

T.C.

TRAKYA ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

**TEKSTİL BOYAHANE İŞLETMELERİNDE MAKİNE ÖĞRENMESİ İLE
FİRE TAHMİNİ**

ÖZGÜR ALTUNSÖĞÜT

DOKTORA TEZİ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

Tez Danışmanı: PROF. DR. Erdem UÇAR

EDİRNE-2022

Özgür ALTUNSÖĞÜT'ün hazırladığı “Tekstil Boyahane İşletmelerinde Makine Öğrenmesi ile Fire Tahmini” başlıklı bu tez, tarafımızca okunmuş, kapsam ve niteliği açısından Bilgisayar Mühendisliği Anabilim Dalında bir Doktora tezi olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Prof. Dr. Erdem UÇAR

.....

Prof. Dr. Şaban AKTAŞ

.....

Doç. Dr. İlhan UMUT

.....

Prof. Dr. Erdiñ UZUN

.....

Dr. Öğr. Üyesi Erkan ÖZHAN

.....

Tez Savunma Tarihi: 08/12/2022

Bu tezin Doktora tezi olarak gerekli şartları sağladığını onaylarım.

İmza

Prof. Dr. Erdem UÇAR

Tez Danışmanı

.....

Trakya Üniversitesi Fen Bilimleri Enstitüsü onayı

Prof. Dr. Hüseyin Rıza Ferhat KARABULUT

Fen Bilimleri Enstitüsü Müdürü

T.Ü. FEN BİLİMLERİ ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ DOKTORA PROGRAMI

DOĞRULUK BEYANI

Trakya Üniversitesi Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmasında, tüm verilerin bilimsel ve akademik kurallar çerçevesinde elde edildiğini, kullanılan verilerde tahrifat yapılmadığını, tezin akademik ve etik kurallara uygun olarak yazıldığını, kullanılan tüm literatür bilgilerinin bilimsel normlara uygun bir şekilde kaynak gösterilerek ilgili tezde yer aldığını ve bu tezin tamamı ya da herhangi bir bölümünün daha önceden Trakya Üniversitesi ya da farklı bir üniversitede tez çalışması olarak sunulmadığını beyan ederim.

08/12/2022

Özgür Altunsöğüt

Doktora Tezi

Tekstil Boyahane İşletmelerinde Makine Öğrenmesi ile Fire Tahmini

T.Ü. Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

ÖZET

Rekabet şartlarının uluslararası boyutta olduğu günümüz şartlarında işletmelerin pazar paylarını koruyabilmeleri için maliyetlerini azaltmaları gerekmektedir. Bu sebeple işletmelerin müşteri siparişlerini yeterli seviyede üretmeleri zorunlu hale gelmiştir. Ayrıca üretim sırasında gerçekleşen imalat hataları da kalite kontrol işlemi sırasında tespit edilmektedir. Bu ürünler fire olarak kabul edilmektedir. Hem sipariş fazlası üretimler hem de imalat hatalı ürünler daha düşük fiyatlara satılmaktadır. Bu durum, işletmelerin zarar etmelerine ve fazladan stok alanlarının işgal edilmesine sebep olmaktadır. Tekstil boyahane işletmeleri emek yoğun ve kimyasal ürünlerin tüketiminin fazla olduğu bir sektördür. Fazla üretim için harcanan enerji ve su kaynağı ekolojik sorunlara da yol açmaktadır. Gerçekleştirilen bu tez çalışmasında, bir işletmenin geçmiş üretim verileri incelenerek sipariş için gerekli en az üretim miktarının tespiti yapılmıştır. Bu tespit yapılırken makine öğrenmesi algoritmalarından faydalanılmıştır. Bu algoritmalarından sınıflandırma temelli çalışan özellikle J48, Naive Bayes, KNN, SVM ve Multilayer Perceptron algoritmaları WEKA uygulamasında kullanılmıştır. Algoritmalarından çıkan sonuçlar karşılaştırılarak en başarılı algoritma tespit edilmiştir.

Yıl : 2022

Sayfa Sayısı : 178

Anahtar Kelimeler : makine öğrenmesi, weka, tekstil, boyahane, kalite kontrol, fire tahmini

Doctoral Thesis

Predicting The Amount Of Wastage Of Finished Goods In Textile Dyeing Factories

Trakya University Institute of Natural and Applied Sciences

Department of Computer Engineering

ABSTRACT

In today's conditions, where competition conditions are international, businesses need to reduce their costs in order to maintain their market share. For this reason, it has become mandatory for businesses to produce customer orders at a sufficient level. In addition, manufacturing defects that occur during production are also detected during the quality control process. These products are considered as waste. Both over-order productions and manufacturing-defective products are sold at lower prices. This situation causes businesses to make losses and occupy extra stock areas. Textile dyeing establishments are a labor-intensive industry with a high consumption of chemical products. The energy and water resources spent for overproduction also cause ecological problems. In this thesis study, the past production data of an enterprise was examined and the minimum production amount required for the order was determined. While making this determination, machine learning algorithms were used. Among these algorithms, J48, Naive Bayes, KNN, SVM and Multilayer Perceptron algorithms, which are classification-based, have been used in WEKA application. The results of the algorithms were compared and the most successful algorithm was determined.

Year : 2022

Number of Pages : 178

Keywords : machine learning, textile, dyeing, quality control, wastage prediction

TEŞEKKÜR

Tezin hazırlanması aşamasında bana her zaman destek olan danışmanım Prof. Dr. Erdem UÇAR’a saygılarımı ve teşekkürlerimi sunuyorum.

Uzun ve zorlu tez çalışmam esnasında sabırlarından ve desteklerinden dolayı sevgili aileme minnet ve teşekkürlerimi sunarım.

İÇİNDEKİLER

ÖZET.....	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
KISALTMALAR DİZİNİ.....	x
ÇİZELGELER DİZİNİ	xi
ŞEKİLLER DİZİNİ.....	xiii
BÖLÜM 1	1
GİRİŞ	1
1.1.Tezin Amacı	2
1.2. Kapsam.....	2
1.3.Hedefler.....	3
1.4. Literatür Taraması.....	3
BÖLÜM 2	4
TEKSTİL BOYAHANE İŞLETMELERİ	4
2.1. Ham Kumaşlar	4
2.2. Örme ve Dokuma Kumaşlar Arasındaki Farklar	4
2.3. Ürün İş Planı	5
2.4. Boya ve Terbiye İşlemleri.....	6
2.5. Üretim Makineleri.....	8
2.6. Üretim	9
2.7. Proses Şartları	9
2.8. Kalite Kontrol.....	10
2.8.1. Kumaş Üretim Hataları	11

2.8.2. Fire Hesaplaması.....	15
BÖLÜM 3	16
VERİ MADENCİLİĞİ.....	16
3.1. Veri Madenciliği Nedir?	16
3.2. Verilerin Hazırlanması	18
3.2.1. Kayıp Veriler.....	18
3.2.2. Gürültülü Veriler	19
3.3. Öğrenme Yöntemleri.....	20
3.3.1. Danışmanlı Öğrenme	21
3.3.2. Danışmansız Öğrenme	22
3.3.3. Takviyeli Öğrenme.....	24
3.3.4. Pekiştirmeli Öğrenme.....	24
3.4. Öğrenme Hedefleri.....	24
3.4.1. Sınıflandırma.....	25
3.4.2. Tahmin	35
3.4.3. Kümeleme	37
3.4.3.3. Bağlantı Analizi	45
3.5. Algoritmalar	46
3.5.1. J48	46
3.5.2. Naive Bayes	52
3.5.3. K-NN (K-Nearest Neighborhood, En Yakın K Komşu) Algoritması.....	55
3.5.4. SVM (Support Vector Machine).....	56
3.5.5. Multilayer Perceptron.....	59
3.6. Değerlendirme Kriterleri	60
3.6.1. Accuracy (Doğruluk)	61
3.6.2. Precision (Kesinlik).....	62
3.6.3. ReCall (Duyarlılık).....	62

3.6.4. F-Measure (F Skor)	62
3.6.5. Kappa	63
BÖLÜM 4	65
UYGULAMA	65
4.1. Uygulamanın Amacı	65
4.2. Verilerin Toplanması	65
4.3. Verilerin Düzenlenmesi	66
4.4. Algoritma Testleri	72
4.4.1. J48	73
4.4.2. Naive Bayes	97
4.4.3. K-NN (K-Nearest Neighborhood, En Yakın K Komşu) Algoritması.....	125
4.4.4. SVM (Support Vector Machine).....	133
4.4.5. Multilayer Perceptron.....	151
4.4.6. Çapraz doğrulama yöntemi	151
4.4.7. Yüzdesel parçalama yöntemi	153
BÖLÜM 5	155
SONUÇ VE DEĞERLENDİRME	155
KAYNAKLAR	157
ÖZGEÇMİŞ	162
VERİ KULLANIM İZİN BELGESİ.....	163
TEZ ÖĞRENCİSİNE AİT BİLİMSEL FAALİYETLER.....	164

KISALTMALAR DİZİNİ

AGNES	Birleştirici gruplama (Agglomerative Nesting)
AVC	Özellik değer sınıf etiketi (Attribute Value Classlabel)
BOOT	Ağaç yapımı için önyüklemeli iyimser algoritma (Bootstrapped Optimistic Algorithm for Tree Construction)
CART	Regresyon ağacı için sınıflandırma (Classification and Regression Tree)
DBSCAN	Gürültülü uygulamaların yoğunluk tabanlı konumsal kümeleneşmesi (Density Based Spatial Clustering of Applications with Noise)
DIANA	Ayırıcı analiz (Divisive Analysis)
HVDM	Ayrı cinsten değer farkı ölçütü (Heterogeneous Value Difference Metric)
ID3	Tekrarlı dikotomizör (Iterative Dichotomiser)
IVDM	Ara değerli fark ölçütü (Interpolated Value Difference Metric)
KDD	Veriden bilgi keşfi (Knowledge Discovery from Data)
KNN	K en yakın komşu (K Nearest Neighborhood)
OPTICS	Kimlik kümeleme yapısına sıralama noktaları (Ordering Points to Identity Clustering Structure)
SVM	Destek karar makinesi (Support Vector Machine)
VDM	Değer mesafe ölçütü (Value Distance Metric)
WEKA	Bilgi analizi için Waikato ortamı (Waikato Environment for Knowledge Analysis)
WVDM	Pencereli değer farkı ölçütü (Windowed Value Difference Metric)

ÇİZELGELER DİZİNİ

Çizelge 2.1. Makine grupları ve prosesler	5
Çizelge 2.2. Proses Listesi	6
Çizelge 2.3. Makine listesi	8
Çizelge 2.4. Kumaş hata listesi	11
Çizelge 3.1. Örnek veri seti.....	21
Çizelge 3.2. Örnek veri seti.....	23
Çizelge 3.3. Örnek Veri seti.....	30
Çizelge 3.4. AVC veri seti	34
Çizelge 3.5. J48 ilk adım sonrası veri seti.....	49
Çizelge 3.6. J48 seçim sonrası veri seti durumu	51
Çizelge 3.7. Tenis oyununun durumlara göre oynanma olasılıkları	51
Çizelge 3.8. K-NN için örnek veri seti.....	53
Çizelge 3.9. Verilerin uzaklıkları	53
Çizelge 3.10. Örnek nesneler ve sınıfları	54
Çizelge 3.11. Karışıklık Matrisi	59
Çizelge 3.12. Kappa değer tablosu.....	64
Çizelge 4.1. Final veri seti	68
Çizelge 4.2. Veri seti SQL sorgusu.....	69
Çizelge 4.3. SQL sorunun çalıştırılmasından sonra edilen sonuç.....	72
Çizelge 4.4. Çapraz doğrulama J48 algoritmasının Weka'daki sonuç adımları	73
Çizelge 4.5. Yüzdesel parçalama J48 algoritmasının Weka'daki sonuç adımları	85
Çizelge 4.6. Çapraz doğrulama Naive Bayes algoritmasının Weka'daki sonuç adımları	97
Çizelge 4.7. Yüzdesel parçalama Naive Bayes algoritmasının Weka'daki sonuç adımları	111
Çizelge 4.8. Çapraz doğrulama K-NN algoritmasının Weka'daki sonuç adımları.....	125

