleyecek ve büyük ihtimalle %100 tahmin başarıları çıkmış olacaktır. Ancak veri seti incelendi sızıntı olduğu anlaşılacak ve tahmin başarısının gerçekçi olmadığı gözler önüne serilecektir.




Şekil 3.2. Bağımlı Değişkenin Gruplandırılması

Şekil 3.3'te veri setindeki 447 öğrencinin diğer dağılımlarına bakılacak olursa; 182 erkek, 265 kadın olduğu görülmektedir.



Şekil 3.3. Cinsiyet Dağılımı


Alan dağılımı söz konusu olduğunda incelenen 6 sene boyunca mesleki dal olarak sözel seçen bulunmamaktadır. Şekil 3.4’te görüldüğü üzere 345 kişi sayısal alana yönelmiş olup 102 kişi de eşit ağırlık tercih etmiştir.



Şekil 3.4. Alan Dağılımı


Şekil 3.5’teki giriş yılı değişkenine bakıldığında, 2010 yılının en az öğrenci alınan yıl olduğu görülmektedir. Bunun sebebi 2010 yılına kadar okulun her sene 60 öğrenci alıyorken, 2010’dan sonraki senelerde 90 öğrenci almaya başlamasıdır. 2013 yılında ortaya çıkan öğrenci sayısındaki azlık ise o sene dershanelerin özel okula çevrilmesinden kaynaklanmaktadır. Bu okullar lisenin son senesinde öğrencilere üniversite sınavına daha iyi hazırlanabilmek için devamsızlık esnekliği ve en yüksek not verme temininde bulunmuşlardır. Bunun sonucu olarak o sene son sınıf öğrencilerinin neredeyse yarısı özel liselere geçmişlerdir. Bu sene ve ilerleyen

senelerde karşılaşılan bu duruma çözüm olarak bu öğrencilerin kazandıkları bölümler bulunmaya çalışılmış ve 12. sınıf ders notları ortalama olarak atanmıştır. Her öğrencinin son sene ders notları diğer senelere göre daha yüksek olduğundan bir değişken olarak önemleri de aynı derece de azdır. Bu sebeple veri kaybı yaşanmaması makine öğrenmesi açısından daha iyi bir seçenek olarak kabul edilmiştir.




Veri setinde yer alan bir başka bağımsız değişken de ek puan hakkı değişkenidir. 2010 ve 2011 giriş senelerinde liseye girmiş öğrenciler mezun olurlarken Anadolu Öğretmen Liseleri özelinde öğretmenlik bölümleri için “+30” puana kadar ek puan alma hakları bulunmaktaydı. 2011 senesini takip eden senelerde ise Anadolu Öğretmen Liselerinin kaldırılmasıyla ek puan hakkı ortadan kalkmıştır. Ek puanın olduğu ilk 2 senede çeşitli öğretmenlik bölümlerini seçen öğrenciler ilerleyen senelere göre daha fazla olsa da bütün senelerde bu bölüm seçimi bulunmaktadır. Ancak seçim motivasyonu ek puan hakkı yüzünden değiştiği için Şekil 3.6’da görüldüğü üzere 2010

ve 2011 senelerinde okula girişini yapan bütün öğrencilere ek puan hakkı değişkeninde “1” verilirken diğer 4 seneye “0” değeri atanmıştır.




Şekil 3.6. Ek Puan Hakkı Dağılımı

Veri setinde yer alan 44 adet ders değişkeninin 10 tanesi 9. sınıf dersleridir. Bu derslerin not ortalamalarının öğrencilerin giriş yıllarına göre gruplandırılmış hali Şekil 3.7’de gösterilmektedir.




Şekil 3.7. Dokuzuncu Sınıf Derslerinin Yıllara Göre Karşılaştırılması

9. sınıf ders notlarının bulunduğu değişkenlerin her birinde göz ardı edilebilecek sayıda aykırı değer mevcuttur. Bu aykırı değerler ile beraber verilerin yoğunlaştığı bölgeler Şekil 3.8’de gösterilmektedir.




Şekil 3.8. Dokuzuncu Sınıf Derslerinin Boxplot Yardımı ile Değerlendirilmesi

Veri setinde yer alan 44 adet ders değişkeninin 9 tanesi 10. sınıf dersleridir. Bu derslerin not ortalamalarının öğrencilerin giriş yıllarına göre gruplandırılmış hali Şekil 3.9’da gösterilmektedir.




Şekil 3.9. Onuncu Sınıf Derslerinin Yıllara Göre Karşılaştırılması

10. sınıf ders notlarının bulunduğu değişkenlerin her birinde göz ardı edilebilecek sayıda aykırı değer mevcuttur. Bu aykırı değerler ile beraber verilerin yoğunlaştığı bölgeler Şekil 3.10’da gösterilmektedir.



Şekil 3.10. Onuncu Sınıf Derslerinin Boxplot Yardımı ile Değerlendirilmesi


Veri setinde yer alan 44 adet ders değişkeninin 13 tanesi 11. sınıf dersleridir. Bu derslerin not ortalamalarının öğrencilerin giriş yıllarına göre gruplandırılmış hali Şekil 3.11’de gösterilmektedir. Seçmeli derslerin ortalamasının düşük olmasının sebebi eşit ağırlık seçenlerin Fizik, Kimya ve Biyoloji derslerini almamasıdır. Aynı şekilde sayısal seçen öğrenciler de Coğrafya, Dil ve Anlatım ve Türk Edebiyatının seçmeli derslerini almamaktadır.



Şekil 3.11 On birinci Sınıf Derslerinin Yıllara Göre Karşılaştırılması


11. sınıf ders notlarının bulunduğu değişkenlerin her birinde göz ardı edilebilecek sayıda aykırı değer mevcuttur. Bu aykırı değerler ile beraber verilerin yoğunlaştığı bölgeler Şekil 3.12’de gösterilmektedir. Veri setinde eşit ağırlık alanını

seçen öğrencilerin sayısal alanı seçen öğrencilere oranı düşük olduğu için, aykırı değerler ve etkili bölgeler hesaplanırken seçmeli eşit ağırlık derslerinde dersleri gerçekten alan öğrenciler aykırı değerler olarak saptanmaktadır. Aynı şekilde 0 değerine sahip olan gözlemler normal kabul edilip grafikte öyle belirtilmektedir.




Şekil 3.12. On birinci Sınıf Derslerinin Boxplot Yardımı ile Değerlendirilmesi

Veri setinde yer alan 44 adet ders değişkeninin 11 tanesi 12. sınıf dersleridir. Bu derslerin not ortalamalarının öğrencilerin giriş yıllarına göre gruplandırılmış hali Şekil 3.13'te gösterilmektedir. Seçmeli derslerin ortalamasının düşük olmasının sebebi eşit ağırlık seçenlerin Fizik, Kimya ve Biyoloji derslerini almamasıdır. Aynı şekilde sayısal seçen öğrenciler de Coğrafya ve Türk Edebiyatının seçmeli derslerini almamaktadır.




Şekil 3.13 On ikinci Sınıf Derslerinin Yıllara Göre Karşılaştırılması

12. sınıf ders notlarının bulunduğu değişkenlerin her birinde göz ardı edilebilecek sayıda aykırı değerler mevcuttur. Bu aykırı değerler ile beraber verilerin yoğunlaştığı bölgeler Şekil 3.14'te gösterilmektedir. Veri setinde eşit ağırlık alanını seçen öğrencilerin sayısal alanı seçen öğrencilere oranı düşük olduğu için, aykırı değerler ve etkili bölgeler hesaplanırken seçmeli eşit ağırlık derslerinde dersleri gerçekten alan öğrenciler aykırı değerler olarak saptanmaktadır. Aynı şekilde 0 değerine sahip olan gözlemler normal kabul edilip grafikte öyle belirtilmektedir.




Şekil 3.14. On ikinci Sınıf Derslerinin Boxplot Yardımı ile Değerlendirilmesi

Veri setinde yer alan Bölüm bağımlı değişkeninde 43 adet sınıf bulunmaktadır ve bu sınıfların dağılımı Şekil 3.15'te gösterilmektedir.




Şekil 3.15. Bölüm Değişkeni Sınıfları

Veri setinde yer alan Grup 1 bağımlı değişkeninde 23 adet sınıf bulunmaktadır ve bu sınıfların dağılımı Şekil 3.16'da gösterilmektedir.




Şekil 3.16. Grup 1 Değişkeni Sınıfları

Veri setinde yer alan Grup 2 bağımlı değişkeninde 10 adet sınıf bulunmaktadır ve bu sınıfların dağılımı Şekil 3.17’de gösterilmektedir.



Şekil 3.17. Grup 2 Değişkeni Sınıfları


Veri setinde yer alan Grup 3 bağımlı değişkeninde 6 adet sınıf bulunmaktadır ve bu sınıfların dağılımı Şekil 3.18’de gösterilmektedir.



Şekil 3.18. Grup 3 Değişkeni Sınıfları

3.2. Yöntem

Şekil 3.19’da gösterildiği haliyle, bu tezde yöntem olarak materyale önce veri ön işleme sonra da makine öğrenmesi adımları uygulanmaktadır. Makine öğrenmesi sonrasında birçok değerlendirme metriği ile modellerin başarıları ölçülmektedir.



Şekil 3.19. Yöntem Diyagramı

Materyale uygulanan bu adımların tamamı “Spyder” uygulaması içerisinde gerçekleştirilmektedir. Spyder entegre geliştirme çevresi orijinal adıyla “Integrated Development Environment (IDE)” olan ve “Python” dilinde bilimsel kodlama yapılabilen açık kaynaklı bir platformdur. Spyder içerisinde programlamada çok önemli yere sahip paketleri bulundurmaktadır. Program içerisinde kodlamayı kolaylaştıran birçok önemli özellik mevcuttur. Kullanım kolaylığı ve sunduğu özellikler sebebiyle veri ön işleme, makine öğrenmesi ve başarı ölçümü yöntemlerinde bu platform kullanılmaktadır.

3.2.1. Veri Ön İşleme

3.2.1.1. Etiket Kodlayıcı

Makine öğrenmesi için kullanılan veri setlerinde değişkenler numerik değerleri içermesinin yanı sıra kategorik değişkenler de içerebilir. Bu kategorik değişkenler 2 sınıflı yani “1” veya “0” ı temsil etse de içerik olarak yazı bulundurabilmektedir. Bu yazılı sınıflandırmalar makine öğrenmesi modelinde algılanamamakta ve hataya sebep olmaktadır. Bu tür durumlarda yazı içeren kategorilerin 1 ve 0 değerlerine atanması gerekmektedir. Örneğin cinsiyeti belirten bir değişkende erkek ve kadın olmak üzere 2 değişken bulunmaktadır. Bu değişkeni makine öğrenmesi modelleri anlayabilsin diye nümeriğe çevirmek gerekmektedir. Burada yapılması gereken erkek yerine 0, kadın yerine 1 yazılmasıdır. Bunun tam tersi de yazılabilmektedir ve bu model için bir

fark oluşturmamaktadır. Kodlaması yapılırken fonksiyonun ilk karşısına çıkana 1 yazılacaktır. Dolayısıyla diğer sınıf 0 olacaktır. Sonuç olarak etiket kodlayıcı, orijinal adıyla “label encoder”, sayesinde makine öğrenmesi algoritmaları düzgün bir şekilde sonuç verebilecektir [18].

3.2.1.2. Dummy Değişkenleri

Veri ön işlemede sıkça kullanılan yöntemlerden biri “dummy” değişkenleridir. Bir dummy değişkeni “ 0 ” veya “ 1 ” değerini alabilmektedir. 0 bir şeyin yokluğunu temsil ederken, 1 o şeyin varlığını temsil etmektedir. Eğer bir kategorik değişkende ikiden fazla sınıf bulunursa dummy değişkenleri setleri ile her bir sınıfın olup olmama durumlarına göre 1 veya 0 verilmektedir. Örnek vermek gerekirse, eğer bir değişkenin A, B ve C sınıfları varsa bu değişken 3 sınıflı bir değişkendir. Dummy kullanılarak bu değişken 3 ayrı değişkene bölünür ve bu değişken 2 sınıflı sıfır ve bir kategorik değişken olarak oluşturulur. A’ya sahip girdiler “Dummy A” değişkeninden 1 değeri alırken “Dummy B” ve “Dummy C” değişkenlerinden 0 değeri alırlar. Dummy değişkenleri sayesinde veri seti, makine öğrenmesi modellerinin uygulanmasına hazır hale getirilmiş olmaktadır [19].


3.2.1.3. Ölçekleme

Makine öğrenmesi modelleri veri setindeki özellikler birbirleriyle benzer ölçekte ise daha hızlı çalışmakta ve daha iyi performans göstermektedir. Nümerik değerleri de $0-1$ aralığına getirmek, kategorik değişkenler ile aynı ölçekte buluşmak anlamına gelmekte ve istenen gerçekleştirilmiş olmaktadır. “Scale” terimi ölçekleme anlamına gelmektedir. Veri setinden ölçekleme birden farklı şekillerde gerçekleştirilebilir. “MinMaxScaler” değerleri $0-1$ arasına oturturken özelliklerde anlamlı bir değişiklik yapmamakta, böylelikle aykırı değerlerin önemini düşürmemektedir. “RobustScaler” ise ölçeği ayarlarken minimum değer yerine medyan ile ilgili işlemler yapmakta, böylelikle ölçeklemenin kullanıldığı veri setinde aykırı değerleri önemi düşürülmektedir. “StandardScaler” ise ölçekleme yaparken verinin ortalaması ile ilgili işlemler yaparak ortalamayı 0 ’a çekip değerleri -1 ile 1 arasına oturtmakta, böylelikle standart sapma da 0 ’a inmiş olmaktadır [20].

3.2.1.4. Boyut Azaltma

Veri setini makine öğrenmesine sokmadan yapılması gereken işlemlerden biri de boyut azaltma işlemidir. Boyut denilen kavram veri setindeki her bir bağımsız

değişken olarak tanımlanabilir. Bu değişkenlerden bazıları bağımlı değişkeni yani etiketi belirlemede son derece önemliken bazı değişkenler neredeyse hiç önemli değildir. Değişkenlerin önemlerinin analizini yapılmadan büyük veri setleri makine öğrenmesine sokulursa performans kaybı yaşanmaktadır. Bu sebeple boyut azaltma işlemi değişken sayılarını farklı yöntemlerle olabildiğince düşürürken mümkün olduğunca veri kaybı yaşamamaya çalışmaktır. Boyut azaltma işlemi uygulanmış bir veri setine makine öğrenmesi algoritmaları uygulandığında işlemler çok daha hızlı gerçekleşecektir ve performans yükselecektir. Ayrıca “overfitting” adı verilen aşırı öğrenme olasılığı da azaltılmış olacaktır. Verileri görselleştirmek kolaylaşacaktır ve “multicollinearity” adı verilen bazı değişkenlerin yüksek korelasyona sahip olması sorununu da giderilecektir. Ayrıca boyut azaltma işlemi, veri setindeki gürültüyü de azaltıp modellerin doğruluğunu arttırmaya yardımcı olacaktır. Boyut azaltma işleminin birçok farklı yaklaşımı bulunmaktadır (Şekil 3.20).



Şekil 3.20. Boyut Azaltma Metotları

“Linear Discriminant Analysis” yani kısaca LDA metodu bu tezde de kullanıldığı gibi genelde çoklu sınıf sınıflandırmada kullanılmaktadır. Ancak aynı zamanda model oluşturulduktan sonra veri setine birtakım fonksiyonlar ile uygulanırsa kaliteli bir boyut azaltma tekniği olarak kullanılabilir. Uygulanabilmesi için bağımlı değişkene yani etiketlere de ihtiyaç vardır. Ayrıca verinin normal bir şekilde dağılmış olması gerekmektedir. LDA otomatik olarak bağımlı değişkendeki sınıf sayısının bir eksiği kadarını bağımsız değişken olarak oluşturmaktadır [21].

3.2.2. Makine Öğrenmesi

İnsanlığın içinde bulunduğu 21. yüzyıl “big data” adı verilen büyük veri çağıdır. Eskiden spesifik yerlerde bazı şirketler verileri elinde bulundururken, kişisel bilgisayarların ve daha sonra da cep telefonlarının yaygınlaşması ile insanlar önce veri üreticisi olmuşlardır. Daha sonrasında ise verileri işleyip bizim yararımıza kullanan araçlar sayesinde insanlık veri tüketicisi haline gelmiştir.

Bir bilgisayarda sorunu çözebilmek için bilgisayarın bir algoritmaya ihtiyacı vardır. Şekil 3.21’de görüldüğü üzere bu algoritma belirli görevleri yerine getirerek girdiyi çıktıya dönüştürmektedir. Algoritmanın amacı bu çıktıyı bulmaktır.




Şekil 3.21. Algoritma Çalışma mantığı

Makine öğrenmesi ise yapay zekânın bir uygulama alanı olarak elde bulunan veriden algoritma oluşturmaya gerek olmadan öğrenerek sorunlara çözüm üreten veya süreç iyileştiren bir bilim dalıdır. Veriyi kullanım biçimi açısından denetimli öğrenme ve denetimsiz öğrenme şeklinde ikiye ayrılmaktadır. Denetimli öğrenmede amaç girdi ve o girdilerin çıktılarına bakarak haritalandırmasını yapmaktır. Bu makine öğrenmesinde doğru cevaplar bir gözetmen tarafından veri içerisinde verilmektedir. Denetimsiz öğrenmede ise cevaplar veride bulunmaz ve makine öğrenmesinin girdideki şablonları, kuralları ve benzerlikleri bulması beklenmektedir. Bu bilgiler ışığında da verinin iskeleti oluşturulmaktadır. Hem denetimli hem de denetimsiz öğrenmede farklı makine öğrenmesi modelleri mevcuttur. Hepsinin veriyi ele alışımda farklılıklar bulunmaktadır [5]. Bu tezde kullanılan modeller de bu bölümde anlatılacaktır.

3.2.2.1. Rasgele Orman

Makine öğrenmesi araştırmaları arttıkça hali hazırda bulunan modellere alternatifler üretilmektedir. Bu alternatiflerden bazıları da zayıf modelleri bazı noktalarda birleştirip tek bir makine öğrenmesi algoritmasında daha başarılı sonuç çıkarma amacı taşımaktadır [22]. Rasgele Orman ya da orijinal adıyla “Random Forest” de ansambl bir makine öğrenmesi modelidir. Bu model birçok karar ağacı oluşturmaktadır. Bu ağaçların her birinin düğümü orijinal niteliklerden rasgele seçilen

bir nitelik alt kümesi kullanmaktadır. Ayrıca her bir ağaçta farklı bir ön yükleme verisi kullanılarak her bir ağaç arasındaki korelasyon minimumda tutulmuş olmaktadır. Şekil 3.22’de görüldüğü üzere belirlenen sayıda oluşturulan ağaçların verdikleri sonuçlara bakılmakta ve sınıflandırma problemlerinde en çok çıkan sonuç nihai sonuç olarak belirlenmektedir [23].



Şekil 3.22. Rasgele Orman Çalışma Mantığı

Rasgele üretilmiş ağaçlar arasında düşük korelasyon olması model açısından çok büyük önem arz etmektedir. Ağaçlar arasında korelasyon yeterince düşük seviyede ise bazı ağaçlar yanlış yönde kararlar almış olsa genel görüş doğru yöne doğru kayacaktır. Çünkü modeldeki her bir ağaç birbirlerini özgün hatalardan korurlar. Bu sebeple Rasgele Orman modelinin veri setinde iyi bir performans sergilemesi için ağaçlar arasında korelasyonun düşük olması ve de verinin içerisinde ağaçların modeli üstüne kurabileceği gerçek bir sinyal olması gereklidir.


Ağaçlar arasında düşük korelasyonu sağlamak için Rasgele orman modeli 2 metot kullanmaktadır. Bunlardan ilkinde “Bootstrap Aggregation” kısaca “Bagging” adı verilir. Bagging sayesinde her bir ağaç değiştirme yöntemi ile rasgele bir şekilde veriden örnekler alır. Yani n büyüklükteki eğitim verisinden her bir ağaç için yine n büyüklükte eğitim verileri oluşturulur ancak bu veri setlerinde özellikler tekrar edebilir. Böylelikle modeldeki her ağaç büyük ihtimalle farklı şekilde oluşmuş olur. Düşük korelasyon sağlamak için kullanılan ikinci metoda ise “Feature Randomness” adı verilir. Normalde bir karar ağacı özelliklere baktıktan sonra en keskin biçimde ayrılacak şekilde özellikleri düğümlere dağıtır. Rasgele orman içerisindeki karar ağaçları ise özellikler arasından her bir ağaç için rasgele alt kümeler oluşturur ve onların arasından düğümlere ayırır. Böylelikle çeşitlendirme daha da artmış

olmaktadır. Sonuç olarak rasgele orman modelinde ağaçlar hem farklı eğitim setleriyle kendilerini eğitip hem de farklı özellikler ile dallanmış olmaktadır [24].

3.2.2.2. K-En Yakın Komşu

K-En Yakın Komşu orijinal adıyla “k-Nearest Neighbor” basit ve parametrik olmayan bir makine öğrenmesi modelidir. “KNN” şeklinde kısaltılabilir. Parametrik olmadığı için verinin dağılımı hakkında bilgi sahibi olunmadığında kullanılacak bir makine öğrenmesi modelidir. Eğitim ve test aşamaları KNN için aynı şeydir. Tembel bir model olduğundan dolayı büyük veri setleri için ideal olmayabilir.

KNN, tahmin yapılacak değişkenin komşularının sınıf olarak yoğunluğuna bakılarak sınıfına karar vermesi prensibine dayanmaktadır. Bu prensipte en temel değer “k” değeridir ve Komşu sayısı anlamına gelmektedir. Şekil 3.23’te de bir örneği gösterildiği gibi K değerine göre tahmin yapılacak değişkenin komşularına bakılmaktadır. Değerin sayısı bakılacak komşunun sayısına eşittir.



Şekil 3.23. KNN Örneği

Örneğe bakılacak olursa; $k=3$ alınırsa yapılan gruptandırılmaya göre k kırmızı kabul edilir. Diğer yandan eğer $k=7$ alınırsa, k mavi olarak kabul edilir. Eğer bir modelde k değeri çok küçük bir sayı olarak belirlenirse o modelin aşırı öğrenme olasılığı artacaktır. Çünkü model tahmini gerçekleştirmek için sadece en yakınındaki değere veya değerlere bakmış olacaktır. k özellikle küçük veri setlerinde yüksek değerlerde alınırsa da modelin başarısı çok düşük olacaktır çünkü komşularından ortak özellikler çıkartma olasılığı düşecektir [25].

K değeri dışında modelde bakılması gereken bir diğer etken uzaklık etkenidir. Uzaklığın hesaplanmasında Denklem 3.1'deki “Minkowsky”, “Manhattan”, “Öklid” ve “Chebchev” ölçüm metrikleri farklı metrikler olarak kullanılabilir.

$$d = \sqrt[p]{\sum_{i=1}^n |x_i - y_i|^p} \quad (3.1)$$

Minkowsky denklemindeki p değeri değıştikçe diğer denklemler elde edilir. p=1 olduğunda Denklem 3.2'de Manhattan ortaya çıkmaktadır.

$$d = \sum_{i=1}^n |x_i - y_i| \quad (3.2)$$

p=2 olursa Denklem 3.3'te Öklid oluşmaktadır.

$$d = \sqrt{\sum_{i=1}^n |x_i - y_i|^2} \quad (3.3)$$

p=∞ olursa Denklem 3.4'te Chebychev meydana gelmektedir.


$$d = \max_i \{|x_i - y_i|\} \quad (3.4)$$

Veri setine hangi KNN uzaklık denkleminin uygulanacağı verinin özellik tipine göre değışebilir [26].

3.2.2.3. Destek Vektör Makineleri

Destek Vektör Makineleri orijinal adıyla “Support Vector Machines (SVM)”, n boyutlu bir uzay düzlemine yerleştirilmiş sınıfları yani etiketleri birbirinden en ayırık olacak şekilde ayıracak bir hiper düzlemi çekerek tahminler yapan makine öğrenmesi algoritmasıdır. Sınıfları birbirinden ayırma amacı taşıyan bu hiper düzlem, sınıflar arasında marjin payı en fazla olan diğer bir deyişle yüzeyi en geniş olacak şekilde oluşturulabilir. Marjin payı arttıkça gelecekte sınıflandırılacak veri noktaları da daha güvenle oluşturulabilmektedir [27].

Uzay düzleminde boyut sayısı olan “n” sınıf sayısına eşittir. 2 sınıflı bağımlı değişkene sahip olan bir veri setinin gösterimi de 2 boyutlu uzay düzleminde gösterilir. Bu boyutta hiper düzlem bir çizgidir. 3 boyutlu bir sınıflandırma düzleminde ise 2 boyutlu bir düzlem halini alır. Optimum hiper düzlem bu sınıfların arasına çekilir. Algoritmaya adını veren destek vektörleri bu hiper düzlemin sınıflara en yakın kenarlarında bulunan özniteliklerdir. Bu destek vektörleri sayesinde Şekil 3.24’teki gibi bir hiper düzlem optimum marjin ile düzlemde oluşturulabilir.



Şekil 3.24. SVM' de hiper düzlem çizimi [28]

Daha önce de belirtildiği gibi destek vektörleri ile hiper düzlemin arasında oluşan marjin ne kadar yüksek olursa model o kadar güvenle kurulur. Denklem 3.5’teki “Hinge Loss” fonksiyonu marjini maksimuma ayarlanmasını sağlayan bir fonksiyondur.

$$c(x, y, f(x)) = (1 - y * f(x))_+ \quad (3.5)$$

Tahmin edilen sınıf ile sınıfın gerçek değeri aynı ise maliyet olmamaktadır. Ancak farklı sınıf ise Denklem 3.6’te görüldüğü gibi fonksiyona düzenleme parametresi eklenir. Bu parametrenin eklenmesinin amacı maksimum marjin ile zarar arasındaki dengeyi bulmaktır.

$$\min_w \lambda \|w\|^2 + \sum_{i=1}^n (1 - y_i \langle x_i, w \rangle)_+ \quad (3.6)$$

Denklem 3.7 ve Denklem 3.8’te gözüktüğü üzere nihai zarar (loss) fonksiyonu oluştuktan sonra ağırlıklara bağlı olarak kısmi türevler alınır ve gradyanlar bulunur. Gradyanlar sayesinde ağırlıklar güncellenir.

$$\frac{\delta}{\delta w_k} \lambda \|w\|^2 = 2\lambda w_k \quad (3.7)$$

$$\frac{\delta}{\delta w_k} (1 - y_i \langle x_i, w \rangle)_+ = \begin{cases} 0, & \text{if } y_i \langle x_i, w \rangle \geq 1 \\ -y_i x_{ik}, & \text{else} \end{cases} \quad (3.8)$$

Denklem 3.9’da görüldüğü üzere yanlış bir sınıflandırma olmadığı zaman yani model veri noktasındaki sınıfı doğru tahmin ettiğinde Gradyan güncellemesi buna göre yapılır.


$$\omega = \omega - \alpha \cdot (2\lambda\omega) \quad (3.9)$$

Yanlış bir sınıflandırma olduğunda yani model hata yaparak veri noktasında sınıfı yanlış belirlediğinde Denklem 3.10’daki gibi gradyan güncellemesine düzenleme parametresi ile birlikte zarar fonksiyonu katılır [28].

$$\omega = \omega + \alpha \cdot (y_i \cdot x_i - 2\lambda\omega) \quad (3.10)$$

3.2.2.4. Gradyan Arttırma Makineleri

Genel olarak rasgele orman gibi ansambl makine öğrenmesi modellerinde tahminler ansambl içerisindeki modellerin ortalamasından ortaya çıkmaktadır. Gradyan arttırma makineleri- orijinal adıyla “Gradient Boosting Machines” kısaca “GBM”- bu metottan farklı olarak yapıcı bir strateji gütmektedir. Şekil 3.25’te görüldüğü gibi bu modelde ana fikir, ansambl modele art arda yeni modeller eklemektir. Her bir iterasyonda yeni ve zayıf model, ansambl modelin o ana kadar öğrendiklerindeki hataya göre eğitilmektedir.



Şekil 3.25. GBM Çalışma Mantığı [29]

GBM makine öğrenmesi modelinde eğitim süreci ardışık olarak yeni modellerin eklenip daha başarılı tahminler elde etmeye dayanır. Böylelikle algoritmanın ansambl ile bağlantılı olarak kayıp fonksiyonun negatif gradyanıyla maksimum ölçüde korelasyon göstermesi beklenir. Kayıp fonksiyonun seçimi araştırmacıya bağlıdır ve farklı görevler için farklı kayıp fonksiyonları mevcuttur. Bu da GBM’i veriye dayalı her göreve göre özelleştirilebilir kılar. Modelin veriye uygulanması da kısmen basit olduğu için deneme yanılma ile kayıp fonksiyonları rahatça seçilebilir [30].


GBM modelinde art arda eklenecek zayıf modeller olarak karar ağaçları kullanılır. Ancak bu ağaçlar diğer ansambl modellerden farklı olarak açgözlü bir tavırla kurulur. Saflık skorlarına göre ve kayıpları minimize edecek şekilde düğümlere ayrılır. Ağaç modellerini zayıf ama açgözlü tutmak GBM için büyük önem arz etmektedir. Bu sebeple ağaçlar kısa ve basit tutulur. Aynı şekilde düğüm sayıları da az olmalıdır [31].

3.2.2.5. Aşırı Gradyan Arttırma

Orijinal adıyla “Extreme Gradient Boosting”, kısaca “XGBoost”, GBM üzerinden geliştirilmiş bir makine öğrenmesi modelidir. Yaratıcıları tarafından ölçeklenebilir uç uca ağaç arttırma sistemi olarak tanımlanır. Öncül modeli gibi XGBoost modelinde de temel işlem sürekli olarak zayıf modellerin eklenerek kaybın minimize edilmesidir. GBM modeline temel katkıları yüksek ölçeklenebilir olması, verimli iskelet yapısı, seyrekliğin otomatik bir şekilde halledilmesi ve optimize edilmiş donanım kullanımı olarak özetlenebilir. Bu katkılar sayesinde modelin eğitim ve test hızı diğer GBM modellerine nazaran daha yüksektir ve daha iyi performanslar gösterebildiği saptanmıştır [32].


3.2.2.6. Hafif Gradyan Arttırma Makineleri

GBM ailesinin bir üyesi olan Hafif Gradyan Arttırma Makineler, orijinal adıyla “LightGBM”, makine öğrenmesinde genel anlamda GBM’nin çizdiği yollardan giderek modeli oluştursa da performans ve başarı ölçümlerinde farkını ortaya koymakta kullandığı birkaç benzersiz özelliği bulunmaktadır. GBM de dahil olmak üzere karar ağacı yapısını kullanan birçok makine öğrenmesi algoritması bu karar ağaçlarını kullanırken seviye odaklı bölünme olarak tanımlanan metodu kullanır. Şekil 3.26’da görüldüğü gibi seviye odaklı bölünme de karar ağacının her bir düğümü aşağı doğru sistematik ve düzenli bir biçimde bölünür.



Şekil 3.26. Seviye Odaklı (Level-wise) Büyüme


Seviye odaklı büyüme de her bir düğüm sürekli olarak bölünme gerçekleştirdiği için modelin oluşturulması yavaşlayacaktır. LightGBM modelinde zamandan tasarruf sağlamak için seviye odaklı büyüme yerine yaprak yani düğüm odaklı büyüme kullanılmıştır. Şekil 3.27’de belirtildiği üzere bu büyüme metodunda kaybın en az olacağı düğümler tespit edilir ve o düğümler bölünür.



Şekil 3.27. Düğüm Odaklı (Leaf-wise) Büyüme


Çoğu gradyan arttırma modeli önce genişlik araması, orijinal adıyla “Breadth First Search (BFS)” metodunu kullanmaktadır. Bu metotta arama kökten başlayarak soldaki düğüme geçer. Oradan sağdaki komşu düğüme geçer. Şekil 3.28’te

görüldüğü gibi daha sonrasında tekrar soldakinin dallarından başlayıp aynı şekilde devam eder.



Şekil 3.28. Breadth First Search (BFS) Metodu

LightGBM modeli ise önce BFS metodu yerine önce derinlik araması, orijinal adıyla “Depth First Search (DFS)” metodunu kullanmaktadır. DFS de BFS gibi aramaya kökten başlamaktadır. Ancak sonrasında her biri alt düğümü incelemek üzere paralel ilerlemek yerine dikey bir şekilde alt düğümü geçer. En alt düğümü kadar bu harekete devam eder. Bundan sonra en alt düğümün komşusuna geçer ve bir üst düğümün alt düğümleri boyunca bunu tekrarlar. Şekil 3.29’da görüldüğü gibi daha sonra kök düğümünün diğer alt düğümüne atlar ve aynı şekilde aramasına devam eder [33].



Şekil 3.29. Depth First Search (DFS) Metodu

LightGBM diğer GBM modellerinden farklı olarak gradyan tabanlı tek taraflı örnekleme, orijinal adıyla “Gradient Based One Side Sampling (GOSS)” kullanır. Bu metot büyük gradyanlı tüm örnekleri saklar ve küçük gradyanlara sahip örnekler üzerinde rasgele örnekleme gerçekleştirir. Kısaca örnek verilerin sayısını azaltarak verinin tamamı yerine alt örneklemler kullanır. LightGBM’nin kullandığı bir diğer metot ise özel öznitelik paketlemesi, orijinal adıyla “Exclusive Feature Bundling


(EFB)” dir. EFB metodu seyrek öznitelikleri birleştirerek daha yoğun öznitelikleri meydana getirir. Bu sayede de LightGBM’nin daha hızlı çalışması sağlanır.

LightGBM’nin GBM’den farklı olarak bünyesinde barındırdığı bütün metotlar algoritmaya ismini de verdiği üzere modelin daha hızlı çalışmasına yöneliktir. Bunu modelde olabildiğince az kayıp yaşatarak gerçekleştirmektedir. LightGBM bu metotlar yüzünden küçük veri setlerine uygulandığında aşırı öğrenme gerçekleştirebilir. Bu sebeple hızı da göz önüne alındığı LightGBM’nin en başarılı olduğu veri setleri büyük veri setleridir [34].

3.2.2.7. CatBoost

Kategorik arttırma ifadesinin orijinali olan “CategoricalBoosting” in kısaltılmışı olarak ortaya çıkan CatBoost, LightGBM ve XGBoost gibi gradyan arttırma makinelerinin eksikliklerine cevap bulmak amacıyla oluşturulmuş bir makine öğrenmesi modelidir. GBM’de yaşanan tahmin kayması ve sızıntısı sorunlarına çözüm olarak sunulmuştur. Bu iki ana sorunu düzenli arttırma yöntemiyle ortadan kaldırmaktadır [35].

CatBoost makine öğrenmesi algoritmasının diğer gradyan arttırma algoritmalarından birtakım farkları bulunmaktadır. Bu farklar sayesinde bu GBM modellerinden birçok konuda daha üstün olduğu öne sürülmektedir. Bu avantajlardan ilki verinin hazırlanması kısmını önemli ölçüde kısaltmasıdır. Kendi algoritması içerisinde boş bırakılmış veriler ile ilgili işlemler yapabilmektedir. Boş verilerin yerine veri sahibinin tercihinə göre verinin modu veya medyanı eklenebilmektedir. Ayrıca kategorik verilere “Label Encoder” veya “One Hot Encoder” gibi ön işleme adımlarının uygulanmasına gerek kalmadan bu verilerle kendisi işlem yapabilmekte, diğer GBM modellerinin aksine hata vermemektedir. CatBoost’un diğer GBM modellerinden bir farkı da Şekil 3.30’da görüldüğü gibi karar ağaç yapılarında simetrik ağaçlar kurmasıdır. Böylelikle ağaçların fazla dallanması engellenmiş olmaktadır. Bu sayede de aşırı öğrenme sorununa bir çözüm sunmaktadır.




Şekil 3.30. Simetrik Olmayan ve Simetrik Olan Ağaç Yapıları

CatBoost’un bir diğer ayırıcı özelliği veri setinde eğitim yaparken Graphics Processing Unit (GPU)’den yararlanabilmesidir. Bilgisayarda yeterli donanım mevcut ise model eğitiminde GPU kullanılması eğitim süresini kısaltmaktadır. Bu sayede CatBoost modelinin öğrenim hızı LightGBM modeline yaklaşmaktadır. Ayrıca CatBoost eğitim setinde işlemler yaparken bir yandan da geldiği yere kadar modeli kaydedebilmektedir. Çok büyük veri setlerinde uzun süreler veri setinin eğitimine gideceği için beklenmedik sıkıntılarda bu kayıtlardan model kaldığı yerden devam etmektedir. CatBoost’ un son ayırıcı özelliği ise “Jupyter Notebook” yardımıyla modelle ilgili özel grafikler sergileyebilmesidir. Bu sayede de algoritmanın okunabilirliği önemli ölçüde artmaktadır.


CatBoost, diğer GBM modellerinden ayrıldığı kısımlar sayesinde kullanımı oldukça kolaylaşmakta, anlaması kolaylaşmaktadır. Neredeyse LightGBM kadar hızlı eğitilebilirken XGBoost kadar isabetli tahminler yapmaktadır [36].

3.2.2.8. Yapay Sinir Ağları

Yapay Sinir Ağları orijinal adıyla “Artificial Neural Networks (ANN)”, Şekil 3.31’de görüldüğü gibi ismini insanların beyin yapısını oluşturan sinir ağlarından almıştır. Başına gelen yapay eki de bu sinir yapılarının bilgisayar üzerinden taklit edilmesi yüzündendir. İnsan beynindeki sinirler diğer bir adıyla nöronların her biri birbirleriyle bağlantı içerisindedir. Bir makine öğrenmesi ve derin öğrenme modeli olan yapay sinir ağları da benzer şekilde Şekil 3.32’deki gibi ağın farklı katmanları üzerinde birbirine bağlı nöronlardan oluşmaktadır.




Şekil 3.31. İnsan Beynindeki Nöron Yapısı [37]



Şekil 3.32. ANN Yapısı

Gerçek nöron yapısındaki dendritler ANN'deki girdilere karşılık gelirken çekirdek yapıları ise “X1, X2, X3, ..., Xn” olarak devam eden düğüm yapılarına karşılık gelmektedir. Sinaptik terminaller ise ANN yapısında “w1, w2, w3, ..., wn” olarak devam eden ağırlıklara eşdeğerdir. Son olarak nöronlarda akson adı verilen yapılar ANN'nin yapay nöronlarında çıktılarına eşdeğer olmaktadır [38].

İnsan beyinde trilyonlarca nöron olduğu düşünülmektedir. Bu nöronların her birinin 1000 ile 100000 aralığında bir ilişki noktası bulunmaktadır. Böylelikle insan beyinde veriler depolanmış olur ve istenildiği zaman dağıtılabilir. Şekil 3.33'de görüldüğü üzere, ANN de aynı mantıkla nöronların her birinin birbirleriyle ilişki halinde olduğu şekilde çalışmaktadır.



Şekil 3.33. ANN Katman Yapısı

ANN'nin katman yapısındaki ilk katman girdi katmanıdır. Algoritmaya sağlanan veriler buradan modele dahil olmaktadır. Son katman hariç bundan sonraki bütün katmanlar ise gizli katman adı verilen katman türleridir. Gizli katmanlar model için bütün hesaplamaları gerçekleştirerek saklı kalmış şablonları ve desenleri bulmaktadırlar. Bulunan desenler ile veriler son katmandan çıktı olarak verilmektedir.

Denklem 3.11'e bakıldığında ANN girdiyi alıp ön yargı yani "bias" ekleyerek girdilerin ağırlıklı toplamını hesapladığı görülmektedir.

$$\sum_{i=1}^n w_i * x_i + b \quad (3.11)$$

Bu transfer fonksiyonu, çıktıyı oluşturabilmek için bir girdi olarak aktivasyon fonksiyonuna gönderilen ağırlıklı toplamı belirlemektedir. Bu aktivasyon fonksiyonu, bir düğümün etkinleştirilip etkinleştirilmeyeceğini seçmektedir. Sadece etkinleşen düğümler en sonunda çıktı katmanına ulaşabilmektedir. Aktivasyon fonksiyonu yapılacak işe göre farklı şekillerde belirlenebilir [37].

ANN paralel şekilde oluşturulmuş işleme yeteneği sayesinde aynı anda birden fazla görevi gerçekleştirebilir. Ayrıca verinin Veri tabanı yerine bütün ağda tutulması da ANN'nin bir avantajı olarak kabul edilir. Böylelikle verinin bir parçasının kaybolması ağıın çalışmasını engellememektedir. ANN'nin bir diğer özelliği de tamamlanmamış veri ile çalışabilmesidir. Son olarak ANN'nin hata toleransı yüksektir [39].

3.2.2.9. Sınıflandırma ve Regresyon Ağaçları

Sınıflandırma ve regresyon ağaçları, orijinal adıyla “Classification and Regression Trees (CART)”, bir veri setini yinelemeli bir şekilde parçalara ayırarak ve her bir parçaya model uydurarak oluşan makine öğrenmesi modelidir. Parçalara ayrılan veri seti grafik üzerinde gösterildiğinde karar ağacı yapısı oluşmaktadır. Adında da belirtildiği üzere bağımlı değişken sonsuz sayıda ayrık değerler yapısında ise de sürekli bir yapıda ise de CART işlemlerini sürdürebilir [40].

CART yapısında veri setindeki özellikler sürekli olarak daha homojen gruplar oluşturacak şekilde parçalara bölünür. En yukarıdan başlayarak en aşağılardaki dallara inildikçe özellikler değişkenler nezdinde büyük benzerlikler göstermeye başlar. Her bir grup ise yanıt değişkeninin tipik bir değeri, gruptaki gözlem sayısı ve onu tanımlayan açıklayıcı değişkenlerin değerleri aracılığıyla karakterize edilir [41].

CART veri setini homojen gruplara ayırabilmek için dallanmalara başlarken birçok metot kullanabilir. Bu metotlara Denklem 3.12’de gösterilen “Gini Impurity” ve Denklem 3.13’te gösterilen “Entropy” örnek olarak verilebilir.

$$Gini\ Impurity = 1 - Gini = 1 - \sum_{i=1}^n p_i^2 \quad (3.12)$$

$$Entropy = - \sum_{i=1}^n p_i \log_2(p_i) \quad (3.13)$$

İki metodu da kullanarak bölünmeler yapılabilmektedir. İkisinde de en iyi bölünmeyi bulmak için hesaplamalar yapıldıktan sonra en küçük değeri veren dallanma alınmalıdır [42].

3.2.2.10. Doğrusal Ayırım Analizi

Doğrusal Ayırım Analizi, orijinal adıyla “Linear Discriminant Analysis (LDA)”, sınıflandırma ve veri görselleştirmede de kullanılan bir boyut azaltma metodudur. LDA, sınıf içi frekansların eşit olmadığı ve performanslarının rastgele oluşturulmuş test verisi üzerindeki incelemesini başarılı bir şekilde yürütebilmektedir. Ayrıca veri setinde sınıflar arası farklılığın sınıf içi farklılığa oranını maksimuma çıkartarak en yüksek ayrılabilirliği sağlamaktadır. LDA’nın oluşturulma amacı Temel

Bileşenler Analizine, orijinal adıyla “Principal Component Analysis (PCA), göre daha isabetli tahminler yapabilen bir sınıflandırma algoritmasına ihtiyaç duyulmasıdır. LDA ile PCA arasındaki temel fark, PCA’nın daha çok özellik sınıflandırması yaparken LDA’nın veri sınıflandırması yapmasıdır. PCA’da orijinal veri setlerinin biçimi ve konumu uzay dönüşümü yaparken değişmektedir. LDA ise konumu değiştirmeyip daha çok sınıf ayrımı sağlamaya ve verilen sınıflar arasında bir karar alanı çizmeye çalışmaktadır [43].


Boyut azaltmakta kullanılan LDA ile makine öğrenmesi modeli olarak kullanılan LDA arasında yöntem açısından bir fark bulunmamaktadır. Veri setine LDA uygulandıktan sonra boyut azaltma veya tahmin işlemlerine göre seçim yapılmaktadır. LDA’nın veri setine uygulanabilmesi için veri setinin normal bir şekilde dağılmış olması gerekmektedir. Ayrıca veri setinin bilinen sınıf etiketleri içermesi gerekmektedir. LDA’nın bulabileceği maksimum bileşen sayısı, sınıf sayısının bir eksisidir. Öznitelik ölçekleme de LDA için gerekli bir işlem değildir [44].

3.2.2.11. Hiyerarşik Kümeleme

Denetimli makine öğrenmesi algoritmalarında y değişkeni olarak kabul edilen etiketler yardımıyla modeller oluşturulurken denetimsiz öğrenme modelleri etiket verilerine ihtiyaç uymamaktadır. Denetimli öğrenmede veri seti eğitim ve test şeklinde ikiye bölündükten sonra eğitim seti yardımı ile model oluşturulurken özniteliklerin etiketleri aracılığıyla işlem gerçekleştirilir. Oluşturulan model ile de test kümesinde etiketler doğru tahmin edilmeye çalışılır. Denetimsiz öğrenmede ise veri seti bölünmemektedir. Bütün halinde ele alınıp özniteliklerin benzerlikleri incelenmekte ve bu benzerliklere göre kümelenmektedir. Bu sebeple denetimsiz öğrenmeye kümeleme de denmektedir. Hiyerarşik Kümeleme, orijinal adıyla “Hierarchical Clustering”, denetimsiz bir makine öğrenme yöntemlerinden biridir [45].

Hiyerarşik kümelemede verileri ayırma yöntemi olarak iki temel yöntem ön plana çıkmaktadır. Bu yöntemler; toplayıcı, orijinal adıyla “agglomerative” ve bölücü, orijinal adıyla “divisive”, olarak adlandırılmaktadır. Toplayıcı yönteminde ilk olarak bütün öznitelikler başlı başına birer küme olarak kabul edilmektedir. Daha sonra her iterasyonda bu kümeler benzerliklerine göre birleştirilmektedir. Bu işlem bir veya belirlenen k küme kalıncaya kadar devam etmektedir. Kümelerin yakınlıkları


hesaplanırken yakınlık matrisi uygulanmaktadır. Şekil 3.34’te açıkça gözüktüğü gibi birbirine en yakın kümeler ilk birleşmektedir.



Şekil 3.34. Hiyerarşik Kümelemede Toplayıcı Yöntemi Örneği

Bölücü hiyerarşik kümeleme yönteminde ise bunun tam tersi bir durum gerçekleşmektedir. Bütün öznitelikler ile tek bir küme oluşturulmaktadır. Daha sonrasında her iterasyonda benzerliklerine göre bir kümedeki en uzak veriler birbirinden ayrılmaktadır.

Hiyerarşik küme ile özdeşleşmiş dendrogram adı verilen ağacımsı yapılar bulunmaktadır. Bu yapılar Şekil 3.35’teki gibi yapılan kümelerin görselleştirilmesini sağlamaktadır.



Şekil 3.35. Dendrogram Yapısı Örneği

Hiyerarşik kümeleme gruplar benzerliklerine göre kümelere ayrılırken farklı yapılar oluşabilmektedir. Toplamda 6 farklı benzerlik yaklaşımı metodu bulunmaktadır. Bunlar; tekli bağlantı orijinal adıyla “Single Linkage”, tam bağlantı

orijinal adıyla “Complete Linkage”, ortalama orijinal adıyla “Average”, merkezler arası uzaklık orijinal adıyla “distance between centroids”, medyan ve “Ward” metodu olarak adlandırılmaktadır [46].

Hiyerarşik kümeleme yöntemi öznitelik etiketleri kullanmadığından dolayı aşırı öğrenme veya önyargı gibi denetimli öğrenme yöntemlerinde rastlanan problemleri göstermemektedir. Bu yöntemde matematiksel olarak bir sonuç alınmamaktadır. Onun yerine dendrogram yardımıyla öznitelikler arasındaki benzerlikler incelenip fikirler yürütülebilmekte ve denetimli modeller kurulurken buna göre hareket edilebilmektedir.

3.2.3. Başarı Ölçümü

Verinin üzerinde ön işleme adımları uygulandıktan ve makine öğrenmesi modelleri oluşturulduktan sonra yapılması gereken bu modellerin başarısını ölçmektir. İşlenmiş veri seti üzerinden birden fazla model denenebileceğinden hangi modelin daha başarılı sonuçlar verdiği bu adım sonucunda anlaşılmış olmaktadır. Başarı ölçümü yapmak için farklı değerlendirme metrikleri kullanılabilir. Bu metriklerin kullanımları veri setine göre değişebilmektedir. Bağımlı değişkenlerin regresyon tipinde olduğu veri setlerinde sonuçlar sürekli yapıda sayılar olduğu için kesin bir doğruluk yüzdeleri yerine hata payları bulunup değerlendirilmektedir. Bağımlı değişkenlerin iki veya daha fazla sınıf içerdiği sınıflandırma tipinde ise makine öğrenmesi modelleri birçok farklı şekilde değerlendirmeye tabi tutulabilir [47, 48].

3.2.3.1. Hata Matrisi

Hata matrisleri, orijinal adıyla “Confusion Matrix”, sınıflandırma tipi bağımlı değişkenlerin bulunduğu veri yapılarının makine öğrenmesi sonucu ortaya çıkan tahmin sonuçlarını anlaşılabilir bir şekilde özet halinde gösteren yapılardır. Doğru ve yanlış tahmin edilen etiketler sayılarak ve sınıf sınıf ayrılarak Şekil 3.36’daki hata matrisi üzerinde gösterilmektedir. Hata matrisi sayesinde incelenen makine öğrenmesi modelinin yoğunlaştığı yerler tespit edilebilir. Böylelikle hataların yüksek ve düşük olduğu yerlere dair bilgiler edinilebilmektedir.

		Tahmin Edilen	
		Pozitif	Negatif
Gerçek	Pozitif	Doğru Pozitif (DP)	Yanlış Negatif (YN)
	Negatif	Yanlış Pozitif (YP)	Doğru Negatif (DN)

Şekil 3.36. Hata Matrisi

Veri setindeki bağımlı değişkenin değeri 1 ise ve makine öğrenmesi modeli de o etiketi 1 olarak tanımlamış ise bu değerlendirme sonucu pozitif değer doğru bir şekilde bulunmuş denilir ve hata matrisinde DP bölümüne yerleştirilir. Ancak etiket 1 iken model sonucunda 0 olarak tahmin edilmiş ise pozitif değer yanlış bir şekilde 0 olarak bulunmuş denilir ve hata matrisinde kendisine YN bölümünde yer bulur. Benzer şekilde etiket 0 ise ve bulunan sonuç da 0'a karşılık geliyorsa doğru bir şekilde negatif bulunmuş denilir ve hata matrisinde DN bölümüne yerleşir. Ancak etiket 0 olmasına rağmen sonuç 1 bulunmuş ise yanlış bir şekilde negatif bulunmuş denilir ve hata matrisinde YP kısmına yerleştirilir. Bu işlemler her özelliğin etiketi ile tekrarlandığında o makine öğrenmesi modelinin genel bir hata matrisi elde edilmiş olur [49].

3.2.3.2. Doğruluk

Doğruluk, orijinal adıyla “Accuracy”, modelin başarısını ölçmek için sıkça kullanılmaktadır. Doğru bir şekilde tahmin edilmiş etiketlerin tahmin edilme işlemine sokulmuş tüm etiketlere oranı olarak hesaplanmaktadır (Denklem 3.14).

$$\text{Doğruluk} = \frac{DP + DN}{DP + DN + YP + YN} \quad (3.14)$$

3.2.3.3. Kesinlik

Denklem 3.15'te gösterildiği üzere kesinlik, orijinal adıyla “Precision”, makine öğrenmesi sonucunda pozitif olarak tahmin edilmiş etiketlerin ne kadarının gerçekte de pozitif olduğunu hesaplayan değerlendirme metriğidir.

$$\text{Kesinlik} = \frac{DP}{DP + YP} \quad (3.15)$$

3.2.3.4. Duyarlılık

Denklem 3.16’da gösterildiği gibi duyarlılık, orijinal adıyla “Recall”, gerçekte pozitif olan etiketlerin ne kadarının makine öğrenmesi sonucunda pozitif olarak tahmin edildiğini hesaplayan değerlendirme metriğidir.

$$Duyarlılık = \frac{DP}{DP + YN} \quad (3.16)$$

3.2.3.5. F1 Skoru

Denklem 3.17’de görüldüğü üzere f1 skoru kesinlik ve duyarlılık metriklerinin harmonik olarak alınmış ortalama değeridir. Aritmetik ortalama yerine harmonik ortalama kullanılması sayesinde uç örneklerde daha doğru sonuçlar alınmaktadır.

$$F1 Skoru = \frac{2 \times Kesinlik \times Duyarlılık}{Kesinlik + Duyarlılık} \quad (3.17)$$

Bazı veri setlerinde doğruluk değeri yerine F1 skoru nihai başarı ölçümü olarak kullanılmaktadır. Bunun sebebi sınıf sayıları eşit olarak dağılmamış veri kümelerinde hatalı model seçimi yapılmamasıdır [50].

3.2.3.6. Cohen Kappa Skoru

Cohen Kappa Skoru doğruluk oranının daha gelişmiş bir versiyonu olarak düşünülmektedir. Doğruluk oranı sınıflar arasında dengesizlik olduğu veri setlerinde bunu değerine yansıtamamakta ve yanlış yönlendiren değerler vermektedir. Bunun aksine Cohen Kappa skoru sınıf dengesizliklerini de değerlendirmeye almaktadır. Ayrıca bu skor etiketlerin başarıları ölçülürken şans faktörünü de ele almaktadır. Denklem 3.18’de görüldüğü üzere hem doğru tahmin edilen değerlerden hem de tüm gözlemlerden şansına eşleşen gözlemlerin çıkarılması ve birbirine bölünmesi ile hesaplanmaktadır.

$$Cohen Kappa Skoru = \frac{Doğruluk - Şans Faktörü}{1 - Şans Faktörü} \quad (3.18)$$

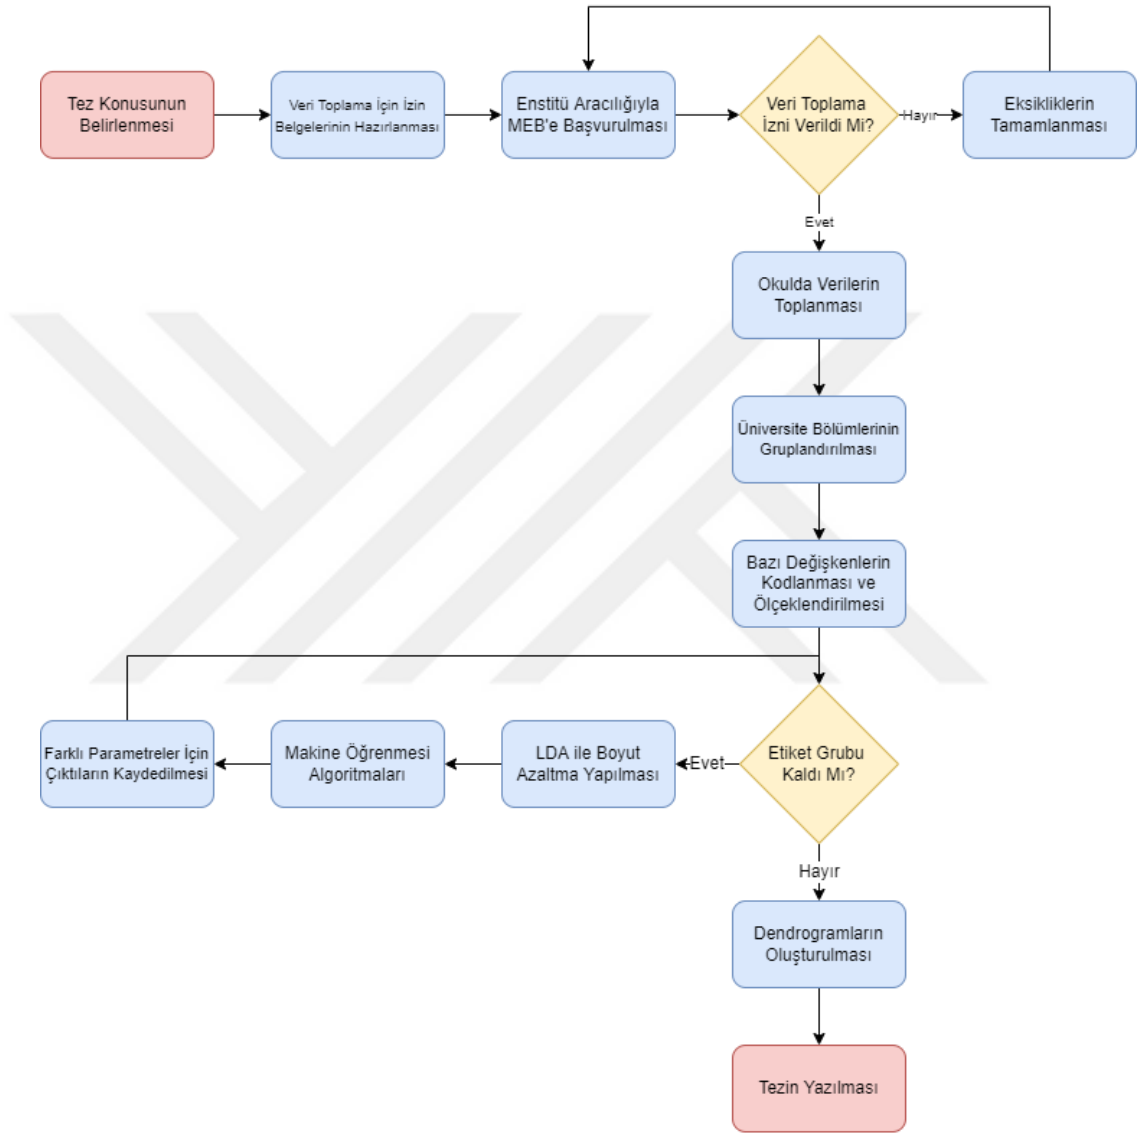
Denklemde şans faktörü olarak adlandırılan değer doğru ve yanlış değerlerin şanslı bir şekilde eşleşmesi anlamına gelmektedir. Çoklu sınıflandırmada her bir

sınıfın bütün etiketler içerisindeki oranları hesaplanır. Daha sonra yine her bir sınıf için makine öğrenmesi sonucu tahmin edilen etiketler içerisinde oranları hesaplanır. Daha sonra sınıf sınıf bu değerler birbirleriyle çarpılıp en sonunda da toplanır. Ortaya çıkan değer şans faktörü olarak adlandırılmaktadır [51, 52].



4. ARAŞTIRMA BULGULARI VE TARTIŞMA

Bu bölümde tezin konusu seçildikten sonra araştırma bulguları elde etmek üzere yapılan tüm işlemler adım adım Şekil 4.1'deki gibi anlatılacaktır. Bu adımlar tezin yazılma aşamasına kadar devam etmektedir.



Şekil 4.1. Ayrıntılı İş Akışı

4.1. Veri Toplama ve Ön işleme

Makine öğrenmesinde en önemli materyal veri setidir. Bu tezde materyal olarak kullanılan veri seti lise öğrencilerinin bilgilerinden oluşmaktadır. Bu bilgiler; öğrencinin dört senelik lise hayatı boyunca aldığı derslerin yıl sonu notları, kazandığı

üniversitedeki seçtiği bölümü, cinsiyeti ve giriş yılıdır. Bilgileri elde etmek için Milli Eğitim Bakanlığından gerekli izinler alınarak ilgili okulda toplanmıştır.¹

447 özniteliğin yani öğrencinin yer aldığı veri setinde bağımlı değişken olarak kullanılacak bölüm değişkeninde 43 sınıf bulunmaktadır. Veri büyüklüğüne göre bu sayı çok yüksek olduğu için makine öğrenmesinin tahmin başarısının düşük çıkması olasılığı ön plana çıkmaktadır. Bu sebeple birbirlerine en çok benzeyen bölümlerden başlamak üzere 3 aşamada sınıflar birleştirilmiştir. Daha önce Şekil 3.2’deki gibi diğer 3 gruplandırmada sırasıyla 23, 9 ve 6 sınıf oluşmaktadır. Bu gruplandırmalar da veri setine ayrı ayrı makine öğrenmesi algoritmalarında denenmek üzere yerleştirilmiştir.

Veri seti elde edildikten sonra ilk aşama Tablo 4.1’de gösterilen ön işleme adımlarını uygulamaktır. Verideki cinsiyet değişkenine etiket kodlayıcı, orijinal adıyla “Label Encoder”, uygulanmaktadır. Kadın sınıfına “1” sayısı verilirken erkek sınıfı da “0” sayısı ile kodlanmaktadır. Böylelikle makine öğrenmesi modellerinin veriyi okuması kolaylaştırılmış olmaktadır. Giriş yılı değişkeni ise 2010, 2011, 2012, 2013, 2014, 2015, 2016 adlarına sahip 7 sınıftan oluştuğu için bu değişkenin kodlanmasında dummy değişkenleri yöntemine başvurulmuştur. Dummy değişkenleri yöntemi ile giriş yılı değişkeni veri setinden kaldırılıp yerine 7 yeni değişken gelmektedir. Bu yeni değişkenlerden her biri giriş yılındaki bir sınıfın değişkeni olarak atanmış ve her bir öznitelik bu değişkenlerin 6 tanesinden “0” etiketini alırken 1 tanesinden “1” etiketini almış olmaktadır. Dummy değişkenlerinin veri setinde kullanılması sayesinde birçok makine öğrenmesi modelinin multi sınıf içeren değişken gördüğünde hata vermesi engellenmiş olmaktadır.

¹ Bu bilgileri verinin gizliliği kanunu ihlal etmeden toplayabilmek için Milli Eğitim Bakanlığı’ndan gerekli izin alınmak üzere başvuruldu. MEB bu tür yüksek lisans tezleri için daha önce izinler vermiş olsa da bunlar genellikle anket içeren izinlerdi. Mezunların geçmişteki bilgilerinin toplanması yeni bir olaydı. İlk başvuru haziran ayında yapıldığı için reddedildi. MEB’teki politika bu tür araştırma izinlerinin öğretim yılı bitmesinden 2 hafta öncesinde sonlanması gerektiği yönündeydi. Bu sebeple gerekli belgeler düzenlenerek 2021 eylül ayında tekrar izin başvurusu yapıldı ve kabul alındı.

Gerekli olan izin alındıktan sonra, izin belgesi ile birlikte okuldan veriler toplanmaya başlandı. Öğrencilerin geçmiş notları sınıf geçme defterlerinde tutulmaktaydı. Bu sebeple dijitale aktarılması birkaç hafta sürdü. Sonrasında eksik kısımlar okul yetkilisi ile beraber tamamlandı ve öğrencilerin kazandığı bölümler de kayda alındı. Son olarak tüm öğrencilerin isim ve soy isimleri verilerden tamamen silindi. Böylelikle kişisel verilerin korunması kanununa uyulmuş oldu.

Veri setinde yer alan sınıf verilerini “1” ve “0” etiketlerine dönüştürdükten sonraki aşama, sürekli verilerin ölçeklendirilmesidir. Makine öğrenmesi algoritmalarının performansını arttırmak için kullanılan bu yöntemde ders notları değişkenlerine min-max ölçekleme, orijinal adıyla “Min-max Scaler”, uygulanmaktadır. Bu ölçekleme metoduyla değerleri 0-100 arasında değişen ders notları değişkenleri 0-1 aralığına oturtulmaktadır. Bu ölçeklendirme yapılırken min-max ölçeklemeni yöntemi sayesinde verilerin birbirleri arasındaki uzaklıklarının oranları sabit kalmış olmaktadır. Yöntem uygulanırken en düşük ders notu değerine “0” etiketi atanırken en yüksek ders notu değerine “1” etiketi atanarak arada kalanlar da ona göre ölçeklendirilmektedir.

Tablo 4.1. Veri Setindeki Değişken Yapıları

Değişken	Yapısı	Ön İşlemesi
Cinsiyet	Sınıf (E-K)	Label Encoder (0-1)
Giriş Yılı	Sınıf (2010, 2011, 2012, 2013, 2014, 2015, 2016)	Dummy Variables
Ek Puan	Sınıf (0-1)	-
Sayısal mı	Sınıf (0-1)	-
Dil ve Anlatım_9	Regresyon (0~100)	MinMaxScaler (0~1)
Türk Edebiyatı_9	Regresyon (0~100)	MinMaxScaler (0~1)
Tarih_9	Regresyon (0~100)	MinMaxScaler (0~1)
Coğrafya_9	Regresyon (0~100)	MinMaxScaler (0~1)
Matematik_9	Regresyon (0~100)	MinMaxScaler (0~1)
Fizik_9	Regresyon (0~100)	MinMaxScaler (0~1)
Kimya_9	Regresyon (0~100)	MinMaxScaler (0~1)
Biyoloji_9	Regresyon (0~100)	MinMaxScaler (0~1)
Yabancı Dil_9	Regresyon (0~100)	MinMaxScaler (0~1)
İkinci Yabancı Dil_9	Regresyon (0~100)	MinMaxScaler (0~1)
Dil ve Anlatım_10	Regresyon (0~100)	MinMaxScaler (0~1)

Türk Edebiyatı_10	Regresyon (0~100)	MinMaxScaler (0~1)
Tarih_10	Regresyon (0~100)	MinMaxScaler (0~1)
Coğrafya_10	Regresyon (0~100)	MinMaxScaler (0~1)
Matematik_10	Regresyon (0~100)	MinMaxScaler (0~1)
Fizik_10	Regresyon (0~100)	MinMaxScaler (0~1)
Kimya_10	Regresyon (0~100)	MinMaxScaler (0~1)
Biyoloji_10	Regresyon (0~100)	MinMaxScaler (0~1)
Yabancı Dil_10	Regresyon (0~100)	MinMaxScaler (0~1)
İkinci Yabancı Dil_10	Regresyon (0~100)	MinMaxScaler (0~1)
Dil ve Anlatım_11	Regresyon (0~100)	MinMaxScaler (0~1)
Türk Edebiyatı_11	Regresyon (0~100)	MinMaxScaler (0~1)
İnkılap Tarihi_11	Regresyon (0~100)	MinMaxScaler (0~1)
Felsefe_11	Regresyon (0~100)	MinMaxScaler (0~1)
S_Coğrafya_11	Regresyon (0~100)	MinMaxScaler (0~1)
S_Dil ve Anlatım_11	Regresyon (0~100)	MinMaxScaler (0~1)
S_Türk Edebiyatı_11	Regresyon (0~100)	MinMaxScaler (0~1)
Matematik_11	Regresyon (0~100)	MinMaxScaler (0~1)
S_Fizik_11	Regresyon (0~100)	MinMaxScaler (0~1)
S_Kimya_11	Regresyon (0~100)	MinMaxScaler (0~1)
S_Biyoloji_11	Regresyon (0~100)	MinMaxScaler (0~1)
Yabancı Dil_11	Regresyon (0~100)	MinMaxScaler (0~1)
İkinci Yabancı Dil_11	Regresyon (0~100)	MinMaxScaler (0~1)
Dil ve Anlatım_12	Regresyon (0~100)	MinMaxScaler (0~1)
Türk Edebiyatı_12	Regresyon (0~100)	MinMaxScaler (0~1)
S_Coğrafya_12	Regresyon (0~100)	MinMaxScaler (0~1)
S_Dil ve Anlatım_12	Regresyon (0~100)	MinMaxScaler (0~1)
S_Türk Edebiyatı_12	Regresyon (0~100)	MinMaxScaler (0~1)
Matematik_12	Regresyon (0~100)	MinMaxScaler (0~1)
S_Fizik_12	Regresyon (0~100)	MinMaxScaler (0~1)
S_Kimya_12	Regresyon (0~100)	MinMaxScaler (0~1)
S_Biyoloji_12	Regresyon (0~100)	MinMaxScaler (0~1)
Yabancı Dil_12	Regresyon (0~100)	MinMaxScaler (0~1)
İkinci Yabancı Dil_12	Regresyon (0~100)	MinMaxScaler (0~1)

Bölüm	Sınıf (43 Etiket)	-
Grup 1	Sınıf (23 Etiket)	-
Grup 2	Sınıf (9 Etiket)	-
Grup 3	Sınıf (6 Etiket)	-

Tabloda da belirtilmiş “Ek puan” değişkeni verinin toplandığı okul ile alakalı bir durumdur. Şu anki statüsü Anadolu Lisesi olsa da 2015 yılından önce okul Anadolu Öğretmen Lisesi idi. 2015 ve öncesinde mezun olan öğrenciler öğretmen kontenjanlarına başvururken ek puan almaktaydılar. Bu sebeple veri setindeki 2010 ve 2011 girişli öğrenciler ek puan değişkeninde “1” etiketini alırken 2012, 2013, 2014, 2015 ve 2016 girişli öğrenciler bu değişkenden “0” etiketini almışlardır.

Tabloda da belirtilmiş “Sayısal mı” değişkeni öğrencilerin lise 2’ün sonunda seçtikleri sayısal, eşit ağırlık veya sözel sınıflarına karşılık gelmektedir. Okulda verilerin toplandığı tarih aralığında hiçbir öğrenci sözel alan grubunu seçmediğinden dolayı bu değişken iki sınıfa sahip olmaktadır. Bu sebeple de herhangi bir kodlamaya gerek kalmadan “1” etiketi sayısala, “0” etiketi de eşit ağırlığa karşılık gelecek şekilde veri setine girişi yapılmıştır.

Tabloda da belirtildiği üzere veri setinde 44 adet ders notu değişkeni bulunmaktadır. Bu dersleri ilk iki sene bütün öğrenciler almışken, son iki sene öğrencilerin alan seçimine göre dersler farklılık göstermiştir. Bu seçmeli dersleri almayanlara o dersten 0 notu verilerek değişkende kayıp veri sorunu ortadan kaldırılmıştır.

Bölüm, Grup 1, Grup 2 ve Grup 3 değişkenleri de daha önce belirtildiği gibi makine öğrenmesi algoritmalarının bağımsız değişkenler aracılığıyla ayrı ayrı tahminlerini yapacağı 4 adet bağımlı değişkendir.

Veri setinin boyutunu azaltma işlemi makine öğrenmesinin tahmin başarısını arttırırken algoritmanın çalışma süresini de azaltmaktadır. Bu sebepler dolayısıyla bu tezde kullanılmasına karar verilmiştir. Birçok boyut azaltma yöntemi mevcuttur. Bu yöntemlerin arasından doğrusal ayırım analizi, orijinal adıyla “Linear Discriminant Analysis (LDA)” kullanılmak üzere seçilmiştir. LDA’nın seçilmesinin sebebi, değişkenlerin bir kısmını çıkartmak yerine tüm değişkenler arasında yeni

kombinasyonlar oluřturması ve bunu yaparken etiketleri de hesaba katmasıdır. LDA yönteminde spesifik olarak deęiřken sayısı belirtilmezse yöntem otomatik olarak baęımlı deęiřkendeki sınıf sayısının bir eksięi kadar deęiřken oluřturmaktadır. Veri setinde yer alan 4 farklı baęımlı deęiřken için 4 farklı boyut azaltma iřlemi gerekleřtirildięi için LDA uygulanması sonucunda farklı verilere sahip 4 veri seti oluřmaktadır. Bölüm baęımlı deęiřkeni 43 sınıfa sahip olduęundan veri seti 42 deęiřkenden oluřmaktadır. Grup 1 baęımlı deęiřkeni ise 23 sınıfa sahip olduęundan veri setinde 22 baęımsız deęiřken oluřturulmaktadır. Aynı řekilde grup 2 baęımlı deęiřkeninde bu sayı 8 iken grup 3'te ise 5'e düşmektedir.