Çizelge 4.9. Yüzdesel parçalama K-NN algoritmasının Weka'daki sonuç adımları	129
Çizelge 4.10. Çapraz doğrulama SVM algoritmasının Weka'daki sonuç adımları	133
Çizelge 4.11. Yüzdesel parçalama SVM algoritmasının Weka'daki sonuç adımları ...	142
Çizelge 4.12. Çapraz doğrulama Multilayer Perceptron algoritmasının Weka'daki sonuç adımları	152
Çizelge 4.13. Yüzdesel parçalama Multilayer Perceptron algoritmasının Weka'daki sonuç adımları.....	147
Çizelge 5.1. Algoritmaların karşılaştırmalı sonuçları	155



ŞEKİLLER DİZİNİ

Şekil 1.1. Weka ana ekranı.....	3
Şekil 3.1. Veri ile bilginin ilişkisi	16
Şekil 3.2. Verinin bilgiye dönüşüm süreci	17
Şekil 3.3. Danışmanlı öğrenme süreci	22
Şekil 3.4. Manhattan ve Euclidean mesafe hesaplama yöntemleri	23
Şekil 3.5. Veri setinin Weka'daki ağaç görünümü	26
Şekil 3.6. Tahmin fonksiyonu	36
Şekil 3.7. Yaşa göre gelir dağılımını gösteren örnek kümeleme verisi	38
Şekil 3.8. Kümeleme iş akışı.....	41
Şekil 3.9. k-means algoritması	42
Şekil 3.10. Agnes ve Diana metotları.....	43
Şekil 3.11. Dbscan yöntemi	44
Şekil 3.12. J48 algoritma özellik seçim adımı	48
Şekil 3.13. J48 algoritma devamı	50
Şekil 3.14. J48 algoritma sonucu	51
Şekil 3.15. SVM vektörleri ve marginler	57
Şekil 3.16. Verilerin vektörlere göre ayrılması.....	57
Şekil 3.17. Polynominal kernel	58
Şekil 3.18. Gaussian kernel.....	59
Şekil 3.19. Multilayer perceptron katmanları	59
Şekil 3.20. İleri yayılım yöntemi	60
Şekil 4.1. Gürültülü verilerin dağılımı	66
Şekil 4.2. Gürültülü veriler temizlendikten sonraki dağılım.....	67
Şekil 4.3. Hataların yüzdesel dağılımı	68
Şekil 4.4. Çapraz doğrulama J48 algoritmasının Weka'daki sonucu.....	73
Şekil 4.5. Yüzdesel parçalama J48 algoritmasının Weka'daki sonucu.....	85
Şekil 4.6. Çapraz doğrulama Naive Bayes algoritmasının Weka'daki sonucu.....	97
Şekil 4.7. Yüzdesel parçalama Naive Bayes algoritmasının Weka'daki sonucu.....	111
Şekil 4.8. Çapraz doğrulama K-NN algoritmasının Weka'daki sonucu	125

Şekil 4.9. Yüzdesel parçalama K-NN algoritmasının Weka'daki sonucu	129
Şekil 4.10. Çapraz doğrulama SVM algoritmasının Weka'daki sonucu	133
Şekil 4.11. Yüzdesel parçalama SVM algoritmasının Weka'daki sonucu.....	142
Şekil 4.12. Çapraz doğrulama Multilayer Perceptron algoritmasının Weka'daki sonucu	151
Şekil 4.13. Yüzdesel parçalama Multilayer Perceptron algoritmasının Weka'daki sonucu	153



BÖLÜM 1

GİRİŞ

Teknoloji ile gelişen iletişim kolaylığı sayesinde artık tüm dünya birbiri ile entegre olmuş durumdadır. Rekabetin uluslararası boyutlara taşındığı günümüz şartlarında işletmelerin rakipleri yalnızca bulundukları ülkelerde veya bölgelerde değil, dünyanın her yerinde olabilmektedir. Müşteriler, daha kaliteli ürünü daha ucuza almak için tüm iletişim yöntemlerini kullanarak istedikleri kalitede ve maliyetlerde ürünlere ulaşabilmektedirler. Bu şartlar altında üretim yapan işletmeler üretim maliyetlerini düşürmek zorundadırlar. En kaliteli ürünü en az fire ile üretmek zorundadırlar. Üretim aşamasında çeşitli sebeplerden dolayı üretim fireleri ortaya çıkmaktadır. Özellikle makineyi kullanan operatörün hatası, hammadde problemleri, makine kaynaklı hatalar üretim sırasında üründe hataların oluşmasına sebep olmaktadır. Kabul edilebilir düzeydeki hataların dışında kalan hatalar fire olarak tanımlanmaktadır. Bu fireler üretim maliyetlerinin çok altında fiyatlarla satılmak zorunda kalınmaktadır.

Tekstil boyahane işletmelerinde müşteri siparişleri metre ve kilo ölçü birimleri ile takip edilmektedir. Müşteriler istedikleri ürün ve miktarları işletmelere bildirirler. Bu istekler işletmeler için müşteri siparişi olarak değerlendirilir. İşletmeler, müşteri siparişlerini karşılayacak üretim planları yaparlar. Amaç, müşterinin istediği miktarda üretim yapmaktır. İşletmeler için eksik üretim yapmak çok maliyetli bir durumdur. Eksik üretilen miktarı üretmek için gerekli tüm makinelerin tekrar ayarlarının yapılması gerekmektedir. Bu hem zaman hem de enerji kaybı anlamına gelmektedir. Bu sebepten işletmeler fazla üretim yapmayı göze alarak müşteri siparişinden biraz fazla miktarda

retim yapmaktadırlar. Bu fazlalık, planlama işini yapan kişinin gemiř tecrbelerine dayanılarak belirlenir. Bu miktar ne kadar fazla olursa iřletme iin o kadar kayıptır.

1.1.Tezin Amacı

Bu tez alıřmasının amacı, halen sektrde insan tecrbesi ile karar verilen retim miktarına baėlı olan olası fire miktarını retim bařlamadan nce tahmin edebilmektir. Bu tahmin iřlemi iin makine ėrenmesi algoritmalarından J48, Naive Bayes, KNN, SVM (Support Vector Machines) ve Multilayer Perceptron algoritmaları kullanılmıřtır. Bu algoritmalar, Yeni Zelanda Waikato niversitesi tarafından geliřtirilen, Weka isimli uygulama ile alıřtırılmıřtır. Tekstil iřletmelerinde, insana dayalı olan fire tahminindeki hatalar neticesinde oluřan fazla retim miktarları tez alıřmasında kullanılan algoritmalar yardımı ile nceden tahmin edilebilecektir. alıřmada, algoritmaların performansları karřılařtırılmıřtır. Elde edilen sonular, gerek veriler ile karřılařtırılarak algoritmaların bařarısı belirlenmiřtir.

1.2. Kapsam

Tez alıřması kapsamında beř adet makine ėrenmesi algoritması incelenmiřtir. Bu algoritmalar, Waikato niversitesi tarafından geliřtirilmiř olan, Java tabanlı, aık kaynak kodlu Weka isimli yazılım ile test edilmiřtir. Test edilen veriler izin alınarak bir tekstil boyahane iřletmesinden alınan gerek verilerdir. Microsoft SQL Server veri tabanında bulunan bu veriler dzenlenerek analiz yapılabilecek řekilde ayarlanmıřtır. Test edilen algoritmalar, kullandıkları parametreler deėiřtirilerek aralarındaki farklar analiz edilmiřtir.



Şekil 1.1. Weka ana ekranı

1.3.Hedefler

Analize uygun hale getirilecek olan veri, beş adet algoritmanın, algoritmalara özel çeşitli parametreleri ile test edilecektir. Buna uygun olan model geliştirilerek gelecekte yapılacak olan üretilere ait fire miktarları üretim yapılmadan önce tahmin edilebilecektir.

1.4. Literatür Taraması

Yapılan araştırmalarda makine öğrenmesi algoritmalarının çok çeşitli alanlarda uygulanmış olduğu görülmüştür. Tekstil işletmeleri için de birçok makine öğrenmesi algoritması çeşitli amaçlar için kullanılmıştır. Fakat makine öğrenmesi algoritmalarının üretim öncesi fire miktarının tahmininde kullanıldığı bir çalışmaya rastlanılmadı.

BÖLÜM 2

TEKSTİL BOYAHANE İŞLETMELERİ

2.1. Ham Kumaşlar

Ham kumaşlar kullanılan üretim tekniğine göre örgü veya dokuma olarak iki temel sınıfa ayrılırlar. Dokuma kumaşlar dokuma makinalarında çözgü leventlerinde bulunan ipliklerin atkı ipliği ile bütünleşmesi ile oluşurlar. Çözgü iplikleri leventlerde bulunurlar. Kumaşın cinsine göre levent üzerinde bulunan iplik tel sayıları değişmektedir. Çözgü iplikleri kumaşın boyuna olan ipliklerdir. Bu ipliklerin arasından enine doğru atkı iplikleri geçerek kumaş oluşur. Burada 1 cm uzunluk içerisinde kullanılacak atkı iplik sayısı yine kumaş cinsine göre değişmektedir. Örgü kumaşlar dokuma kumaşlara göre daha esnektir. Örme işlemi dairesel bir düzlemde oluşur ve bir kumaş tüpü oluşturulur. Örme iğneleri dairesel yataklar üzerine yerleştirilir ve iğneler tek tek hareket ederek tüp şeklinde kumaş oluşturulur.

2.2. Örme ve Dokuma Kumaşlar Arasındaki Farklar

- Örme kumaş üretimi daha kısa sürer.
- Örme kumaşlar esnektir. Likralılar haricinde dokuma kumaşlar esnemez.
- Örme kumaşları daha fazla nem alır.
- Örme kumaşlar yıkamadan sonra daha çok çeker.
- Örme kumaşlar daha az kırışır.
- Örme kumaşlar daha dökümlüdür. Vücudu kolay sarar.
- Dikim sonrası örme kumaşlar yıkanmadan kullanılabilir.

2.3. Ürün İş Planı

Ham kumaşlar, mamul kumaş oluncaya kadar belirli sıra ve sayıda önceden belirlenmiş olan bir yolu izlerler. Bu yoldaki her adıma proses denilmektedir. Bu prosesler makinelerde belirli sıcaklık, hız ve kimyasallar ile yapılırlar. Bu prosesler bir araya gelerek Rota adı verilen grupları oluştururlar. Rotalar, işletmelerin istenilen ürünü elde etmek için uyguladıkları proses listesidir. Bu liste işletmelerin veri tabanlarında saklanırlar. Bu listeler genellikle kumaş kodu, desen ve renk bazında değişiklik gösterirler. Bazen müşterinin istediği çok özel ürünler için bile özel rotalar oluşturulabilir. Aşağıda Saten kumaşa rotasyon baskı yapabilmek için oluşturulmuş örnek bir rota bulunmaktadır.