Veri setinde belirlenen bölüm deęiřkeninin ve bu deęiřkenden oluřturulan grup 1, grup 2, grup 3 deęiřkenlerinin makine öğrenmesi yöntemlerinde etiket olarak iřlem görmesine karar verilmiřtir. Denetimli makine öğrenmesi olarak adlandırılan bu iřlemde 10 adet farklı makine öğrenmesi algoritması veri seti üzerinde denenmiřtir. Bu algoritmalar; rasgele orman, k en yakın komřu, destek vektör makineleri, gradyan arttırma makineleri, ařırı gradyan arttırma, hafif gradyan arttırma makineleri, CatBoost, yapay sinir aęları, sınıflandırma ve regresyon aęaçları ve doęrusal ayırım analizidir.

Sınıflandırma ve regresyon aęaçları karar verme sürecinde tüm olasılıkları deęerlendirdięinden, anlaması ve tercüme etmesi kolay olduęundan ve de birok bařka makine öğrenmesi yönteminde temeli oluřturduęundan bu tezde kullanılması uygun görölmektedir. Rasgele orman algoritması ise aęaç yapısını ok daha ileri bir noktaya tařımaktadır. ok fazla aęaç yapısı kullanarak ezberlemeyi engellemekte ve modele rasgelelelik eklemektedir. Bu sebeple bu tezde kullanılması uygun görölmektedir.

K en yakın komřu yöntemi veri noktalarını birbirlerine benzerliklerine göre yerleřtirdięi için denetimsiz bir öğrenme yöntemi iřlevi görmektedir. Tahmin etme iřlemi bařladıęında etiket tahminine gemektedir. Bu sebeple model oluřturma ve tahmin etme hızı ok yüksektir. Ayrıca benzerliklerine göre etiket tahmini benzersiz bir yöntemdir. Bu sebepler göz önüne alınarak k en yakın komřu yönteminin bu tezde kullanılması uygun görölmektedir.

Destek vektör makineleri bir düzlem yardımıyla etiketleri birbirinden ayırmaktadır. Yüksek boyutlu veri setlerinde bařarısı daha yüksektir. Bu sebepler göz

önüne alınarak destek vektör makinelerinin bu tezde kullanılması uygun görülmektedir.

Gradyan arttırma makineleri karar ağaçlarından yararlanarak oluşturulmuş ansambl bir makine öğrenmesi yöntemidir. Rasgele ormanın aksine ön yargıyı düşürmeye çalışarak hatayı azaltmayı hedeflemektedir. Bu yöntemi temel alarak oluşturulmuş olan aşırı gradyan arttırma, hafif gradyan arttırma makineleri, CatBoost da destek vektör makinelerinin farklı kısımlarına odaklanarak daha iyi sonuçlar hedeflemektedir. Aşırı gradyan arttırma tahmin hızından kayıp verirken başarıyı yükseltmeyi hedeflemektedir. Hafif gradyan arttırma makineleri ise bunun tam tersi olarak çalışmakta, başarıyı düşürmeden hızı arttırmayı hedeflemektedir. CatBoost ise hem hızını korurken hem de başarıyı en yükseğe çıkarmayı hedeflemektedir. Bu sebepler göz önüne alınarak gradyan arttırma yöntemlerinin bu tezde kullanılması uygun görülmektedir.

Yapay sinir ağlarının en önemli işlevi değişkenler arasında lineer olmayan ve görülemeyen ilişkileri bulabilmesidir. Ağı genişlettikçe insan beyni yapısına benzeyen yapılar ortaya çıkmakta ve model gelişmektedir. Bundan dolayı diğer yöntemlerin kuramadığı bağlantıları kurup daha yüksek sonuçlar elde edebilmektedir. Bu sebepler göz önüne alınarak bu tezde kullanılması uygun görülmektedir.

Doğrusal ayırım analizi boyut azaltmada kullanıldığı gibi sınıflandırma problemlerinde de kullanılmaktadır. Bu tezde boyut azaltma LDA ile yapıldığından dolayı yeni oluşan değişkenlerde aynı yöntemin tahmin başarısının yüksek olacağı düşünülmektedir. Bu nedenle de bu tezde kullanılması uygun görülmektedir.

4.2. Makine Öğrenmesi Modellerinde Parametreler ve Skorlar

Modelin tahmin başarısı ölçülürken veri setinde aşırı öğrenme durumu olup olmadığını öğrenmek için eğitim verisinin doğruluk oranı hesaplanmaktadır. Cohen, F1 ve test verisinin doğruluk oranları ise nihai tahmin başarıları olarak alınmaktadır. Bu skorlarda en iyi sonuçlar alınabilmesi için her bir algoritmanın en önemli parametre değerlerinin birbiriyle çaprazlanıp en iyi sonucu veren parametre kombinasyonunun bulunması gerekmektedir. Bunu elde edebilmek için parametrelere mantıklı değer aralıkları verilip makine öğrenmesi algoritmasındaki her bir parametre değeri, diğer parametreler ile birleşip bir sonuç çıkarmaktadır.

4.2.1. Rasgele Orman Parametreleri ve Skorları

Rasgele Orman algoritmasının parametreleri incelendiğinde sonuca direkt etkisi olan 2 parametre ön plana çıkmaktadır. Bu parametrelerden ilki olan “n_estimators” parametresi, oluşturulacak ağaç sayısına işaret etmektedir. Bir diğer önemli parametre olan “min_samples_split” parametresi ise, bir iç düğümü dallandırmak için gerekli olan minimum örnek sayısına karşılık gelmektedir [53]. Bu veri setinde “n_estimators” parametresine {100, 200, 300, 400, 500, 600, 700, 800, 900, 1000} değerleri verilirken “min_samples_split” parametresine {2, 3, 4, 5, 6, 7, 8, 9} değerleri verilerek en iyi sonuçlar elde edilebilmesi hedeflenmiştir. Bu parametrelerin değerleri çaprazlandığında her bir bağımlı değişken için 80 adet farklı sonuç ortaya çıkmaktadır. Bu sonuçlar en yüksek test verisi doğruluk oranına göre sıralandığında en iyi skorları veren 5 modele ışık tutulmuştur (Tablo 4.2).

Tablo 4.2. En Başarılı RF Sonuçları ve Parametreleri

	n_estimators	min_samp les_split	accuracy_tr ain	cohen	f1	accuracy_te st
Bölüm	500	6	1	0.331683168	0.314194605	0.407407407
	400	6	1	0.323705857	0.317474611	0.4
	600	6	1	0.323077875	0.308286327	0.4
	700	6	1	0.322532681	0.307425107	0.4
	1000	6	1	0.322490706	0.311153123	0.4
Grup 1	700	6	1	0.398506094	0.421862634	0.496296296
	400	2	1	0.387654483	0.415155786	0.488888889
	400	6	1	0.390578999	0.419997337	0.488888889
	500	6	1	0.390100177	0.415239931	0.488888889
	500	8	0.971153846	0.385756677	0.411922889	0.488888889
Grup 2	200	4	0.996794872	0.563043947	0.649523239	0.666666667
	300	5	0.996794872	0.53300663	0.626963273	0.644444444
	500	5	0.996794872	0.533846486	0.626961875	0.644444444
	900	9	0.932692308	0.534549634	0.626561667	0.644444444
	100	9	0.935897436	0.523620913	0.616552644	0.637037037
Grup 3	300	9	0.913461538	0.665640949	0.7580647	0.755555556
	200	8	0.923076923	0.654497554	0.74970929	0.748148148
	200	9	0.907051282	0.654497554	0.74970929	0.748148148
	800	8	0.935897436	0.655431274	0.750300098	0.748148148
	900	8	0.939102564	0.655431274	0.750300098	0.748148148

4 bağımlı değişkenin her birindeki en iyi skorları veren model en başarılı RF modeli olarak alınmış ve diğer makine öğrenmesi algoritmalarının modelleri ile karşılaştırılmıştır. Parametre çaprazlamalarından elde edilen tüm değerler EK-A’da verilmiştir.

4.2.2. K En Yakın Komşu Parametreleri ve Skorları

K En Yakın Komşu algoritmasının parametreleri incelendiğinde sonuca direkt etkisi olan 2 parametre ön plana çıkmaktadır. Bu parametrelerden ilki olan “n_neighbors” parametresi, gruplandırma için bakılacak komşu veri noktası sayısına işaret etmektedir. Bir diğer önemli parametre olan “p” parametresi ise, Minkowski metriğine karşılık gelmektedir [54]. Bu veri setinde “n_neighbors” parametresine 1 ile 50 arası değerler verilirken “p” parametresine {1, 2, 3, 4, 5, 6, 7, 8, 9, 10} değerleri verilerek algoritmanın en iyi sonuçları elde edilebilmesi hedeflenmiştir. Bu parametrelerin değerleri çaprazlandığında her bir bağımlı değişken için 500 adet farklı sonuç ortaya çıkmaktadır. Bu sonuçlar en yüksek test verisi doğruluk oranına göre sıralandığında en iyi skorları veren 5 modele Tablo 4.3’te ışık tutulmuştur.

Tablo 4.3. En Başarılı KNN Sonuçları ve Parametreleri

	n_neighbors	p	accuracy_train	cohen	f1	accuracy_test
Bölüm	33	1	0.269230769	0.245955316	0.231583528	0.355555556
	37	1	0.269230769	0.24338079	0.2251647	0.355555556
	16	7	0.326923077	0.261790841	0.26477654	0.348148148
	30	1	0.288461538	0.238656755	0.229554807	0.348148148
	38	1	0.266025641	0.234881175	0.220255477	0.348148148
Grup 1	18	4	0.416666667	0.292183031	0.344091571	0.42962963
	19	3	0.413461538	0.28786737	0.32787853	0.42962963
	20	3	0.403846154	0.286057692	0.31548725	0.42962963
	21	3	0.413461538	0.285223131	0.322468067	0.42962963
	22	3	0.403846154	0.285763364	0.324195934	0.42962963
Grup 2	12	3	0.631410256	0.596721311	0.667443152	0.696296296
	12	4	0.657051282	0.575595847	0.646702451	0.681481481
	12	7	0.644230769	0.577141608	0.654564279	0.681481481
	12	8	0.647435897	0.576679064	0.65162401	0.681481481
	12	9	0.644230769	0.576184566	0.65070939	0.681481481

Grup 3	11	10	0.682692308	0.629939846	0.718391251	0.733333333
	19	1	0.666666667	0.629714286	0.725136258	0.733333333
	11	8	0.701923077	0.619254516	0.710968708	0.725925926
	11	9	0.695512821	0.619254516	0.710968708	0.725925926
	7	5	0.685897436	0.611863509	0.708862867	0.718518519

4 bağımlı değişkenin her birindeki en iyi skorları veren model en başarılı KNN modeli olarak alınmış ve diğer makine öğrenmesi algoritmalarının modelleri ile karşılaştırılmıştır. Parametre çaprazlamalarından elde edilen tüm değerler EK-A’da verilmiştir.

4.2.3. Destek Vektör Makineleri Parametreleri ve Skorları

Destek Vektör Makineleri algoritmasının parametreleri incelendiğinde sonuca direkt etkisi olan 3 parametre ön plana çıkmaktadır. Bu parametrelerden ilki olan “C” parametresi, regülerizasyon parametresi olarak kabul edilmektedir. Bir diğer önemli parametre olan “kernel” parametresi ise, algoritmada kullanılacak kernel tipine karşılık gelmektedir. 3. önemli parametre olan “gamma” parametresi ise, kernelde kullanılacak katsayıya işaret etmektedir [55]. Bu veri setinde “C” parametresine 1 ile 20 arası değerler, “kernel” parametresine {linear, rbf, sigmoid} değerleri verilirken “gamma” parametresine {scale, auto} değerleri verilerek algoritmanın en iyi sonuçları elde edilebilmesi hedeflenmiştir. Bu parametrelerin değerleri çaprazlandığında her bir bağımlı değişken için 120 adet farklı sonuç ortaya çıkmaktadır. Bu sonuçlar en yüksek test verisi doğruluk oranına göre sıralandığında en iyi skorları veren 5 modele Tablo 4.4’te ışık tutulmuştur.

Tablo 4.4. En Başarılı SVM Sonuçları ve Parametreleri

	C	kernel	gamma	accuracy_train	cohen	f1	accuracy_test
Bölüm	1	rbf	scale	0.576923077	0.255986317	0.243092511	0.355555556
	1	rbf	auto	0.733974359	0.262016965	0.247415657	0.355555556
	1	sigmoid	scale	0.397435897	0.2622024	0.256608255	0.355555556
	2	rbf	scale	0.875	0.282748092	0.295442334	0.355555556
	2	sigmoid	auto	0.458333333	0.283754116	0.290731117	0.355555556
Grup 1	1	rbf	scale	0.628205128	0.348830977	0.38447249	0.466666667
	1	rbf	auto	0.769230769	0.33836858	0.376589542	0.459259259
	1	sigmoid	scale	0.432692308	0.329683036	0.33844409	0.459259259
	2	sigmoid	auto	0.426282051	0.363166397	0.388109827	0.459259259

	3	sigmoid	scale	0.554487179	0.343626807	0.365363352	0.451851852
Grup 2	3	rbf	scale	0.724358974	0.571119134	0.661657837	0.674074074
	1	linear	scale	0.698717949	0.565232949	0.660185292	0.666666667
	1	linear	auto	0.698717949	0.565232949	0.660185292	0.666666667
	1	rbf	scale	0.673076923	0.559623052	0.644328059	0.666666667
	2	rbf	scale	0.701923077	0.560769286	0.65091376	0.666666667
Grup 3	2	rbf	scale	0.666666667	0.613908331	0.718688616	0.718518519
	3	rbf	scale	0.673076923	0.61472024	0.719041145	0.718518519
	4	rbf	scale	0.676282051	0.614314713	0.718138488	0.718518519
	5	rbf	scale	0.685897436	0.614314713	0.718138488	0.718518519
	12	rbf	scale	0.698717949	0.616419919	0.712603622	0.718518519

4 bağımlı değişkenin her birindeki en iyi skorları veren model en başarılı SVM modeli olarak alınmış ve diğer makine öğrenmesi algoritmalarının modelleri ile karşılaştırılmıştır. Parametre çaprazlamalarından elde edilen tüm değerler EK-A’da verilmiştir.

4.2.4. Gradyan Arttırma Makineleri Parametreleri ve Skorları

Gradyan Arttırma Makineleri algoritmasının parametreleri incelendiğinde sonuca direkt etkisi olan 3 parametre ön plana çıkmaktadır. Bu parametrelerden ilki olan “learning_rate” parametresi, her ağacın modele katkısı olarak kabul edilmektedir. Bir diğer önemli parametre olan “n_estimators” parametresi ise, gerçekleştirilecek arttırma aşamalarına karşılık gelmektedir. 3. önemli parametre olan “max_depth” parametresi ise, bir ağaçtaki düğüm sayısını sınırlayan maksimum derinliğe işaret etmektedir [56]. Bu veri setinde “learning_rate” parametresine {0.001, 0.005, 0.007, 0.01, 0.05, 0.07, 0.1, 0.3, 0.5} değerleri, “n_estimators” parametresine {100, 300, 500, 700, 900} değerleri verilirken “max_depth” parametresine {2, 4, 6} değerleri verilerek algoritmanın en iyi sonuçları elde edilebilmesi hedeflenmiştir. Bu parametrelerin değerleri çaprazlandığında her bir bağımlı değişken için 135 adet farklı sonuç ortaya çıkmaktadır. Bu sonuçlar en yüksek test verisi doğruluk oranına göre sıralandığında en iyi skorları veren 5 modele Tablo 4.5’te ışık tutulmuştur.

Tablo 4.5. En Başarılı GBM Sonuçları ve Parametreleri

	learning_rate	n_estimators	max_depth	accuracy_train	cohen	f1	accuracy_test
--	---------------	--------------	-----------	----------------	-------	----	---------------

Bölüm	0.001	300	2	0.599358974	0.24071991	0.25942538	0.333333333
	0.001	700	2	0.743589744	0.2373818	0.268241007	0.318518519
	0.005	300	2	0.900641026	0.240288031	0.28646687	0.311111111
	0.005	700	2	0.990384615	0.24946198	0.29467303	0.311111111
	0.007	300	2	0.955128205	0.244130042	0.285674573	0.311111111
Grup 1	0.005	300	2	0.830128205	0.327257229	0.357389771	0.437037037
	0.001	500	2	0.628205128	0.291481631	0.329205028	0.422222222
	0.005	100	2	0.631410256	0.291481631	0.329205028	0.422222222
	0.01	100	2	0.75	0.304031725	0.342952226	0.422222222
	0.01	700	2	1	0.317352621	0.361699225	0.414814815
Grup 2	0.3	300	4	1	0.51605965	0.615298652	0.62962963
	0.001	900	2	0.746794872	0.497481936	0.599271826	0.622222222
	0.007	100	2	0.711538462	0.486241218	0.591550355	0.614814815
	0.01	100	2	0.762820513	0.490455106	0.595327894	0.614814815
	0.1	700	6	1	0.4963048	0.60370498	0.614814815
Grup 3	0.01	300	2	0.823717949	0.557545732	0.67687647	0.681481481
	0.001	700	2	0.717948718	0.536408335	0.654475413	0.674074074
	0.005	300	6	0.996794872	0.548803646	0.668421876	0.674074074
	0.005	500	2	0.791666667	0.546876192	0.668694592	0.674074074
	0.005	700	2	0.83974359	0.548288973	0.66943313	0.674074074

4 bağımlı değişkenin her birindeki en iyi skorları veren model en başarılı GBM modeli olarak alınmış ve diğer makine öğrenmesi algoritmalarının modelleri ile karşılaştırılmıştır. Parametre çaprazlamalarından elde edilen tüm değerler EK-A’da verilmiştir.

4.2.5. Aşırı Arttırma Parametreleri ve Skorları

Aşırı Arttırma algoritmasının parametreleri incelendiğinde sonuca direkt etkisi olan 4 parametre ön plana çıkmaktadır. Bu parametrelerden ilki olan “learning_rate” parametresi, her ağacın modele katkısı olarak kabul edilmektedir. Bir diğer önemli parametre olan “n_estimators” parametresi ise, gerçekleştirilecek arttırma aşamalarına karşılık gelmektedir. 3. önemli parametre olan “max_depth” parametresi ise, bir ağaçtaki düğüm sayısını sınırlayan maksimum derinliğe işaret etmektedir. Son önemli parametre ise “subsample” parametresidir ve eğitimdeki alt örnek kümelenmesi oranı demektir [57]. Bu veri setinde “learning_rate” parametresine {0.001, 0.005, 0.01, 0.05, 0.1, 0.3} değerleri, “n_estimators” parametresine {100, 400, 700, 1000} değerleri, “max_depth” parametresine {2, 4, 6, 8} değerleri verilirken “subsample”

parametresine {0.2, 0.4, 0.6, 0.8} değerleri verilerek algoritmanın en iyi sonuçları elde edilebilmesi hedeflenmiştir. Bu parametrelerin değerleri çaprazlandığında her bir bağımlı değişken için 384 adet farklı sonuç ortaya çıkmaktadır. Bu sonuçlar en yüksek test verisi doğruluk oranına göre sıralandığında en iyi skorları veren 5 modele Tablo 4.6’da ışık tutulmuştur.

Tablo 4.6. En Başarılı XGBoost Sonuçları ve Parametreleri

	learn ing_ rate	n_ est imators	max_ depth	sub sam ple	accuracy_ train	cohen	f1	accuracy_ test
Bölüm	0.001	100	2	0.4	0.448717949	0.355268871	0.326569864	0.42962963
	0.001	100	4	0.4	0.461538462	0.355588618	0.324100728	0.42962963
	0.001	100	6	0.4	0.461538462	0.355588618	0.324100728	0.42962963
	0.001	100	8	0.4	0.461538462	0.355588618	0.324100728	0.42962963
	0.005	100	4	0.6	0.66025641	0.346627458	0.339520533	0.414814815
Grup 1	0.05	100	2	0.4	0.820512821	0.440704298	0.45128124	0.525925926
	0.005	1000	2	0.4	0.817307692	0.426470588	0.434454466	0.518518519
	0.005	1000	4	0.4	0.881410256	0.431155193	0.445024566	0.518518519
	0.01	400	2	0.4	0.801282051	0.427331463	0.432727884	0.518518519
	0.005	700	4	0.4	0.842948718	0.42206655	0.436309331	0.511111111
Grup 2	0.001	1000	6	0.2	0.730769231	0.541015625	0.627928253	0.651851852
	0.001	1000	8	0.2	0.730769231	0.541015625	0.627928253	0.651851852
	0.005	400	2	0.2	0.689102564	0.537940577	0.625584835	0.651851852
	0.01	100	2	0.8	0.708333333	0.543426639	0.634106655	0.651851852
	0.001	1000	2	0.2	0.669871795	0.526661797	0.615468158	0.644444444
Grup 3	0.005	400	2	0.6	0.717948718	0.651639344	0.746573612	0.748148148
	0.005	400	2	0.8	0.717948718	0.651797906	0.745416035	0.748148148
	0.001	1000	2	0.4	0.698717949	0.630502547	0.733420757	0.733333333
	0.005	100	2	0.4	0.692307692	0.62812763	0.72931369	0.733333333
	0.005	400	2	0.4	0.705128205	0.633235228	0.734623484	0.733333333

4 bağımlı değişkenin her birindeki en iyi skorları veren model en başarılı XGBoost modeli olarak alınmış ve diğer makine öğrenmesi algoritmalarının modelleri ile karşılaştırılmıştır. Parametre çaprazlamalarından elde edilen tüm değerler EK-A’da verilmiştir.

4.2.6. Hafif Gradyan Arttırma Makineleri Parametreleri ve Skorları

Hafif Gradyan Arttırma Makineleri algoritmasının parametreleri incelendiğinde sonuca direkt etkisi olan 3 parametre ön plana çıkmaktadır. Bu parametrelerden ilki olan “learning_rate” parametresi, her ağacın modele katkısı olarak kabul edilmektedir. Bir diğer önemli parametre olan “n_estimators” parametresi ise, gerçekleştirilecek arttırma aşamalarına karşılık gelmektedir. 3. önemli parametre olan “max_depth” parametresi ise, bir ağaçtaki düğüm sayısını sınırlayan maksimum derinliğe işaret etmektedir [58]. Bu veri setinde “learning_rate” parametresine {0.001, 0.005, 0.007, 0.01, 0.05, 0.07, 0.1, 0.3, 0.5} değerleri, “n_estimators” parametresine {100, 300, 500, 700} değerleri verilirken “max_depth” parametresine {2, 3, 4, 5} değerleri verilerek algoritmanın en iyi sonuçları elde edilebilmesi hedeflenmiştir. Bu parametrelerin değerleri çaprazlandığında her bir bağımlı değişken için 144 adet farklı sonuç ortaya çıkmaktadır. Bu sonuçlar en yüksek test verisi doğruluk oranına göre sıralandığında en iyi skorları veren 5 modele Tablo 4.7’de ışık tutulmuştur.

Tablo 4.7. En Başarılı LGBM Sonuçları ve Parametreleri

	learnin g _rate	n_esti m ators	max_ dept h	accuracy_ train	cohen	f1	accuracy_te st
Bölüm	0.001	500	3	0.810897436	0.33995544	0.337058364	0.414814815
	0.005	100	3	0.810897436	0.34064915	0.337523295	0.414814815
	0.001	500	5	0.858974359	0.317088217	0.320967333	0.392592593
	0.001	700	2	0.788461538	0.317425083	0.319379305	0.392592593
	0.005	100	5	0.858974359	0.316961807	0.321752967	0.392592593
Grup 1	0.007	700	2	0.996794872	0.362150428	0.39420934	0.451851852
	0.05	500	4	1	0.366197183	0.413862589	0.451851852
	0.005	700	2	0.971153846	0.351501954	0.385214913	0.444444444
	0.01	500	2	0.996794872	0.354643381	0.389110607	0.444444444
	0.5	100	3	1	0.356652688	0.405472334	0.444444444
Grup 2	0.007	100	3	0.698717949	0.508375819	0.600596069	0.62962963
	0.001	700	2	0.682692308	0.497665256	0.59223383	0.622222222
	0.007	100	2	0.685897436	0.497665256	0.59223383	0.622222222
	0.001	700	3	0.698717949	0.488375483	0.590837663	0.614814815
	0.05	300	3	1	0.497818156	0.605402775	0.614814815

Grup 3	0.005	300	2	0.708333333	0.611628435	0.71927231	0.718518519
	0.01	100	5	0.772435897	0.613267998	0.720043742	0.718518519
	0.005	300	3	0.717948718	0.606090079	0.713683035	0.711111111
	0.01	100	3	0.721153846	0.601739788	0.712906147	0.711111111
	0.001	700	5	0.740384615	0.561111541	0.669350339	0.688888889

4 bağımlı değişkenin her birindeki en iyi skorları veren model en başarılı LGBM modeli olarak alınmış ve diğer makine öğrenmesi algoritmalarının modelleri ile karşılaştırılmıştır. Parametre çaprazlamalarından elde edilen tüm değerler EK-A’da verilmiştir.

4.2.7. Kategorik Arttırma Parametreleri ve Skorları

Kategorik Arttırma algoritmasının parametreleri incelendiğinde sonuca direkt etkisi olan 3 parametre ön plana çıkmaktadır. Bu parametrelerden ilki olan “learning_rate” parametresi, her ağacın modele katkısı olarak kabul edilmektedir. Bir diğer önemli parametre olan “iterations” parametresi ise, oluşturulacak maksimum ağaç sayısına karşılık gelmektedir. 3. önemli parametre olan “depth” parametresi ise, bir ağaçtaki düğüm sayısını sınırlayan maksimum derinliğe işaret etmektedir [59]. Bu veri setinde “learning_rate” parametresine {0.001, 0.005, 0.01, 0.05, 0.1, 0.3} değerleri, “iterations” parametresine {100, 200, 500} değerleri verilirken “depth” parametresine {2, 3, 4, 5} değerleri verilerek algoritmanın en iyi sonuçları elde edilebilmesi hedeflenmiştir. Bu parametrelerin değerleri çaprazlandığında her bir bağımlı değişken için 72 adet farklı sonuç ortaya çıkmaktadır. Bu sonuçlar en yüksek test verisi doğruluk oranına göre sıralandığında en iyi skorları veren 5 modele Tablo 4.8’te ışık tutulmuştur.

Tablo 4.8. En Başarılı CatBoost Sonuçları ve Parametreleri

	learning_rate	iterations	depth	accuracy_train	cohen	f1	accuracy_test
Bölüm	0.05	200	3	0.698717949	0.315652819	0.298594412	0.392592593
	0.05	200	4	0.804487179	0.314466188	0.299999286	0.392592593
	0.05	200	5	0.897435897	0.318097819	0.308661074	0.392592593
	0.05	200	2	0.544871795	0.29854764	0.281860861	0.385185185
	0.1	100	2	0.522435897	0.299993753	0.287610186	0.385185185

Grup 1	0.05	200	3	0.730769231	0.376443418	0.400765069	0.481481481
	0.1	200	2	0.724358974	0.388942774	0.414855702	0.481481481
	0.05	500	3	0.91025641	0.379491163	0.412262505	0.474074074
	0.05	500	2	0.804487179	0.370588616	0.403549577	0.466666667
	0.1	100	3	0.740384615	0.359978929	0.389689816	0.466666667
Grup 2	0.01	500	5	0.782051282	0.530638853	0.620720259	0.644444444
	0.1	200	4	0.926282051	0.537473233	0.634755527	0.644444444
	0.05	200	2	0.733974359	0.51284642	0.612160274	0.62962963
	0.05	200	4	0.823717949	0.517305492	0.61976251	0.62962963
	0.05	500	2	0.807692308	0.516787172	0.613894986	0.62962963
Grup 3	0.001	200	3	0.650641026	0.61070844	0.698817497	0.725925926
	0.005	100	5	0.685897436	0.607107299	0.698566924	0.718518519
	0.005	200	2	0.647435897	0.601150676	0.69265113	0.718518519
	0.01	100	2	0.647435897	0.601491494	0.693153269	0.718518519
	0.01	200	2	0.653846154	0.601491494	0.693153269	0.718518519

4 bağımlı değişkenin her birindeki en iyi skorları veren model en başarılı CatBoost modeli olarak alınmış ve diğer makine öğrenmesi algoritmalarının modelleri ile karşılaştırılmıştır. Parametre çaprazlamalarından elde edilen tüm değerler EK-A’da verilmiştir.

4.2.8. Yapay Sinir Ağları Parametreleri ve Skorları

Yapay Sinir Ağları algoritmasının parametreleri incelendiğinde sonuca direkt etkisi olan 2 parametre ön plana çıkmaktadır. Bu parametrelerden ilki olan “alpha” parametresi, ceza yani regülerizasyon terimini işaret etmektedir. Bir diğer önemli parametre olan “hidden_layer_sizes” parametresi ise, gizli katmandaki nöron sayısına karşılık gelmektedir [60]. Bu veri setinde “alpha” parametresine {0.0001, 0.0005, 0.001, 0.005, 0.01, 0.03, 0.05, 0.1, 1, 5, 8} değerleri verilirken “hidden_layer_sizes” parametresine {(10,10), (100,100,100), (100,100), (3,5), (10,10,10), (50,50), (50,50,50)} değerleri verilerek algoritmanın en iyi sonuçları elde edilebilmesi hedeflenmiştir. Bu parametrelerin değerleri çaprazlandığında her bir bağımlı değişken için 77 adet farklı sonuç ortaya çıkmaktadır. Bu sonuçlar en yüksek test verisi doğruluk oranına göre sıralandığında en iyi skorları veren 5 modele Tablo 4.9’da ışık tutulmuştur.

Tablo 4.9. En Başarılı ANN Sonuçları ve Parametreleri

	alpha	hidden_layer _sizes	accuracy_train	cohen	f1	accuracy_test
Bölüm	8	"(50,50,50)"	0.333333333	0.26612097	0.24081868	0.355555556
	8	"(100,100,100)"	0.355769231	0.258010118	0.236337384	0.348148148
	8	"(10,10,10)"	0.230769231	0.22241131	0.204781145	0.348148148
	5	"(3,5)"	0.266025641	0.223937476	0.198502828	0.340740741
	0.0001	"(3,5)"	0.269230769	0.223344413	0.214432222	0.333333333
Grup 1	8	"(100,100,100)"	0.455128205	0.354281539	0.33748465	0.466666667
	8	"(100,100)"	0.551282051	0.349821022	0.38404089	0.451851852
	8	"(50,50)"	0.525641026	0.352476018	0.368942425	0.451851852
	5	"(10,10)"	0.41025641	0.310051107	0.314047305	0.444444444
	8	"(50,50,50)"	0.435897436	0.319647897	0.308961533	0.444444444
Grup 2	0.005	"(10,10,10)"	0.625	0.567905725	0.646267664	0.674074074
	5	"(50,50,50)"	0.615384615	0.556050862	0.629929458	0.666666667
	1	"(100,100)"	0.782051282	0.557786798	0.655553652	0.659259259
	0.1	"(50,50)"	0.794871795	0.545649839	0.641414552	0.651851852
	5	"(50,50)"	0.66025641	0.541413703	0.632175121	0.651851852
Grup 3	0.0001	"(50,50)"	0.727564103	0.627461217	0.729256326	0.725925926
	0.001	"(10,10,10)"	0.676282051	0.612625538	0.707753904	0.718518519
	0.0001	"(10,10,10)"	0.657051282	0.602611518	0.696105411	0.711111111
	0.001	"(50,50,50)"	0.772435897	0.607470365	0.713832043	0.711111111
	0.01	"(100,100)"	0.775641026	0.609015298	0.715028106	0.711111111

4 bağımlı değişkenin her birindeki en iyi skorları veren model en başarılı ANN modeli olarak alınmış ve diğer makine öğrenmesi algoritmalarının modelleri ile karşılaştırılmıştır. Parametre çaprazlamalarından elde edilen tüm değerler EK-A’da verilmiştir.

4.2.9. Sınıflandırma ve Regresyon Ağaçları Parametreleri ve Skorları

Sınıflandırma ve Regresyon Ağaçları algoritmasının parametreleri incelendiğinde sonuca direkt etkisi olan 2 parametre ön plana çıkmaktadır. Bu parametrelerden ilki olan “max_depth” parametresi, ağacın maksimum derinliğine belirtmektedir. Bir diğer önemli parametre olan “min_samples_split” parametresi ise, bir düğümü bölmek için gereken örnek sayısını ifade etmektedir [61]. Bu veri setinde “max_depth” parametresine 1 ile 20 arasındaki değerler verilirken “min_samples_split” parametresine 2 ile 50 arasındaki çift sayı değerleri verilerek algoritmanın en iyi sonuçları elde edilebilmesi hedeflenmiştir. Bu parametrelerin

değerleri çaprazlandığında her bir bağımlı değişken için 500 adet farklı sonuç ortaya çıkmaktadır. Bu sonuçlar en yüksek test verisi doğruluk oranına göre sıralandığında en iyi skorları veren 5 modele Tablo 4.10’da ışık tutulmuştur.

Tablo 4.10. En Başarılı CART Sonuçları ve Parametreleri

	max_ depth	min_samples _split	accuracy_train	cohen	f1	accuracy_test
Bölüm	2	2	0.269230769	0.247453066	0.205719579	0.355555556
	2	4	0.269230769	0.247453066	0.205719579	0.355555556
	2	6	0.269230769	0.247453066	0.205719579	0.355555556
	2	8	0.269230769	0.247453066	0.205719579	0.355555556
	2	10	0.269230769	0.247453066	0.205719579	0.355555556
Grup 1	6	12	0.663461538	0.320669267	0.374269316	0.407407407
	4	2	0.544871795	0.292324618	0.328564448	0.4
	4	4	0.544871795	0.292324618	0.328564448	0.4
	4	6	0.544871795	0.292324618	0.328564448	0.4
	4	8	0.541666667	0.292553536	0.330247949	0.4
Grup 2	4	24	0.637820513	0.428508868	0.545354967	0.57037037
	4	26	0.637820513	0.428508868	0.545354967	0.57037037
	4	28	0.637820513	0.428508868	0.545354967	0.57037037
	4	30	0.637820513	0.428508868	0.545354967	0.57037037
	4	32	0.637820513	0.428508868	0.545354967	0.57037037
Grup 3	6	8	0.791666667	0.525430067	0.649918964	0.651851852
	6	10	0.78525641	0.515839809	0.643187444	0.644444444
	2	2	0.628205128	0.493917833	0.602329586	0.637037037
	2	4	0.628205128	0.493917833	0.602329586	0.637037037
	2	6	0.628205128	0.493917833	0.602329586	0.637037037

4 bağımlı değişkenin her birindeki en iyi skorları veren model en başarılı CART modeli olarak alınmış ve diğer makine öğrenmesi algoritmalarının modelleri ile karşılaştırılmıştır. Parametre çaprazlamalarından elde edilen tüm değerler EK-A’da verilmiştir.

4.2.10. Doğrusal Ayrım Analizi Parametreleri ve Skorları

Doğrusal Ayrım Analizi algoritmasının değerlendirmeye değer tek parametresi olan “solver” parametresi kullanılacak çözücüyü ifade etmektedir [62]. Bu

parametreye {svd, lsqr, eigen} değerleri verilerek ortaya çıkan 3 sonuç incelenmiş ve en yüksek test verisi doğruluk oranına göre Tablo 4.11’de sıralanmıştır.

Tablo 4.11. En Başarılı LDA Sonuçları ve Parametreleri

	solver	accuracy_train	cohen	f1	accuracy_test
Bölüm	svd	0.711538462	0.140279498	0.190877811	0.2
	lsqr	0.711538462	0.143159379	0.194820867	0.2
	eigen	0.711538462	0.143159379	0.194820867	0.2
Grup 1	svd	0.647435897	0.405361188	0.461395419	0.481481481
	lsqr	0.647435897	0.383137206	0.446509552	0.459259259
	eigen	0.647435897	0.383137206	0.446509552	0.459259259
Grup 2	svd	0.641025641	0.540490711	0.644321744	0.644444444
	lsqr	0.634615385	0.531946508	0.637530583	0.637037037
	eigen	0.634615385	0.531946508	0.637530583	0.637037037
Grup 3	svd	0.641025641	0.598751672	0.708008523	0.703703704
	lsqr	0.641025641	0.590091091	0.700833241	0.696296296
	eigen	0.641025641	0.590091091	0.700833241	0.696296296

4 bağımlı değişkenin her birindeki en iyi skorları veren model en başarılı LDA modeli olarak alınmış ve diğer makine öğrenmesi algoritmalarının modelleri ile karşılaştırılmıştır.

4.3. Hiyerarşik Kümeleme ve Dendrogram Yapıları

Veri seti 10 farklı denetimli makine öğrenmesi yöntemine sokulduktan sonra son olarak denetimsiz bir makine öğrenmesi yöntemi olan “Hiyerarşik Kümeleme, orijinal adıyla Hierarchical Clustering (HC)” yöntemi ile {complete, average, single, median, ward, centroid} metotları ile 6 dendrogram oluşturulmuştur. Single metodu en yakın komşuyu, complete metodu en uzak komşuyu, average metodu uzaklıkların ortalamalarını, centroid ve median metodu geometrik merkezleri, ward metodu ise kareleri toplamındaki artışı baz alarak dendrogramı oluşturmaktadır.

Bu metotların her biri sayısal alanı seçmiş öğrencileri eşit ağırlık seçmişlerden en başta ayırmaktadır. Yani “sayısal mı” değişkeninin önemini baştan tespit edebilmektedir. Dendrogramlar incelendiğinde öğrenci notları yakın olan öğrencilerin alt dallarda gruplandırıldığı ve bu öğrencilerin kısmen de olsa benzer bölümleri seçtiği görülmektedir (EK-B).

5. SONUÇ VE ÖNERİLER

Makine öğrenmesi algoritmalarının her birinin en önemli parametrelerinde oynamalar yapıp bütün sonuçlar kaydedildikten sonra 4 etiketleme yaklaşımı için de verdiği en iyi sonuçlar alınıp karşılaştırmalar yapılmıştır. En iyi sonuçlar alınırken test verisi doğruluğu haricinde modelin aşırı öğrenme yapıp yapmadığına ve Cohen ile F1 skorlarının test verisi ile yakın ilişkisine de bakılmıştır.

Bağımlı değişkenin “Bölüm” değişkeni olarak kabul edilip her bir makine öğrenmesi algoritması aracılığıyla ölçülen tahmin başarılarının en iyi sonuçları raporlanmak üzere kaydedilmiştir ve Tablo 5.1’de gösterilmektedir.

Tablo 5.1. Bölüm Etiketi ile En İyi Tahmin Başarıları

Yöntem	Eğitim Verisi Doğruluğu	Cohen Skoru	F1 Skoru	Test Verisi Doğruluğu
Rasgele Orman (RF)	1	0.332	0.314	0.407
K En Yakın Komşu (KNN)	0.269	0.246	0.232	0.356
Destek Vektör Makineleri (SVM)	0.458	0.284	0.290	0.356
Gradyan Arttırma Makineleri (GBM)	0.599	0.241	0.259	0.333
Aşırı Gradyan Arttırma (XGBoost)	0.449	0.355	0.327	0.430
Hafif Gradyan Arttırma (LGBM)	0.811	0.340	0.337	0.415
Kategorik Arttırma (CatBoost)	0.699	0.316	0.299	0.393
Yapay Sinir Ağları (ANN)	0.333	0.266	0.241	0.356
Sınıflandırma Ağaçları (CART)	0.269	0.247	0.206	0.356

Doğrusal Ayrım Analizi (LDA)	0.712	0.140	0.191	0.200
---------------------------------	-------	-------	-------	-------

Makine öğrenmesi sonucunda LGBM F1 skorunda %33,7 ile en yüksek sonucu veren model olsa da Cohen skorunda ve test verisinin doğruluğunda XGBoost daha yüksek sonuçlar vermektedir. Buna ek olarak LGBM %81,1 ile çok yüksek eğitim verisi doğruluğu vermektedir ve bu sonuç aşırı öğrenme olduğuna işaret etmektedir. En yüksek sonuçlardan birisini veren RF de %100 oranında eğitim kümesinde başarı oranı vererek aşırı öğrenmeye maruz kaldığını açık etmektedir. Bu sebeple hem %35,5 ile en yüksek Cohen skoru ve %43 ile test verisi doğruluğunu verdiği için hem de %44,9 ile eğitim verisi doğruluğu test verisine yakın bir değer olduğu için yani aşırı öğrenme gerçekleşmediği için en iyi sonuç veren model XGBoost kabul edilmektedir. %43 düşük bir oran gibi gözükse de 43 sınıflı bir bağımlı değişkende bu oranın çıkması çok da düşük bir oran olmadığını işaret etmektedir.

Bağımlı değişkenin “Grup 1” değişkeni olarak kabul edilip her bir makine öğrenmesi algoritması aracılığıyla ölçülen tahmin başarılarının en iyi sonuçları raporlanmak üzere kaydedilmiştir Tablo 5.2’de gösterilmektedir.

Tablo 5.2. Grup 1 Etiketli ile En İyi Tahmin Başarıları

Yöntem	Eğitim Verisi Doğruluğu	Cohen Skoru	F1 Skoru	Test Verisi Doğruluğu
Rasgele Orman (RF)	1	0,399	0,422	0,496
K En Yakın Komşu (KNN)	0,417	0,292	0,344	0,430
Destek Vektör Makineleri (SVM)	0,426	0,363	0,388	0,459
Gradyan Arttırma Makineleri (GBM)	0,830	0,327	0,357	0,437
Aşırı Gradyan Arttırma (XGBoost)	0,820	0,441	0,451	0,526
Hafif Gradyan Arttırma (LGBM)	0,997	0,362	0,394	0,452

Kategorik Arttırma (CatBoost)	0,724	0,389	0,415	0,481
Yapay Sinir Ağları (ANN)	0,455	0,354	0,337	0,467
Sınıflandırma Ağaçları (CART)	0,663	0,321	0,374	0,407
Doğrusal Ayrım Analizi (LDA)	0,647	0,405	0,461	0,481

Makine öğrenmesi sonucunda en yüksek F1 skorunu %46,1 ile LDA verse de hem Cohen skorunda hem de test verisinin doğruluk oranında XGBoost'un gerisinde kalmaktadır. CatBoost ise %48,1 ile yüksek bir test verisi doğruluk oranı verse de %38,9 Cohen skoru ve %41,5 F1 skoru ile hem LDA'nın hem de XGBoost'un gerisinde kalmaktadır. XGBoost'un eğitim verisinin doğruluk oranı %82 ile LDA'ya göre yüksek çıksa da test verisinin doğruluk oranı %52,6 ile en yüksek orandır. Aşırı öğrenmeye yakın olsa da yüksek Cohen ve test verisi doğruluk skorları sebebiyle XGBoost en başarılı model olarak görülmektedir. %53,6 düşük bir oran gibi gözükse de 23 sınıflı bir bağımlı değişkende bu oranın çıkması çok da düşük bir oran olmadığını işaret etmektedir.

Bağımlı değişkenin "Grup 2" değişkeni olarak kabul edilip her bir makine öğrenmesi algoritması aracılığıyla ölçülen tahmin başarılarının en iyi sonuçları raporlanmak üzere kaydedilmiştir Tablo 5.3'te gösterilmektedir.

Tablo 5.3. Grup 2 Etiketli ile En İyi Tahmin Başarıları

Yöntem	Eğitim Verisi Doğruluğu	Cohen Skoru	F1 Skoru	Test Verisi Doğruluğu
Rasgele Orman (RF)	0,997	0,563	0,650	0,667
K En Yakın Komşu (KNN)	0,631	0,597	0,667	0,696
Destek Vektör Makineleri (SVM)	0,724	0,571	0,662	0,674

Gradyan Arttırma Makineleri (GBM)	0,747	0,497	0,599	0,622
Aşırı Gradyan Arttırma (XGBoost)	0,709	0,543	0,634	0,651
Hafif Gradyan Arttırma (LGBM)	0,699	0,508	0,601	0,630
Kategorik Arttırma (CatBoost)	0,782	0,531	0,621	0,644
Yapay Sinir Ağları (ANN)	0,626	0,568	0,646	0,674
Sınıflandırma Ağaçları (CART)	0,638	0,429	0,545	0,570
Doğrusal Ayrım Analizi (LDA)	0,641	0,540	0,644	0,644

Makine öğrenmesi sonucunda %59,7 ile en yüksek Cohen skorunu, %66,7 ile en yüksek F1 skorunu ve %69,6 ile en yüksek test verisinin doğruluğunu veren KNN, %63,1 ile eğitim verisinin doğruluk oranında da düşük bir oran vererek aşırı öğrenmeye maruz kalmadığını göstermektedir. KNN'ye benzer şekilde %72,4 ile düşük eğitim verisinin doğruluk oranı veren SVM %57,1 Cohen skoru, %66,2 F1 skoru ve %67,4 test verisinin doğruluğu ile başarılı bir model ortaya koymaktadır. SVM ile aynı test verisi doğruluk oranını veren ANN de %62,6 ile düşük bir eğitim verisi doğruluk oranı ve %56,8 Cohen, %64,6 F1 skoru ile yüksek skorlar ortaya koymaktadır. Ancak KNN bütün metriklerde SVM'den daha başarılı sonuçlar verdiğinden en başarılı model olarak görülmektedir. 9 sınıflı bir bağımlı değişken üzerinde yapılan ölçümler sonucunda KNN'nin %69,6 test verisi doğruluk oranı modelin başarılı sonuçlar verdiğine işaret etmektedir.

Bağımlı değişkenin “Grup 3” değişkeni olarak kabul edilip her bir makine öğrenmesi algoritması aracılığıyla ölçülen tahmin başarılarının en iyi sonuçları raporlanmak üzere kaydedilmiştir Tablo 5.4’de gösterilmektedir.

Tablo 5.4. Grup 3 Etiketli ile En İyi Tahmin Başarıları

Yöntem	Eğitim Verisi Doğruluğu	Cohen Skoru	F1 Skoru	Test Verisi Doğruluğu
Rasgele Orman (RF)	0,913	0,666	0,758	0,756
K En Yakın Komşu (KNN)	0,667	0,630	0,725	0,733
Destek Vektör Makineleri (SVM)	0,667	0,614	0,719	0,719
Gradyan Arttırma Makineleri (GBM)	0,823	0,558	0,677	0,681
Aşırı Gradyan Arttırma (XGBoost)	0,718	0,652	0,747	0,748
Hafif Gradyan Arttırma (LGBM)	0,708	0,611	0,719	0,719
Kategorik Arttırma (CatBoost)	0,651	0,611	0,699	0,726
Yapay Sinir Ağları (ANN)	0,728	0,627	0,729	0,726
Sınıflandırma Ağaçları (CART)	0,792	0,525	0,650	0,652
Doğrusal Ayrım Analizi (LDA)	0,641	0,599	0,708	0,704

Makine öğrenmesi sonucunda en yüksek test verisinin doğruluk oranını %75,6 ile RF vermektedir. Benzer şekilde %66,6 ile en yüksek Cohen skorunu ve %75,8 ile en yüksek F1 skorunu da RF modeli vermektedir. Ancak RF önceki ölçümlerde de olduğu gibi %91,3 ile yüksek bir eğitim verisi doğruluk oranı vermektedir. Test verisi doğruluk oranı da yüksek olduğu için bu değerler birbirine yakın olsa RF'den sonra %65,2 ile en yüksek Cohen, %74,7 ile en yüksek F1 ve %74,8 ile en yüksek test verisi doğruluk skorlarını veren XGBoost %71,8 ile gayet düşük bir eğitim kümesi doğruluk oranı vermektedir. KNN modeli de gayet iyi sonuçlar verse de 3 ölçüm kriterinde de XGBoost daha üstün gözükmetedir. Bu sebeple de XGBoost en başarılı model olarak

kabul edilmektedir. 6 etiketli bağımlı değişken üzerinden yapılan bu ölçümlerde %74,8 başarılı bir oran olarak kabul edilmektedir.

Veri seti 4 farklı bağımlı değişken üzerinden 4 kez makine öğrenmesine sokulduğunda makine öğrenmesi modellerinin tahmin başarıları kısmen değişmektedir. Bölüm ve Grup 1 etiketlerinde en iyi tahminleri XGBoost ve CatBoost yapmasına rağmen Grup 2 etiketindeki modellere bakıldığında en iyi modeller KNN, SVM ve ANN olarak göze çarpmaktadır. Son etiket olan Grup 3 de ise XGBoost tekrar en iyi sonucu verirken KNN, CatBoost ve ANN de başarılı sonuç vermektedir.

ANN'nin çalışma mantığı ele alındığında multi sınıflandırmada etiketteki sınıf sayısının veri setinin büyüklüğüne oranı ne kadar düşük olursa o kadar iyi sonuçlar vereceği düşünülmektedir. KNN de benzer şekilde veri seti büyürse tahminlerinde daha da iyi sonuçlar verebileceğini işaret etmektedir. RF'nin sonuçları incelendiğinde veri setinin büyüklüğü ve multi sınıflandırma yapıldığından dolayı her seferinde eğitim verisi üzerinden model oluştururken aşırı öğrenmektedir. Aşırı öğrenme yaptığı için de sonuçları dikkate alınmamaktadır. GBM ise hiçbir tahmininde kendi mantığından geliştirilmiş olan diğer makine öğrenmesi yöntemlerine başarı olarak yaklaşmamaktadır. Bu yöntemlerden LGBM hız olarak diğerlerinden üstün performans sergilese de tahmin başarısı olarak çok şey feda etmekte ve benzer modellerinden geride kalmaktadır. CatBoost ise XGBoost kadar olmasa da gayet başarılı sonuçlar göstermektedir. SVM yönteminin çalışma mantığı göz önüne alındığında özellikle son 2 etikette daha yüksek tahmin başarısı vermesi beklenirken sonuçlar incelendiğinde bu beklentiyi karşılayamadığı görülmektedir. CART yöntemi de hem GBM ailesi içerisinde hem de RF içerisinde kullanıldığı için tahmin başarısında yer verilmiştir ancak sonuçlar çok yetersiz kalmaktadır. LDA ise doğrusal bir sınıflandırma yöntemi olarak genelde vasat bir performans sergilemektedir. Neredeyse bütün etiketlerde en iyi sonucu veren XGBoost ise kendi ailesindeki yöntemler bu kadar geride kalırken kendisinin bu kadar iyi sonuçlar vermesini regülerize formlar oluşturarak aşırı öğrenmenin önüne geçmesine borçludur. XGBoost'un bu başarısının rasgele olmadığını internet ortamında düzenlenen ödüllü makine öğrenmesi yarışmalarının da çoğunda XGBoost kullanan yarışmacıların ödülleri kazanması da göstermektedir.

Tezde kullanılan veri setinin sınırlı büyüklükte olması başarı oranlarını olumsuz yönde etkilemektedir. 447 veri noktasının sahip olduğu 48 bağımsız değişken yeterince dağınık olmadığından dolayı üst düzey tahmin başarıları elde edilememektedir. Öğrenci sayısı artırılıp sözel alandan tercih yapmış öğrenciler de veri setine katılırsa bağımlı değişkeni gruplandırma ihtiyacı ortadan kalkabilecek ve bölüm değişkeninde daha yüksek tahmin başarıları elde edilecektir. Özellikle yapay sinir ağları ile derin öğrenme sayesinde çok yüksek başarılar ortaya çıkabilmektedir.

Veri seti genişletilip başarı oranları arttıktan sonra en yüksek sonucu veren makine öğrenmesi modeli ile beraber bir arayüz geliştirilebilir. Bu uygulama okullardaki rehberlik öğretmenlerine yardımcı olmak amacı ile kullanılabilir. Lisenin son sınıfında meslek seçememiş öğrencilere yapay zekâ destekli meslek seçim önerisinde bulunabilir. Çıkan sonuçlara göre öğrenci hangi mesleklere yatkın olduğu konusunda bir fikir edinmiş olur ve o meslekler konusunda araştırmaya sevk edilebilir.

KAYNAKLAR

- [1] IBM Cloud Education. Artificial Intelligence (AI). <https://www.ibm.com/cloud/learn/what-is-artificial-intelligence>, 2020. (Eriřim Tarihi: 05 Kasım 2021)
- [2] Sarıgöz, Y., Çağlar, B. Endüstride Yapay Zekâ Uygulamaları. AI LABS BİLGİ TEKNOLOJİLERİ. https://www.emo.org.tr/ekler/9051cea806787fe_ek.pdf?tipi=2&turu=X&sube=14, 2016. (Eriřim Tarihi: 05 Kasım 2021)
- [3] mysoft. <https://www.mysoft.com.tr/yapay-zeka-nedir>, 2021. (Eriřim Tarihi: 5 Kasım 2021)
- [4] Javatpoint. <https://www.javatpoint.com/difference-between-artificial-intelligence-and-machine-learning>, 2017. (Eriřim Tarihi: 05 Kasım 2021)
- [5] Alpaydin, E. Introduction to machine learning. MIT press, 2020.
- [6] Kucak, D., Juricic, V., Dambic, G. Machine Learning In Education-A Survey Of Current Research Trends. Annals of DAAAM & Proceedings, 2018, 29.
- [7] Gottsegen, G. These edtech companies are using machine learning to improve human learning. <https://builtin.com/artificial-intelligence/machine-learning-in-education>, 2019. (Eriřim Tarihi: 07 Kasım 2021)
- [8] Chopra, A. 21 Vital Chatbot Statistics for 2019. <https://outgrow.co/blog/vital-chatbot-statistics>, 2019. (Eriřim Tarihi: 07 Kasım 2021)
- [9] İşler, B., Kılıç, M. Eğitimde Yapay Zekâ Kullanımı ve Geliřimi. Yeni Medya Elektronik Dergisi, 2021, 5.1: 1-11.
- [10] Lynch, M. 8 Ways Machine Learning Will Improve Education. <https://www.thetechadvocate.org/8-ways-machine-learning-will-improve-education/>, 2018. (Eriřim Tarihi: 07 Kasım 2021)
- [11] Dirik, M. Z. Öğretim İlke ve Yöntemleri. Ankara: Pegem Akademi, 2015.
- [12] Timms, M. J. Letting artificial intelligence in education out of the box: educational cobots and smart classrooms. International Journal of Artificial Intelligence in Education, 2016, 26(2), 701-712.
- [13] Anand, V. K., Rahiman, S. A., George, E. B., Huda, A. S. Recursive clustering technique for students' performance evaluation in programming courses. In 2018 Majan International Conference, 2018, 1-5.
- [14] Darji, M. J., Nakrani, T. MACHINE LEARNING BASED PREDICTION TECHNIQUE FOR STUDENT'S PERFORMANCE, 2020

- [15] Alam, M. M., Mohiuddin, K., Das, A. K., Islam, M. K., Kaonain, M. S., Ali, M. H. A reduced feature based neural network approach to classify the category of students. In Proceedings of the 2nd International Conference on Innovation in Artificial Intelligence, 2018, 28-32.
- [16] Sugiyanto, S. Predict high school students' final grades using basic machine learning. Journal of Applied Data Sciences, 2021, 2(1), 26-39.
- [17] Hasan, R., Ovy, M. K. A., Nishi, I. Z., Hakim, M. A., Hafiz, R. A Decision Support System of Selecting Groups (Science/Business Studies/Humanities) for Secondary School Students in Bangladesh. In 2020 11th International Conference on Computing, Communication and Networking Technologies (ICCCNT), 2020, 1-6.
- [18] Yadav, D. Categorical encoding using Label-Encoding and One-Hot-Encoder. <https://towardsdatascience.com/categorical-encoding-using-label-encoding-and-one-hot-encoder-911ef77fb5bd>, 2019. (Erişim Tarihi: 24 Kasım 2021)
- [19] Bock, T. What are Dummy Variables?. <https://www.displayr.com/what-are-dummy-variables/>, 2021. (Erişim Tarihi: 24 Kasım 2021)
- [20] Hale, J. Scale, Standardize, or Normalize with Scikit-Learn. <https://towardsdatascience.com/scale-standardize-or-normalize-with-scikit-learn-6ccc7d176a02>, 2019. (Erişim Tarihi: 25 Kasım 2021)
- [21] Pramoditha, R. 11 Dimensionality reduction techniques you should know in 2021. <https://towardsdatascience.com/11-dimensionality-reduction-techniques-you-should-know-in-2021-dcb9500d388b>, 2019. (Erişim Tarihi: 25 Kasım 2021)
- [22] Sirikulviriya, N., Sinthupinyo, S. Integration of rules from a random forest. In International Conference on Information and Electronics Engineering, 2011, 194-198.
- [23] Oshiro, T. M., Perez, P. S., Baranauskas, J. A. How many trees in a random forest?. In International workshop on machine learning and data mining in pattern recognition, Springer, Berlin, Heidelberg, Germany, 2012, 154-168.
- [24] Yiu, T. Understanding Random Forest. <https://towardsdatascience.com/understanding-random-forest-58381e0602d2>, 2019. (Erişim Tarihi: 02 Aralık 2021)
- [25] Arslan, E. Makine Öğrenmesi - KNN (K-Nearest Neighbors) Algoritması Nedir?. <https://medium.com/@arslanev/makine-ogrenmesi-knn-k-nearest-neighbors-algoritması-bdfb688d7c5f>, 2020. (Erişim Tarihi: 29 Kasım 2021)
- [26] Chomboon, K., Chujai, P., Teerarassamee, P., Kerdprasop, K., Kerdprasop, N. An empirical study of distance metrics for k-nearest neighbor algorithm. In

Proceedings of the 3rd international conference on industrial application engineering, 2015, 280-285.

[27] Noble, W. S. What is a support vector machine?. Nature biotechnology, 2006, 24(12), 1565-1567.

[28] Gandhi, R. Support Vector Machine - Introduction to Machine Learning Algorithms. <https://towardsdatascience.com/support-vector-machine-introduction-to-machine-learning-algorithms-934a444fca47>, 2018. (Erişim Tarihi: 01 Aralık 2021)

[29] AI Wiki. Gradient Boosting. <https://docs.paperspace.com/machine-learning/wiki/gradient-boosting>, 2020. (Erişim Tarihi: 02 Aralık 2021)

[30] Natekin, A., Knoll, A Gradient boosting machines, a tutorial. Frontiers in neurorobotics, 7, 2013, 21.

[31] Brownlee, J. A Gentle Introduction to the Gradient Boosting Algorithm for Machine Learning. <https://machinelearningmastery.com/gentle-introduction-gradient-boosting-algorithm-machine-learning/>, 2020. (Erişim Tarihi: 02 Aralık 2021)

[32] Chen, T., Guestrin, C. Xgboost: A scalable tree boosting system. In Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining, 2016, 785-794.

[33] Kurt, K. Matematiği ve Python Uygulamasıyla LightGBM. <https://medium.com/kaveai/matematiği-ve-python-uygulamasıyla-lightgbm-hafif-gradyan-artırma-makinesi-18d2f12e7870>, 2020. (Erişim Tarihi: 05 Aralık 2021)

[34] Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., ... Liu, T. Y. Lightgbm: A highly efficient gradient boosting decision tree. Advances in neural information processing systems, 30, 2017, 3146-3154.

[35] Prokhorenkova, L., Gusev, G., Vorobev, A., Dorogush, A. V., Gulin, A. CatBoost: unbiased boosting with categorical features. Advances in neural information processing systems, 2018, 31.

[36] Ray, S. CatBoost: A machine learning library to handle categorical (CAT) data automatically. <https://www.analyticsvidhya.com/blog/2017/08/catboost-automated-categorical-data/>, 2017. (Erişim Tarihi: 06 Aralık 2021)

[37] Abraham, A. Artificial neural networks. Handbook of measuring system design, 2005.

[38] Javatpoint. <https://www.javatpoint.com/difference-between-artificial-intelligence-and-machine-learning>, 2017. (Erişim Tarihi: 07 Aralık 2021)

- [39] Livingstone, D. J., Manallack, D. T., Tetko, I. V. Data modelling with neural networks: advantages and limitations. *Journal of computer-aided molecular design*, 11(2), 1997, 135-142.
- [40] Loh, W. Y. Classification and regression trees. *Wiley interdisciplinary reviews: data mining and knowledge discovery*, 1(1), 2011, 14-23.
- [41] De'ath, G., Fabricius, K. E. Classification and regression trees: a powerful yet simple technique for ecological data analysis. *Ecology*, 81(11), 2000, 3178-3192.
- [42] Dobilas, S. CART: Classification and Regression Trees for Clean but Powerful Models. <https://towardsdatascience.com/cart-classification-and-regression-trees-for-clean-but-powerful-models-cc89e60b7a85>, 2021. (Erişim Tarihi: 10 Aralık 2021)
- [43] Balakrishnama, S., Ganapathiraju, A. Linear discriminant analysis-a brief tutorial. *Institute for Signal and information Processing*, 18(1998), 1998, 1-8.
- [44] Pramoditha, R. 11 Dimensionality reduction techniques you should know in 2021. <https://towardsdatascience.com/11-dimensionality-reduction-techniques-you-should-know-in-2021-dcb9500d388b>, 2021. (Erişim Tarihi: 10 Aralık 2021)
- [45] Sharma, P. A Beginner's Guide to Hierarchical Clustering and how to Perform it in Python. <https://www.analyticsvidhya.com/blog/2019/05/beginners-guide-hierarchical-clustering/>, 2019. (Erişim Tarihi: 16 Aralık 2021)
- [46] Patlolla, C. R. Understanding the concept of Hierarchical clustering Technique. <https://towardsdatascience.com/understanding-the-concept-of-hierarchical-clustering-technique-c6e8243758ec>, 2018. (Erişim Tarihi: 16 Aralık 2021)
- [47] Mishra, A. Metrics to Evaluate your Machine Learning Algorithm. <https://towardsdatascience.com/metrics-to-evaluate-your-machine-learning-algorithm-f10ba6e38234> 2018. (Erişim Tarihi: 22 Aralık 2021)
- [48] Srivastava, T. 11 Important Model Evaluation Metrics for Machine Learning Everyone should know. <https://www.analyticsvidhya.com/blog/2019/08/11-important-model-evaluation-error-metrics/>, 2019. (Erişim Tarihi: 22 Aralık 2021)
- [49] Brownlee, J. What is a Confusion Matrix in Machine Learning. <https://machinelearningmastery.com/confusion-matrix-machine-learning/>, 2016. (Erişim Tarihi: 22 Aralık 2021)
- [50] Hossin, M., Sulaiman, M. N. A review on evaluation metrics for data classification evaluations. *International journal of data mining & knowledge management process*, 5(2), 2015, 1.

- [51] Kvålseth, T. O. Note on Cohen's kappa. Psychological reports, 65(1), 1989, 223-226.
- [52] Pykes, K. Kohen's Kappa. <https://towardsdatascience.com/cohens-kappa-9786ceceab58>, 2020. (Erişim Tarihi: 22 Aralık 2021)
- [53] scikitlearn. sklearn.ensemble.RandomForestClassifier. <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.RandomForestClassifier.html>. (Erişim Tarihi: 03 Ocak 2022)
- [54] scikitlearn. sklearn.neighbors.KNeighborsClassifier. <https://scikit-learn.org/stable/modules/generated/sklearn.neighbors.KNeighborsClassifier.html>. (Erişim Tarihi: 03 Ocak 2022)
- [55] scikitlearn. sklearn.svm.SVC. <https://scikit-learn.org/stable/modules/generated/sklearn.svm.SVC.html>. (Erişim Tarihi: 04 Ocak 2022)
- [56] scikitlearn. sklearn.ensemble.GradientBoostingClassifier. <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.GradientBoostingClassifier.html>. (Erişim Tarihi: 04 Ocak 2022)
- [57] XGBoost. XGBoost Parameters. <https://xgboost.readthedocs.io/en/stable/parameter.html>. (Erişim Tarihi: 05 Ocak 2022)
- [58] lightgbm. Parameters. <https://lightgbm.readthedocs.io/en/latest/Parameters.html>. (Erişim Tarihi: 05 Ocak 2022)
- [59] CatBoost. Overview. <https://catboost.ai/en/docs/references/training-parameters/>. (Erişim Tarihi: 06 Ocak 2022)
- [60] scikitlearn. sklearn.neural_network.MLPClassifier. https://scikit-learn.org/stable/modules/generated/sklearn.neural_network.MLPClassifier.html. (Erişim Tarihi: 06 Ocak 2022)
- [61] scikitlearn. sklearn.tree.DecisionTreeClassifier. <https://scikit-learn.org/stable/modules/generated/sklearn.tree.DecisionTreeClassifier.html>. (Erişim Tarihi: 07 Ocak 2022)
- [62] scikitlearn. sklearn.discriminant_analysis.LinearDiscriminantAnalysis. https://scikit-learn.org/stable/modules/generated/sklearn.discriminant_analysis.LinearDiscriminantAnalysis.html. (Erişim Tarihi: 07 Ocak 2022)

EKLER

EK-A. Tüm Parametre Değerleri ile Makine Öğrenmesi Modellerinin Sonuçları

Tablo 0.1. RF En Başarılı 50 Model

	Model	n_estimators	min_samples_split	accuracy_train	cohen	f1	accuracy_test
Bölüm Etiketleri	1	500	6	1	0.331683168	0.314194605	0.407407407
	2	400	6	1	0.323705857	0.317474611	0.4
	3	600	6	1	0.323077875	0.308286327	0.4
	4	700	6	1	0.322532681	0.307425107	0.4
	5	1000	6	1	0.322490706	0.311153123	0.4
	6	800	6	1	0.312763844	0.303957356	0.392592593
	7	900	6	1	0.313360625	0.305209312	0.392592593
	8	100	9	0.971153846	0.306621287	0.302161522	0.385185185
	9	200	9	0.980769231	0.305546948	0.30544777	0.385185185
	10	300	7	1	0.308290635	0.314482334	0.385185185
	11	400	7	1	0.307521167	0.313862113	0.385185185
	12	500	7	1	0.307606748	0.305820465	0.385185185
	13	700	4	1	0.306621287	0.30057482	0.385185185
	14	100	8	0.983974359	0.299740645	0.305274972	0.377777778
	15	200	5	1	0.299567634	0.2990914	0.377777778
	16	400	3	1	0.29770236	0.298605935	0.377777778
	17	400	5	1	0.298788029	0.305790624	0.377777778
	18	400	8	0.996794872	0.298310748	0.298083116	0.377777778
	19	400	9	0.993589744	0.298614547	0.290103909	0.377777778
	20	500	4	1	0.299134734	0.296956724	0.377777778
	21	500	5	1	0.297876292	0.301263497	0.377777778
	22	600	4	1	0.29900476	0.293529576	0.377777778
	23	600	5	1	0.29665695	0.298873208	0.377777778
	24	700	5	1	0.298961424	0.297084054	0.377777778
	25	800	4	1	0.299178048	0.294709163	0.377777778
	26	800	7	1	0.298701299	0.290184157	0.377777778
	27	1000	4	1	0.297484822	0.295471795	0.377777778
	28	1000	8	1	0.298744666	0.289334527	0.377777778
	29	200	7	1	0.292932405	0.305279782	0.37037037
	30	300	5	1	0.290352505	0.303119707	0.37037037
	31	300	6	1	0.287444113	0.287553503	0.37037037
	32	300	9	0.987179487	0.288901283	0.291118537	0.37037037
	33	500	8	0.996794872	0.2907911	0.295221459	0.37037037
	34	500	9	0.990384615	0.288151365	0.283060364	0.37037037
	35	600	7	1	0.290966387	0.290573181	0.37037037
	36	600	9	0.990384615	0.289033457	0.284088304	0.37037037

Grup 1 Etiketleri	37	700	9	0.990384615	0.287974684	0.282801036	0.37037037
	38	800	5	1	0.290440267	0.293233645	0.37037037
	39	800	8	1	0.290001237	0.28294713	0.37037037
	40	800	9	0.993589744	0.288239672	0.281637769	0.37037037
	41	900	4	1	0.289913366	0.290329749	0.37037037
	42	900	7	1	0.289385682	0.285732029	0.37037037
	43	900	9	0.993589744	0.2879305	0.281637769	0.37037037
	44	1000	5	1	0.290308615	0.296368374	0.37037037
	45	1000	7	1	0.289297659	0.290758932	0.37037037
	46	1000	9	0.990384615	0.287399863	0.283470903	0.37037037
	47	100	4	1	0.283863805	0.302562587	0.362962963
	48	100	6	0.996794872	0.282092506	0.295321027	0.362962963
	49	200	8	0.993589744	0.280936455	0.290906844	0.362962963
	50	300	3	1	0.281426007	0.282896258	0.362962963
	1	700	6	1	0.398506094	0.421862634	0.496296296
	2	400	2	1	0.387654483	0.415155786	0.488888889
	3	400	6	1	0.390578999	0.419997337	0.488888889
	4	500	6	1	0.390100177	0.415239931	0.488888889
	5	500	8	0.971153846	0.385756677	0.411922889	0.488888889
	6	600	5	1	0.3900203	0.413720463	0.488888889
	7	600	6	1	0.389140271	0.413690976	0.488888889
	8	700	8	0.974358974	0.386848341	0.412603904	0.488888889
	9	800	6	1	0.387130732	0.415545595	0.488888889
	10	900	6	1	0.388297872	0.413858962	0.488888889
	11	1000	5	1	0.386201898	0.413760493	0.488888889
	12	1000	6	0.996794872	0.388297872	0.413858962	0.488888889
	13	100	7	0.980769231	0.380083967	0.409524347	0.481481481
	14	200	6	0.993589744	0.382433669	0.41039072	0.481481481
	15	300	3	1	0.375701922	0.401150342	0.481481481
	16	300	8	0.974358974	0.375701922	0.40287863	0.481481481
	17	400	3	1	0.376319958	0.402912171	0.481481481
	18	400	5	1	0.381017882	0.41108939	0.481481481
	19	400	8	0.974358974	0.376895688	0.403902859	0.481481481
	20	500	5	1	0.379636316	0.405574737	0.481481481
	21	600	3	1	0.378698225	0.406671856	0.481481481
	22	600	8	0.971153846	0.378412155	0.405958913	0.481481481
	23	700	2	1	0.378289474	0.410546681	0.481481481
	24	700	3	1	0.378125823	0.409174822	0.481481481
	25	700	4	1	0.377921138	0.407158442	0.481481481
	26	700	5	1	0.380896226	0.405612932	0.481481481
	27	800	5	1	0.379799173	0.405472124	0.481481481
	28	900	5	1	0.379799173	0.405472124	0.481481481
	29	900	8	0.974358974	0.377470356	0.405175284	0.481481481
	30	1000	2	1	0.380043299	0.407361953	0.481481481