Çizelge 2.1. Makine grupları ve prosesler

Makine Grubu	Proses
HAM DEPO	HAM DEPO ÇIKIŞ
YAKMA	YAKMA+HAŞIL SÖKME
KASAR GRUBU	KASAR
MERSERİZE GRUBU	MERSERİZE
YIKAMA	MERSERİZE YIKAMA
RAM GRUBU	EGALİZE
BASKI	ROTASYON REAKTİF BASKI
FİXE BUHARLAMA	BUHARLAMA
YIKAMA	REAKTİF YIKAMA
RAM GRUBU	APRE
KALENDER GRUBU	KALANDIR

Makine Grubu	Proses
KALİTE KONTROL GRUBU	KALİTE KONTROL

Prosesler belirli makina grubunda yapılan işlemlerdir. Her makina grubuna ait en az bir adet makine işletmede bulunmaktadır. Rota içerisinde bulunan prosesler makine grubunda istenilen makinede yapılabilir.

2.4. Boya ve Terbiye İşlemleri

Ham kumaşlar, mamul kumaş oluncaya kadar birçok işleme uğrarlar. Bu işlemler kumaşın rengini, üzerindeki deseni, sertliğini, yumuşaklığını, boyanın akmazlığını, kumaşın çekmezliğini ayarlamak için uygulanırlar. Bu prosesler işleme özel makinelerde yapılır. Bu işlemler uygulanırken belirli şartlar göz önünde bulundurulmak zorundadır. Sıcaklık ve makine hızı gibi temel faktörlerin dışında işlemden kullanılacak kimyasal maddelerin miktarları da çok önemlidir. Bunlarda yapılacak yanlış uygulamalar kumaş üzerinde hataların oluşmasına sebep olacaktır. Örnek proses isimleri Çizelge 2.2’de gösterilmiştir.

Çizelge 2.2. Proses Listesi

Proses Kodu	Proses
1	HAM DEPO ÇIKIŞ
50	REFAKAT BÖLME
100	YAKMA
101	YAKMA+HAŞIL SÖKME
102	HAŞIL SÖKME
103	YAKMA+SOĞUK KASAR
104	YAKMA+OPTİKLİ SOĞUK KASAR
105	MERSERİZE
106	DISPERS YIKAMA

Proses Kodu	Proses
107	ŞARDON SONU YIKAMA
112	MERSERİZE YIKAMA
113	REAKTİF YIKAMA
114	KASAR
117	KASAR YIKAMA
122	ŞARDON
123	RAM EMÜSYON
124	RAM FİXE
125	EGALİZE
126	PİGMENT ZB
127	PİGMENT DB
128	OPTİK+EGALİZE
129	APRE
132	RAM BEYAZ
133	İPLİĞİ BOYALI
134	RAM ŞEKER KASAR
135	ROTASYON PİGMENT BASKI
136	ROTASYON REAKTİF BASKI
137	ROTASYON DİSPERS BASKI
140	FLAT PİGMENT BASKI
141	FLAT REAKTİF BASKI
142	FLAT DİSPERS BASKI
145	BUHARLAMA
146	FİXE
147	REAKTİF DB
148	REAKTİF ZB
152	KALANDIR
153	SANFOR
154	SANFOR+EGALİZE
155	GOFRE

Proses Kodu	Proses
156	KALİTE KONTROL

2.5. Üretim Makineleri

Ham kumaştan mamul kumaş elde etmek için uygulanan prosesler belirli makinelerde yapılırlar. Bu makineler hem yerli hem de yabancı üretim olmaktadır. Makineler, elektrik, su, buhar ve doğalgaz gibi kaynakları kullanarak bu prosesleri gerçekleştirirler. Bu makineler kumaşların üzerinden geçeceği silindirler ve işlemlerin uygulanacağı kabinlerden oluşmaktadır. Kumaşlar bu silindirler üzerinden geçerek kabinlerde belirli sıcaklık altında belirli kimyasallar ile işlenirler. Makinenin bir ucundan dok, araba veya palet adı verilen taşıyıcı aktarım sistemleri ile makineye bağlanan kumaşlar, yine aynı şekilde istenen aktarım aparatına aktarılırlar. Bu esnada makine üzerinden geçen kumaşların metreleri ölçülür. Böylelikle giren ve çıkan kumaş takip edilir. Bazı işlemlerde kumaş uzayabilir veya kısalabilir. Örnek makineler Çizelge 2.3'te gösterilmiştir.

Çizelge 2.3. Makine listesi

Makine Kodu	Makine
1	FLAT BASKI
2	ROTASYON BASKI-1
3	ROTASYON BASKI-2
4	AÇIK EN YIKAMA
5	FİXE BUHARLAMA-1
6	FİXE BUHARLAMA-2
7	GAZE
8	KASAR
9	MERSERİZE
10	ŞARDON
11	GOFRE

Makine Kodu	Makine
12	AÇIK EN SANFOR

2.6. Üretim

Tekstil işletmeleri pamuğun iplik, ipliğin ham kumaş, ham kumaşın baskılı/boyalı kumaş ve nihayetinde hayatımızda kullandığımız ürün haline gelmesi süreçlerinin birini veya birkaçını yapan işletmelerdir. Bu çalışma, ham kumaşın baskılı/boyalı kumaş haline gelinceye kadar ki üretim süreçlerinden kaynaklı hatalardan dolayı yapılan fazla üretimi azaltmayı hedeflemektedir. Müşteriler, istedikleri deseni ve rengi belirterek belirli miktarda siparişini tekstil fabrikalarına iletirler. Fabrikalar geçmişten gelen tecrübelerine dayanarak bir miktar fire payını öngörerek müşterinin istediği miktardan fazla üretim yaparlar. Eksik üretim olması durumunda kalan küçük parça için tüm üretim makinalarının ayarlarının tekrar yapılıp üretilmesi çok daha fazla maliyet oluşturmaktadır. Örneğin müşterinin 1000 metrelik siparişi için fabrikanın %10'luk bir fire öngörüsü yapması durumunda 1100 metrelik bir üretim emri işletmeye verilmektedir. Üretim aşamasında 100 metrenin altında hata olması durumunda kalan parça fabrikada kalacaktır. Her siparişte artan bu parçalar fabrikalar için büyük maliyet kalemleri olurlar. Bu çalışmadaki temel amaç işletmelerin varsayılan olarak her üretim için uyguladıkları standart fire oranı yerine, kumaşın üretim proseslerini göz önünde bulundurarak çıkabilecek fire miktarını tahmin etmektedir. Böylelikle her siparişte üretilen fazla miktardaki kumaş miktarı azaltılarak işletmelerin karlılıkları arttırılacaktır.

2.7. Proses Şartları

Prosesler makinelerde yapılırken önceden tanımlanmış parametrelerin makineye yüklenmesi ile tamamlanırlar. Bu şartlar makinenin kumaşı işleyeceği hız (metre/dakika), kumaşa uygulayacağı işlem sırasındaki makine sıcaklığı, hazırlanacak kumaşın eni, gramajı gibi bilgilerdir. Makine başında bulunan operatöre bu bilgiler bir üretim emri ile birlikte verilir. Operatör bu değerlere göre makinenin ayarlarını yapar. Böylelikle ilgili

prosesi tamamlar. Aynı ürünün bir sonraki üretim aşamasında yine aynı parametreler kullanılır. Böylelikle müşteri her istediğinde aynı şartlarda üretilmiş ürünü alır. Proses şartları üretilen ürünün kalitesini doğrudan etkilemektedir. Operatörden kaynaklı veya makine yıpranmalarından ötürü olacak hatalar ürünün kalitesini bozabilir hatta fire oluşmasına sebep olabilir.

2.8. Kalite Kontrol

Müşteri siparişi için işletmeye verilen üretim emrinde bulunan tüm prosesler tamamlandıktan sonra nihai kalite kontrol aşamasına geçilir. Kalite kontrol işlemi kumaşların kontrolü için özel olarak üretilmiş olan makinelerde yapılır. Bu makinelerin arka tarafına takılan top veya arabada bulunan kumaşlar özel ışık ve açı ile operatörün göz ile kontrol edebileceği bir bölümden geçerek yine makinenin diğer ucunda bulunan bir dok veya araba içerisine aktarılır. Kalite kontrol işlemini yapan kamera destekli sistemlerde bulunmaktadır. Bu sistemlere gözsüz kontrol sistemi denilmektedir. Özel kameralar ile daha önceden tanımlanmış olan hatalar otomatik olarak algılanarak bir veri tabanına kaydedilmektedir. Eğer otomatik kontrol sistemi yok ise bu işlemi bir operatör göz ile kontrol ederek yapar. Eğer bir hata görür ise bu hatayı veri tabanına kaydeder. Operatör bu işlemi ancak belirli bir hızın altında yapabilmektedir. Çok hızlı akan bir kumaşı operatör kontrol edemez ve hataları gözden geçirir. Hatalar uzunluklarına göre ikiye ayrılırlar;

- a. Noktasal Hatalar: Kumaşın herhangi bir yerinde bulunan ufak hatalardır.
- b. Sürekli Hatalar: Kumaşın herhangi bir yerinde başlayıp devam eden uzun hatalardır.

Hatalar ayrıca tiplerine göre ikiye ayrılmaktadır;

- a. Minor Hatalar: Müşterilerin isteği doğrultusunda göz ardı edilebilecek hatalardır.
- b. Major Hatalar: Kumaşa ciddi zarar vermiş olan büyük hatalardır.

2.8.1. Kumaş Üretim Hataları

İplikten elde edilen dokuma ya da örgü kumaşların müşterinin istediği desen ve renge gelene kadarki üretim aşamalarında kumaş üzerinde hatalar oluşabilmektedir. Bu hatalar aşağıdaki sebeplerden oluşabilir:

- Prosesin gerçekleştiği makinedeki arızalar
- Makineyi kullanan operatörün tecrübe eksikliği
- Kumaşın meydana geldiği ipliğin kalitesinden
- Proses Şartlarının hatalı uygulanmasından
- Kullanılan kimyasallardan

Hatalar ham kumaş ve mamul kumaş kaynaklı olmak üzere ikiye ayrılırlar. Çizelge 2.4'te ham ve mamul kumaş kaynaklı hata tanımları mevcuttur.

Çizelge 2.4. Kumaş hata listesi

Hata Türü	Hata
Mamul	ABRAJ
Mamul	APRE LEKESİ
Mamul	ATKI EĞRİ
Mamul	ATKI KESİĞİ
Mamul	AYAK KAÇIĞI
Mamul	BASILMAMIŞ PANO
Mamul	BASKI KIRIŞIĞI
Mamul	BLANKET İZİ
Mamul	BOYA DAMLAMASI
Mamul	BOYA YAYILMASI
Mamul	BOYA YOLU
Mamul	BOYASIZ
Mamul	ÇÖZGÜ KOPUĞU
Mamul	DELİK
Mamul	DESEN EĞRİ
Mamul	DOKUMA YAĞ LEKESİ

Hata Türü	Hata
Mamul	DURUŞ
Mamul	ENİ DAR
Mamul	EZME
Mamul	ISKARTA
Mamul	İÇNE İZİ APRE
Mamul	KAFES
Mamul	KALANDIR İZİ
Mamul	KALANDIRSIZ
Mamul	KASA İZİ
Mamul	KASAR DURUŞU
Mamul	KASAR KIRIĞI
Mamul	KELEŞ
Mamul	KENAR BOYALI
Mamul	KENAR KATLI
Mamul	KENAR YAZISI YOK
Mamul	KISA PARÇA
Mamul	KİRLENME
Mamul	MAL KAYMASI
Mamul	NEPS
Mamul	RAKLE İZİ
Mamul	RAM KIRIŞIĞI
Mamul	RAMÖZ KAÇIĞI
Mamul	RENK FARKI
Mamul	RENK FARKI İHZ
Mamul	RÖTÜŞ
Mamul	SAKAL
Mamul	SANFOR KIRIĞI
Mamul	SARARMA
Mamul	SIK SEYREK
Mamul	STAMPA

Hata Türü	Hata
Mamul	SU DAMLASI
Mamul	SÜRTME
Mamul	ŞABLON SİLME
Mamul	ŞARDON İZİ
Mamul	TERLEME
Mamul	TERS YÜZE BASKI
Mamul	TIKALI
Mamul	TOPBAŞI İZİ
Mamul	TÜYSÜZ
Mamul	UZUN UÇ
Mamul	YABANCI İPLİK
Mamul	YAĞ LEKESİ
Mamul	YİĞİLMA
Mamul	YIRTIK
Ham	ARA
Ham	ARMÜR HATASI
Ham	ATKI HARMAN BANDI
Ham	ATKI İPLİK DÜZGÜNSÜZLÜĞÜ
Ham	ATKI KAÇIĞI
Ham	ATKI KOPUĞU
Ham	ATKI RENK BANDI
Ham	ATKI SAĞILMASI
Ham	ATLAMA
Ham	BONCUKLAMA
Ham	BOYA ABRAJİ
Ham	BÜYÜK DÜĞÜM
Ham	CIMBAR
Ham	CIMBAR DELİĞİ
Ham	ÇİFT ATKI
Ham	ÇÖZGÜ HARMAN BANDI

Hata Türü	Hata
Ham	ÇÖZGÜ İPLİK DÜZGÜNSÜZLÜĞÜ
Ham	ÇÖZGÜ KAÇIĞI
Ham	ÇÖZGÜ UCU
Ham	ÇÖZGÜDE ÇİFT İPLİK
Ham	DALMA
Ham	DELİK-YIRTIK
Ham	DESEN HATASI
Ham	DURUŞ İZİ
Ham	EZİLME
Ham	GERGİ ÇÖZGÜ
Ham	GEVŞEK ÇÖZGÜ
Ham	GEVŞEK KENAR
Ham	HAŞIL LEKESİ
Ham	İNCE ATKI
Ham	İNCE ÇÖZGÜ
Ham	KAFES
Ham	KALIN ATKI
Ham	KALIN ÇÖZGÜ
Ham	KENAR BOZUK
Ham	KIRIK KENAR
Ham	KİRLİ KUMAŞ
Ham	NEPS ÇEPEL
Ham	PAMUKLAMA
Ham	PATLAK
Ham	RENK FARKI
Ham	ROPER
Ham	SEYREK
Ham	SIK
Ham	SPLIT
Ham	SÜRTME

Hata Türü	Hata
Ham	ŞANTUK BALIK
Ham	TAHAR HATASI
Ham	TARAK DİŞ HATASI
Ham	TARAK HATASI
Ham	TOP BAŞI
Ham	YABANCI ATKI ELYAFI
Ham	YABANCI ÇÖZGÜ ELYAFI
Ham	YAĞLI UÇUNTU
Ham	YAĞLI-KİRLİ İPLİK
Ham	YAĞ-PAS-KİR
Ham	YANLIŞ ÇÖZGÜ
Ham	YAPIŞIK ÇÖZGÜ
Ham	YARIM ATKI KAÇIĞI

2.8.2. Fire Hesaplaması


Üretim sürecindeki fireler hesaplanırken işletmelerde geçmiş üretimlerden elde edilmiş olan tecrübeler dikkate alınarak üretim gerçekleştirilir. Genellikle bu oranlar fazla tutulur. Böylelikle az üretim yapıp tekrar üretim yapılmaz. Çünkü tekrar üretimin maliyeti çok fazladır. Makinenin üretim yapılabilmesi için temizliği, ayarları ve üretim süreci zaman almaktadır. Bu süreler maliyeti arttırmaktadır. Bu yüzden fire miktarını işletmeler her zaman normal tahmin değerlerinin üzerinde tutarlar. Siparişler alınırken belirli yüzde toleranslarla alınır. Fire miktarları bu toleransları da dikkate alarak hesaplanır. Oluşan fire miktarı eğer üretim esnasında ciddi bir hata ile karşılaşılır ise o anda, eğer fark edilmez ise nihai kalite kontrol işlemi sırasında tespit edilir.

BÖLÜM 3

VERİ MADENCİLİĞİ

3.1. Veri Madenciliği Nedir?

Ham veriler, belirli araç ve algoritmalar ile işlenerek bilgi elde edilir. Ham verinin işlenebilmesi için öncelikle belirli ön işlemlerden geçirilmesi gerekmektedir. Bu işlemler ile veri analiz edilebilecek duruma getirilir. Bu durum KDD (Knowledge Discovery from Data) olarak adlandırılır (Han vd., 2011; Witten vd., 2005). Veriden bilgiye ulaşma sürecidir. Veri madenciliği bu süreç içerisinde bir adım olarak düşünülebilir. Ham verinin bilgi haline gelebilmesi için geçeceği adımlar Şekil 3.1’de gösterilmiştir.




Şekil 3.1. Veri ile bilginin ilişkisi

1. **Verilerin Temizlenmesi:** Eksik ve hatalı verilerin düzenlenmesi
2. **Verilerin Birleştirilmesi:** Farklı veri kaynaklarında bulunan verilerin toplanarak veri ambarına aktarılma sürecidir.
3. **Verilerin Seçimi:** Toplanan veri kaynaklarından elde edilen verilerden hangilerinin analiz edileceğinin belirlenme sürecidir.

4. **Verilerin Dönüştürülmesi:** Verilerin analiz yapılabilecek duruma getirilme sürecidir. Bu süreçte veriler gruplanarak veya toplamalar alınarak analiz düzeyine indirgenir.
5. **Veri Madenciliği:** Verinin bilgiye dönüşümündeki temel süreçtir. Çeşitli algoritmalar ile veri bilgiye dönüştürülür.
6. **Modelin Değerlendirilmesi:** Veri madenciliği sonrasında elde edilen model ve kurallardan hangilerinin analiz edileceğinin belirlenmesi sürecidir.
7. **Bilginin Sunumu:** Elde edilen analiz sonuçlarının gösterileceği grafiksel arayüzlerdir.

Verinin bilgiye dönüşüm süreci Şekil 3.2’de gösterilmiştir.



Şekil 3.2. Verinin bilgiye dönüşüm süreci

3.2. Verilerin Hazırlanması

Veri kavramı tek başına anlamlı bir bilgi değildir. Veriler kimi zaman bir otomasyon sisteminden gelen sayısal veya analog bir sinyal, kimi zaman operatörün girdiği bir sıcaklık verisi, kimi zaman müşteri temsilcisinin girdiği bir sipariş verisi olabilir. Bu veriler girilirken gerek veriyi giren kullanıcısı gerekse verilerin girildiği yazılımlardan kaynaklı nedenlerden dolayı yanlış girilebilir. Bu yanlış girilen bilgiler veri tabanında gürültülü veri olarak adlandırılır (Ian H. & Eibe, 2005). Bir analiz yapılmadan önce bu gürültülü bilgilerin temizlenmesi veya düzeltilmesi gereklidir. Veri madenciliği yapmaya başlarken ilk olarak yapılması gereken veri ambarını oluşturacak olan tüm veri kaynaklarından toplanacak olan bilgilerin temiz veriler olması gereklidir. Bir veri 100 olması gerekirken 1000 olmuş ise veri ortalama değerleri bozacağı için düzenlenmelidir. Eğer 100 olması gereken veri boş geçilmiş ise bunun da düzeltilmesi gereklidir. Verilerin düzenlenebilmesi için birtakım yöntemler geliştirilmiştir.

3.2.1. Kayıp Veriler

Analizi yapılmak istenen verilerin veri tabanlarında bulunmadığı durumlarda bu veriler üzerinde işlem yapmak için bu verilerin bulunması gereklidir. Bu kayıp verileri bulabilmek için aşağıdaki yöntemler uygulanabilir.

3.2.1.1. Verileri iptal etmek

Eğer iptal edilecek veri miktarı, elde bulunan tüm veri miktarına göre sonucun hassasiyetini etkilemeyecek kadar küçük ise bu veriler göz ardı edilebilir. Eğer kayıp veri miktarı çok fazla ise bu durum sonucun olumsuz etkilenmesine sebep olabilir.

3.2.1.2. Verileri el ile doldurmak

Bu yöntem özellikle büyük veri tabanları için çok uygun bir yöntem değildir. Bu verilerin el ile teker teker doldurulması çok fazla zaman alacaktır. Eğer bu veriler analiz için yüksek derecede önem taşıyor ise uygun değildir.

3.2.1.3. Aynı veri ile doldurmak

Bu yöntemde tüm veriler aynı veri ile doldurulur. Bu veri sayısal bir veri ise ∞ ile, sayısal olmayan bir veri ise “YOK” gibi bir veri ile doldurulabilir. Bu yöntem analizi olumsuz yönde etkileyebileceği gibi çok çarpıcı sonuçlarda ortaya çıkarabilir. Bazen kişilerin özellikle boş bıraktığı cinsiyet gibi bilgilerin satın aldıkları ürünler ile bir ilgisi olabilir. Böylelikle bu durumda ortaya çıkabilir.

3.2.1.4. Ortalama değer ile doldurmak

Kayıp veri o özellik içerisindeki verilerin ortalaması ile doldurulabilir. Fakat bu durum hassasiyeti azaltabilir. Bunun yerine kayıp verinin ait olduğu grup veya sınıfa ait verilerin ortalamasının alınması daha yakın bir sonuç ortaya çıkaracaktır.

3.2.1.5. Değişkenler yardımı ile tahmin etmek

Kayıp veriler elde edilecek olan regresyon katsayıları veya Bayesyen sınıflandırma, karar ağaçları gibi teknikler ile tahmin edilebilir.

3.2.2. Gürültülü Veriler

Kayıp verilerin dışında analizi güçleştiren bir diğer etmen ise gürültülü verilerdir. Gürültülü veri, kullanıcı tarafından hatalı girilmiş veya sistem tarafından hatalı ölçüm yapılmış olan verilerdir. Bu veriler ortalamanın çok üzerinde veya çok altında verilerdir. Bu verilerin analiz öncesi tespit edilerek silinmesi veya düzenlenmesi gereklidir. Gürültülü verilerin düzenlenmesi için çeşitli yöntemler bulunmaktadır.

3.2.2.1. Kutulama Yöntemi

Bu yöntem uygulanırken kayıp verilerin olduğu özellikteki veriler öncelikle sıralanırlar. Daha belirli gruplar halinde ortalamaları alınarak o gruba ait tüm veriler grubun ortalaması ile değiştirilirler. Örneğin 4, 6, 5 değerlerine sahip grup için $(4 + 5 + 6) / 3 = 5$ olarak tüm veriler güncellenir. Kutulama yönteminde ortalamanın dışında sınır değerlerin alınması yöntemi de uygulanabilir. Düzenlenecek olan değer alınan grupların alt ve üst sınırlarından hangisine yakın ise o değer ile güncellenir. Örneğin grup içerisinde

10,12,17 değerleri olsun. Sınır değerler 10 ve 17'dir. Dolayısı ile 12 değeri en yakın değer olan 10 ile güncellenir. Böylelikle son durum 10, 10, 17 olur.