Grup 2 Etiketi	31	1000	3	1	0.379106439	0.40733568	0.481481481
	32	100	4	1	0.366783378	0.40238647	0.474074074
	33	100	8	0.974358974	0.371640226	0.399639347	0.474074074
	34	300	6	1	0.371887287	0.406647032	0.474074074
	35	500	2	1	0.368743414	0.401198264	0.474074074
	36	500	4	1	0.365063593	0.393478663	0.474074074
	37	600	2	1	0.369324911	0.403329207	0.474074074
	38	600	4	1	0.365651886	0.392548275	0.474074074
	39	700	7	0.987179487	0.371516622	0.399152189	0.474074074
	40	800	2	1	0.370029576	0.400130782	0.474074074
	41	800	3	1	0.371969598	0.401400511	0.474074074
	42	800	8	0.971153846	0.369988169	0.39917724	0.474074074
	43	900	3	1	0.370773978	0.402701579	0.474074074
	44	900	4	1	0.369573796	0.397315947	0.474074074
	45	900	7	0.983974359	0.371557828	0.398999956	0.474074074
	46	1000	4	1	0.369573796	0.397315947	0.474074074
	47	1000	8	0.977564103	0.369698165	0.401197952	0.474074074
	48	100	2	1	0.360231686	0.39133106	0.466666667
	49	100	5	0.996794872	0.363207547	0.391609352	0.466666667
	50	200	2	1	0.360231686	0.393853197	0.466666667
	1	200	4	0.996794872	0.563043947	0.649523239	0.666666667
	2	300	5	0.996794872	0.53300663	0.626963273	0.644444444
	3	500	5	0.996794872	0.533846486	0.626961875	0.644444444
	4	900	9	0.932692308	0.534549634	0.626561667	0.644444444
	5	100	9	0.935897436	0.523620913	0.616552644	0.637037037
	6	200	6	0.990384615	0.524134954	0.623153582	0.637037037
	7	200	9	0.935897436	0.525023336	0.619461169	0.637037037
	8	300	2	1	0.522555034	0.619970519	0.637037037
	9	300	4	0.996794872	0.52543224	0.618881104	0.637037037
	10	400	2	1	0.524511213	0.619638445	0.637037037
	11	600	3	1	0.524682044	0.620056327	0.637037037
	12	900	3	1	0.524682044	0.620056327	0.637037037
	13	900	5	0.996794872	0.523449319	0.620081021	0.637037037
	14	1000	3	1	0.524169184	0.618907584	0.637037037
	15	100	8	0.955128205	0.517684887	0.615547659	0.62962963
	16	400	4	0.996794872	0.515920826	0.611836513	0.62962963
	17	400	5	0.996794872	0.514981677	0.612648919	0.62962963
	18	500	3	1	0.514807361	0.612920099	0.62962963
	19	500	7	0.983974359	0.514423423	0.612919351	0.62962963
	20	600	5	0.996794872	0.513898891	0.613140637	0.62962963
	21	600	9	0.929487179	0.514772482	0.612920993	0.62962963
	22	700	3	1	0.515364733	0.612523045	0.62962963
	23	700	5	0.996794872	0.513898891	0.613140637	0.62962963
	24	700	9	0.929487179	0.514772482	0.612920993	0.62962963

Grup 3 Etiketleri	25	800	3	1	0.515364733	0.612523045	0.62962963
	26	800	5	0.996794872	0.513898891	0.613140637	0.62962963
	27	800	9	0.932692308	0.516233068	0.613354387	0.62962963
	28	100	2	1	0.505672028	0.60739484	0.622222222
	29	100	3	1	0.50655773	0.609982754	0.622222222
	30	100	6	0.987179487	0.504889976	0.609600155	0.622222222
	31	100	7	0.961538462	0.505387931	0.606460518	0.622222222
	32	300	6	0.990384615	0.50321091	0.606337565	0.622222222
	33	300	7	0.974358974	0.504533679	0.605814636	0.622222222
	34	300	9	0.932692308	0.504747518	0.606166243	0.622222222
	35	400	9	0.929487179	0.505281311	0.605358941	0.622222222
	36	500	4	0.996794872	0.506380843	0.606329131	0.622222222
	37	600	4	0.996794872	0.50655773	0.606713263	0.622222222
	38	900	6	0.990384615	0.504889976	0.605923818	0.622222222
	39	1000	4	1	0.506380843	0.606329131	0.622222222
	40	1000	5	0.996794872	0.505103508	0.605595921	0.622222222
	41	1000	6	0.987179487	0.506380843	0.606329131	0.622222222
	42	1000	9	0.929487179	0.505281311	0.605358941	0.622222222
	43	100	4	0.996794872	0.498356438	0.599626682	0.614814815
	44	200	3	1	0.494272747	0.597681964	0.614814815
	45	200	5	0.996794872	0.49500036	0.598876827	0.614814815
	46	200	7	0.971153846	0.495725882	0.599474005	0.614814815
	47	300	3	1	0.4963048	0.600404254	0.614814815
	48	300	8	0.948717949	0.495580944	0.598600388	0.614814815
	49	400	3	1	0.49648544	0.600742153	0.614814815
	50	400	6	0.990384615	0.494964029	0.599253752	0.614814815
	1	300	9	0.913461538	0.665640949	0.7580647	0.755555556
	2	200	8	0.923076923	0.654497554	0.74970929	0.748148148
	3	200	9	0.907051282	0.654497554	0.74970929	0.748148148
	4	800	8	0.935897436	0.655431274	0.750300098	0.748148148
	5	900	8	0.939102564	0.655431274	0.750300098	0.748148148
	6	200	7	0.942307692	0.643960515	0.740653914	0.740740741
	7	400	9	0.913461538	0.6452969	0.743769151	0.740740741
	8	500	9	0.913461538	0.644923724	0.742783924	0.740740741
	9	700	8	0.939102564	0.645669291	0.743188413	0.740740741
	10	800	7	0.951923077	0.644923724	0.742783924	0.740740741
	11	100	7	0.942307692	0.633787959	0.731735774	0.733333333
	12	100	8	0.926282051	0.633787959	0.734304708	0.733333333
	13	500	8	0.935897436	0.635162525	0.735715762	0.733333333
	14	600	5	0.996794872	0.633787959	0.734304708	0.733333333
	15	600	7	0.951923077	0.635080342	0.736180218	0.733333333
	16	600	8	0.939102564	0.635162525	0.735715762	0.733333333
	17	600	9	0.91025641	0.634394042	0.735210407	0.733333333
	18	700	7	0.948717949	0.634394042	0.735210407	0.733333333

	19	900	7	0.951923077	0.634394042	0.735210407	0.733333333
	20	1000	7	0.951923077	0.634394042	0.735210407	0.733333333
	21	1000	8	0.935897436	0.634476534	0.735459562	0.733333333
	22	100	9	0.903846154	0.626542056	0.727112888	0.725925926
	23	300	7	0.945512821	0.623132639	0.723794847	0.725925926
	24	300	8	0.923076923	0.623842157	0.727573723	0.725925926
	25	400	7	0.948717949	0.623927119	0.727886045	0.725925926
	26	500	7	0.951923077	0.624549008	0.728606702	0.725925926
	27	600	6	0.980769231	0.623530298	0.725370925	0.725925926
	28	700	9	0.916666667	0.624549008	0.728606702	0.725925926
	29	800	4	1	0.623842157	0.725941675	0.725925926
	30	800	9	0.919871795	0.623927119	0.727886045	0.725925926
	31	900	9	0.919871795	0.623927119	0.727886045	0.725925926
	32	1000	9	0.916666667	0.623927119	0.727886045	0.725925926
	33	400	8	0.942307692	0.614980486	0.721330943	0.718518519
	34	700	5	0.996794872	0.613355442	0.717773584	0.718518519
	35	700	6	0.967948718	0.612859407	0.717379788	0.718518519
	36	800	5	0.996794872	0.613675729	0.714860593	0.718518519
	37	800	6	0.971153846	0.613675729	0.719127933	0.718518519
	38	900	5	0.996794872	0.613675729	0.714860593	0.718518519
	39	900	6	0.967948718	0.613675729	0.719127933	0.718518519
	40	1000	4	1	0.61358843	0.719793841	0.718518519
	41	1000	5	0.996794872	0.613675729	0.714860593	0.718518519
	42	1000	6	0.971153846	0.612947035	0.717734241	0.718518519
	43	200	4	1	0.602251265	0.706596381	0.711111111
	44	300	6	0.977564103	0.60234139	0.705863396	0.711111111
	45	400	3	1	0.60234139	0.707025012	0.711111111
	46	400	6	0.977564103	0.60234139	0.710028408	0.711111111
	47	500	2	1	0.603837472	0.712800896	0.711111111
	48	500	6	0.977564103	0.60234139	0.710028408	0.711111111
	49	700	4	1	0.6035093	0.711330662	0.711111111
	50	900	4	1	0.603001056	0.70799081	0.711111111

Tablo 0.2. KNN En Başarılı 50 Model

	Model	n_neighbors	p	accuracy_train	cohen	f1	accuracy_test
Bölüm Etiketİ	1	33	1	0.269230769	0.245955316	0.231583528	0.355555556
	2	37	1	0.269230769	0.24338079	0.2251647	0.355555556
	3	16	7	0.326923077	0.261790841	0.26477654	0.348148148
	4	30	1	0.288461538	0.238656755	0.229554807	0.348148148
	5	38	1	0.266025641	0.234881175	0.220255477	0.348148148
	6	42	1	0.269230769	0.235816287	0.221498647	0.348148148

7	42	2	0.278846154	0.235422834	0.221251733	0.348148148
8	43	1	0.269230769	0.235767128	0.221251733	0.348148148
9	45	2	0.278846154	0.233350542	0.214679148	0.348148148
10	13	2	0.333333333	0.252519597	0.272056341	0.340740741
11	15	7	0.333333333	0.25242658	0.25328931	0.340740741
12	17	6	0.307692308	0.253819401	0.252581328	0.340740741
13	29	1	0.288461538	0.232415511	0.226041037	0.340740741
14	29	2	0.288461538	0.232660621	0.22020202	0.340740741
15	32	1	0.272435897	0.226833977	0.215931868	0.340740741
16	34	1	0.272435897	0.226983208	0.214585066	0.340740741
17	35	1	0.266025641	0.227629211	0.219265927	0.340740741
18	36	1	0.269230769	0.228917982	0.220040404	0.340740741
19	37	2	0.28525641	0.228620955	0.219786008	0.340740741
20	39	1	0.272435897	0.225887507	0.216769638	0.340740741
21	40	1	0.282051282	0.226086957	0.217667506	0.340740741
22	41	1	0.272435897	0.225088681	0.216904084	0.340740741
23	41	2	0.275641026	0.227529896	0.217447745	0.340740741
24	43	2	0.282051282	0.226684688	0.211285403	0.340740741
25	44	1	0.262820513	0.225238587	0.20648882	0.340740741
26	44	2	0.275641026	0.226684688	0.211285403	0.340740741
27	45	1	0.259615385	0.226883727	0.20778372	0.340740741
28	46	1	0.253205128	0.225887507	0.20862149	0.340740741
29	47	1	0.246794872	0.225887507	0.20862149	0.340740741
30	7	1	0.381410256	0.254464012	0.286675155	0.333333333
31	7	3	0.387820513	0.257607235	0.277132828	0.333333333
32	14	2	0.320512821	0.241573034	0.255975578	0.333333333
33	14	8	0.342948718	0.248562063	0.258764756	0.333333333
34	14	9	0.349358974	0.247771174	0.257738011	0.333333333
35	16	3	0.326923077	0.245200969	0.263808424	0.333333333
36	16	8	0.342948718	0.242471476	0.248564889	0.333333333
37	17	5	0.314102564	0.245388485	0.256091898	0.333333333
38	18	3	0.317307692	0.242046163	0.251614854	0.333333333
39	31	1	0.275641026	0.221203769	0.220576132	0.333333333
40	36	2	0.282051282	0.220954091	0.216811389	0.333333333
41	38	2	0.278846154	0.218950887	0.215684836	0.333333333
42	39	2	0.288461538	0.219853602	0.214448802	0.333333333
43	40	2	0.288461538	0.221752498	0.214162792	0.333333333
44	45	3	0.278846154	0.214151737	0.206778477	0.333333333
45	46	2	0.269230769	0.213999224	0.199021663	0.333333333
46	46	3	0.278846154	0.214151737	0.206778477	0.333333333
47	47	2	0.269230769	0.212980956	0.198269297	0.333333333
48	48	1	0.246794872	0.216381812	0.204154364	0.333333333
49	48	2	0.262820513	0.212776986	0.19737143	0.333333333
50	49	2	0.269230769	0.212878984	0.19737143	0.333333333

Grup 1 Etiketi	1	18	4	0.416666667	0.292183031	0.344091571	0.42962963
	2	19	3	0.413461538	0.28786737	0.32787853	0.42962963
	3	20	3	0.403846154	0.286057692	0.31548725	0.42962963
	4	21	3	0.413461538	0.285223131	0.322468067	0.42962963
	5	22	3	0.403846154	0.285763364	0.324195934	0.42962963
	6	7	2	0.541666667	0.295086357	0.344513085	0.422222222
	7	11	9	0.490384615	0.289952798	0.349164294	0.422222222
	8	12	3	0.490384615	0.287695326	0.336961153	0.422222222
	9	13	8	0.477564103	0.289473684	0.349164294	0.422222222
	10	16	4	0.442307692	0.28702011	0.344267558	0.422222222
	11	9	5	0.525641026	0.286669788	0.347985256	0.414814815
	12	10	8	0.503205128	0.284660272	0.345321929	0.414814815
	13	11	3	0.477564103	0.280072904	0.334188034	0.414814815
	14	11	7	0.5	0.28196324	0.342131742	0.414814815
	15	11	8	0.490384615	0.280315811	0.341676016	0.414814815
	16	11	10	0.496794872	0.281237364	0.341083486	0.414814815
	17	12	4	0.5	0.28118892	0.340135735	0.414814815
	18	12	9	0.471153846	0.281382656	0.342843244	0.414814815
	19	13	2	0.487179487	0.277390067	0.325144474	0.414814815
	20	13	3	0.471153846	0.278074866	0.326324894	0.414814815
	21	13	9	0.471153846	0.282398062	0.343924691	0.414814815
	22	13	10	0.467948718	0.283506886	0.344211279	0.414814815
	23	14	1	0.448717949	0.271018455	0.311759452	0.414814815
	24	15	1	0.445512821	0.269370419	0.306960278	0.414814815
	25	16	2	0.429487179	0.271914255	0.315065478	0.414814815
	26	16	3	0.439102564	0.272262027	0.322808535	0.414814815
	27	18	2	0.423076923	0.26766463	0.300767834	0.414814815
	28	18	3	0.426282051	0.268719144	0.311622291	0.414814815
	29	19	1	0.413461538	0.263924356	0.287950168	0.414814815
	30	20	1	0.403846154	0.263161531	0.286949027	0.414814815
	31	21	2	0.426282051	0.263161531	0.291499118	0.414814815
	32	21	4	0.413461538	0.267312448	0.312077339	0.414814815
	33	22	1	0.413461538	0.261119579	0.287821893	0.414814815
	34	23	2	0.397435897	0.264482759	0.298804156	0.414814815
	35	23	3	0.416666667	0.267513736	0.311612372	0.414814815
	36	24	3	0.403846154	0.267362781	0.308660001	0.414814815
	37	5	6	0.570512821	0.290966387	0.357198102	0.407407407
	38	10	5	0.503205128	0.272237197	0.331136021	0.407407407
	39	10	7	0.506410256	0.273900766	0.334338698	0.407407407
	40	11	4	0.483974359	0.272874167	0.333505257	0.407407407
	41	11	5	0.490384615	0.270762998	0.331641712	0.407407407
	42	12	2	0.487179487	0.267051239	0.315009928	0.407407407
	43	12	7	0.487179487	0.273412271	0.335803183	0.407407407
	44	13	7	0.487179487	0.270664506	0.332315007	0.407407407

Grup 2 Etiketleri	45	16	1	0.435897436	0.260071252	0.294426392	0.407407407
	46	17	2	0.423076923	0.260932047	0.30697815	0.407407407
	47	18	1	0.413461538	0.255942129	0.273893535	0.407407407
	48	18	5	0.416666667	0.26274831	0.321793265	0.407407407
	49	19	2	0.416666667	0.25819081	0.294035635	0.407407407
	50	20	2	0.413461538	0.254401105	0.285892341	0.407407407
	1	12	3	0.631410256	0.596721311	0.667443152	0.696296296
	2	12	4	0.657051282	0.575595847	0.646702451	0.681481481
	3	12	7	0.644230769	0.577141608	0.654564279	0.681481481
	4	12	8	0.647435897	0.576679064	0.65162401	0.681481481
	5	12	9	0.644230769	0.576184566	0.65070939	0.681481481
	6	12	10	0.644230769	0.576184566	0.65070939	0.681481481
	7	15	3	0.653846154	0.577141608	0.653980143	0.681481481
	8	19	3	0.618589744	0.576493762	0.650351693	0.681481481
	9	11	4	0.657051282	0.566328393	0.641738333	0.674074074
	10	11	9	0.657051282	0.565948118	0.641207091	0.674074074
	11	11	10	0.657051282	0.566929134	0.645439338	0.674074074
	12	12	5	0.641025641	0.566201709	0.64068789	0.674074074
	13	14	3	0.628205128	0.56715004	0.64705143	0.674074074
	14	15	4	0.618589744	0.567622652	0.647452916	0.674074074
	15	15	7	0.644230769	0.564516129	0.637925863	0.674074074
	16	15	8	0.647435897	0.563556209	0.635786456	0.674074074
	17	16	4	0.644230769	0.566296729	0.644079697	0.674074074
	18	10	9	0.653846154	0.55705432	0.637327125	0.666666667
	19	11	3	0.647435897	0.556504599	0.63635905	0.666666667
	20	11	5	0.657051282	0.556310254	0.633547826	0.666666667
	21	11	8	0.650641026	0.555921053	0.634321451	0.666666667
	22	12	6	0.628205128	0.557215743	0.63787406	0.666666667
	23	14	5	0.634615385	0.555270864	0.631658164	0.666666667
	24	16	10	0.637820513	0.553964758	0.630117891	0.666666667
	25	17	4	0.631410256	0.555628703	0.632854136	0.666666667
	26	19	4	0.628205128	0.55647222	0.636254281	0.666666667
	27	20	3	0.631410256	0.55419388	0.628575611	0.666666667
	28	10	7	0.653846154	0.546715328	0.627086542	0.659259259
	29	10	8	0.657051282	0.546715328	0.627086542	0.659259259
	30	11	7	0.650641026	0.546218487	0.627480846	0.659259259
	31	13	3	0.644230769	0.548133595	0.634084974	0.659259259
	32	14	6	0.647435897	0.545221531	0.62485404	0.659259259
	33	15	2	0.637820513	0.546781492	0.629139291	0.659259259
	34	15	6	0.641025641	0.545387994	0.625377971	0.659259259
	35	15	9	0.637820513	0.543382353	0.619011685	0.659259259
	36	16	7	0.641025641	0.544754783	0.621309591	0.659259259
	37	16	9	0.637820513	0.544754783	0.621309591	0.659259259
	38	17	3	0.618589744	0.546251644	0.629082332	0.659259259

Grup 3 Etiketi	39	17	5	0.644230769	0.545088272	0.625605127	0.659259259
	40	18	4	0.634615385	0.54591986	0.625834692	0.659259259
	41	18	5	0.641025641	0.545254833	0.626045318	0.659259259
	42	21	6	0.612179487	0.543617256	0.618102912	0.659259259
	43	9	6	0.679487179	0.536624553	0.618183185	0.651851852
	44	10	6	0.641025641	0.536861314	0.620666789	0.651851852
	45	10	10	0.644230769	0.536692223	0.620154467	0.651851852
	46	11	6	0.653846154	0.536387549	0.619093022	0.651851852
	47	13	10	0.637820513	0.53502858	0.61542622	0.651851852
	48	14	4	0.634615385	0.537637543	0.623355121	0.651851852
	49	14	7	0.644230769	0.534994503	0.616004552	0.651851852
	50	14	8	0.653846154	0.534311927	0.611912064	0.651851852
	1	11	10	0.682692308	0.629939846	0.718391251	0.733333333
	2	19	1	0.666666667	0.629714286	0.725136258	0.733333333
	3	11	8	0.701923077	0.619254516	0.710968708	0.725925926
	4	11	9	0.695512821	0.619254516	0.710968708	0.725925926
	5	7	5	0.685897436	0.611863509	0.708862867	0.718518519
	6	7	6	0.692307692	0.610951009	0.71014276	0.718518519
	7	7	7	0.695512821	0.610951009	0.71014276	0.718518519
	8	7	9	0.692307692	0.61168723	0.710988398	0.718518519
	9	11	6	0.695512821	0.608635948	0.703134266	0.718518519
	10	11	7	0.701923077	0.608217504	0.702697166	0.718518519
	11	15	8	0.666666667	0.606202502	0.70309822	0.718518519
	12	18	1	0.669871795	0.608635948	0.708564546	0.718518519
	13	21	1	0.647435897	0.607798165	0.705052571	0.718518519
	14	7	8	0.692307692	0.601045692	0.703856185	0.711111111
	15	11	5	0.698717949	0.597384721	0.695658873	0.711111111
	16	13	3	0.673076923	0.600045579	0.697810975	0.711111111
	17	13	4	0.669871795	0.600379507	0.698639335	0.711111111
	18	13	6	0.666666667	0.598857143	0.697132001	0.711111111
	19	13	7	0.669871795	0.598857143	0.697132001	0.711111111
	20	13	8	0.663461538	0.598857143	0.697132001	0.711111111
	21	13	9	0.669871795	0.598857143	0.697132001	0.711111111
	22	14	9	0.657051282	0.597230722	0.696911977	0.711111111
	23	15	3	0.673076923	0.5984288	0.696448702	0.711111111
	24	15	7	0.666666667	0.596273292	0.696148556	0.711111111
	25	15	9	0.663461538	0.597323136	0.696657937	0.711111111
	26	15	10	0.66025641	0.597323136	0.696657937	0.711111111
	27	16	8	0.663461538	0.599558868	0.701172405	0.711111111
	28	17	1	0.66025641	0.600470481	0.702472101	0.711111111
	29	20	1	0.66025641	0.596706243	0.697452955	0.711111111
	30	6	5	0.695512821	0.588728104	0.689976548	0.703703704
	31	6	6	0.689102564	0.588289113	0.694939875	0.703703704
	32	7	10	0.692307692	0.591249716	0.696716793	0.703703704

	33	9	10	0.692307692	0.588194921	0.695598333	0.703703704
	34	10	7	0.685897436	0.587061253	0.688314385	0.703703704
	35	11	4	0.692307692	0.587155963	0.689944588	0.703703704
	36	12	8	0.695512821	0.587250631	0.687880437	0.703703704
	37	12	9	0.695512821	0.587345254	0.688353237	0.703703704
	38	12	10	0.692307692	0.587345254	0.688353237	0.703703704
	39	13	5	0.66025641	0.588915956	0.690290688	0.703703704
	40	13	10	0.673076923	0.588665448	0.690633894	0.703703704
	41	15	6	0.673076923	0.585476318	0.688737951	0.703703704
	42	16	1	0.669871795	0.587597373	0.690308342	0.703703704
	43	16	9	0.663461538	0.5883205	0.690771204	0.703703704
	44	17	9	0.653846154	0.586808478	0.689838811	0.703703704
	45	17	10	0.653846154	0.586808478	0.689838811	0.703703704
	46	24	3	0.663461538	0.587345254	0.688353237	0.703703704
	47	6	7	0.682692308	0.577545413	0.68758555	0.696296296
	48	6	8	0.685897436	0.577545413	0.68758555	0.696296296
	49	8	1	0.689102564	0.577835405	0.686943066	0.696296296
	50	8	5	0.673076923	0.57618683	0.686599327	0.696296296

Tablo 0.3. SVM En Başarılı 50 Model

	Model	C	kernel	gamma	accuracy_train	cohen	f1	accuracy_test
Bölüm Etiketi	1	1	rbf	scale	0.576923077	0.255986317	0.243092511	0.355555556
	2	1	rbf	auto	0.733974359	0.262016965	0.247415657	0.355555556
	3	1	sigmoid	scale	0.397435897	0.2622024	0.256608255	0.355555556
	4	2	rbf	scale	0.875	0.282748092	0.295442334	0.355555556
	5	2	sigmoid	auto	0.458333333	0.283754116	0.290731117	0.355555556
	6	1	sigmoid	auto	0.407051282	0.249722119	0.259902807	0.333333333
	7	3	sigmoid	scale	0.570512821	0.260409058	0.269742288	0.333333333
	8	3	sigmoid	auto	0.506410256	0.264839354	0.280642403	0.333333333
	9	4	sigmoid	scale	0.618589744	0.261083744	0.267933342	0.333333333
	10	2	sigmoid	scale	0.522435897	0.248761695	0.266539957	0.325925926
	11	5	sigmoid	scale	0.647435897	0.260162602	0.279481447	0.325925926
	12	6	sigmoid	scale	0.673076923	0.264106865	0.287691899	0.325925926
	13	4	sigmoid	auto	0.525641026	0.248956885	0.256380084	0.318518519
	14	7	sigmoid	scale	0.682692308	0.258108835	0.286735702	0.318518519
	15	3	rbf	scale	0.932692308	0.241114603	0.273369134	0.311111111
	16	4	rbf	scale	0.974358974	0.245447443	0.280273098	0.311111111
	17	5	rbf	scale	0.990384615	0.246398559	0.278709956	0.311111111
	18	8	sigmoid	scale	0.705128205	0.25174325	0.278001113	0.311111111

	19	2	rbf	auto	0.955128205	0.227726388	0.252807247	0.303703704
	20	8	rbf	scale	1	0.238934869	0.270832874	0.303703704
	21	9	rbf	scale	1	0.238934869	0.270832874	0.303703704
	22	10	rbf	scale	1	0.239710023	0.271870051	0.303703704
	23	11	rbf	scale	1	0.239710023	0.271870051	0.303703704
	24	19	sigmoid	auto	0.612179487	0.248267283	0.281976315	0.303703704
	25	20	sigmoid	auto	0.615384615	0.248356335	0.280080467	0.303703704
	26	5	sigmoid	auto	0.570512821	0.23152975	0.246752312	0.296296296
	27	6	rbf	scale	0.993589744	0.232035928	0.26565409	0.296296296
	28	7	rbf	scale	0.996794872	0.232127889	0.266277872	0.296296296
	29	12	rbf	scale	1	0.23254144	0.265427035	0.296296296
	30	13	rbf	scale	1	0.23254144	0.265427035	0.296296296
	31	14	rbf	scale	1	0.23254144	0.265427035	0.296296296
	32	15	rbf	scale	1	0.23254144	0.265427035	0.296296296
	33	16	rbf	scale	1	0.23254144	0.265427035	0.296296296
	34	17	rbf	scale	1	0.23254144	0.265427035	0.296296296
	35	17	sigmoid	auto	0.612179487	0.240405117	0.276033487	0.296296296
	36	18	rbf	scale	1	0.23254144	0.265427035	0.296296296
	37	18	sigmoid	auto	0.612179487	0.240405117	0.275713935	0.296296296
	38	19	rbf	scale	1	0.23254144	0.265427035	0.296296296
	39	20	rbf	scale	1	0.23254144	0.265427035	0.296296296
	40	3	rbf	auto	0.993589744	0.214402619	0.2454774	0.288888889
	41	10	sigmoid	scale	0.733974359	0.230540878	0.257209528	0.288888889
	42	13	sigmoid	auto	0.615384615	0.227651967	0.249450667	0.288888889
	43	14	sigmoid	auto	0.605769231	0.231225531	0.265512245	0.288888889
	44	4	rbf	auto	1	0.208952519	0.243414281	0.281481481
	45	5	rbf	auto	1	0.208856936	0.242838338	0.281481481
	46	6	rbf	auto	1	0.208856936	0.242838338	0.281481481
	47	6	sigmoid	auto	0.599358974	0.217180775	0.234069853	0.281481481
	48	7	rbf	auto	1	0.209668658	0.243743316	0.281481481
	49	8	rbf	auto	1	0.209668658	0.243743316	0.281481481
	50	8	sigmoid	auto	0.586538462	0.220257235	0.229340539	0.281481481
Grup 1 Etiketi	1	1	rbf	scale	0.628205128	0.348830977	0.38447249	0.466666667
	2	1	rbf	auto	0.769230769	0.33836858	0.376589542	0.459259259
	3	1	sigmoid	scale	0.432692308	0.329683036	0.33844409	0.459259259
	4	2	sigmoid	auto	0.426282051	0.363166397	0.388109827	0.459259259
	5	3	sigmoid	scale	0.554487179	0.343626807	0.365363352	0.451851852
	6	1	sigmoid	auto	0.403846154	0.327421283	0.348277326	0.444444444
	7	2	sigmoid	scale	0.516025641	0.3254497	0.346506531	0.444444444
	8	2	rbf	scale	0.78525641	0.332682927	0.375484706	0.437037037
	9	4	sigmoid	scale	0.560897436	0.33259611	0.360743201	0.437037037
	10	5	sigmoid	auto	0.429487179	0.343191857	0.372086882	0.437037037
	11	6	sigmoid	auto	0.439102564	0.343402022	0.377209142	0.437037037
	12	11	sigmoid	scale	0.669871795	0.356013055	0.416977853	0.437037037

	13	7	sigmoid	auto	0.445512821	0.337433871	0.364092819	0.42962963
	14	4	sigmoid	auto	0.435897436	0.321258218	0.346050836	0.422222222
	15	5	sigmoid	scale	0.586538462	0.320908036	0.353408189	0.422222222
	16	8	sigmoid	scale	0.647435897	0.33138612	0.394020909	0.422222222
	17	12	sigmoid	scale	0.669871795	0.332276474	0.39054954	0.422222222
	18	15	sigmoid	scale	0.663461538	0.335520919	0.390876369	0.422222222
	19	16	sigmoid	scale	0.663461538	0.337735849	0.40053534	0.422222222
	20	17	sigmoid	scale	0.657051282	0.325597572	0.383627647	0.414814815
	21	20	sigmoid	scale	0.647435897	0.328949852	0.393027663	0.414814815
	22	2	rbf	auto	0.923076923	0.295544974	0.349845135	0.407407407
	23	3	rbf	scale	0.855769231	0.306180136	0.360860974	0.407407407
	24	3	rbf	auto	0.96474359	0.302550856	0.356888004	0.407407407
	25	3	sigmoid	auto	0.419871795	0.302910992	0.335036345	0.407407407
	26	4	rbf	scale	0.894230769	0.311619606	0.366623001	0.407407407
	27	4	rbf	auto	0.990384615	0.307337096	0.361728395	0.407407407
	28	6	sigmoid	scale	0.599358974	0.30698152	0.358352819	0.407407407
	29	7	sigmoid	scale	0.631410256	0.312539784	0.374771617	0.407407407
	30	10	sigmoid	scale	0.669871795	0.322076455	0.387648638	0.407407407
	31	14	sigmoid	scale	0.679487179	0.316498956	0.3775516	0.407407407
	32	18	sigmoid	scale	0.66025641	0.319899244	0.382853161	0.407407407
	33	19	sigmoid	scale	0.641025641	0.321053624	0.384047591	0.407407407
	34	5	rbf	auto	0.993589744	0.301991574	0.356983629	0.4
	35	6	rbf	auto	0.996794872	0.303414448	0.359307531	0.4
	36	7	rbf	auto	1	0.303414448	0.359307531	0.4
	37	8	rbf	auto	1	0.305582016	0.360548493	0.4
	38	9	rbf	auto	1	0.305582016	0.360548493	0.4
	39	9	sigmoid	scale	0.666666667	0.313128141	0.382881871	0.4
	40	10	rbf	auto	1	0.305582016	0.360548493	0.4
	41	10	sigmoid	auto	0.461538462	0.309092058	0.336857222	0.4
	42	11	rbf	auto	1	0.305758365	0.361118293	0.4
	43	12	rbf	auto	1	0.305758365	0.361118293	0.4
	44	13	rbf	auto	1	0.305758365	0.361118293	0.4
	45	14	rbf	auto	1	0.305758365	0.361118293	0.4
	46	15	rbf	auto	1	0.305758365	0.361118293	0.4
	47	16	rbf	auto	1	0.305758365	0.361118293	0.4
	48	17	rbf	auto	1	0.305758365	0.361118293	0.4
	49	18	rbf	auto	1	0.305758365	0.361118293	0.4
	50	19	rbf	auto	1	0.305758365	0.361118293	0.4
Grup 2 Etiketi	1	3	rbf	scale	0.724358974	0.571119134	0.661657837	0.674074074
	2	1	linear	scale	0.698717949	0.565232949	0.660185292	0.666666667
	3	1	linear	auto	0.698717949	0.565232949	0.660185292	0.666666667
	4	1	rbf	scale	0.673076923	0.559623052	0.644328059	0.666666667
	5	2	rbf	scale	0.701923077	0.560769286	0.65091376	0.666666667
	6	8	rbf	scale	0.753205128	0.553430174	0.649285713	0.659259259

7	4	rbf	scale	0.733974359	0.542933295	0.636930661	0.651851852
8	5	rbf	scale	0.737179487	0.543459491	0.637269049	0.651851852
9	6	rbf	scale	0.740384615	0.543295185	0.636774873	0.651851852
10	7	rbf	scale	0.75	0.543295185	0.636774873	0.651851852
11	9	rbf	scale	0.766025641	0.544932941	0.642235326	0.651851852
12	10	rbf	scale	0.769230769	0.544932941	0.642235326	0.651851852
13	7	sigmoid	scale	0.586538462	0.527903249	0.597620027	0.644444444
14	11	rbf	scale	0.772435897	0.535083943	0.630837106	0.644444444
15	1	rbf	auto	0.775641026	0.518804103	0.618092459	0.637037037
16	2	linear	scale	0.701923077	0.528846154	0.63225248	0.637037037
17	2	linear	auto	0.701923077	0.528846154	0.63225248	0.637037037
18	3	linear	scale	0.705128205	0.528846154	0.63225248	0.637037037
19	3	linear	auto	0.705128205	0.528846154	0.63225248	0.637037037
20	12	rbf	scale	0.775641026	0.525023336	0.624030573	0.637037037
21	13	rbf	scale	0.775641026	0.525023336	0.624030573	0.637037037
22	14	rbf	scale	0.782051282	0.525023336	0.624030573	0.637037037
23	15	rbf	scale	0.78525641	0.525023336	0.624030573	0.637037037
24	16	rbf	scale	0.78525641	0.525023336	0.624030573	0.637037037
25	19	rbf	scale	0.794871795	0.523792384	0.622760732	0.637037037
26	20	rbf	scale	0.798076923	0.523792384	0.622760732	0.637037037
27	1	sigmoid	scale	0.583333333	0.502395872	0.566956585	0.62962963
28	3	sigmoid	scale	0.586538462	0.506975385	0.578977482	0.62962963
29	4	linear	scale	0.705128205	0.519743863	0.624412264	0.62962963
30	4	linear	auto	0.705128205	0.519743863	0.624412264	0.62962963
31	4	sigmoid	scale	0.58974359	0.506578947	0.582467489	0.62962963
32	17	rbf	scale	0.78525641	0.514248705	0.615583012	0.62962963
33	18	rbf	scale	0.791666667	0.514248705	0.615583012	0.62962963
34	5	linear	scale	0.705128205	0.509755056	0.618193008	0.622222222
35	5	linear	auto	0.705128205	0.509755056	0.618193008	0.622222222
36	5	sigmoid	scale	0.576923077	0.497261774	0.575385348	0.622222222
37	7	linear	scale	0.701923077	0.510417407	0.620271058	0.622222222
38	7	linear	auto	0.701923077	0.510417407	0.620271058	0.622222222
39	8	linear	scale	0.701923077	0.510556622	0.620674066	0.622222222
40	8	linear	auto	0.701923077	0.510556622	0.620674066	0.622222222
41	9	linear	scale	0.705128205	0.510556622	0.620674066	0.622222222
42	9	linear	auto	0.705128205	0.510556622	0.620674066	0.622222222
43	10	linear	scale	0.705128205	0.510556622	0.620674066	0.622222222
44	10	linear	auto	0.705128205	0.510556622	0.620674066	0.622222222
45	10	sigmoid	scale	0.570512821	0.498177843	0.576600613	0.622222222
46	11	linear	scale	0.705128205	0.510556622	0.620674066	0.622222222
47	11	linear	auto	0.705128205	0.510556622	0.620674066	0.622222222
48	11	sigmoid	scale	0.570512821	0.498944764	0.585404434	0.622222222
49	12	linear	scale	0.705128205	0.510556622	0.620674066	0.622222222
50	12	linear	auto	0.705128205	0.510556622	0.620674066	0.622222222