3.2.2.2. Regresyon Yöntemi

Gürültülü veri elde edilecek regresyon fonksiyonu ile bulunur. Tek değişkenli lineer regresyon olabileceği gibi çok değişkenli regresyon yöntemi de özellik sayısına göre kullanılabilir.

3.2.2.3. Kümeleme Yöntemi

Bu yöntem ile benzer değerler belirli kümelerle konularak analiz yapılır. Küme dışarısında kalan uç değerler kendilerine ek yakın kümelerle atanırlar. Böylelikle küme ile düzgünleştirilmiş bir veri elde edilir.

3.3. Öğrenme Yöntemleri

İşlenmiş ve analize hazır veriler makine öğrenmesi algoritmaları kullanılarak bilgiye dönüştürülürler. Geçmişte olan veriler kullanılarak veriler üzerinde, tahmin, sınıflandırma ve kümeleme işlemleri makine öğrenmesi algoritmaları kullanılarak yapılabilmektedir (Kelleher vd., 2001). Makinelerin öğrenebilmesi için geçmişe dayalı verinin olması gereklidir (Flach, 2012). Bu veriler farklı veri kaynaklarından toplanabilirler. Verilerden elde edilecek sonuç bazı durumlarda belirli olabileceği gibi bazı durumlarda belirsiz olabilmektedir. Öğrenme yöntemleri üç başlık altında toplanabilir.

1. Danışmanlı Öğrenme
2. Danışmansız Öğrenme
3. Takviyeli Öğrenme

Tez kapsamındaki algoritmalar açıklanırken Çizelge 3.1. örnek olarak kullanılacaktır. Bu tablo belirli hava şartlarında tenis oyunu oynanıp oynanamayacağına ait 14 adet veri içermektedir. Bu verilere göre çıkarılan algoritmalar ile daha önce karşılaşılmamış olan bir durum olduğunda algorithmadan tenis oynanıp oynanamayacağına dair tahmin yapması beklenmektedir.

Çizelge 3.1. Örnek veri seti

NO	HAVA	SICAKLIK	NEM	RÜZGAR	TENİS
1	GUNESLI	SICAK	YUKSEK	YOK	HAYIR
2	GUNESLI	SICAK	YUKSEK	VAR	HAYIR
3	BULUTLU	SICAK	YUKSEK	YOK	EVET
4	YAGMURLU	NORMAL	YUKSEK	YOK	EVET
5	YAGMURLU	SERIN	NORMAL	YOK	EVET
6	YAGMURLU	SERIN	NORMAL	VAR	HAYIR
7	BULUTLU	SERIN	NORMAL	VAR	EVET
8	GUNESLI	NORMAL	YUKSEK	YOK	HAYIR
9	GUNESLI	SERIN	NORMAL	YOK	EVET
10	YAGMURLU	NORMAL	NORMAL	YOK	EVET
11	GUNESLI	NORMAL	NORMAL	VAR	EVET
12	BULUTLU	NORMAL	YUKSEK	VAR	EVET
13	BULUTLU	SICAK	NORMAL	YOK	EVET
14	YAGMURLU	NORMAL	YUKSEK	VAR	HAYIR
15	GUNESLI	SICAK	NORMAL	YOK	?

Tabloya göre hava, sıcaklık, nem ve rüzgar olmak üzere 4 adet özellik bulunmaktadır. Bu özelliklerin durumlarına göre tenis oynanıp oynanmayacağına ait veriler bulunmaktadır. Tabloya göre sınıflandırma durumu en son kolondadır. Evet ya da hayır durumlarını içermektedir.

3.3.1. Danışmanlı Öğrenme

Bu öğrenme yönteminde, geçmişte toplanan verilere ait sınıf değeri girilmiş olmalıdır. Sınıf değeri bir veri kümesi içerisinde analizi yapılmak istenen özelliktir. Danışmanlı öğrenmede özelliklerin sınıf özelliği olan ilişkileri incelenir ve aralarındaki bağ tespit edilir. Danışmanlı öğrenme algoritmaları bu ilişki üzerinden yola çıkarak daha önce tecrübe edilmemiş bir verinin sınıf değerini tahmin eder. Sınıf değeri sayısal bir değer olabileceği gibi verinin hangi sınıfa ait olacağını gösteren bir karakter de olabilir.

Yukarıdaki veri kümesinde bulunan ilk 14 veri geçmişte meydana gelmiş olayları içermektedir. Son satırda ise daha önce karşılaşılmamış bir veri bulunmaktadır. Böyle bir veri gelmesi halinde Tenis oynanıp oynanamayacağının bulunması Makine Öğrenmesi algoritmaları ile bulunur.


Örnek veride bulunan özellik sayısı çok fazla değildir. Bir DNA haritasına bakılarak bir hastalığın olup olmasını tahmin etmek ise normal şartlarda bir insan için zordur. Oysa Makine Öğrenme algoritmaları bu karmaşık problemleri çözmek için geliştirilmektedir. Aşağıda Şekil 3.3'te danışmanlı öğrenme süreci gösterilmiştir.



Şekil 3.3. Danışmanlı öğrenme süreci

3.3.2. Danışmansız Öğrenme

Bu öğrenme yönteminde geçmiş verilere ait bir sınıf değişkeni bulunmamaktadır. Kümeleme algoritmaları kullanılarak bulunan verilerden birbirine benzer olanlar aynı kümelerle aktarılırlar. Danışmanlı öğrenmenin aksine mevcut verilerin hangi sınıfa ait oldukları algoritma tarafından tahmin edilir. Kümeleme algoritmalarına örnek olarak k-means algoritması gösterilebilir. Algoritmaya göre istenen sınıf sayısı belirtilerek verilerin kümeleneceği beklenmektedir. Algoritma verileri kümelerken birbirlerine olan mesafelerini hesaplayarak yakın olanları aynı kümeye koymaktadır. Mesafe algoritması olarak Euclidean Distance ve Manhattan Distance algoritmaları kullanılmaktadır. Sayısal olmayan verilerin aralarındaki mesafeleri hesaplamak için VDM (Value Distance Metric), HVDM (Heterogeneous Value Difference Metric), IVDM (Interpolated Value Difference Metric), WVDM (Windowed Value Difference Metric) ve Gower Distance algoritmaları kullanılabilir (Gower & Legendre, 1986; Li vd., 2014; Wilson & Martinez, 1997). Aşağıda Şekil 3.4'te Manhattan ve Euclidean mesafe hesaplama yöntemleri gösterilmiştir.



Şekil 3.4. Manhattan ve Euclidean mesafe hesaplama yöntemleri

Çizelge 3.2. Örnek veri seti

No	X	Y	Z
1	10	23	1
2	16	33	1
3	23	29	0

Yukarıdaki Çizelge 3.2’de X ve Y girişler ve Z çıkış olmak üzere 3 adet örnek veri bulunmaktadır.

3.3.2.1. Euclidean Distance Algoritması

Bu algoritma iki nokta arasındaki en kısa mesafeyi hesaplamaktadır. Tabloya göre 1. ve 2. örnekleri için euclidian mesafesi denklem 3.1’deki gibi hesaplanacaktır.

$$\begin{aligned}
 d(p,q) = d(q,p) &= \sqrt{(q_1 - p_1)^2 + (q_2 - p_2)^2 + \dots + (q_n - p_n)^2} \\
 &= \sqrt{\sum_{i=1}^n (q_i - p_i)^2}
 \end{aligned} \tag{3.1}$$

Yukarıdaki formüle göre;

$$d(p,q) = d(1, 2) = \sqrt{(10 - 16)^2 + (23 - 33)^2} = 11,66 \text{ olarak hesaplanır.}$$

3.3.2.2. Manhattan Distance Algoritması

Bu algoritma iki nokta arasında mesafe farkının mutlak değeri alınarak hesaplanır. Noktalar arası mesafe yatay ya da dikey olarak hesaplanır. Çapraz bir erişim kullanılmaz. Denklem 3.2’de Manhattan Distance algoritması gösterilmiştir.

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

$d(p,q) = d(1,2) = |10-16| + |23-33| = 16$ olarak hesaplanır.

3.3.3. Takviyeli Öğrenme

Bu öğrenme yöntemi danışmanlı ve danışmansız öğrenme yöntemlerini birlikte kullanır. Veri seti içerisinde sınıf değeri önceden verilmiş olan veriler ve sınıf değeri olmayan veriler mevcuttur.

3.3.4. Pekiştirmeli Öğrenme


Bu öğrenme yönteminde algoritmanın sonuçlarından daha iyi bir sonuç elde edildiğinde, algoritma bu yeni sonuçlara göre kendini günceller. Bu durum daha iyi bulunan her sonuçta aynı şekilde tekrarlanır. Google firması, Çin kökenli Go oyununu oynayan yapay zeka sistemini geçmişte oynanan oyunların ve kendi kopyası ile oynadığı oyunlardan kazananlarının hamlelerini öğrenmesi ile geliştirilmiştir. Bu sistem dünya şampiyonunu yenmeyi başarmıştır.

3.4. Öğrenme Hedefleri

Algoritmalar mevcut verileri kullanarak sınıflandırma, tahmin, kümeleme ve bağlantı analizi yapımında kullanılırlar. Etiketlenmiş, sınıf bilgisi olan kayıtlar kullanılarak model oluşturulur. Etiketlenmeyen veriler ile de sınıflar arası sınırlar belirlenir.

3.4.1. Sınıflandırma

Sınıflandırma, önemli veri sınıflarını tanımlayan modelleri çıkaran bir veri analizi biçimidir. Makine öğrenmesi, bağlantı analizleri ve istatistikte sınıflandırma yöntemleri kullanılmaktadır. Sınıflandırma, yöntemleri çok çeşitli alanlarda kullanılmaktadır. Kan akışından beyin aktivitelerinin tespiti (Bhandari & Joensson, 2009), sahtekarlık tespiti, hedef pazarların tespiti, performans tahminleri, üretim (Wai vd., 2016), sağlık (Bhandari & Joensson, 2009), gıda (De Miranda Coelho vd., 2016; Reutter vd., 2017), enerji (Barma vd., 2017; Jurušs & Seile, 2017) eğitim alanlarında kullanılmaktadır. Hava durumu örneğini incelediğimizde veri seti içerisinde bulunan her satır için Evet/Hayır olmak üzere tenis oynanıp oynanamayacağı belirtilmiştir. Bu sütun evet/hayır olabileceği gibi kötü, orta, iyi, çok iyi şeklinde kategorik değerlerde olabilir. Sınıf değeri kategorik olabileceği gibi sayısal veri de olabilir. Bu durumda sayısal veriler arasındaki ilişki bulunarak sayısal tahminler de yapılabilir. Sınıflandırma algoritmaları belirli bir çıktı kümesine göre verilerin hangi sınıfta olacağını bulabileceği gibi sayısal veri tahmininde de kullanılır. Sınıflandırma işlemi iki temel aşamada gerçekleşir. İlk aşamada veri seti kullanılarak öğrenme yapılır. İkinci aşamada ise ilk aşamada elde edilen modele göre sınıflandırma işlemi yapılır. Eğitim veri seti ile test veri seti ayrı değil ise, veri seti içerisindeki verilerin 2/3 ü eğitim için, kalan 1/3 ü ise test için kullanılabilir. Ayrıca yaygın olarak kullanılan bir diğer yöntemde ise, veri seti 10 parçaya bölünür, her seferinde 9 bölüm eğitim için 1 bölüm test için kullanılır. Bu bölümler her seferinde değiştirilerek en sonunda ortalama değerler alınarak sonuçlar değerlendirilir. Şekil 3.5'te verilerin Weka içerisinde J48 algoritmasına uygulanması ile aşağıdaki gibi bir ağaç yapısı elde edilmiştir.



Şekil 3.5. Veri setinin Weka'daki ağaç görünümü

Yukarıdaki ağaç yapısına göre aşağıdaki kurallar çıkarılabilir.

1. IF (HAVA='GUNESLI' AND NEM='YUKSEK') TENIS = HAYIR
2. IF (HAVA='GUNESLI' AND NEM='NORMAL') TENIS = EVET
3. IF (HAVA='BULUTLU') TENIS = EVET
4. IF (HAVA='YAGMURLU' AND RUZGAR='YOK') TENIS = EVET
5. IF (HAVA='YAGMURLU' AND RUZGAR='VAR') TENIS = HAYIR

Bu kurallar çıkarıldıktan sonra test verileri bu modele uygulanarak modelin doğruluğu hesaplanır. Doğruluk değeri eğer kabul edilebilir eşik değerinin üzerinde ise model kullanılır. Böylelikle daha önce hiç karşılaşılmamış bir durum için model kullanılarak tahmin yapılabilir. Örneğimizin 15. Satırına baktığımızda tenis oynanıp oynanmayacağına dair bir bilgi bulunmamaktadır. Yukarıda çıkarılan kural çerçevesinde bu durumu tahmin edebiliriz.

P(GUNESLI, SICAK, NORMAL, YOK)

İkinci kurala bakıldığında Havanın güneşli ve nemin normal olduğu durumda tenis oynanabileceği görülmektedir. Kurallara yukarıdan aşağıya doğru bakıldığından bu veri için EVET sonucu çıkmaktadır.

3.4.1.1. Karar Ağaçları

Sınıflandırmanın ağaç şeklinde yapıldığı yöntemdir. Eğitim verisi kullanılarak ağacın dalları ve kökleri tespit edilir. Ağacın son altında sınıf değeri bulunur. Ağacın tepesinden köküne kadar izlenen yol ise kuralları ifade etmektedir. Karar ağaçları kullanılarak sınıflandırma kuralları tespit edilir. Bu kurallara göre verilerin sınıfları tespit edilir. Karar ağaçları, veri üzerinde çok fazla bilgi gerektirmediği ve çok karmaşık parametreler içermediğinden yoğun olarak kullanılmaktadır. Kuralların ağaç şeklinde gösterilmesi anlaşılabilirlik için önemlidir. Karar ağaçları, ilaç (López-Vallverdú vd., 2012), finansal analizler (Kim & Upneja, 2014), astronomi (Ohm vd., 2009) ve biyoloji (Zhao & Xue, 2017) gibi çok farklı alanlarda kullanılmaktadır.

J. Ross Quinlan tarafından 1975 yılında ID3 (Iterative Dichotomiser) isminde bir karar ağacı algoritması geliştirildi. Daha sonra yine Quinlan C4.5 isminde ID3 algoritmasının geliştirilmiş halini yayınladı. 1984 yılında L. Breiman, J. Friedman, R. Olshen, ve C. Stone isminde istatistikçiler CART (Classification and Regression Trees) isminde ikili karar ağacını anlatan bir kitap yayınladı. ID3 ve CART algoritmaları aynı zamanlarda fakat birbirinden bağımsız olarak geliştirilmiştir. ID3, C4.5 ve CART algoritmaları ve diğer birçok karar ağacı uygulaması yukarıdan aşağıya doğru ağacı oluştururlar. Veriyi parçalayarak aşağıya kadar ulaşırlar. Karar ağacı algoritmaları genel olarak aşağıdaki gibi çalışır.

Algoritmanın çalışacağı veri setine “V” diyelim. Veri seti içerisinde birçok özellik bulunabilir. Bu özellikler tablonun sütunlarında yer almaktadırlar. Her özellik ilgili verinin o özelliğe ait değerini göstermektedir. Bu özelliklerinin tümünün oluşturduğu listeye “Ö” diyelim. Ağaç yapısını oluşturabilmek için hangi özelliğin üstte ve hangilerinin dallarda olacağına karar vermek lazım. Hangi özelliğin seçileceğini belirlemek için kullanılacak metot “M” ile adlandırılacaktır. Bu metot hangi özelliğin seçileceğini belirlemek için Gain veya Gini index değerlerini kullanır. Ağaç öncelikle tüm verileri içeren “D” düğümü ile başlar.

Girişler:

V: Eğitim veri seti

L: Sınıf özelliği dışındaki özelliklerin listesi

M: Özellik seçici metot

Ö: Seçilen özellik

Başla

1. Eğer V boş ise hata döndür.
2. N isimli bir düğüm oluştur,
3. Eğer V içerisindeki örneklerin tümü aynı S sınıfı ise D düğümünü S sınıfı ile döndür,
4. Eğer L boş ise D düğümünü sayısı en fazla S sınıfını ile döndür,
5. M (V, L) metodunu çağırarak en önemli Ö özelliğini bul ve D düğümünü oluştur.
6. **DÖNGÜ** Ö özelliği içerisinde bulunan tüm farklı j değerleri için
7. Eğer j için tek bir S sınıf değeri var ise S sınıfı ile düğüm oluştur,
8. Eğer j için birden fazla sınıf mevcut ise M metodu ile Ö özelliği içerisindeki j değerine sahip veri setine aynı işlemler uygulanarak en önemli Ö özelliği tespit edilir.
9. Bulunan Ö özelliğine ait değerler recursive (özyinelemeli) olarak tekrarlanır ve alt düğümler oluşturulur.
10. **DÖNGÜ sonu**

3.4.1.1.1. Özellik seçimi

Karar ağacı algoritmaları çalışırken ağacın oluşabilmesi için özelliklerin belirlenmesi gereklidir. Hangi özelliğin ağacın en tepesinde yer alacağı ve özelliğe ait değerlere göre alt dallardaki özelliklerin neler olacağının belirlenebilmesi için iki temel yaklaşım bulunmaktadır. Information Gain ve Gini index değerleri kullanılarak ağaçların dallarındaki özellikler tespit edilebilir.

3.4.1.1.1.1. Information Gain(Bilgi kazancı)

ID3 algoritması bilgi kazancı üzerinden özellik seçimi yapar. Bilgi kazancı Claude Shannon'un bilgi teoremine dayanır. Bilgi kazancı ile ilgili hesaplamalar J48 algoritması içerisinde anlatılmıştır.

3.4.1.1.1.2. Gini Index

Gini index CART algoritmasında kullanılır. Gini index, information gain yönteminde olduğu gibi düzensizlik hesaplaması yapar. Denklem 3.3'te gini index information gain gösterilmiştir.

$$Gini(D) = 1 - \sum_{i=1}^m P_i^2 \quad (3.3)$$

P_i , farklı sınıf değerlerinin olasılıklarıdır.

Tenis oyunu için veri setimizden Gini indexini hesaplayacak olursak;

$$\begin{aligned} Gini(D) &= 1 - \left(\frac{9}{14}\right)^2 - \left(\frac{5}{14}\right)^2 \\ &= 0,46 \end{aligned}$$

Bu aşamadan sonra her özellik için Gini indexi hesaplanır.

$$GiniA(D) = \frac{|D1|}{|D|} Gini(D1) + \frac{|D2|}{|D|} Gini(D2)$$

Tenis oyunu örnek veri setimizde bulunan ilk özelliğimiz için Gini index hesaplanırken ikili gruplar halinde tüm kombinasyonlar denenir. İlk özelliğimiz olan Hava, güneşli, bulutlu ve yağmurlu değerlerini almaktadır. Sırası ile {Güneşli, Bulutlu}, {Güneşli, Yağmurlu} ve {Bulutlu, Yağmurlu} kümelerine göre Gini index hesaplanacaktır. İkili gruplar D1, bunların dışında kalanlara da D2 kümesi olarak adlandırılacaktır.

İlk olarak {Güneşli, Bulutlu} ve kalanlar için Gini değerini hesaplayalım.

Toplamda 14 adet verimiz bulunmaktadır. Güneşli ve bulutlu 9 adet ve kalan 5 adet veri bulunmaktadır.

Çizelge 3.3. Örnek Veri seti

NO	HAVA	SICAKLIK	NEM	RÜZGAR	TENİS
1	GUNESLI	SICAK	YUKSEK	YOK	HAYIR
2	GUNESLI	SICAK	YUKSEK	VAR	HAYIR
3	BULUTLU	SICAK	YUKSEK	YOK	EVET
4	BULUTLU	SERIN	NORMAL	VAR	EVET
5	GUNESLI	NORMAL	YUKSEK	YOK	HAYIR
6	GUNESLI	SERIN	NORMAL	YOK	EVET
7	GUNESLI	NORMAL	NORMAL	VAR	EVET
8	BULUTLU	NORMAL	YUKSEK	VAR	EVET
9	BULUTLU	SICAK	NORMAL	YOK	EVET

Çizelge 3.3'te görüleceği gibi 9 adet veri için 6 tane EVET, 3 tane Hayır bulunmaktadır.

Geri kalan 5 veri için ise 3 tane EVET ve 2 tane HAYIR bulunmaktadır.

$$\begin{aligned}
 GINI(Hava) \in \{\text{Güneşli, Bulutlu}\} &= \frac{9}{14} GiniD1 + \frac{5}{14} GiniD2 \\
 &= \frac{9}{14} \left(1 - \left(\frac{6}{9} \right)^2 - \left(\frac{3}{9} \right)^2 \right) + \frac{5}{14} \left(1 - \left(\frac{3}{5} \right)^2 - \left(\frac{2}{5} \right)^2 \right) \\
 &= 0,46
 \end{aligned}$$

$$\begin{aligned}
 GINI(Hava) \in \{\text{Güneşli, Yağmurlu}\} &= \frac{10}{14} GiniD1 + \frac{4}{14} GiniD2 \\
 &= \frac{10}{14} \left(1 - \left(\frac{5}{10} \right)^2 - \left(\frac{5}{10} \right)^2 \right) + \frac{4}{14} \left(1 - \left(\frac{4}{4} \right)^2 - \left(\frac{0}{4} \right)^2 \right) \\
 &= 0,36
 \end{aligned}$$

$$\begin{aligned}
 GINI(Hava) \in \{\text{Bulutlu, Yağmurlu}\} &= \frac{9}{14} GiniD1 + \frac{5}{14} GiniD2 \\
 &= \frac{9}{14} \left(1 - \left(\frac{7}{9} \right)^2 - \left(\frac{2}{9} \right)^2 \right) + \frac{5}{14} \left(1 - \left(\frac{2}{5} \right)^2 - \left(\frac{3}{5} \right)^2 \right) \\
 &= 0,39
 \end{aligned}$$

{Güneşli, Yağmurlu} grup en düşük Gini indexine sahiptir.