Grup 3 Etiketleri	1	2	rbf	scale	0.666666667	0.613908331	0.718688616	0.718518519
	2	3	rbf	scale	0.673076923	0.61472024	0.719041145	0.718518519
	3	4	rbf	scale	0.676282051	0.614314713	0.718138488	0.718518519
	4	5	rbf	scale	0.685897436	0.614314713	0.718138488	0.718518519
	5	12	rbf	scale	0.698717949	0.616419919	0.712603622	0.718518519
	6	13	rbf	scale	0.698717949	0.616419919	0.712603622	0.718518519
	7	1	linear	scale	0.666666667	0.605322339	0.713841402	0.711111111
	8	1	linear	auto	0.666666667	0.605322339	0.713841402	0.711111111
	9	1	rbf	scale	0.657051282	0.601558953	0.708495487	0.711111111
	10	2	linear	scale	0.663461538	0.605322339	0.713841402	0.711111111
	11	2	linear	auto	0.663461538	0.605322339	0.713841402	0.711111111
	12	3	linear	scale	0.66025641	0.605322339	0.713841402	0.711111111
	13	3	linear	auto	0.66025641	0.605322339	0.713841402	0.711111111
	14	4	linear	scale	0.66025641	0.605322339	0.713841402	0.711111111
	15	4	linear	auto	0.66025641	0.605322339	0.713841402	0.711111111
	16	6	rbf	scale	0.689102564	0.605411077	0.704667742	0.711111111
	17	7	rbf	scale	0.689102564	0.605411077	0.704667742	0.711111111
	18	8	rbf	scale	0.692307692	0.605411077	0.704667742	0.711111111
	19	9	rbf	scale	0.692307692	0.605411077	0.704667742	0.711111111
	20	10	rbf	scale	0.692307692	0.605411077	0.704667742	0.711111111
	21	11	rbf	scale	0.695512821	0.605411077	0.704667742	0.711111111
	22	14	rbf	scale	0.698717949	0.605411077	0.704667742	0.711111111
	23	15	rbf	scale	0.698717949	0.605411077	0.704667742	0.711111111
	24	5	rbf	auto	0.78525641	0.593923898	0.696641167	0.703703704
	25	16	rbf	scale	0.698717949	0.595626778	0.698185373	0.703703704
	26	17	rbf	scale	0.698717949	0.595626778	0.698185373	0.703703704
	27	18	rbf	scale	0.701923077	0.595959596	0.699812641	0.703703704
	28	19	rbf	scale	0.701923077	0.595959596	0.699812641	0.703703704
	29	20	rbf	scale	0.698717949	0.595959596	0.699812641	0.703703704
	30	4	rbf	auto	0.775641026	0.58480234	0.690627661	0.696296296
	31	5	linear	scale	0.666666667	0.58749441	0.699591984	0.696296296
	32	5	linear	auto	0.666666667	0.58749441	0.699591984	0.696296296
	33	6	linear	scale	0.666666667	0.58749441	0.699591984	0.696296296
	34	6	linear	auto	0.666666667	0.58749441	0.699591984	0.696296296
	35	7	linear	scale	0.666666667	0.58749441	0.699591984	0.696296296
	36	7	linear	auto	0.666666667	0.58749441	0.699591984	0.696296296
	37	8	linear	scale	0.666666667	0.58749441	0.699591984	0.696296296
	38	8	linear	auto	0.666666667	0.58749441	0.699591984	0.696296296
	39	9	linear	scale	0.666666667	0.58749441	0.699591984	0.696296296
	40	9	linear	auto	0.666666667	0.58749441	0.699591984	0.696296296
	41	10	linear	scale	0.666666667	0.58749441	0.699591984	0.696296296
	42	10	linear	auto	0.666666667	0.58749441	0.699591984	0.696296296
	43	11	linear	scale	0.666666667	0.58749441	0.699591984	0.696296296
	44	11	linear	auto	0.666666667	0.58749441	0.699591984	0.696296296

	45	12	linear	scale	0.666666667	0.58749441	0.699591984	0.696296296
	46	12	linear	auto	0.666666667	0.58749441	0.699591984	0.696296296
	47	13	linear	scale	0.666666667	0.58749441	0.699591984	0.696296296
	48	13	linear	auto	0.666666667	0.58749441	0.699591984	0.696296296
	49	2	rbf	auto	0.746794872	0.573812387	0.684522413	0.688888889
	50	3	rbf	auto	0.753205128	0.573427626	0.683526655	0.688888889

Tablo 0.4. GBM En Başarılı 50 Model

	Model	learnig_rate	n_estimators	max_depth	accuracy_train	cohen	f1	accuracy_test
Bölüm Etiketi	1	0.001	300	2	0.599358974	0.24071991	0.25942538	0.333333333
	2	0.001	700	2	0.743589744	0.2373818	0.268241007	0.318518519
	3	0.005	300	2	0.900641026	0.240288031	0.28646687	0.311111111
	4	0.005	700	2	0.990384615	0.24946198	0.29467303	0.311111111
	5	0.007	300	2	0.955128205	0.244130042	0.285674573	0.311111111
	6	0.01	300	2	0.980769231	0.245900655	0.289667688	0.311111111
	7	0.001	900	2	0.794871795	0.226926592	0.265469852	0.303703704
	8	0.005	500	2	0.971153846	0.237837838	0.28181866	0.303703704
	9	0.007	100	2	0.746794872	0.219028863	0.257479413	0.303703704
	10	0.01	900	2	1	0.245989305	0.291099602	0.303703704
	11	0.05	300	2	1	0.244552923	0.286900651	0.303703704
	12	0.07	100	2	1	0.245047296	0.293110804	0.303703704
	13	0.007	500	2	0.990384615	0.234785203	0.281794143	0.296296296
	14	0.007	700	2	1	0.23396249	0.278763079	0.296296296
	15	0.01	100	2	0.820512821	0.221358752	0.263420472	0.296296296
	16	0.01	500	2	1	0.233779424	0.278009342	0.296296296
	17	0.05	100	2	1	0.23254144	0.280352597	0.296296296
	18	0.3	300	2	0.996794872	0.236379875	0.284515519	0.296296296
	19	0.001	500	2	0.673076923	0.199950614	0.238197661	0.288888889
	20	0.005	100	2	0.673076923	0.20004938	0.238197661	0.288888889
	21	0.005	900	2	1	0.227007038	0.272947747	0.288888889
	22	0.01	700	2	1	0.229855004	0.274942854	0.288888889
	23	0.05	500	4	1	0.231362315	0.274830954	0.288888889
	24	0.07	300	2	1	0.231863442	0.284337361	0.288888889
	25	0.07	300	4	1	0.231316726	0.273823394	0.288888889
	26	0.5	900	4	1	0.228203907	0.281018023	0.288888889
	27	0.007	900	2	1	0.220582108	0.269427326	0.281481481
	28	0.05	500	2	1	0.22505622	0.2783568	0.281481481
	29	0.07	500	2	1	0.223585912	0.276601307	0.281481481
	30	0.3	100	2	0.996794872	0.224367707	0.271841778	0.281481481
	31	0.3	100	4	1	0.23106283	0.278512359	0.281481481
	32	0.3	500	2	0.996794872	0.219327531	0.268007364	0.281481481
	33	0.3	500	6	1	0.217601721	0.264698981	0.281481481
	34	0.5	100	4	1	0.220164364	0.272549049	0.281481481

	35	0.1	100	4	1	0.21474359	0.268368768	0.274074074
	36	0.1	700	4	1	0.214137214	0.268319374	0.274074074
	37	0.1	900	4	1	0.212921649	0.263910526	0.274074074
	38	0.3	700	4	1	0.209299546	0.262304687	0.274074074
	39	0.3	900	6	1	0.206929625	0.244714032	0.274074074
	40	0.005	300	4	1	0.200944637	0.248992532	0.266666667
	41	0.007	900	4	1	0.209545777	0.261995712	0.266666667
	42	0.01	900	4	1	0.212062257	0.262693811	0.266666667
	43	0.05	100	4	1	0.211225212	0.266012395	0.266666667
	44	0.05	300	4	1	0.209031189	0.255616173	0.266666667
	45	0.05	900	2	1	0.20851593	0.264556201	0.266666667
	46	0.05	900	4	1	0.207154298	0.252163689	0.266666667
	47	0.07	500	4	1	0.205599144	0.25974304	0.266666667
	48	0.07	700	2	1	0.208	0.262637154	0.266666667
	49	0.07	900	2	1	0.206401045	0.261617837	0.266666667
Grup 1 Etiketi	50	0.1	300	2	1	0.211132098	0.26617482	0.266666667
	1	0.005	300	2	0.830128205	0.327257229	0.357389771	0.437037037
	2	0.001	500	2	0.628205128	0.291481631	0.329205028	0.422222222
	3	0.005	100	2	0.631410256	0.291481631	0.329205028	0.422222222
	4	0.01	100	2	0.75	0.304031725	0.342952226	0.422222222
	5	0.01	700	2	1	0.317352621	0.361699225	0.414814815
	6	0.001	900	2	0.71474359	0.288209319	0.331728143	0.407407407
	7	0.007	300	2	0.881410256	0.302910992	0.336597786	0.407407407
	8	0.007	900	2	1	0.305600206	0.353447102	0.407407407
	9	0.3	900	2	0.993589744	0.306135561	0.359860159	0.407407407
	10	0.001	700	2	0.676282051	0.270465008	0.318002463	0.4
	11	0.007	100	2	0.679487179	0.269977969	0.316880129	0.4
	12	0.01	500	2	0.990384615	0.300607611	0.352931001	0.4
	13	0.005	500	2	0.91025641	0.285806452	0.32349273	0.392592593
	14	0.005	700	2	0.958333333	0.284883721	0.32726039	0.392592593
	15	0.005	900	2	0.977564103	0.287094281	0.330362915	0.392592593
	16	0.007	500	2	0.958333333	0.283355991	0.325871793	0.392592593
	17	0.007	700	2	0.990384615	0.287919722	0.327485123	0.392592593
	18	0.01	300	2	0.939102564	0.287186091	0.328580175	0.392592593
	19	0.01	900	2	1	0.291020879	0.341533898	0.392592593
	20	0.05	500	4	1	0.297633399	0.359666637	0.392592593
	21	0.5	900	6	1	0.285944656	0.343173514	0.392592593
	22	0.05	100	2	0.996794872	0.284848098	0.335185185	0.385185185
	23	0.07	700	4	1	0.277108434	0.335360296	0.377777778
	24	0.5	300	4	1	0.267725688	0.327015149	0.377777778
	25	0.05	100	4	1	0.264375922	0.317085935	0.37037037
	26	0.05	300	2	1	0.272306424	0.334016814	0.37037037
	27	0.07	500	2	1	0.276253548	0.343891265	0.37037037
	28	0.3	100	2	0.993589744	0.280338664	0.34965566	0.37037037

Grup 2 Etiketi	29	0.3	700	6	1	0.265082618	0.328008996	0.37037037
	30	0.5	300	6	1	0.263526089	0.319642661	0.37037037
	31	0.07	100	4	1	0.263932036	0.319204766	0.362962963
	32	0.07	300	4	1	0.261168385	0.327049381	0.362962963
	33	0.001	500	4	0.875	0.210950621	0.280986407	0.355555556
	34	0.001	700	4	0.913461538	0.217313075	0.280765949	0.355555556
	35	0.005	300	4	0.993589744	0.232904448	0.29454633	0.355555556
	36	0.005	900	4	1	0.24503439	0.302926086	0.355555556
	37	0.007	700	4	1	0.244111211	0.29340958	0.355555556
	38	0.01	500	4	1	0.24127907	0.290758699	0.355555556
	39	0.01	900	4	1	0.249088933	0.300624325	0.355555556
	40	0.05	500	2	1	0.262295082	0.334690977	0.355555556
	41	0.07	100	2	1	0.256127684	0.317928497	0.355555556
	42	0.07	500	4	1	0.254380396	0.320808373	0.355555556
	43	0.07	700	2	1	0.258522727	0.331120215	0.355555556
	44	0.07	900	2	1	0.260576681	0.331938399	0.355555556
	45	0.1	300	2	1	0.259270938	0.331825179	0.355555556
	46	0.1	500	2	1	0.259551128	0.331347295	0.355555556
	47	0.3	100	4	1	0.252815065	0.32173508	0.355555556
	48	0.3	500	2	0.993589744	0.258756706	0.328645506	0.355555556
	49	0.3	500	6	1	0.243429528	0.307316368	0.355555556
	50	0.5	300	2	1	0.253622267	0.330637603	0.355555556
	1	0.3	300	4	1	0.51605965	0.615298652	0.62962963
	2	0.001	900	2	0.746794872	0.497481936	0.599271826	0.622222222
	3	0.007	100	2	0.711538462	0.486241218	0.591550355	0.614814815
	4	0.01	100	2	0.762820513	0.490455106	0.595327894	0.614814815
	5	0.1	700	6	1	0.4963048	0.60370498	0.614814815
	6	0.3	100	4	1	0.503219871	0.611458106	0.614814815
	7	0.3	700	4	1	0.494673193	0.602448641	0.614814815
	8	0.001	700	2	0.717948718	0.47555523	0.584543298	0.607407407
	9	0.007	900	4	1	0.490928495	0.596801385	0.607407407
	10	0.1	900	6	1	0.482384432	0.592621285	0.607407407
	11	0.3	500	4	1	0.484287156	0.594825668	0.607407407
	12	0.5	300	4	1	0.484807028	0.595149519	0.607407407
	13	0.007	300	4	0.96474359	0.478540773	0.586800853	0.6
	14	0.05	700	6	1	0.478503469	0.590267769	0.6
	15	0.1	300	6	1	0.479694526	0.596425448	0.6
	16	0.1	500	6	1	0.477119495	0.589461279	0.6
	17	0.001	500	4	0.820512821	0.460745152	0.573018225	0.592592593
	18	0.005	300	2	0.78525641	0.467780087	0.580116719	0.592592593
	19	0.005	700	2	0.871794872	0.472918293	0.584344949	0.592592593
	20	0.007	300	2	0.817307692	0.470437201	0.582829674	0.592592593
	21	0.007	500	2	0.871794872	0.472918293	0.584344949	0.592592593
	22	0.01	100	4	0.887820513	0.466441506	0.575017174	0.592592593

Grup 3 Etiketleri	23	0.01	700	4	1	0.473180077	0.58312019	0.592592593
	24	0.01	900	4	1	0.469036041	0.580164392	0.592592593
	25	0.05	300	2	1	0.471116176	0.581776805	0.592592593
	26	0.05	700	4	1	0.473740166	0.582362239	0.592592593
	27	0.05	900	6	1	0.464826294	0.57947825	0.592592593
	28	0.07	500	6	1	0.469339623	0.586745669	0.592592593
	29	0.07	900	6	1	0.464980545	0.579529597	0.592592593
	30	0.1	500	2	1	0.475894685	0.584786387	0.592592593
	31	0.3	300	6	1	0.464324363	0.577242939	0.592592593
	32	0.5	100	4	1	0.47418738	0.584427447	0.592592593
	33	0.5	300	6	1	0.464710547	0.583139606	0.592592593
	34	0.5	900	4	1	0.463162461	0.580461621	0.592592593
	35	0.001	700	4	0.852564103	0.45631068	0.568423159	0.585185185
	36	0.001	900	4	0.875	0.457675753	0.567541068	0.585185185
	37	0.005	100	4	0.820512821	0.451139829	0.566428946	0.585185185
	38	0.005	300	4	0.932692308	0.459033989	0.567996839	0.585185185
	39	0.005	500	4	0.990384615	0.462686567	0.573259138	0.585185185
	40	0.005	700	6	1	0.457636846	0.571139668	0.585185185
	41	0.005	900	2	0.907051282	0.464513387	0.577341398	0.585185185
	42	0.007	100	4	0.855769231	0.45631068	0.568423159	0.585185185
	43	0.007	900	6	1	0.459111397	0.567825713	0.585185185
	44	0.01	500	6	1	0.460500963	0.568460676	0.585185185
	45	0.05	300	6	1	0.45775355	0.569824234	0.585185185
	46	0.05	900	2	1	0.466177094	0.577145783	0.585185185
	47	0.07	100	4	1	0.463373083	0.573123333	0.585185185
	48	0.07	300	6	1	0.460385439	0.57879828	0.585185185
	49	0.07	700	2	1	0.466177094	0.577145783	0.585185185
	50	0.3	900	4	1	0.452213608	0.573413592	0.585185185
	1	0.01	300	2	0.823717949	0.557545732	0.67687647	0.681481481
	2	0.001	700	2	0.717948718	0.536408335	0.654475413	0.674074074
	3	0.005	300	6	0.996794872	0.548803646	0.668421876	0.674074074
	4	0.005	500	2	0.791666667	0.546876192	0.668694592	0.674074074
	5	0.005	700	2	0.83974359	0.548288973	0.66943313	0.674074074
	6	0.007	100	2	0.71474359	0.536408335	0.654475413	0.674074074
	7	0.007	300	2	0.778846154	0.54541976	0.667217733	0.674074074
	8	0.007	300	6	1	0.550816697	0.671922497	0.674074074
	9	0.007	500	2	0.846153846	0.548288973	0.66943313	0.674074074
	10	0.005	300	2	0.740384615	0.532979705	0.659517945	0.666666667
	11	0.005	300	4	0.935897436	0.539249147	0.662193128	0.666666667
	12	0.01	100	4	0.881410256	0.536011609	0.658495889	0.666666667
	13	0.001	700	4	0.842948718	0.522050335	0.646449078	0.659259259
	14	0.001	900	2	0.721153846	0.516392804	0.641395738	0.659259259
	15	0.001	900	4	0.871794872	0.523992028	0.649504907	0.659259259
	16	0.01	100	2	0.717948718	0.516392804	0.641395738	0.659259259

	17	0.001	700	6	0.967948718	0.51188553	0.638453859	0.651851852
	18	0.005	500	6	1	0.522321765	0.650978938	0.651851852
	19	0.005	700	6	1	0.522501505	0.652286389	0.651851852
	20	0.007	300	4	0.958333333	0.519281764	0.648312461	0.651851852
	21	0.01	300	6	1	0.519791115	0.650125511	0.651851852
	22	0.01	700	6	1	0.518003646	0.646750362	0.651851852
	23	0.05	100	2	0.903846154	0.521853806	0.651933096	0.651851852
	24	0.05	100	6	1	0.522609284	0.651964632	0.651851852
	25	0.5	100	6	1	0.521023628	0.649997595	0.651851852
	26	0.5	700	6	1	0.518990221	0.647160373	0.651851852
	27	0.001	500	2	0.682692308	0.489803952	0.615616162	0.644444444
	28	0.005	100	2	0.682692308	0.489803952	0.615616162	0.644444444
	29	0.005	900	2	0.891025641	0.511164756	0.644182878	0.644444444
	30	0.007	100	4	0.83974359	0.50234237	0.633191766	0.644444444
	31	0.007	100	6	0.967948718	0.501921599	0.631916085	0.644444444
	32	0.007	500	6	1	0.51285521	0.645585283	0.644444444
	33	0.007	900	6	1	0.511238498	0.644566175	0.644444444
	34	0.1	100	6	1	0.512965051	0.645226749	0.644444444
	35	0.5	900	6	1	0.507374183	0.640595428	0.644444444
	36	0.005	900	6	1	0.503229198	0.6388474	0.637037037
	37	0.007	700	2	0.903846154	0.501507159	0.637303467	0.637037037
	38	0.007	700	4	0.996794872	0.5078125	0.64023445	0.637037037
	39	0.007	700	6	1	0.50218242	0.637540802	0.637037037
	40	0.007	900	2	0.932692308	0.501507159	0.636531714	0.637037037
	41	0.01	500	2	0.907051282	0.501507159	0.637303467	0.637037037
	42	0.05	300	6	1	0.503676471	0.639426935	0.637037037
	43	0.07	100	2	0.945512821	0.503490205	0.638163447	0.637037037
	44	0.07	300	6	1	0.503490205	0.637785286	0.637037037
	45	0.1	500	6	1	0.502107482	0.638121942	0.637037037
	46	0.3	100	4	1	0.502219881	0.637403405	0.637037037
	47	0.3	100	6	1	0.501995031	0.6363862	0.637037037
	48	0.3	700	6	1	0.496690253	0.63446551	0.637037037
	49	0.3	900	6	1	0.501507159	0.638007204	0.637037037
	50	0.5	500	4	1	0.499848783	0.637139412	0.637037037

Tablo 0.5. XGBoost En Başarılı 50 Model

	Model	learning_rate	n_estimators	max_depth	subsample	accuracy_train	cohen	f1	accuracy_test
Bölüm Etiketİ	1	0.001	100	2	0.4	0.448717949	0.355268871	0.326569864	0.42962963
	2	0.001	100	4	0.4	0.461538462	0.355588618	0.324100728	0.42962963
	3	0.001	100	6	0.4	0.461538462	0.355588618	0.324100728	0.42962963
	4	0.001	100	8	0.4	0.461538462	0.355588618	0.324100728	0.42962963
	5	0.005	100	4	0.6	0.66025641	0.346627458	0.339520533	0.414814815
	6	0.005	100	6	0.6	0.666666667	0.347786204	0.340256082	0.414814815

7	0.005	100	8	0.6	0.666666667	0.347786204	0.340256082	0.414814815
8	0.001	100	2	0.6	0.477564103	0.332302937	0.312507779	0.407407407
9	0.001	100	4	0.6	0.53525641	0.335670788	0.318084904	0.407407407
10	0.001	100	6	0.6	0.53525641	0.335670788	0.318084904	0.407407407
11	0.001	100	8	0.6	0.53525641	0.335670788	0.318084904	0.407407407
12	0.001	400	2	0.6	0.557692308	0.332921557	0.3209683	0.407407407
13	0.001	400	4	0.4	0.522435897	0.330689142	0.29905806	0.407407407
14	0.001	400	4	0.6	0.637820513	0.336242394	0.324090885	0.407407407
15	0.001	400	6	0.4	0.522435897	0.330689142	0.29905806	0.407407407
16	0.001	400	6	0.6	0.641025641	0.336242394	0.324090885	0.407407407
17	0.001	400	8	0.4	0.522435897	0.330689142	0.29905806	0.407407407
18	0.001	400	8	0.6	0.641025641	0.336242394	0.324090885	0.407407407
19	0.005	100	2	0.4	0.490384615	0.32994168	0.309137447	0.407407407
20	0.01	100	2	0.4	0.554487179	0.332096475	0.305298382	0.407407407
21	0.001	400	2	0.4	0.5	0.320723071	0.294880158	0.4
22	0.001	700	2	0.4	0.532051282	0.320849637	0.293922893	0.4
23	0.001	1000	2	0.4	0.557692308	0.320933987	0.293536243	0.4
24	0.005	100	2	0.6	0.564102564	0.325956975	0.320749423	0.4
25	0.005	100	4	0.4	0.516025641	0.322154724	0.302006519	0.4
26	0.005	100	6	0.4	0.516025641	0.322154724	0.302006519	0.4
27	0.005	100	8	0.4	0.516025641	0.322154724	0.302006519	0.4
28	0.001	700	4	0.6	0.695512821	0.325740041	0.336189449	0.392592593
29	0.01	100	4	0.8	0.820512821	0.331602463	0.349807796	0.392592593
30	0.001	700	4	0.4	0.567307692	0.306020067	0.285006235	0.385185185
31	0.001	700	6	0.4	0.567307692	0.306020067	0.285006235	0.385185185
32	0.001	700	6	0.6	0.695512821	0.318098832	0.331022599	0.385185185
33	0.001	700	8	0.4	0.567307692	0.306020067	0.285006235	0.385185185
34	0.001	700	8	0.6	0.695512821	0.318098832	0.331022599	0.385185185
35	0.001	1000	2	0.2	0.403846154	0.290957413	0.265339981	0.385185185
36	0.001	1000	4	0.2	0.403846154	0.292077331	0.268264667	0.385185185
37	0.001	1000	6	0.2	0.403846154	0.292077331	0.268264667	0.385185185
38	0.001	1000	8	0.2	0.403846154	0.292077331	0.268264667	0.385185185
39	0.01	100	8	0.6	0.746794872	0.319134715	0.326365407	0.385185185
40	0.001	700	2	0.6	0.631410256	0.301982026	0.296117759	0.377777778
41	0.001	700	2	0.8	0.66025641	0.305700116	0.324992601	0.377777778
42	0.001	1000	2	0.8	0.71474359	0.308578745	0.326751718	0.377777778
43	0.001	1000	4	0.4	0.599358974	0.300647549	0.283992279	0.377777778
44	0.001	1000	4	0.6	0.743589744	0.312185358	0.327017436	0.377777778
45	0.001	1000	6	0.4	0.602564103	0.300647549	0.283992279	0.377777778
46	0.001	1000	6	0.6	0.75	0.312185358	0.327017436	0.377777778
47	0.001	1000	8	0.4	0.602564103	0.300647549	0.283992279	0.377777778
48	0.001	1000	8	0.6	0.75	0.312185358	0.327017436	0.377777778
49	0.005	100	2	0.8	0.605769231	0.306082487	0.322789803	0.377777778
50	0.005	400	2	0.2	0.461538462	0.293765959	0.277063584	0.377777778

Grup 1 Etiketi	1	0.05	100	2	0.4	0.820512821	0.440704298	0.45128124	0.525925926
	2	0.005	1000	2	0.4	0.817307692	0.426470588	0.434454466	0.518518519
	3	0.005	1000	4	0.4	0.881410256	0.431155193	0.445024566	0.518518519
	4	0.01	400	2	0.4	0.801282051	0.427331463	0.432727884	0.518518519
	5	0.005	700	4	0.4	0.842948718	0.42206655	0.436309331	0.511111111
	6	0.005	1000	2	0.6	0.878205128	0.421466139	0.437782094	0.511111111
	7	0.01	700	4	0.4	0.945512821	0.422291383	0.439573474	0.511111111
	8	0.01	700	6	0.4	0.955128205	0.424046542	0.438441622	0.511111111
	9	0.005	400	4	0.4	0.798076923	0.412166114	0.431413864	0.503703704
	10	0.005	700	2	0.4	0.756410256	0.406457117	0.41662329	0.503703704
	11	0.005	700	6	0.4	0.855769231	0.415206569	0.43312873	0.503703704
	12	0.005	700	8	0.4	0.855769231	0.416074887	0.434900066	0.503703704
	13	0.005	1000	6	0.4	0.897435897	0.416413962	0.435714067	0.503703704
	14	0.005	1000	8	0.4	0.900641026	0.416413962	0.435714067	0.503703704
	15	0.01	400	4	0.4	0.858974359	0.411362749	0.429438117	0.503703704
	16	0.01	700	2	0.4	0.855769231	0.409864944	0.425969216	0.503703704
	17	0.01	700	8	0.4	0.958333333	0.414563107	0.434170824	0.503703704
	18	0.01	1000	2	0.4	0.923076923	0.411975036	0.429227457	0.503703704
	19	0.005	400	6	0.4	0.810897436	0.405247813	0.427878741	0.496296296
	20	0.005	400	8	0.4	0.807692308	0.407168227	0.42980546	0.496296296
	21	0.005	700	4	0.2	0.695512821	0.39577437	0.412307538	0.496296296
	22	0.005	700	8	0.2	0.698717949	0.39577437	0.412307538	0.496296296
	23	0.01	400	6	0.4	0.868589744	0.408543264	0.431337928	0.496296296
	24	0.01	400	8	0.4	0.868589744	0.408543264	0.430632461	0.496296296
	25	0.01	1000	4	0.4	0.987179487	0.406247979	0.428012531	0.496296296
	26	0.01	1000	6	0.4	0.987179487	0.408314534	0.431253336	0.496296296
	27	0.01	1000	8	0.4	0.987179487	0.407283058	0.430621601	0.496296296
	28	0.005	400	2	0.4	0.698717949	0.386646474	0.395781623	0.488888889
	29	0.005	700	2	0.6	0.810897436	0.394303921	0.416266151	0.488888889
	30	0.005	700	6	0.2	0.698717949	0.385878165	0.402974547	0.488888889
	31	0.005	1000	4	0.2	0.730769231	0.390419475	0.410818702	0.488888889
	32	0.005	1000	6	0.2	0.730769231	0.390259868	0.411395903	0.488888889
	33	0.005	1000	8	0.2	0.727564103	0.390259868	0.411395903	0.488888889
	34	0.01	400	4	0.2	0.711538462	0.388899823	0.406310947	0.488888889
	35	0.01	400	6	0.2	0.711538462	0.388899823	0.406310947	0.488888889
	36	0.01	400	8	0.2	0.711538462	0.388899823	0.406310947	0.488888889
	37	0.01	1000	2	0.2	0.794871795	0.390738439	0.409655756	0.488888889
	38	0.001	1000	4	0.2	0.477564103	0.363936192	0.354219317	0.481481481
	39	0.001	1000	6	0.2	0.477564103	0.364962032	0.355564883	0.481481481
	40	0.001	1000	8	0.2	0.477564103	0.364962032	0.355564883	0.481481481
	41	0.005	400	4	0.2	0.58974359	0.376114082	0.39065924	0.481481481
	42	0.005	400	6	0.2	0.592948718	0.376114082	0.39065924	0.481481481
	43	0.005	400	8	0.2	0.592948718	0.376114082	0.39065924	0.481481481
	44	0.01	100	6	0.4	0.71474359	0.382110632	0.404828188	0.481481481

Grup 2 Etiketi	45	0.01	100	8	0.4	0.721153846	0.382110632	0.404828188	0.481481481
	46	0.01	400	2	0.6	0.852564103	0.38564556	0.410112305	0.481481481
	47	0.01	1000	4	0.2	0.804487179	0.385885105	0.411837792	0.481481481
	48	0.001	1000	8	0.4	0.730769231	0.375610709	0.402064771	0.474074074
	49	0.005	1000	2	0.2	0.698717949	0.369490856	0.394563265	0.474074074
	50	0.01	100	4	0.4	0.695512821	0.370319275	0.387925875	0.474074074
	1	0.001	1000	6	0.2	0.730769231	0.541015625	0.627928253	0.651851852
	2	0.001	1000	8	0.2	0.730769231	0.541015625	0.627928253	0.651851852
	3	0.005	400	2	0.2	0.689102564	0.537940577	0.625584835	0.651851852
	4	0.01	100	2	0.8	0.708333333	0.543426639	0.634106655	0.651851852
	5	0.001	1000	2	0.2	0.669871795	0.526661797	0.615468158	0.644444444
	6	0.001	1000	4	0.2	0.721153846	0.531419481	0.621158565	0.644444444
	7	0.005	100	4	0.2	0.701923077	0.52848723	0.617237021	0.644444444
	8	0.005	100	6	0.2	0.708333333	0.528143887	0.61656689	0.644444444
	9	0.005	100	8	0.2	0.708333333	0.528143887	0.61656689	0.644444444
	10	0.005	400	4	0.2	0.730769231	0.531791908	0.623433793	0.644444444
	11	0.05	100	4	0.2	0.78525641	0.536712662	0.633630299	0.644444444
	12	0.05	100	6	0.2	0.801282051	0.536049259	0.627989247	0.644444444
	13	0.05	100	8	0.2	0.788461538	0.536049259	0.627989247	0.644444444
	14	0.001	100	2	0.2	0.641025641	0.514958205	0.607408926	0.637037037
	15	0.001	100	2	0.4	0.669871795	0.517821999	0.610346855	0.637037037
	16	0.001	400	2	0.2	0.641025641	0.514174501	0.604213278	0.637037037
	17	0.001	400	2	0.4	0.679487179	0.517962545	0.611845421	0.637037037
	18	0.001	400	2	0.8	0.679487179	0.519468255	0.608845377	0.637037037
	19	0.001	700	2	0.2	0.66025641	0.515845715	0.606494995	0.637037037
	20	0.001	700	2	0.4	0.682692308	0.519398431	0.612200935	0.637037037
	21	0.001	700	6	0.2	0.708333333	0.521276596	0.613558225	0.637037037
	22	0.005	100	2	0.2	0.679487179	0.517435074	0.608721603	0.637037037
	23	0.005	100	2	0.4	0.676282051	0.518734085	0.611224008	0.637037037
	24	0.01	100	2	0.2	0.676282051	0.517223763	0.609345684	0.637037037
	25	0.01	100	2	0.6	0.685897436	0.522072105	0.616356108	0.637037037
	26	0.01	100	6	0.6	0.855769231	0.52533008	0.622223528	0.637037037
	27	0.05	100	6	0.4	0.923076923	0.529080943	0.629238486	0.637037037
	28	0.001	100	2	0.6	0.663461538	0.508017493	0.601974132	0.62962963
	29	0.001	100	2	0.8	0.641025641	0.509661485	0.598827114	0.62962963
	30	0.001	100	4	0.4	0.740384615	0.512494583	0.609373459	0.62962963
	31	0.001	100	4	0.6	0.772435897	0.511400651	0.607969636	0.62962963
	32	0.001	100	6	0.4	0.746794872	0.513408304	0.609900933	0.62962963
	33	0.001	100	6	0.6	0.798076923	0.512670565	0.609785762	0.62962963
	34	0.001	100	8	0.4	0.753205128	0.513408304	0.609900933	0.62962963
	35	0.001	100	8	0.6	0.807692308	0.512670565	0.609785762	0.62962963
	36	0.001	400	4	0.4	0.759615385	0.512670565	0.609785762	0.62962963
	37	0.001	700	4	0.2	0.701923077	0.509839518	0.604814582	0.62962963
	38	0.001	700	8	0.2	0.708333333	0.511117549	0.605599303	0.62962963

	39	0.001	1000	2	0.4	0.692307692	0.509981851	0.605095141	0.62962963
	40	0.005	100	2	0.6	0.676282051	0.508554787	0.603403649	0.62962963
	41	0.005	100	4	0.6	0.778846154	0.511223751	0.607533109	0.62962963
	42	0.005	100	8	0.6	0.846153846	0.513548573	0.611477411	0.62962963
	43	0.005	400	2	0.6	0.733974359	0.51319775	0.611026882	0.62962963
	44	0.005	400	2	0.8	0.746794872	0.514632919	0.613823588	0.62962963
	45	0.005	400	4	0.6	0.836538462	0.514598015	0.614798239	0.62962963
	46	0.005	700	2	0.2	0.721153846	0.511577424	0.60870051	0.62962963
	47	0.005	700	4	0.2	0.762820513	0.513898891	0.61180891	0.62962963
	48	0.005	700	8	0.2	0.775641026	0.515503876	0.61217581	0.62962963
	49	0.005	1000	2	0.2	0.746794872	0.513898891	0.61180891	0.62962963
	50	0.005	1000	4	0.2	0.810897436	0.514248705	0.61225721	0.62962963
Grup 3 Etiketi	1	0.005	400	2	0.6	0.717948718	0.651639344	0.746573612	0.748148148
	2	0.005	400	2	0.8	0.717948718	0.651797906	0.745416035	0.748148148
	3	0.001	1000	2	0.4	0.698717949	0.630502547	0.733420757	0.733333333
	4	0.005	100	2	0.4	0.692307692	0.62812763	0.72931369	0.733333333
	5	0.005	400	2	0.4	0.705128205	0.633235228	0.734623484	0.733333333
	6	0.01	100	2	0.6	0.71474359	0.632096896	0.731398421	0.733333333
	7	0.001	400	2	0.6	0.708333333	0.619776205	0.720133993	0.725925926
	8	0.001	700	2	0.8	0.724358974	0.620584884	0.720535319	0.725925926
	9	0.001	700	8	0.4	0.814102564	0.626848947	0.72824581	0.725925926
	10	0.001	1000	2	0.8	0.711538462	0.620671324	0.722245948	0.725925926
	11	0.001	1000	4	0.4	0.778846154	0.626848947	0.72824581	0.725925926
	12	0.001	1000	8	0.4	0.83974359	0.626848947	0.72824581	0.725925926
	13	0.005	100	2	0.8	0.717948718	0.619863014	0.72152161	0.725925926
	14	0.005	100	6	0.2	0.721153846	0.623842157	0.727525156	0.725925926
	15	0.005	100	8	0.2	0.721153846	0.623842157	0.727525156	0.725925926
	16	0.005	700	2	0.2	0.708333333	0.625506073	0.727795783	0.725925926
	17	0.005	700	2	0.4	0.733974359	0.625982778	0.72808276	0.725925926
	18	0.01	100	2	0.8	0.71474359	0.620671324	0.722245948	0.725925926
	19	0.001	100	2	0.4	0.689102564	0.605778837	0.710282946	0.718518519
	20	0.001	100	2	0.6	0.701923077	0.60941069	0.713347704	0.718518519
	21	0.001	100	4	0.2	0.685897436	0.611628435	0.720252422	0.718518519
	22	0.001	100	6	0.2	0.698717949	0.611628435	0.720252422	0.718518519
	23	0.001	100	8	0.2	0.698717949	0.611628435	0.720252422	0.718518519
	24	0.001	400	2	0.4	0.698717949	0.608307246	0.715893609	0.718518519
	25	0.001	400	4	0.4	0.746794872	0.614749174	0.720448174	0.718518519
	26	0.001	400	6	0.4	0.791666667	0.616448598	0.720833613	0.718518519
	27	0.001	700	4	0.4	0.775641026	0.616362549	0.720645611	0.718518519
	28	0.001	700	6	0.2	0.708333333	0.612625538	0.71945731	0.718518519
	29	0.001	700	6	0.4	0.807692308	0.616362549	0.720645611	0.718518519
	30	0.001	700	8	0.2	0.708333333	0.612625538	0.71945731	0.718518519
	31	0.001	1000	6	0.2	0.724358974	0.615067157	0.720551033	0.718518519
	32	0.005	100	2	0.6	0.705128205	0.609915596	0.71312926	0.718518519