Aynı şekilde Sıcaklık özelliği için Gini index hesaplanırsa;

{Sıcak, Normal} toplam 10 veriden 6'sı EVET 4'ü HAYIR,

{Sıcak, Serin} toplam 8 veriden 5'i EVET 3'ü HAYIR,

{Normal, Serin} toplam 10 veriden 7'si EVET 3'ü HAYIR,

$$\begin{aligned} \text{Gini}(\text{Sıcaklık}) \in \{\text{Sıcak, Normal}\} &= \frac{10}{14} \text{GiniD1} + \frac{4}{14} \text{GiniD2} \\ &= \frac{10}{14} \left(1 - \left(\frac{6}{10} \right)^2 - \left(\frac{4}{10} \right)^2 \right) + \frac{4}{14} \left(1 - \left(\frac{3}{4} \right)^2 - \left(\frac{1}{4} \right)^2 \right) \\ &= 0,45 \end{aligned}$$

$$\begin{aligned} \text{Gini}(\text{Sıcaklık}) \in \{\text{Sıcak, Serin}\} &= \frac{8}{14} \text{GiniD1} + \frac{6}{14} \text{GiniD2} \\ &= \frac{8}{14} \left(1 - \left(\frac{5}{8} \right)^2 - \left(\frac{3}{8} \right)^2 \right) + \frac{6}{14} \left(1 - \left(\frac{4}{6} \right)^2 - \left(\frac{2}{6} \right)^2 \right) \\ &= 0,46 \end{aligned}$$

$$\begin{aligned} \text{Gini}(\text{Sıcaklık}) \in \{\text{Normal, Serin}\} &= \frac{10}{14} \text{GiniD1} + \frac{4}{14} \text{GiniD2} \\ &= \frac{10}{14} \left(1 - \left(\frac{7}{10} \right)^2 - \left(\frac{3}{10} \right)^2 \right) + \frac{4}{14} \left(1 - \left(\frac{2}{4} \right)^2 - \left(\frac{2}{4} \right)^2 \right) \\ &= 0,44 \end{aligned}$$

Nem özelliği için Normal ve Yüksek değerleri bulunmaktadır.

{Yüksek} toplam 7 veriden 3'ü EVET 4'ü HAYIR

{Normal} toplam 7 veriden 6'sı EVET 1'i HAYIR

$$\begin{aligned} \text{Gini}(\text{Nem}) \in \{\text{Yüksek}\} &= \frac{7}{14} \text{GiniD1} + \frac{7}{14} \text{GiniD2} \\ &= \frac{7}{14} \left(1 - \left(\frac{3}{7} \right)^2 - \left(\frac{4}{7} \right)^2 \right) + \frac{7}{14} \left(1 - \left(\frac{6}{7} \right)^2 - \left(\frac{1}{7} \right)^2 \right) \\ &= 0,37 \end{aligned}$$

$$\text{Gini}(\text{Nem}) \in \{\text{Normal}\} = \frac{7}{14} \text{GiniD1} + \frac{7}{14} \text{GiniD2}$$

$$= \frac{7}{14} \left(1 - \left(\frac{6}{7} \right)^2 - \left(\frac{1}{7} \right)^2 \right) + \frac{7}{14} \left(1 - \left(\frac{3}{7} \right)^2 - \left(\frac{4}{7} \right)^2 \right)$$

$$= 0,37$$

Rüzgar özelliği için Var ve Yok değerleri bulunmaktadır.

{Var} toplam 6 veriden 3'ü EVET 3'ü HAYIR

{Yok} toplam 8 veriden 6'sı EVET 2'si HAYIR

$$\text{GINI}(\text{Rüzgar}) \in \{\text{Var}\} = \frac{6}{14} \text{GiniD1} + \frac{8}{14} \text{GiniD2}$$

$$= \frac{6}{14} \left(1 - \left(\frac{3}{6} \right)^2 - \left(\frac{3}{6} \right)^2 \right) + \frac{8}{14} \left(1 - \left(\frac{6}{8} \right)^2 - \left(\frac{2}{8} \right)^2 \right)$$

$$= 0,43$$

$$\text{GINI}(\text{Rüzgar}) \in \{\text{Yok}\} = \frac{8}{14} \text{GiniD1} + \frac{6}{14} \text{GiniD2}$$

$$= \frac{8}{14} \left(1 - \left(\frac{6}{8} \right)^2 - \left(\frac{2}{8} \right)^2 \right) + \frac{6}{14} \left(1 - \left(\frac{3}{6} \right)^2 - \left(\frac{3}{6} \right)^2 \right)$$

$$= 0,43$$

Tüm özelliklere ait gruplarının Gini indexlerine bakıldığında en küçük olan 0,36 değeri ile Hava {Güneşli, Yağmurlu} grubudur.

0,46 – 0,36 = 0,1'lik değer ile en düşük düzensizlik değerine sahiptir. Böylelikle ağacımızın en tepesine Hava özelliğimizi koyarak aynı işlemleri sonrasında Hava özelliğinin alt kümelerini süzerek devam ederiz. Böylelikle ağaç tamamlanmış olur.

3.4.1.1.2. Ağaç budama

Eğitim verisi içerisinde bulunan hatalı veya çok aşırı sapma gösteren değerler ağaçlar için ezberleme sorununu ortaya çıkarmaktadır. Budanmış ağaçlar, daha küçük, anlaşılması kolay ve hızlı çalışan sonuçlar üretir.

Budama işlemi iki şekilde yapılabilir. Prepruning (Ön budama) işlemi ağaç yapısı oluşturulurken düğümlerin parçalanmasına gerek olup olmadığına karar verilerek yapılan budamadır. Böylelikle daha ağaç oluşurken çok fazla dallanma yapmamış olur. Ağaç oluşturulurken information gain ya da gini index gibi yöntemler ile dallarına ayrılır. Bu

aşamada önceden belirlenmiş bir eşik değeri ile karşılaştırılarak bu dallanmanın olup olmayacağına karar verilir. Bu eşik değerinin belirlenmesi çok önemlidir. Eğer çok yüksek bir değer seçilecek olursa ağaç çok sade olacaktır. Eğer çok düşük bir eşik değeri seçilirse o zaman ağaç sadeliğini kaybedecektir.

Bir diğer budama yöntemi ise postpruning (sonradan budama) işlemidir. Bu yöntemde öncelikle ağaç komple oluşturulur. Alt ağaçlar budanarak yaprak düğüm ile birleştirilir. Bu yaprak sınıflandırma kümesinin bir elemanı olur. Cost complexity algoritması post pruning yöntemi ile çalışır. Örneğin CART algoritması bu yöntem ile budama işlemi yapar. Bu algoritma cost complexity adı verilen ağaçtaki yaprak sayısını ve yanlış sınıflandırılmış örneklerin yüzdesine göre hata oranını dikkate alır. Ağacın en altından çalışmaya başlar. Bir düğümün budanıp budanmamasına karar vermek için budama öncesi ve budama sonrası cost complexity değeri hesaplanır. Eğer budama sonrası hesaplanan değer daha küçük ise budama yapılır, değilse o düğüme dokunulmaz. Bu dallanma hesabı için eğitim verisi harince veriler kullanılır.

C4.5 ise pessimistic pruning (kötümser budama) yöntemini kullanır. Bu yöntemde cost complexity yöntemine benzer olarak çalışır. Burada cost complexity yönteminden farklı olarak hesaplama yapılırken eğitim kümesi kullanılır.

3.4.1.1.3. Ölçeklenebilirlik

ID3, C4.5 ve CART gibi algoritmalar küçük veri setleri için güzel sonuçlar üretmektedir. Fakat belleğe sığmayacak kadar büyük veri setlerinin analizi için farklı yöntemlere ihtiyaç duyulmaktadır. Günümüzde veri madenciliği uygulamaları için çok büyük veritabanları kullanılmaktadır. Genellikle bu veriler belleğe sığmayacak kadar büyüktür. Bu sorunu çözmek için birçok yöntem geliştirilmiştir. Bu yöntemlerden biri RainForest (Thangaparvathi & Anandhavalli, 2010) yöntemidir. Bu yöntemde her düğümdeki özellik için AVC (Attribute-Value Classlabel) set oluşturulur. AVC-set, D düğümündeki Ö özelliği için S sınıfına ait bir özet bilgiler içerir. Bu özet bilgi farklı örneklerin çıktığı sınıfına ait sayılarını tutar. Bu her düğüm için oluşturulan AVG-setlerine AVG-group adı verilir. Büyük veri setlerinde bu gruplar genellikle belleğe sığarlar. Eğer bu gruplarında belleğe sığmaması durumunda farklı yöntemler kullanılabilir. Tenis oyunu veri seti için AVC setleri Çizelge 3.4'te gibi hesaplanır.

Çizelge 3.4. AVC veri seti

Tennis Oynama			Tennis Oynama		
Hava	Evet	Hayır	Sıcaklık	Evet	Hayır
Güneşli	2	3	Normal	4	2
Yağmurlu	3	2	Serin	3	1
Bulutlu	4	0	Sıcak	2	2
Tennis Oynama			Tennis Oynama		
Nem	Evet	Hayır	Rüzgar	Evet	Hayır
Normal	6	1	Var	3	3
Yüksek	3	4	Yok	6	2

BOOT (Bootstrapped Optimistic Algorithm for Tree construction) (Kleiner vd., 2011) algoritması da büyük veri setlerinin ölçeklemekte kullanılan farklı bir yöntemdir. Bu algoritma düğümler için özet veriler tutmak yerine istatistiksel teknikler kullanarak eğitim kümesinin küçük bir halini elde ederek bu küme üzerinden model oluşturur. Özellik seçimi için ikili ayırma ya da Gini indexi kullanır. Algoritma veri setini iki kere tarar. Diğer algoritmalara göre çok hızlıdır. Özellikle sürekli artan veri setleri için çok idealdir.

3.4.1.2. Bayes sınıflandırma

Bayes sınıflandırıcılar istatistiksel yöntemler kullanarak verilen örneklerin sınıflandırmasını yapar. Bayes teoremini baz alan sınıflandırmadır. Büyük veri setlerinde çok hızlı sonuç üretirler. Naive bayes algoritması bayes yöntemine göre çalışan bir

algoritmadır. Bu algoritmanın detayı Algoritmalar bölümünde detaylı olarak anlatılmıştır (Ethem, 2015).

3.4.1.3. Kural bazlı sınıflandırma

Programcılıkta IF koşul THEN sonuç kuralları olarak bilinir. Eğer belirtilen şart sağlanmış ise istenen işler yapılır. Sınıflandırma birçok kuraldan oluşur. Bu kurallar sırası ile alt alta yazılır. En üstten başlanarak kurallar uygulanır. Eğer uygun kural bulunur ise alttaki kurallar uygulanmaz. Kurallar için coverage (kapsam) ve accuracy (doğruluk) değerleri hesaplanarak değerlendirme yapılır. Denklem 3.4'te Coverage ve denklem 3.5'te Accuracy'nin hesaplanma tarifi yapılmıştır.

$$\text{Coverage(R)} = \frac{\text{Tahmin Sayısı}}{\text{Örnek Sayısı}} \quad (3.4)$$

$$\text{Accuracy(R)} = \frac{\text{Doğru Tahmin Sayısı}}{\text{Toplam Tahmin Sayısı}} \quad (3.5)$$

IF (HAVA='GÜNESLİ' AND NEM='NORMAL') TENIS = EVET

Buna göre yukardaki kural için kapsam ve doğruluk değerleri şöyledir.

$$\text{Coverage(R)} = \frac{2}{14} = \%14,28$$

$$\text{Accuracy(R)} = \frac{2}{2} = \% 100$$


Bu kural toplam örneklerin %14,28'ini kapsamaktadır ve %100 doğruluktadır.