33	0.005	100	4	0.8	0.788461538	0.617820159	0.718048363	0.718518519
34	0.005	100	8	0.4	0.807692308	0.6180478	0.721109627	0.718518519
35	0.01	100	2	0.2	0.685897436	0.608874657	0.715693954	0.718518519
36	0.01	100	2	0.4	0.698717949	0.610803429	0.719199965	0.718518519
37	0.01	100	4	0.2	0.730769231	0.6140826	0.720534886	0.718518519
38	0.01	100	4	0.8	0.833333333	0.617107031	0.717710629	0.718518519
39	0.01	100	8	0.4	0.817307692	0.618927351	0.721641405	0.718518519
40	0.01	400	2	0.2	0.727564103	0.614980486	0.720150897	0.718518519
41	0.01	400	8	0.4	0.907051282	0.620112559	0.723334243	0.718518519
42	0.001	100	8	0.4	0.759615385	0.605942669	0.713026155	0.711111111
43	0.001	400	2	0.8	0.717948718	0.600924733	0.706347145	0.711111111
44	0.001	400	8	0.4	0.801282051	0.605942669	0.713233414	0.711111111
45	0.001	700	2	0.4	0.695512821	0.597569365	0.708238552	0.711111111
46	0.001	700	2	0.6	0.708333333	0.599040439	0.706755719	0.711111111
47	0.001	700	4	0.2	0.698717949	0.602851324	0.71251675	0.711111111
48	0.001	700	4	0.6	0.788461538	0.607762795	0.711697299	0.711111111
49	0.001	1000	2	0.2	0.679487179	0.599284573	0.710600952	0.711111111
50	0.001	1000	2	0.6	0.708333333	0.599893609	0.707375886	0.711111111

Tablo 0.6. LGBM En Başarılı 50 Model

	Model	learning_rate	n_estimators	max_depth	accuracy_train	cohen	f1	accuracy_test
Bölüm Etiket	1	0.001	500	3	0.810897436	0.33995544	0.337058364	0.414814815
	2	0.005	100	3	0.810897436	0.34064915	0.337523295	0.414814815
	3	0.001	500	5	0.858974359	0.317088217	0.320967333	0.392592593
	4	0.001	700	2	0.788461538	0.317425083	0.319379305	0.392592593
	5	0.005	100	5	0.858974359	0.316961807	0.321752967	0.392592593
	6	0.001	500	4	0.852564103	0.309526744	0.315993156	0.385185185
	7	0.005	100	4	0.855769231	0.308674729	0.315535234	0.385185185
	8	0.005	300	3	0.990384615	0.318015825	0.332802745	0.385185185
	9	0.005	500	4	1	0.322018515	0.334129947	0.385185185
	10	0.007	300	2	0.961538462	0.319258809	0.338849837	0.385185185
	11	0.001	500	2	0.689102564	0.296875	0.292023516	0.377777778
	12	0.001	700	5	0.942307692	0.30582762	0.316271015	0.377777778
	13	0.005	100	2	0.689102564	0.296875	0.292023516	0.377777778
	14	0.005	300	2	0.923076923	0.309715121	0.328791319	0.377777778
	15	0.007	100	2	0.791666667	0.300474986	0.308956669	0.377777778
	16	0.007	100	3	0.903846154	0.303268616	0.317719884	0.377777778
	17	0.007	300	3	0.993589744	0.311851447	0.328162164	0.377777778
	18	0.007	300	4	1	0.313393073	0.328570444	0.377777778
	19	0.001	300	2	0.467948718	0.26653883	0.266309795	0.37037037
	20	0.001	300	5	0.641025641	0.273504274	0.276363972	0.37037037
	21	0.001	700	4	0.942307692	0.297735618	0.313184239	0.37037037
	22	0.007	300	5	1	0.304039301	0.318799791	0.37037037
	23	0.01	100	2	0.858974359	0.296831914	0.30783822	0.37037037

Grup 1 Etiketİ	24	0.01	300	4	1	0.305135037	0.321077123	0.37037037
	25	0.001	300	3	0.58974359	0.262623055	0.268376469	0.362962963
	26	0.001	300	4	0.647435897	0.264957265	0.267898364	0.362962963
	27	0.001	700	3	0.903846154	0.286635945	0.306501838	0.362962963
	28	0.005	300	4	0.996794872	0.293236744	0.311603327	0.362962963
	29	0.005	300	5	0.996794872	0.292332074	0.310720545	0.362962963
	30	0.005	500	2	0.980769231	0.298277425	0.324988461	0.362962963
	31	0.005	500	5	1	0.296704628	0.318297213	0.362962963
	32	0.005	700	2	0.993589744	0.29912466	0.318123359	0.362962963
	33	0.007	100	4	0.942307692	0.288690112	0.304450698	0.362962963
	34	0.007	100	5	0.948717949	0.288297677	0.307266691	0.362962963
	35	0.007	500	4	1	0.295381441	0.314817071	0.362962963
	36	0.01	300	2	0.990384615	0.300138646	0.324044087	0.362962963
	37	0.05	100	3	1	0.299378432	0.321824045	0.362962963
	38	0.07	100	2	1	0.29963202	0.328893708	0.362962963
	39	0.005	500	3	1	0.289903265	0.314012541	0.355555556
	40	0.005	700	3	1	0.289946194	0.309837011	0.355555556
	41	0.005	700	4	1	0.289301706	0.309109738	0.355555556
	42	0.007	500	2	0.993589744	0.290418076	0.313175194	0.355555556
	43	0.007	500	3	1	0.288914452	0.305038673	0.355555556
	44	0.01	100	4	0.980769231	0.282704287	0.309512052	0.355555556
	45	0.01	500	2	1	0.291701845	0.314183993	0.355555556
	46	0.05	100	2	1	0.293533835	0.32058908	0.355555556
	47	0.07	100	5	1	0.287663755	0.304948464	0.355555556
	48	0.005	700	5	1	0.281219748	0.304773751	0.348148148
	49	0.007	700	2	1	0.28489737	0.308347067	0.348148148
	50	0.007	700	4	1	0.281828074	0.303751869	0.348148148
	1	0.007	700	2	0.996794872	0.362150428	0.39420934	0.451851852
	2	0.05	500	4	1	0.366197183	0.413862589	0.451851852
	3	0.005	700	2	0.971153846	0.351501954	0.385214913	0.444444444
	4	0.01	500	2	0.996794872	0.354643381	0.389110607	0.444444444
	5	0.5	100	3	1	0.356652688	0.405472334	0.444444444
	6	0.005	300	3	0.939102564	0.337936375	0.374685625	0.437037037
	7	0.007	300	2	0.887820513	0.342012441	0.376506386	0.437037037
	8	0.007	300	3	0.983974359	0.341294299	0.383983289	0.437037037
	9	0.01	100	2	0.724358974	0.319131993	0.342460013	0.437037037
	10	0.05	700	4	1	0.350221659	0.402939068	0.437037037
	11	0.1	300	3	1	0.35059181	0.401781018	0.437037037
	12	0.005	300	2	0.823717949	0.320232801	0.353610425	0.42962963
	13	0.005	300	5	0.980769231	0.331683168	0.376926434	0.42962963
	14	0.005	500	2	0.907051282	0.335782748	0.373451405	0.42962963
	15	0.005	700	3	0.996794872	0.338445873	0.382712629	0.42962963
	16	0.005	700	5	1	0.335273053	0.387404328	0.42962963
	17	0.007	500	2	0.971153846	0.334975369	0.371875166	0.42962963
	18	0.01	300	3	0.993589744	0.335060449	0.383609959	0.42962963

	19	0.01	700	2	1	0.337180386	0.37403445	0.42962963
	20	0.01	700	5	1	0.333012512	0.381735668	0.42962963
	21	0.05	100	2	0.996794872	0.335315557	0.369265077	0.42962963
	22	0.1	100	5	1	0.335527998	0.389032015	0.42962963
	23	0.5	300	3	1	0.338445873	0.387855664	0.42962963
	24	0.005	300	4	0.967948718	0.322350216	0.369832794	0.422222222
	25	0.005	500	4	0.996794872	0.326812428	0.375075838	0.422222222
	26	0.007	300	5	1	0.323959938	0.367825866	0.422222222
	27	0.007	500	5	1	0.325648415	0.376062949	0.422222222
	28	0.01	100	3	0.846153846	0.31324594	0.350979951	0.422222222
	29	0.01	300	2	0.951923077	0.327027545	0.366432291	0.422222222
	30	0.05	300	4	1	0.329470199	0.381320582	0.422222222
	31	0.05	300	5	1	0.332784185	0.387249572	0.422222222
	32	0.05	700	2	1	0.328957431	0.373675668	0.422222222
	33	0.05	700	3	1	0.332022329	0.382378856	0.422222222
	34	0.07	300	4	1	0.332403474	0.387175565	0.422222222
	35	0.07	500	4	1	0.33223413	0.387382765	0.422222222
	36	0.1	100	3	1	0.330067439	0.383700497	0.422222222
	37	0.1	300	2	1	0.328871893	0.377461993	0.422222222
	38	0.1	500	3	1	0.334723275	0.388320707	0.422222222
	39	0.5	300	4	1	0.335017367	0.39885423	0.422222222
	40	0.5	500	3	1	0.330833757	0.382874607	0.422222222
	41	0.5	700	3	1	0.33223413	0.384586403	0.422222222
	42	0.005	500	3	0.990384615	0.314676777	0.361877316	0.414814815
	43	0.005	500	5	1	0.318878529	0.368441563	0.414814815
	44	0.007	300	4	0.996794872	0.314412445	0.360786157	0.414814815
	45	0.007	500	3	0.996794872	0.320614091	0.369148429	0.414814815
	46	0.01	300	4	1	0.31744	0.366303692	0.414814815
	47	0.01	300	5	1	0.3164776	0.367660854	0.414814815
	48	0.05	500	2	1	0.321133036	0.368548157	0.414814815
	49	0.05	500	3	1	0.322340831	0.376987092	0.414814815
	50	0.07	300	3	1	0.320787161	0.373820653	0.414814815
Grup 2 Etiketi	1	0.007	100	3	0.698717949	0.508375819	0.600596069	0.62962963
	2	0.001	700	2	0.682692308	0.497665256	0.59223383	0.622222222
	3	0.007	100	2	0.685897436	0.497665256	0.59223383	0.622222222
	4	0.001	700	3	0.698717949	0.488375483	0.590837663	0.614814815
	5	0.05	300	3	1	0.497818156	0.605402775	0.614814815
	6	0.005	300	2	0.743589744	0.484324324	0.586560646	0.607407407
	7	0.007	700	5	0.996794872	0.49042091	0.594264798	0.607407407
	8	0.01	100	2	0.711538462	0.479484941	0.58187804	0.607407407
	9	0.01	100	3	0.746794872	0.48159687	0.584823028	0.607407407
	10	0.01	100	5	0.798076923	0.4846586	0.591581999	0.607407407
	11	0.07	100	3	0.987179487	0.49139892	0.600699426	0.607407407
	12	0.07	300	5	1	0.489985031	0.597923195	0.607407407
	13	0.07	700	5	1	0.489621228	0.601190697	0.607407407

	14	0.1	100	3	0.996794872	0.489220445	0.598705802	0.607407407
	15	0.005	300	3	0.794871795	0.474972992	0.582668592	0.6
	16	0.005	300	5	0.849358974	0.476518742	0.582961914	0.6
	17	0.007	300	3	0.826923077	0.474632459	0.582957743	0.6
	18	0.007	500	5	0.974358974	0.478727208	0.585044161	0.6
	19	0.01	100	4	0.788461538	0.474746019	0.584123778	0.6
	20	0.07	100	4	0.996794872	0.48080621	0.591806614	0.6
	21	0.07	500	5	1	0.47887626	0.589788252	0.6
	22	0.1	300	3	1	0.478466161	0.58951349	0.6
	23	0.001	700	5	0.753205128	0.461995508	0.572644547	0.592592593
	24	0.005	500	3	0.858974359	0.467398321	0.574723588	0.592592593
	25	0.005	700	5	0.974358974	0.469415464	0.584486053	0.592592593
	26	0.007	100	4	0.746794872	0.460784314	0.56913455	0.592592593
	27	0.007	100	5	0.756410256	0.462151394	0.571470413	0.592592593
	28	0.01	700	4	0.996794872	0.471755834	0.585960358	0.592592593
	29	0.01	700	5	1	0.468580017	0.583779371	0.592592593
	30	0.05	500	4	1	0.468389776	0.58258903	0.592592593
	31	0.05	700	3	1	0.46854198	0.583178945	0.592592593
	32	0.07	100	5	1	0.470965444	0.584526348	0.592592593
	33	0.1	100	5	1	0.469415464	0.586860192	0.592592593
	34	0.1	300	5	1	0.473030518	0.588093636	0.592592593
	35	0.1	700	5	1	0.47265625	0.587647456	0.592592593
	36	0.001	500	2	0.634615385	0.436031332	0.552152895	0.585185185
	37	0.001	700	4	0.746794872	0.449421018	0.564412748	0.585185185
	38	0.007	500	4	0.955128205	0.461269864	0.577994043	0.585185185
	39	0.01	300	2	0.814102564	0.460154242	0.575416233	0.585185185
	40	0.01	300	5	0.961538462	0.459729865	0.575688621	0.585185185
	41	0.01	700	3	0.980769231	0.463867811	0.577088867	0.585185185
	42	0.05	500	3	1	0.461423381	0.576958069	0.585185185
	43	0.05	700	4	1	0.461576811	0.577363303	0.585185185
	44	0.07	300	4	1	0.457052571	0.573850304	0.585185185
	45	0.1	100	4	1	0.460462461	0.578019109	0.585185185
	46	0.1	300	4	1	0.459498105	0.57759017	0.585185185
	47	0.1	500	5	1	0.463258786	0.580718005	0.585185185
	48	0.3	100	4	1	0.460269865	0.576838648	0.585185185
	49	0.005	100	2	0.634615385	0.426431127	0.543771512	0.577777778
	50	0.005	300	4	0.833333333	0.44684063	0.560761002	0.577777778
Grup 3 Etiketi	1	0.005	300	2	0.708333333	0.611628435	0.71927231	0.718518519
	2	0.01	100	5	0.772435897	0.613267998	0.720043742	0.718518519
	3	0.005	300	3	0.717948718	0.606090079	0.713683035	0.711111111
	4	0.01	100	3	0.721153846	0.601739788	0.712906147	0.711111111
	5	0.001	700	5	0.740384615	0.561111541	0.669350339	0.688888889
	6	0.005	500	2	0.746794872	0.572656014	0.690421911	0.688888889
	7	0.005	700	2	0.788461538	0.576328178	0.691686749	0.688888889
	8	0.007	100	5	0.740384615	0.561111541	0.669350339	0.688888889

9	0.007	300	2	0.743589744	0.571558108	0.69097668	0.688888889
10	0.007	500	2	0.788461538	0.576328178	0.691686749	0.688888889
11	0.01	100	2	0.689102564	0.563980314	0.681268441	0.688888889
12	0.01	100	4	0.769230769	0.573459716	0.691043983	0.688888889
13	0.01	300	2	0.756410256	0.57310646	0.690767066	0.688888889
14	0.005	300	5	0.807692308	0.564875197	0.683602961	0.681481481
15	0.007	300	3	0.778846154	0.569585527	0.685350234	0.681481481
16	0.007	700	2	0.820512821	0.564973022	0.682682929	0.681481481
17	0.01	500	2	0.823717949	0.564973022	0.682682929	0.681481481
18	0.01	300	3	0.801282051	0.561397032	0.679148551	0.674074074
19	0.05	100	2	0.817307692	0.55505618	0.67461973	0.674074074
20	0.001	700	3	0.682692308	0.52720056	0.647121398	0.666666667
21	0.001	700	4	0.727564103	0.529762366	0.648407185	0.666666667
22	0.005	100	5	0.708333333	0.522518274	0.646312367	0.666666667
23	0.005	500	3	0.791666667	0.550499445	0.670405472	0.666666667
24	0.007	100	3	0.682692308	0.530525502	0.646909342	0.666666667
25	0.007	100	4	0.727564103	0.529762366	0.648407185	0.666666667
26	0.001	500	5	0.705128205	0.510097823	0.638384604	0.659259259
27	0.005	100	4	0.685897436	0.512444061	0.639646606	0.659259259
28	0.005	300	4	0.801282051	0.535005616	0.661456637	0.659259259
29	0.005	500	4	0.830128205	0.53811826	0.663225832	0.659259259
30	0.007	300	4	0.814102564	0.537533512	0.663382046	0.659259259
31	0.007	500	3	0.826923077	0.542102935	0.665243074	0.659259259
32	0.001	500	4	0.682692308	0.5	0.631735657	0.651851852
33	0.005	100	3	0.673076923	0.499645138	0.631910995	0.651851852
34	0.005	500	5	0.855769231	0.531596043	0.657942187	0.651851852
35	0.007	700	4	0.932692308	0.529895532	0.655397542	0.651851852
36	0.01	300	5	0.881410256	0.530313125	0.655858493	0.651851852
37	0.001	500	3	0.673076923	0.488434515	0.624477846	0.644444444
38	0.005	700	5	0.903846154	0.518323051	0.647366913	0.644444444
39	0.007	300	5	0.826923077	0.518537781	0.649491012	0.644444444
40	0.05	700	4	1	0.519359146	0.650056759	0.644444444
41	0.07	100	2	0.865384615	0.516201284	0.645235638	0.644444444
42	0.005	700	3	0.830128205	0.512743076	0.642883678	0.637037037
43	0.005	700	4	0.878205128	0.50941857	0.640020993	0.637037037
44	0.007	500	4	0.887820513	0.511447563	0.641651072	0.637037037
45	0.007	500	5	0.903846154	0.510507622	0.640618496	0.637037037
46	0.01	300	4	0.855769231	0.511339292	0.641698449	0.637037037
47	0.01	700	2	0.868589744	0.504048583	0.637089163	0.637037037
48	0.07	500	5	1	0.511411478	0.643884237	0.637037037
49	0.07	700	5	1	0.513531402	0.64460555	0.637037037
50	0.007	700	5	0.958333333	0.499146694	0.632696373	0.62962963

Tablo 0.7. Catboost En Başarılı 50 Model

	Model	learning_rate	iterations	depth	accuracy_train	cohen	f1	accuracy_test	↓
Bölüm Etiketleri	1	0.05	200	3	0.698717949	0.315652819	0.298594412	0.392592593	
	2	0.05	200	4	0.804487179	0.314466188	0.299999286	0.392592593	
	3	0.05	200	5	0.897435897	0.318097819	0.308661074	0.392592593	
	4	0.05	200	2	0.544871795	0.29854764	0.281860861	0.385185185	
	5	0.1	100	2	0.522435897	0.299993753	0.287610186	0.385185185	
	6	0.05	100	3	0.458333333	0.278534165	0.248779862	0.377777778	
	7	0.01	500	4	0.592948718	0.26854921	0.256542227	0.37037037	
	8	0.01	500	5	0.698717949	0.263195069	0.240109739	0.37037037	
	9	0.05	100	4	0.592948718	0.270965693	0.247585336	0.37037037	
	10	0.05	500	2	0.782051282	0.29760666	0.302931293	0.37037037	
	11	0.005	500	2	0.304487179	0.24256263	0.224453124	0.362962963	
	12	0.005	500	3	0.33974359	0.245319813	0.221093298	0.362962963	
	13	0.01	500	2	0.378205128	0.249515191	0.228225273	0.362962963	
	14	0.05	100	5	0.695512821	0.261027306	0.243668932	0.362962963	
	15	0.05	500	5	1	0.293021556	0.299683135	0.362962963	
	16	0.1	200	2	0.676282051	0.285846097	0.29318499	0.362962963	
	17	0.005	500	4	0.384615385	0.234653981	0.216670586	0.355555556	
	18	0.01	200	4	0.362179487	0.232954545	0.217185763	0.355555556	
	19	0.01	500	3	0.46474359	0.246680777	0.220959763	0.355555556	
	20	0.1	100	4	0.807692308	0.282309808	0.290106105	0.355555556	
	21	0.1	100	5	0.881410256	0.277586419	0.284223511	0.355555556	
	22	0.005	500	5	0.46474359	0.224998369	0.209946951	0.348148148	
	23	0.01	200	2	0.275641026	0.221545115	0.209879229	0.348148148	
	24	0.01	200	3	0.307692308	0.223377133	0.207536181	0.348148148	
	25	0.01	200	5	0.426282051	0.223427899	0.210362021	0.348148148	
	26	0.05	500	3	0.900641026	0.275830539	0.286794818	0.348148148	
	27	0.1	100	3	0.695512821	0.269776876	0.272258782	0.348148148	
	28	0.1	200	3	0.868589744	0.280392513	0.295091343	0.348148148	
	29	0.1	200	4	0.948717949	0.276536143	0.291351292	0.348148148	
	30	0.1	200	5	0.983974359	0.276315789	0.287052922	0.348148148	
	31	0.3	100	2	0.759615385	0.275256223	0.293604517	0.348148148	
	32	0.01	100	4	0.294871795	0.209955287	0.202331962	0.340740741	
	33	0.1	500	4	1	0.273447421	0.293060742	0.340740741	
	34	0.3	100	3	0.923076923	0.271464953	0.293205522	0.340740741	
	35	0.3	100	4	0.974358974	0.272479564	0.277933375	0.340740741	
	36	0.3	100	5	1	0.273183715	0.287785695	0.340740741	
	37	0.005	100	4	0.272435897	0.199182705	0.190055095	0.333333333	
	38	0.005	200	5	0.365384615	0.199077126	0.192297728	0.333333333	
	39	0.05	100	2	0.365384615	0.217542504	0.205045986	0.333333333	
	40	0.05	500	4	0.977564103	0.261487965	0.285014761	0.333333333	
	41	0.001	100	2	0.208333333	0.187123668	0.181151715	0.325925926	
	42	0.001	100	3	0.211538462	0.187553733	0.178006036	0.325925926	

	43	0.001	100	4	0.246794872	0.189376443	0.179116063	0.325925926
	44	0.001	100	5	0.301282051	0.187338758	0.179534791	0.325925926
	45	0.001	200	2	0.208333333	0.187338758	0.179534791	0.325925926
	46	0.001	200	3	0.208333333	0.188251619	0.18007659	0.325925926
	47	0.001	200	4	0.243589744	0.188466112	0.178556573	0.325925926
	48	0.001	200	5	0.310897436	0.188251619	0.18007659	0.325925926
	49	0.001	500	2	0.208333333	0.187553733	0.178006036	0.325925926
	50	0.001	500	3	0.233974359	0.188466112	0.178556573	0.325925926
Grup 1 Etiketİ	1	0.05	200	3	0.730769231	0.376443418	0.400765069	0.481481481
	2	0.1	200	2	0.724358974	0.388942774	0.414855702	0.481481481
	3	0.05	500	3	0.91025641	0.379491163	0.412262505	0.474074074
	4	0.05	500	2	0.804487179	0.370588616	0.403549577	0.466666667
	5	0.1	100	3	0.740384615	0.359978929	0.389689816	0.466666667
	6	0.1	100	5	0.887820513	0.36362446	0.393897262	0.466666667
	7	0.3	100	3	0.907051282	0.37768103	0.429456218	0.466666667
	8	0.1	200	3	0.865384615	0.361681456	0.402644002	0.459259259
	9	0.1	200	4	0.939102564	0.363536554	0.407394945	0.459259259
	10	0.1	200	5	0.993589744	0.366115649	0.404607525	0.459259259
	11	0.1	500	2	0.900641026	0.370327775	0.411505468	0.459259259
	12	0.05	200	4	0.842948718	0.349821022	0.384177489	0.451851852
	13	0.05	200	5	0.891025641	0.344488189	0.372722268	0.451851852
	14	0.05	500	5	1	0.352140078	0.390245132	0.451851852
	15	0.1	100	2	0.625	0.339591459	0.358016601	0.451851852
	16	0.1	500	3	0.983974359	0.358257853	0.402147727	0.451851852
	17	0.3	100	2	0.823717949	0.350792826	0.390846522	0.451851852
	18	0.3	100	5	1	0.35677033	0.394988437	0.451851852
	19	0.3	500	5	1	0.357018729	0.397763253	0.451851852
	20	0.1	100	4	0.814102564	0.336891741	0.383575182	0.444444444
	21	0.1	500	4	1	0.349919743	0.401048118	0.444444444
	22	0.1	500	5	1	0.345676619	0.387610899	0.444444444
	23	0.3	200	2	0.942307692	0.346310285	0.391240904	0.444444444
	24	0.3	200	5	1	0.352952454	0.401196208	0.444444444
	25	0.3	500	2	1	0.353159139	0.404906842	0.444444444
	26	0.05	100	3	0.583333333	0.30137546	0.330859798	0.437037037
	27	0.05	100	5	0.740384615	0.305160504	0.339057475	0.437037037
	28	0.05	200	2	0.641025641	0.320034462	0.347666038	0.437037037
	29	0.05	500	4	0.961538462	0.337936375	0.383495257	0.437037037
	30	0.3	200	3	0.993589744	0.333269194	0.388830351	0.42962963
	31	0.3	200	4	1	0.334592242	0.393881858	0.42962963
	32	0.01	500	4	0.647435897	0.288705755	0.319869412	0.422222222
	33	0.3	500	3	1	0.327242525	0.385019185	0.422222222
	34	0.3	500	4	1	0.328914664	0.38560534	0.422222222
	35	0.005	500	4	0.480769231	0.25891182	0.289165144	0.414814815
	36	0.01	200	3	0.41025641	0.254716981	0.273478967	0.414814815
	37	0.01	500	2	0.490384615	0.270769231	0.308234849	0.414814815

	38	0.01	500	3	0.573717949	0.276114844	0.314489338	0.414814815
	39	0.01	500	5	0.733974359	0.27345187	0.310140883	0.414814815
	40	0.3	100	4	0.977564103	0.317396313	0.373259935	0.414814815
	41	0.005	100	4	0.375	0.232900737	0.243695192	0.4
	42	0.005	200	3	0.362179487	0.232685426	0.246446515	0.4
	43	0.005	500	2	0.378205128	0.235261207	0.247086352	0.4
	44	0.005	500	3	0.439102564	0.240835879	0.276633045	0.4
	45	0.01	100	3	0.358974359	0.232685426	0.246446515	0.4
	46	0.01	100	4	0.394230769	0.235955841	0.256507937	0.4
	47	0.05	100	2	0.474358974	0.251540041	0.28087637	0.4
	48	0.001	100	2	0.317307692	0.220367632	0.231316096	0.392592593
	49	0.001	100	3	0.320512821	0.220367632	0.231316096	0.392592593
	50	0.001	100	4	0.371794872	0.22261236	0.231042627	0.392592593
Grup 2 Etiketi	1	0.01	500	5	0.782051282	0.530638853	0.620720259	0.644444444
	2	0.1	200	4	0.926282051	0.537473233	0.634755527	0.644444444
	3	0.05	200	2	0.733974359	0.51284642	0.612160274	0.62962963
	4	0.05	200	4	0.823717949	0.517305492	0.61976251	0.62962963
	5	0.05	500	2	0.807692308	0.516787172	0.613894986	0.62962963
	6	0.05	500	3	0.900641026	0.517684887	0.617704036	0.62962963
	7	0.05	500	4	0.961538462	0.518098094	0.620562555	0.62962963
	8	0.1	100	4	0.826923077	0.517650422	0.620992456	0.62962963
	9	0.1	200	2	0.78525641	0.515642939	0.617778565	0.62962963
	10	0.01	500	3	0.701923077	0.498324104	0.598844801	0.622222222
	11	0.05	100	2	0.663461538	0.49493838	0.596851077	0.622222222
	12	0.05	100	5	0.78525641	0.50260078	0.602273599	0.622222222
	13	0.005	200	3	0.605769231	0.479112562	0.566675442	0.614814815
	14	0.01	200	3	0.637820513	0.481880582	0.58018363	0.614814815
	15	0.01	500	4	0.740384615	0.491119971	0.594052888	0.614814815
	16	0.05	200	3	0.756410256	0.495979322	0.598870391	0.614814815
	17	0.1	200	5	0.977564103	0.498499786	0.605449453	0.614814815
	18	0.005	500	2	0.615384615	0.470078507	0.564496827	0.607407407
	19	0.01	200	4	0.685897436	0.475747362	0.579307026	0.607407407
	20	0.01	500	2	0.650641026	0.476667642	0.580055039	0.607407407
	21	0.05	100	4	0.737179487	0.480769231	0.587223009	0.607407407
	22	0.05	200	5	0.881410256	0.488050944	0.594228767	0.607407407
	23	0.05	500	5	0.996794872	0.4902757	0.600413845	0.607407407
	24	0.1	100	2	0.727564103	0.48260901	0.588751649	0.607407407
	25	0.1	100	3	0.762820513	0.483094928	0.589651549	0.607407407
	26	0.1	500	2	0.907051282	0.488490134	0.598185146	0.607407407
	27	0.1	500	5	1	0.488343822	0.598141573	0.607407407
	28	0.3	100	4	0.980769231	0.489621228	0.601211766	0.607407407
	29	0.001	500	3	0.599358974	0.456618962	0.543705146	0.6
	30	0.005	100	3	0.596153846	0.457791	0.550943207	0.6
	31	0.005	500	4	0.692307692	0.468232548	0.575807895	0.6
	32	0.005	500	5	0.743589744	0.4672221	0.573265748	0.6

	33	0.01	100	3	0.605769231	0.460159953	0.553908759	0.6
	34	0.01	200	2	0.602564103	0.457710333	0.549893653	0.6
	35	0.1	200	3	0.855769231	0.479322906	0.590107423	0.6
	36	0.3	100	2	0.826923077	0.480880154	0.591889246	0.6
	37	0.001	200	5	0.641025641	0.451381705	0.55203497	0.592592593
	38	0.001	500	5	0.650641026	0.451786769	0.551361899	0.592592593
	39	0.005	200	5	0.685897436	0.455525409	0.565479049	0.592592593
	40	0.005	500	3	0.650641026	0.453078963	0.560527127	0.592592593
	41	0.01	100	4	0.628205128	0.450040738	0.55092153	0.592592593
	42	0.01	200	5	0.71474359	0.45695897	0.565923355	0.592592593
	43	0.1	100	5	0.868589744	0.469604972	0.581486482	0.592592593
	44	0.1	500	4	1	0.468694097	0.585473301	0.592592593
	45	0.3	100	5	1	0.471906117	0.584896756	0.592592593
	46	0.3	200	3	1	0.472018773	0.58670713	0.592592593
	47	0.001	100	5	0.650641026	0.440993789	0.544785392	0.585185185
	48	0.001	200	3	0.576923077	0.433538139	0.528268439	0.585185185
	49	0.001	500	4	0.618589744	0.440331655	0.54419769	0.585185185
	50	0.05	100	3	0.701923077	0.449621433	0.563639027	0.585185185
Grup 3 Etiketi	1	0.001	200	3	0.650641026	0.61070844	0.698817497	0.725925926
	2	0.005	100	5	0.685897436	0.607107299	0.698566924	0.718518519
	3	0.005	200	2	0.647435897	0.601150676	0.69265113	0.718518519
	4	0.01	100	2	0.647435897	0.601491494	0.693153269	0.718518519
	5	0.01	200	2	0.653846154	0.601491494	0.693153269	0.718518519
	6	0.01	500	2	0.679487179	0.607738186	0.713660922	0.718518519
	7	0.05	100	2	0.689102564	0.609142857	0.716387057	0.718518519
	8	0.05	200	2	0.708333333	0.616448598	0.720833613	0.718518519
	9	0.05	500	2	0.807692308	0.620112559	0.72230157	0.718518519
	10	0.1	100	2	0.705128205	0.61627646	0.721379484	0.718518519
	11	0.1	200	2	0.772435897	0.618360363	0.721686476	0.718518519
	12	0.001	500	3	0.657051282	0.591448747	0.686398956	0.711111111
	13	0.005	100	2	0.650641026	0.589409655	0.682671156	0.711111111
	14	0.005	500	2	0.653846154	0.592239777	0.687967483	0.711111111
	15	0.005	500	5	0.743589744	0.598673679	0.706280946	0.711111111
	16	0.01	100	5	0.698717949	0.596242331	0.691863571	0.711111111
	17	0.01	500	4	0.737179487	0.606178473	0.71410883	0.711111111
	18	0.01	500	5	0.78525641	0.603598856	0.713862304	0.711111111
	19	0.05	100	4	0.733974359	0.605677052	0.713496309	0.711111111
	20	0.05	200	4	0.826923077	0.607499627	0.714459715	0.711111111
	21	0.001	100	3	0.650641026	0.579340968	0.675964014	0.703703704
	22	0.001	200	4	0.663461538	0.582237351	0.680899609	0.703703704
	23	0.001	200	5	0.676282051	0.583943293	0.682599444	0.703703704
	24	0.001	500	4	0.682692308	0.582237351	0.680899609	0.703703704
	25	0.001	500	5	0.689102564	0.584391595	0.682736792	0.703703704
	26	0.005	100	3	0.657051282	0.580517362	0.678572983	0.703703704
	27	0.01	100	3	0.663461538	0.58214037	0.681168258	0.703703704

28	0.01	100	4	0.682692308	0.584743156	0.683629695	0.703703704
29	0.01	200	4	0.711538462	0.587849183	0.693474322	0.703703704
30	0.01	200	5	0.730769231	0.58775479	0.693758632	0.703703704
31	0.01	500	3	0.695512821	0.594381432	0.706103726	0.703703704
32	0.05	100	5	0.778846154	0.591435273	0.704412211	0.703703704
33	0.1	100	3	0.772435897	0.596412556	0.706277303	0.703703704
34	0.1	100	4	0.817307692	0.598692033	0.707127111	0.703703704
35	0.001	100	5	0.679487179	0.574917441	0.676104206	0.696296296
36	0.005	100	4	0.676282051	0.573180136	0.674648694	0.696296296
37	0.005	200	3	0.657051282	0.570397392	0.672383135	0.696296296
38	0.005	200	4	0.682692308	0.573180136	0.674648694	0.696296296
39	0.005	200	5	0.705128205	0.575276243	0.67681842	0.696296296
40	0.005	500	3	0.682692308	0.573541875	0.675566062	0.696296296
41	0.005	500	4	0.717948718	0.576996561	0.686421574	0.696296296
42	0.05	100	3	0.698717949	0.582736525	0.698095868	0.696296296
43	0.05	200	3	0.762820513	0.587186754	0.69983958	0.696296296
44	0.05	200	5	0.884615385	0.588751022	0.700344457	0.696296296
45	0.001	100	4	0.676282051	0.560396961	0.665676053	0.688888889
46	0.01	200	3	0.663461538	0.562567505	0.668344625	0.688888889
47	0.1	100	5	0.884615385	0.578375967	0.692187844	0.688888889
48	0.1	200	3	0.852564103	0.578344612	0.69313649	0.688888889
49	0.05	500	3	0.891025641	0.570826556	0.685615184	0.681481481
50	0.05	500	4	0.929487179	0.570477248	0.687430904	0.681481481

Tablo 0.8. ANN En Başarılı 50 Model

	Model	alpha	hidden_layer_sizes	accuracy_train	cohen	f1	accuracy_test
Bölüm Etiketİ	1	8	"(50,50,50)"	0.333333333	0.26612097	0.24081868	0.355555556
	2	8	"(100,100,100)"	0.355769231	0.258010118	0.236337384	0.348148148
	3	8	"(10,10,10)"	0.230769231	0.22241131	0.204781145	0.348148148
	4	5	"(3,5)"	0.266025641	0.223937476	0.198502828	0.340740741
	5	0.0001	"(3,5)"	0.269230769	0.223344413	0.214432222	0.333333333
	6	1	"(3,5)"	0.227564103	0.199341021	0.190119376	0.333333333
	7	8	"(50,50)"	0.394230769	0.250462677	0.238752206	0.333333333
	8	5	"(10,10,10)"	0.272435897	0.212298025	0.19681257	0.325925926
	9	5	"(10,10)"	0.217948718	0.179764892	0.173069605	0.318518519
	10	8	"(100,100)"	0.442307692	0.238597352	0.230362176	0.318518519
	11	8	"(3,5)"	0.224358974	0.195126693	0.185686805	0.318518519
	12	0.001	"(3,5)"	0.227564103	0.189110637	0.18485466	0.311111111
	13	0.005	"(3,5)"	0.233974359	0.206735326	0.188731762	0.311111111
	14	8	"(10,10)"	0.304487179	0.193330763	0.187302982	0.311111111
	15	0.0005	"(10,10)"	0.432692308	0.223805737	0.235636941	0.303703704

	16	0.001	"(10,10,10)"	0.471153846	0.224801466	0.240996347	0.303703704
	17	5	"(50,50)"	0.592948718	0.228525024	0.262108465	0.296296296
	18	0.01	"(3,5)"	0.25	0.177299562	0.185421664	0.288888889
	19	1	"(50,50)"	0.987179487	0.233498935	0.289045166	0.288888889
	20	0.03	"(3,5)"	0.240384615	0.157823654	0.182990828	0.281481481
	21	0.001	"(50,50)"	1	0.213529901	0.268215836	0.274074074
	22	0.0001	"(50,50,50)"	1	0.215254536	0.253043033	0.266666667
	23	0.001	"(10,10)"	0.400641026	0.190049088	0.226605802	0.266666667
	24	0.005	"(10,10,10)"	0.384615385	0.175152749	0.20719199	0.266666667
	25	0.05	"(3,5)"	0.224358974	0.165574078	0.170671484	0.266666667
	26	0.05	"(10,10,10)"	0.400641026	0.190294438	0.21742979	0.266666667
	27	0.1	"(100,100)"	1	0.211364843	0.263691252	0.266666667
	28	0.1	"(10,10,10)"	0.429487179	0.186648004	0.222507123	0.266666667
	29	0.01	"(100,100,100)"	1	0.208025343	0.268238954	0.259259259
	30	0.05	"(10,10)"	0.467948718	0.184142141	0.23723917	0.259259259
	31	0.1	"(10,10)"	0.413461538	0.176075679	0.214356014	0.259259259
	32	1	"(100,100,100)"	1	0.203445834	0.249218812	0.259259259
	33	1	"(10,10,10)"	0.371794872	0.165997405	0.203837896	0.259259259
	34	5	"(100,100)"	0.711538462	0.197431782	0.242662794	0.259259259
	35	0.03	"(50,50)"	1	0.194624926	0.233359823	0.251851852
	36	0.0001	"(10,10,10)"	0.378205128	0.161490683	0.20080593	0.244444444
	37	0.0005	"(10,10,10)"	0.41025641	0.161082003	0.217908506	0.244444444
	38	0.0005	"(50,50)"	1	0.181623678	0.233189181	0.244444444
	39	0.005	"(100,100)"	1	0.181769564	0.236701661	0.244444444
	40	0.1	"(50,50,50)"	1	0.18698707	0.239797713	0.244444444
	41	5	"(50,50,50)"	0.567307692	0.176041168	0.210520226	0.244444444
	42	0.001	"(100,100)"	1	0.18138467	0.236465684	0.237037037
	43	0.05	"(100,100,100)"	1	0.179307088	0.238380867	0.237037037
	44	0.05	"(100,100)"	1	0.182443556	0.234107273	0.237037037
	45	0.05	"(50,50)"	1	0.178482808	0.227954145	0.237037037
	46	0.1	"(3,5)"	0.221153846	0.141772621	0.170890037	0.237037037
	47	0.1	"(50,50)"	1	0.175022249	0.217147377	0.237037037
	48	5	"(100,100,100)"	0.724358974	0.175706918	0.221283005	0.237037037
	49	0.0001	"(10,10)"	0.442307692	0.158576052	0.207069966	0.22962963
	50	0.0001	"(100,100,100)"	1	0.175136596	0.222227755	0.22962963
Grup 1 Etiket	1	8	"(100,100,100)"	0.455128205	0.354281539	0.33748465	0.466666667
	2	8	"(100,100)"	0.551282051	0.349821022	0.38404089	0.451851852
	3	8	"(50,50)"	0.525641026	0.352476018	0.368942425	0.451851852
	4	5	"(10,10)"	0.41025641	0.310051107	0.314047305	0.444444444
	5	8	"(50,50,50)"	0.435897436	0.319647897	0.308961533	0.444444444
	6	0.01	"(10,10)"	0.5	0.319743472	0.327358054	0.42962963
	7	1	"(50,50)"	0.919871795	0.348357573	0.41229145	0.42962963
	8	0.03	"(10,10,10)"	0.477564103	0.319723496	0.342203395	0.422222222
	9	0.005	"(10,10)"	0.493589744	0.320614091	0.345362755	0.414814815
	10	1	"(10,10)"	0.528846154	0.312113003	0.357623045	0.414814815

	11	5	"(100,100,100)"	0.685897436	0.324144487	0.372656308	0.414814815
	12	5	"(100,100)"	0.689102564	0.320527523	0.3706155	0.414814815
	13	0.0001	"(10,10)"	0.458333333	0.295958279	0.307831881	0.407407407
	14	0.0005	"(10,10)"	0.490384615	0.298427959	0.339107158	0.407407407
	15	0.0005	"(100,100,100)"	1	0.327396151	0.38953174	0.407407407
	16	0.001	"(3,5)"	0.336538462	0.251196006	0.254588552	0.407407407
	17	0.001	"(10,10,10)"	0.451923077	0.291152533	0.312884752	0.407407407
	18	0.001	"(50,50)"	0.980769231	0.327018943	0.395019558	0.407407407
	19	0.005	"(100,100)"	1	0.323859012	0.385828978	0.407407407
	20	0.03	"(100,100,100)"	1	0.322671684	0.387215388	0.407407407
	21	0.05	"(50,50)"	0.977564103	0.319556452	0.378301724	0.407407407
	22	0.1	"(100,100,100)"	1	0.325168708	0.391530822	0.407407407
	23	0.1	"(100,100)"	1	0.324915614	0.381992629	0.407407407
	24	1	"(100,100)"	0.993589744	0.324028291	0.387670997	0.407407407
	25	1	"(10,10,10)"	0.391025641	0.259969851	0.264716214	0.407407407
	26	5	"(50,50)"	0.605769231	0.313544778	0.364895113	0.407407407
	27	0.0001	"(50,50,50)"	1	0.323580354	0.380387175	0.4
	28	0.005	"(100,100,100)"	1	0.318139303	0.377568974	0.4
	29	0.01	"(3,5)"	0.346153846	0.240150094	0.248215982	0.4
	30	1	"(3,5)"	0.333333333	0.241362564	0.245581579	0.4
	31	5	"(50,50,50)"	0.634615385	0.296829786	0.347192339	0.4
	32	0.0001	"(3,5)"	0.320512821	0.221792619	0.229047366	0.392592593
	33	0.0001	"(50,50)"	0.980769231	0.306912096	0.373309606	0.392592593
	34	0.005	"(10,10,10)"	0.483974359	0.285529883	0.329013139	0.392592593
	35	0.03	"(100,100)"	1	0.306260575	0.37111396	0.392592593
	36	0.03	"(3,5)"	0.346153846	0.245192963	0.242693448	0.392592593
	37	0.05	"(10,10)"	0.467948718	0.271518821	0.307316017	0.392592593
	38	0.05	"(100,100)"	1	0.306738477	0.366439806	0.392592593
	39	0.05	"(3,5)"	0.317307692	0.228356336	0.255714033	0.392592593
	40	0.05	"(10,10,10)"	0.467948718	0.26993339	0.295432417	0.392592593
	41	0.1	"(10,10,10)"	0.467948718	0.276234063	0.303945244	0.392592593
	42	5	"(3,5)"	0.320512821	0.221792619	0.229047366	0.392592593
	43	8	"(10,10)"	0.323717949	0.222994315	0.239643897	0.392592593
	44	8	"(3,5)"	0.320512821	0.221792619	0.229047366	0.392592593
	45	8	"(10,10,10)"	0.326923077	0.225711688	0.231846672	0.392592593
	46	0.0005	"(100,100)"	1	0.304339728	0.361857566	0.385185185
	47	0.0005	"(50,50)"	0.990384615	0.309143597	0.382985032	0.385185185
	48	0.03	"(10,10)"	0.496794872	0.279930596	0.316108796	0.385185185
	49	0.1	"(50,50)"	0.96474359	0.299205704	0.375899879	0.385185185
	50	1	"(50,50,50)"	0.980769231	0.300299738	0.363996077	0.385185185
Grup 2 Etiket	1	0.005	"(10,10,10)"	0.625	0.567905725	0.646267664	0.674074074
	2	5	"(50,50,50)"	0.615384615	0.556050862	0.629929458	0.666666667
	3	1	"(100,100)"	0.782051282	0.557786798	0.655553652	0.659259259
	4	0.1	"(50,50)"	0.794871795	0.545649839	0.641414552	0.651851852
	5	5	"(50,50)"	0.66025641	0.541413703	0.632175121	0.651851852

6	5	"(100,100,100)"	0.637820513	0.532400058	0.625173296	0.644444444
7	0.0001	"(10,10)"	0.628205128	0.517962545	0.603496478	0.637037037
8	0.0001	"(50,50)"	0.772435897	0.526010318	0.628522564	0.637037037
9	0.005	"(100,100)"	0.903846154	0.527364961	0.627253815	0.637037037
10	0.01	"(50,50)"	0.788461538	0.530117914	0.62848665	0.637037037
11	0.03	"(10,10,10)"	0.653846154	0.523483648	0.627496602	0.637037037
12	0.05	"(50,50,50)"	0.871794872	0.530751224	0.630613507	0.637037037
13	0.1	"(10,10)"	0.618589744	0.524682044	0.621655227	0.637037037
14	1	"(50,50)"	0.746794872	0.529717048	0.632634722	0.637037037
15	8	"(50,50)"	0.612179487	0.51534911	0.595797377	0.637037037
16	0.0005	"(10,10,10)"	0.615384615	0.510230736	0.591806139	0.62962963
17	0.005	"(50,50)"	0.810897436	0.518476245	0.623103913	0.62962963
18	0.01	"(50,50,50)"	0.878205128	0.51947035	0.622572072	0.62962963
19	5	"(100,100)"	0.650641026	0.512740923	0.611687325	0.62962963
20	8	"(100,100)"	0.612179487	0.501771479	0.582989877	0.62962963
21	0.03	"(100,100)"	0.881410256	0.51356507	0.616674307	0.622222222
22	0.03	"(50,50)"	0.798076923	0.508775685	0.614287935	0.622222222
23	0.05	"(100,100)"	0.878205128	0.511667494	0.614557474	0.622222222
24	0.05	"(50,50)"	0.782051282	0.508179156	0.612848131	0.622222222
25	0.1	"(50,50,50)"	0.836538462	0.506239243	0.613104105	0.622222222
26	0.0001	"(100,100)"	0.891025641	0.506502636	0.614841949	0.614814815
27	0.001	"(50,50)"	0.782051282	0.498499786	0.605953403	0.614814815
28	0.01	"(10,10)"	0.634615385	0.491746308	0.587871584	0.614814815
29	1	"(100,100,100)"	0.858974359	0.502656748	0.609733936	0.614814815
30	0.0001	"(50,50,50)"	0.916666667	0.487611	0.597681073	0.607407407
31	0.0005	"(10,10)"	0.621794872	0.478802448	0.557801985	0.607407407
32	0.0005	"(100,100)"	0.887820513	0.493881304	0.601948583	0.607407407
33	0.001	"(10,10)"	0.608974359	0.473005819	0.56364329	0.607407407
34	0.005	"(10,10)"	0.647435897	0.485436893	0.582568174	0.607407407
35	0.005	"(50,50,50)"	0.875	0.489766812	0.6022715	0.607407407
36	0.03	"(50,50,50)"	0.903846154	0.490384615	0.605920197	0.607407407
37	0.05	"(10,10,10)"	0.634615385	0.481032857	0.583285637	0.607407407
38	0.1	"(100,100)"	0.884615385	0.49168798	0.603397265	0.607407407
39	1	"(10,10,10)"	0.599358974	0.474167708	0.556479328	0.607407407
40	0.001	"(100,100,100)"	0.996794872	0.485968129	0.597347071	0.6
41	0.01	"(100,100)"	0.875	0.485750564	0.5947414	0.6
42	5	"(10,10)"	0.564102564	0.456294749	0.533370248	0.6
43	0.001	"(100,100)"	0.878205128	0.47519084	0.587340507	0.592592593
44	1	"(10,10)"	0.576923077	0.449061364	0.528412762	0.592592593
45	8	"(50,50,50)"	0.570512821	0.445481703	0.512812148	0.592592593
46	0.0001	"(10,10,10)"	0.657051282	0.458219865	0.572744315	0.585185185
47	0.0005	"(50,50)"	0.794871795	0.463449255	0.580318994	0.585185185
48	0.001	"(3,5)"	0.532051282	0.435820896	0.50336483	0.585185185
49	0.001	"(50,50,50)"	0.878205128	0.465422147	0.580437872	0.585185185
50	0.05	"(10,10)"	0.576923077	0.446923696	0.540245661	0.585185185

Grup 3 Etiketi	1	0.0001	"(50,50)"	0.727564103	0.627461217	0.729256326	0.725925926
	2	0.001	"(10,10,10)"	0.676282051	0.612625538	0.707753904	0.718518519
	3	0.0001	"(10,10,10)"	0.657051282	0.602611518	0.696105411	0.711111111
	4	0.001	"(50,50,50)"	0.772435897	0.607470365	0.713832043	0.711111111
	5	0.01	"(100,100)"	0.775641026	0.609015298	0.715028106	0.711111111
	6	0.03	"(10,10)"	0.663461538	0.592821596	0.696086314	0.703703704
	7	1	"(100,100)"	0.71474359	0.597075063	0.707592715	0.703703704
	8	5	"(100,100)"	0.657051282	0.594350962	0.707384184	0.703703704
	9	0.005	"(10,10,10)"	0.666666667	0.59154306	0.683491102	0.696296296
	10	0.01	"(10,10)"	0.650641026	0.584490654	0.698265311	0.696296296
	11	0.05	"(10,10)"	0.621794872	0.578253581	0.691480068	0.696296296
	12	0.05	"(50,50)"	0.727564103	0.588873208	0.700812394	0.696296296
	13	1	"(50,50)"	0.692307692	0.586044425	0.698727292	0.696296296
	14	0.001	"(50,50)"	0.724358974	0.578689255	0.692981615	0.688888889
	15	0.03	"(100,100)"	0.766025641	0.578062212	0.692514988	0.688888889
	16	0.05	"(10,10,10)"	0.669871795	0.576423129	0.684794613	0.688888889
	17	0.1	"(100,100)"	0.762820513	0.576991943	0.692646427	0.688888889
	18	0.1	"(50,50,50)"	0.730769231	0.581642441	0.693927037	0.688888889
	19	5	"(10,10,10)"	0.625	0.562837317	0.669301817	0.688888889
	20	8	"(50,50)"	0.650641026	0.563846154	0.675459276	0.688888889
	21	0.0001	"(100,100)"	0.775641026	0.56666169	0.685000767	0.681481481
	22	0.0005	"(10,10)"	0.669871795	0.558823529	0.680817524	0.681481481
	23	0.0005	"(10,10,10)"	0.647435897	0.570191026	0.675745816	0.681481481
	24	0.005	"(10,10)"	0.618589744	0.563106796	0.67155726	0.681481481
	25	0.005	"(100,100)"	0.762820513	0.566823371	0.682066775	0.681481481
	26	0.01	"(50,50)"	0.724358974	0.569808804	0.685769654	0.681481481
	27	0.01	"(50,50,50)"	0.743589744	0.572659011	0.683599705	0.681481481
	28	0.03	"(50,50,50)"	0.778846154	0.571871082	0.689294456	0.681481481
	29	0.1	"(50,50)"	0.717948718	0.56901032	0.686457606	0.681481481
	30	5	"(10,10)"	0.634615385	0.558857056	0.673498161	0.681481481
	31	5	"(100,100,100)"	0.644230769	0.562580062	0.677567254	0.681481481
	32	5	"(50,50)"	0.669871795	0.56300813	0.679135576	0.681481481
	33	8	"(100,100)"	0.625	0.552428682	0.659372395	0.681481481
	34	0.0005	"(50,50)"	0.733974359	0.559445227	0.677965736	0.674074074
	35	0.001	"(10,10)"	0.650641026	0.544268835	0.661223497	0.674074074
	36	0.05	"(50,50,50)"	0.762820513	0.556285949	0.670393277	0.674074074
	37	1	"(50,50,50)"	0.711538462	0.561461794	0.678128918	0.674074074
	38	0.0001	"(50,50,50)"	0.75	0.546472564	0.668300343	0.666666667
	39	0.0005	"(100,100)"	0.772435897	0.547452324	0.669929395	0.666666667
	40	0.005	"(50,50)"	0.730769231	0.552585064	0.670880332	0.666666667
	41	0.03	"(10,10,10)"	0.657051282	0.546201539	0.664594351	0.666666667
	42	0.03	"(50,50)"	0.724358974	0.55073214	0.671672137	0.666666667
	43	0.1	"(10,10)"	0.657051282	0.544977904	0.66971675	0.666666667
	44	0.1	"(100,100,100)"	0.849358974	0.547654505	0.669622307	0.666666667
	45	5	"(50,50,50)"	0.657051282	0.540781616	0.660914312	0.666666667

	46	0.0005	"(100,100,100)"	0.842948718	0.538358608	0.663394234	0.659259259
	47	0.001	"(100,100)"	0.766025641	0.537292303	0.662340768	0.659259259
	48	0.03	"(100,100,100)"	0.846153846	0.53601315	0.659266509	0.659259259
	49	0.05	"(100,100)"	0.769230769	0.538255632	0.663805034	0.659259259
	50	0.1	"(10,10,10)"	0.637820513	0.529545455	0.646318363	0.659259259

Tablo 0.9. CART En Başarılı 50 Model

	Model	max_depth	min_samples_split	accuracy_train	cohen	f1	accuracy_test
Bölüm Etiketleri	1	2	2	0.269230769	0.247453066	0.205719579	0.355555556
	2	2	4	0.269230769	0.247453066	0.205719579	0.355555556
	3	2	6	0.269230769	0.247453066	0.205719579	0.355555556
	4	2	8	0.269230769	0.247453066	0.205719579	0.355555556
	5	2	10	0.269230769	0.247453066	0.205719579	0.355555556
	6	2	12	0.269230769	0.247453066	0.205719579	0.355555556
	7	2	14	0.269230769	0.247453066	0.205719579	0.355555556
	8	2	16	0.269230769	0.247453066	0.205719579	0.355555556
	9	2	18	0.269230769	0.247453066	0.205719579	0.355555556
	10	2	20	0.269230769	0.247453066	0.205719579	0.355555556
	11	2	22	0.269230769	0.247453066	0.205719579	0.355555556
	12	2	24	0.269230769	0.247453066	0.205719579	0.355555556
	13	2	26	0.269230769	0.247453066	0.205719579	0.355555556
	14	2	28	0.269230769	0.247453066	0.205719579	0.355555556
	15	2	30	0.269230769	0.247453066	0.205719579	0.355555556
	16	2	32	0.269230769	0.247453066	0.205719579	0.355555556
	17	2	34	0.269230769	0.247453066	0.205719579	0.355555556
	18	2	36	0.269230769	0.247453066	0.205719579	0.355555556
	19	2	38	0.269230769	0.247453066	0.205719579	0.355555556
	20	2	40	0.269230769	0.247453066	0.205719579	0.355555556
	21	2	42	0.269230769	0.247453066	0.205719579	0.355555556
	22	2	44	0.269230769	0.247453066	0.205719579	0.355555556
	23	2	46	0.269230769	0.247453066	0.205719579	0.355555556
	24	2	48	0.269230769	0.247453066	0.205719579	0.355555556
	25	2	50	0.269230769	0.247453066	0.205719579	0.355555556
	26	5	2	0.496794872	0.276161215	0.301656818	0.340740741
	27	5	4	0.496794872	0.276161215	0.301656818	0.340740741
	28	5	14	0.490384615	0.276161215	0.301656818	0.340740741
	29	4	28	0.403846154	0.268645037	0.28750422	0.333333333
	30	4	30	0.403846154	0.268645037	0.28750422	0.333333333
	31	4	32	0.403846154	0.268645037	0.28750422	0.333333333
	32	4	34	0.403846154	0.268645037	0.28750422	0.333333333
	33	4	36	0.403846154	0.268645037	0.28750422	0.333333333
	34	4	38	0.403846154	0.268645037	0.28750422	0.333333333
	35	4	40	0.403846154	0.268645037	0.28750422	0.333333333
	36	4	42	0.403846154	0.268645037	0.28750422	0.333333333


Grup 1 Etiketi	37	4	44	0.403846154	0.268645037	0.28750422	0.333333333
	38	4	46	0.403846154	0.268645037	0.28750422	0.333333333
	39	4	48	0.403846154	0.268645037	0.28750422	0.333333333
	40	4	50	0.403846154	0.268645037	0.28750422	0.333333333
	41	5	6	0.493589744	0.26890908	0.296388391	0.333333333
	42	5	8	0.493589744	0.26890908	0.296388391	0.333333333
	43	5	10	0.493589744	0.26890908	0.296388391	0.333333333
	44	5	12	0.493589744	0.26890908	0.296388391	0.333333333
	45	1	2	0.208333333	0.187553733	0.178006036	0.325925926
	46	1	4	0.208333333	0.187553733	0.178006036	0.325925926
	47	1	6	0.208333333	0.187553733	0.178006036	0.325925926
	48	1	8	0.208333333	0.187553733	0.178006036	0.325925926
	49	1	10	0.208333333	0.187553733	0.178006036	0.325925926
	50	1	12	0.208333333	0.187553733	0.178006036	0.325925926
Grup 1 Etiketi	1	6	12	0.663461538	0.320669267	0.374269316	0.407407407
	2	4	2	0.544871795	0.292324618	0.328564448	0.4
	3	4	4	0.544871795	0.292324618	0.328564448	0.4
	4	4	6	0.544871795	0.292324618	0.328564448	0.4
	5	4	8	0.541666667	0.292553536	0.330247949	0.4
	6	4	10	0.541666667	0.292553536	0.330247949	0.4
	7	4	12	0.541666667	0.292553536	0.330247949	0.4
	8	4	14	0.541666667	0.292553536	0.330247949	0.4
	9	4	16	0.541666667	0.292553536	0.330247949	0.4
	10	4	18	0.538461538	0.292553536	0.330247949	0.4
	11	4	20	0.538461538	0.292553536	0.330247949	0.4
	12	4	22	0.538461538	0.292553536	0.330247949	0.4
	13	5	12	0.621794872	0.308217878	0.361339623	0.4
	14	6	2	0.727564103	0.312825991	0.366082696	0.4
	15	6	14	0.644230769	0.312998681	0.365661863	0.4
	16	6	16	0.644230769	0.312998681	0.365661863	0.4
	17	1	2	0.320512821	0.221792619	0.229047366	0.392592593
	18	1	4	0.320512821	0.221792619	0.229047366	0.392592593
	19	1	6	0.320512821	0.221792619	0.229047366	0.392592593
	20	1	8	0.320512821	0.221792619	0.229047366	0.392592593
	21	1	10	0.320512821	0.221792619	0.229047366	0.392592593
	22	1	12	0.320512821	0.221792619	0.229047366	0.392592593
	23	1	14	0.320512821	0.221792619	0.229047366	0.392592593
	24	1	16	0.320512821	0.221792619	0.229047366	0.392592593
	25	1	18	0.320512821	0.221792619	0.229047366	0.392592593
	26	1	20	0.320512821	0.221792619	0.229047366	0.392592593
	27	1	22	0.320512821	0.221792619	0.229047366	0.392592593
	28	1	24	0.320512821	0.221792619	0.229047366	0.392592593
	29	1	26	0.320512821	0.221792619	0.229047366	0.392592593
	30	1	28	0.320512821	0.221792619	0.229047366	0.392592593
	31	1	30	0.320512821	0.221792619	0.229047366	0.392592593

	32	1	32	0.320512821	0.221792619	0.229047366	0.392592593
	33	1	34	0.320512821	0.221792619	0.229047366	0.392592593
	34	1	36	0.320512821	0.221792619	0.229047366	0.392592593
	35	1	38	0.320512821	0.221792619	0.229047366	0.392592593
	36	1	40	0.320512821	0.221792619	0.229047366	0.392592593
	37	1	42	0.320512821	0.221792619	0.229047366	0.392592593
	38	1	44	0.320512821	0.221792619	0.229047366	0.392592593
	39	1	46	0.320512821	0.221792619	0.229047366	0.392592593
	40	1	48	0.320512821	0.221792619	0.229047366	0.392592593
	41	1	50	0.320512821	0.221792619	0.229047366	0.392592593
	42	5	14	0.602564103	0.299810247	0.349701867	0.392592593
	43	5	16	0.602564103	0.299810247	0.349701867	0.392592593
	44	6	8	0.695512821	0.306564771	0.362190702	0.392592593
	45	6	22	0.599358974	0.306477885	0.350795605	0.392592593
	46	7	18	0.637820513	0.31139587	0.366927476	0.392592593
	47	5	18	0.592948718	0.291405805	0.343775941	0.385185185
	48	5	20	0.592948718	0.291405805	0.343775941	0.385185185
	49	5	22	0.580128205	0.291405805	0.343775941	0.385185185
	50	6	4	0.71474359	0.299030341	0.355803974	0.385185185
Grup 2 Etiketi	1	4	24	0.637820513	0.428508868	0.545354967	0.57037037
	2	4	26	0.637820513	0.428508868	0.545354967	0.57037037
	3	4	28	0.637820513	0.428508868	0.545354967	0.57037037
	4	4	30	0.637820513	0.428508868	0.545354967	0.57037037
	5	4	32	0.637820513	0.428508868	0.545354967	0.57037037
	6	4	34	0.637820513	0.428508868	0.545354967	0.57037037
	7	4	36	0.628205128	0.428508868	0.545354967	0.57037037
	8	4	38	0.628205128	0.428508868	0.545354967	0.57037037
	9	4	40	0.628205128	0.428508868	0.545354967	0.57037037
	10	4	42	0.628205128	0.428508868	0.545354967	0.57037037
	11	4	44	0.628205128	0.428508868	0.545354967	0.57037037
	12	4	46	0.628205128	0.428508868	0.545354967	0.57037037
	13	4	48	0.628205128	0.428508868	0.545354967	0.57037037
	14	4	50	0.628205128	0.428508868	0.545354967	0.57037037
	15	5	32	0.644230769	0.427254773	0.54254505	0.57037037
	16	5	34	0.644230769	0.427254773	0.54254505	0.57037037
	17	5	36	0.634615385	0.427254773	0.54254505	0.57037037
	18	5	38	0.634615385	0.427254773	0.54254505	0.57037037
	19	5	40	0.634615385	0.427254773	0.54254505	0.57037037
	20	5	42	0.634615385	0.427254773	0.54254505	0.57037037
	21	5	44	0.634615385	0.427254773	0.54254505	0.57037037
	22	5	46	0.634615385	0.427254773	0.54254505	0.57037037
	23	5	48	0.634615385	0.427254773	0.54254505	0.57037037
	24	5	50	0.634615385	0.427254773	0.54254505	0.57037037
	25	7	32	0.701923077	0.436569044	0.550001357	0.57037037
	26	7	34	0.701923077	0.436569044	0.550001357	0.57037037


Grup 3 Etiketi	27	7	36	0.692307692	0.436569044	0.550001357	0.57037037
	28	7	38	0.692307692	0.436569044	0.550001357	0.57037037
	29	2	2	0.541666667	0.407366071	0.498225689	0.562962963
	30	2	4	0.541666667	0.407366071	0.498225689	0.562962963
	31	2	6	0.541666667	0.407366071	0.498225689	0.562962963
	32	2	8	0.541666667	0.407366071	0.498225689	0.562962963
	33	2	10	0.541666667	0.407366071	0.498225689	0.562962963
	34	2	12	0.541666667	0.407366071	0.498225689	0.562962963
	35	2	14	0.541666667	0.407366071	0.498225689	0.562962963
	36	2	16	0.541666667	0.407366071	0.498225689	0.562962963
	37	2	18	0.541666667	0.407366071	0.498225689	0.562962963
	38	2	20	0.541666667	0.407366071	0.498225689	0.562962963
	39	2	22	0.541666667	0.407366071	0.498225689	0.562962963
	40	2	24	0.541666667	0.407366071	0.498225689	0.562962963
	41	2	26	0.541666667	0.407366071	0.498225689	0.562962963
	42	2	28	0.541666667	0.407366071	0.498225689	0.562962963
	43	2	30	0.541666667	0.407366071	0.498225689	0.562962963
	44	2	32	0.541666667	0.407366071	0.498225689	0.562962963
	45	2	34	0.541666667	0.407366071	0.498225689	0.562962963
	46	2	36	0.541666667	0.407366071	0.498225689	0.562962963
	47	2	38	0.541666667	0.407366071	0.498225689	0.562962963
	48	2	40	0.541666667	0.407366071	0.498225689	0.562962963
	49	2	42	0.541666667	0.407366071	0.498225689	0.562962963
	50	2	44	0.541666667	0.407366071	0.498225689	0.562962963
Grup 3 Etiketi	1	6	8	0.791666667	0.525430067	0.649918964	0.651851852
	2	6	10	0.78525641	0.515839809	0.643187444	0.644444444
	3	2	2	0.628205128	0.493917833	0.602329586	0.637037037
	4	2	4	0.628205128	0.493917833	0.602329586	0.637037037
	5	2	6	0.628205128	0.493917833	0.602329586	0.637037037
	6	2	8	0.628205128	0.493917833	0.602329586	0.637037037
	7	2	10	0.628205128	0.493917833	0.602329586	0.637037037
	8	2	12	0.628205128	0.493917833	0.602329586	0.637037037
	9	2	14	0.628205128	0.493917833	0.602329586	0.637037037
	10	2	16	0.628205128	0.493917833	0.602329586	0.637037037
	11	2	18	0.628205128	0.493917833	0.602329586	0.637037037
	12	2	20	0.628205128	0.493917833	0.602329586	0.637037037
	13	2	22	0.628205128	0.493917833	0.602329586	0.637037037
	14	2	24	0.628205128	0.493917833	0.602329586	0.637037037
	15	2	26	0.628205128	0.493917833	0.602329586	0.637037037
	16	2	28	0.628205128	0.493917833	0.602329586	0.637037037
	17	2	30	0.628205128	0.493917833	0.602329586	0.637037037
	18	2	32	0.628205128	0.493917833	0.602329586	0.637037037
	19	2	34	0.628205128	0.493917833	0.602329586	0.637037037
	20	2	36	0.628205128	0.493917833	0.602329586	0.637037037
	21	2	38	0.628205128	0.493917833	0.602329586	0.637037037

22	2	40	0.628205128	0.493917833	0.602329586	0.637037037
23	2	42	0.628205128	0.493917833	0.602329586	0.637037037
24	2	44	0.628205128	0.493917833	0.602329586	0.637037037
25	2	46	0.628205128	0.493917833	0.602329586	0.637037037
26	2	48	0.628205128	0.493917833	0.602329586	0.637037037
27	2	50	0.628205128	0.493917833	0.602329586	0.637037037
28	6	12	0.775641026	0.506269592	0.637411628	0.637037037
29	6	14	0.775641026	0.506269592	0.637411628	0.637037037
30	6	16	0.775641026	0.506269592	0.637411628	0.637037037
31	7	16	0.775641026	0.506269592	0.637411628	0.637037037
32	7	10	0.798076923	0.500481018	0.632583685	0.62962963
33	7	12	0.782051282	0.49996296	0.633075087	0.62962963
34	7	14	0.782051282	0.49996296	0.633075087	0.62962963
35	10	16	0.810897436	0.498402318	0.631493085	0.62962963
36	7	8	0.814102564	0.492069347	0.626531882	0.622222222
37	8	16	0.794871795	0.487837536	0.62297506	0.622222222
38	9	16	0.794871795	0.487837536	0.62297506	0.622222222
39	11	16	0.814102564	0.488902086	0.624684177	0.622222222
40	12	16	0.814102564	0.488902086	0.624684177	0.622222222
41	13	16	0.814102564	0.488902086	0.624684177	0.622222222
42	14	16	0.814102564	0.488902086	0.624684177	0.622222222
43	15	16	0.814102564	0.488902086	0.624684177	0.622222222
44	16	16	0.814102564	0.488902086	0.624684177	0.622222222
45	17	16	0.814102564	0.488902086	0.624684177	0.622222222
46	18	16	0.814102564	0.488902086	0.624684177	0.622222222
47	19	16	0.814102564	0.488902086	0.624684177	0.622222222
48	20	16	0.814102564	0.488902086	0.624684177	0.622222222
49	7	2	0.855769231	0.482529854	0.621278457	0.614814815
50	8	8	0.849358974	0.481152993	0.616725276	0.614814815


EK-B. Hiyerarşik Kümeleme ile Oluşan Dendrogramlar




Şekil 0.1. Complete Yöntemi ile Oluşturulmuş Dendrogram Yapısı




Şekil 0.2. Average Yöntemi ile Oluşturulmuş Dendrogram Yapısı




Şekil 0.3. Single Yöntemi ile Oluşturulmuş Dendrogram Yapısı



Şekil 0.4. Median Yöntemi ile Oluşturulmuş Dendrogram Yapısı



Şekil 0.5. Ward Yöntemi ile Oluşturulmuş Dendrogram Yapısı



Şekil 0.6. Centroid Yöntemi ile Oluşturulmuş Dendrogram Yapısı

ÖZGEÇMİŞ

Adı Soyadı : Esat Fazlullah ÇELİK

Doğum Yeri : Manisa

Medeni Hali : Bekar

Yabancı Dili : İngilizce

Eğitim Durumu

Lise : Manisa Anadolu Öğretmen Lisesi, 2013

Lisans : Yıldız Teknik Üniversitesi, Mekatronik Mühendisliği Bölümü, 2020

Yüksek Lisans : Celal Bayar Üniversitesi, Yazılım Mühendisliği Bölümü, halen

Mesleki Deneyim

Autür Asansör Ltd. Şti. 2018-2019

CTech Bilişim Teknolojileri Sanayi A. Ş. 2020-2020