Kurallar, karar ağaçlarından çıkarılacağı gibi ağaçlar kullanılmadan eğitim verisinin analizi ile de çıkarılabilir. Sequential covering algorithm (Sıralı kapsama algoritması) olarak adlandırılan bu yöntemde her sınıf elemanı için tüm veri setinin bir kere taranması ile o sınıfı kapsayacak en uygun kural elde edilir. AQ, CN2 ve RIPPER gibi birçok algoritma sıralı kapsama algoritmalarına örnek olarak gösterilebilir. Her seferinde bir kural öğrenilir. Öğrenilen kuralı kapsayan veriler eğitim kümesinden çıkarılır. Kalan veriler için tekrar kural öğrenilir.

3.4.2. Tahmin

Çıktı sınıfı sayısal olan veri setleri için kullanılmaktadır. Tahmin algoritmaları belirli bir fonksiyonun olmadığı durumlarda öncelikle algoritmanın mevcut verileri

kullanarak en iyi tahmin yapacağı fonksiyonu üretir. Bu fonksiyonu kullanarak gelecek için tahminler yapar. Doğrusal regresyon algoritması mevcut verileri kullanarak bir tahmin fonksiyonu üretmektedir. Tenis oyunu tahmin veri setine göre aşağıdaki kuralı inceleyelim.



Şekil 3.6. Tahmin fonksiyonu

Şekil 3.6 incelendiğinde mavi noktalar veri seti içerisindeki değerleri göstermektedir. Kırmızı renkli doğru ise üretilen tahmin fonksiyonunu göstermektedir. Bu fonksiyon mevcut verileri kapsayacak şekilde belirlenmeye çalışılır. Doğru üzerinde olmayan veriler için tahmin hataları hesaplanır. Hata değeri gerçek değerler ile tahmin değerleri arasındaki farkların karelerinin toplamıdır. Bu değer RSS olarak ifade edilir. Denklem 3.6'da bu ifade edilmiştir.

$$RSS = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3.6)$$

En uygun doğruyu bulabilmek için sistemin üreteceği doğrular için hata değerleri hesaplanır. Hata değeri en küçük olan doğru fonksiyonu seçilir.

Basit ve çoklu olmak üzere iki çeşit regresyon bulunmaktadır. Basit regresyon bir adet bağımlı değişken ile bir adet bağımsız değişken arasındaki ilişkiyi gösterir. Çoklu regresyon ise birden fazla bağımsız değişken ve bir bağımlı değişken arasındaki ilişkiyi

gösterir. Basit regresyonun denklemi Denklem 3.7’de çoklu regresyonun denklemi 3.8’de gösterilmiştir.

$$y = \beta_0 + \beta_1 x + \varepsilon \quad \text{Basit Regresyon} \quad (3.7)$$

β_0 = x sıfır olduğunda y’nin alacağı değerdir.


ε = Gerçek değer ile tahmin edilen değer arasındaki hata

$$y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + \varepsilon \quad \text{Çoklu regresyon} \quad (3.8)$$

3.4.3. Kümeleme

Verilerin önceden sınıflandırılmadığı danışmansız öğrenme yöntemi olarak kullanılır. Sistemden verileri kendisinin gruplara ayırması beklenir. Kümeleme algoritmaları sayesinde insanların yapması gereken sınıflandırma işlemlerini bilgisayarlar yapmış olur. Kümeleme algoritmaları Partitioning method (kısımlara ayırma metodu), hierarchical method (hiyerarşik method), density-based method (yoğunluk bazlı metot) ve grid-based method (grid tabanlı metot) olmak üzere dört grupta incelenebilir. Kümeleme, veri setindeki örnekleri alt kısımlara ayırma işlemi olarak tanımlanabilir. Her alt kısım bir cluster(küme) olarak adlandırılır. Bu yapılan işleme clustering (kümeleme) denilir. Kümeleme algoritmaları aynı veri setini farklı kümelere ayırabilir. İnsan tarafından sınıflandırılması çok zaman alacak büyük veri setleri için kümeleme algoritmalarını kullanmak daha uygun olacaktır. Aksi takdirde bu işlem çok fazla zaman alacak ve maliyetli olacaktır.

Kümeleme algoritmaları, biyoloji (Pagnuco vd., 2017), web üzerinde kelime aramaları (Alam & Sadaf, 2015), resim sınıflandırılması (Hou vd., 2016), dokümanların gruptandırılması (Forsati vd., 2013), birtakım özellikleri bilinen benzer müşterilerin gruptandırılması (Wang vd., 2014) gibi birçok alanda kullanılabilir. Kümeleme aynı zamanda veri sınıflandırması olarak da adlandırılır. Çünkü çok büyük veri setleri içerisindeki benzer özellikli verileri gruplamaktadır. Aynı zamanda veri setlerindeki aykırı verilerin tespitinde de kullanılabilir (Gan & Ng, 2017). Şekil 3.7’de yaşa göre gelir dağılımını gösteren örnek kümeleme verisi gösterilmiştir.



Şekil 3.7. Yaşa göre gelir dağılımını gösteren örnek kümeleme verisi

3.4.3.1. Kümeleme Analizi için Gereksinimler

Kümeleme algoritmalarının doğru çalışabilmesi için bazı gereksinimlerin olması gereklidir. Böylelikle veriler üzerinden elde edilecek kümelerin doğruluğu artacaktır.

3.4.3.1.1. Ölçeklenebilirlik

Birçok kümeleme algoritması çok büyük olmayan veri setleri üzerinde çalışmaktadır. Fakat web aramaları gibi milyonlarca hatta milyarlarca veri içeren büyük veri setleri de mevcuttur. Kümeleme algoritmaları büyük veri setlerinde çalışabilmelidir.

3.4.3.1.2. Farklı veri tipleri ile çalışabilmeli

Birçok kümeleme algoritması sayısal verilerle çalışmak üzere tasarlanmışlardır. Oysa sayısal verilerin dışında ikili, kategorik, sıra numarası veya karışık veri içeren özelliklerde bulunabilir. Ayrıca grafikler, dokümanlar ve resimler içeren veri setleri mevcuttur.

3.4.3.1.3. Olay şekillerinin tespit edilmesi

Kümeleme algoritmaları genel olarak Euclidian ve Manhattan algoritmalarını kullanarak örnekler arasındaki mesafeyi hesaplayarak kümeleme yaparlar. Uzaklık bazlı

mesafe ölçerek kümeleme yapan algoritmalar verileri küresel şekillerde kümelerler. Fakat küresel olmayan şekillerde de kümeleme yapılabilir. Bir orman yangını, hırsızlık, trafik kazaları gibi olayları kümeleyecek algoritmalar geliştirilebilir.

3.4.3.1.4. Özelliklerin belirlenmesi

Veri setindeki özellikleri belirlemek için veriyi çok iyi tanımak gereklidir. Genellikle kümeleme algoritmaları için bu özellikler ve istenen küme sayısı önceden belirtilmelidir. Oysa çok büyük veri setleri için bunları tespit etmek çok zordur. İnsanların veriyi iyi analiz ederek, çok fazla zaman ayırması gereklidir.

3.4.3.1.5. Gürültülü verilerin tespiti

Veri setleri içerisinde bozuk veri olarak adlandırılan ve normal şartlarda olması çok olası olmayan verilerin tespit edilerek veri setinden çıkarılması gereklidir. Bu verileri dikkate alarak yapılacak kümeleme işlemi yanlış sonuçlar üretebilir. Kümeleme algoritmaları gürültülü verileri tespit edebilmelidir.

3.4.3.1.6. Sürekli güncellenen veriler

Birçok uygulamada veriler sürekli artmaktadır. Gelen yeni veriler kümeler üzerinde değişikliğe sebep olabilir. Kümeleme algoritmalarının bu durumları analiz edebilmelidir.

3.4.3.2. Kümeleme Metotları

Literatürde kullanılan birçok kümeleme algoritması mevcuttur. Bu algoritmaları temel olarak dört bölümde inceleyebiliriz.

3.4.3.2.1. Kısımlara ayırma metodu

Bu metot verilerin kaç kümeye ayrılacağını insan tarafından tespit edilerek algoritmaya verilmesi ile çalışır. Öncelikle elimizdeki veri setinin kaç küme olacağını belirtiriz. Küme sayısı en fazla veri setindeki eleman sayısı kadar olabilir. Kümeler tespit edilirken verilerin birbirlerine olan mesafeleri kullanılarak bezer olan veriler aynı


kümelere eklenirler. Farklı kümeler içerisindeki veriler birbirlerine benzemezler. K-means ve k-medoids algoritmaları en yaygın kullanılan kısımlara ayırma algoritmalarıdır.

3.4.3.2.1.1. k-Means Algoritması

Bu algoritma ile her bir küme için bir kütle ağırlık merkezi hesaplanır. Genellikle bu nokta kümenin merkezidir. k adet küme olduğu varsayılan bir veri seti için her C_i , ($1 \leq i \leq k$) bulunduğu kümenin kütle merkezini temsil etsin. $p \in C_i$ olan bir eleman olsun. p 'nin C_i kütle merkezine olan uzaklık $dist(p, C_i)$ euclidian distance algoritması ile hesaplanır. Küme içerisindeki her bir elemanın merkeze olan uzaklıkları hesaplanır. Tüm kümelerin içerisindeki elemanların merkez ile uzaklıklarının kareleri toplanarak merkeze olan sapma hesaplanır. Toplam sapma Denklem 3.9'da gösterilmiştir.


$$E = \sum_{i=1}^k \sum_{p \in C_i} dist(p, C_i)^2 \quad (3.9)$$

Bu fonksiyonun amacı k adet kümeyi birbirinden ayırmak ve kümeleri sıklılaştırmaktır. Algoritmanın çalışması Şekil 3.8'de gösterilmiştir.



Şekil 3.8. Kümeleme iş akışı

Şekil 3.9.'da 21 adet örnek içeren bir veri seti 3 adet kümeye ayrılmıştır. İlk aşamada rastgele 3 değer seçilerek her bir kümenin merkezi olarak atanmıştır. İkinci resimde iterasyon sonrası elemanların kümelerinin değiştiği gösterilmiştir. Son resimde ise değişikliklerin durduğu final kümeler görünmektedir.



Şekil 3.9. k-means algoritması

3.4.3.2.1.2. k-Medoid Algoritması


Bu algoritma genel olarak k-means algoritmasına benzemektedir. Öncelikle k küme sayısı sisteme girilir. Sonrasında k adet rastgele veri elemanı veri seti içerisinde seçilir. Veri setindeki elemanlar uzaklıklarına göre ait oldukları kümelere atanırlar. Buraya kadar k-means ile aynı şekilde çalışmaktadır. Kütle merkezi bulunurken k-means küme içerisindeki elemanların ortalaması alınır. Bu merkez değeri küme içerisindeki bir eleman olmayabilir. Fakat k-medoid algoritmasında ise küme içerisindeki elemanlar tek tek denenerek en az hata olan değeri yeni kütle merkezi olarak belirlenir. Bu durum herhangi bir değişiklik olmayana kadar devam eder.

3.4.3.2.2. Hiyerarşik Kümeleme

Kısımlara ayırma algoritmaları veri setini gruplara ayırır. Hiyerarşik gruplama ise bir ağaç yapısı gibi verileri kümeler. Verileri bu şekilde göstermek hem özetlemek hem de görsel açıdan faydalıdır. Örneğin bir süpermarket ürünlerini yiyecekler, içecekler, temizlik malzemeleri, elektronik malzemeler gibi gruplara ayırabilir. İçecekleri de kendi içerisinde gazlı içecekler, alkollü içecekler, meyve suları gibi alt gruplara ayırabilir. Bu şekilde her grubu daha kolay analiz edebilir. Bu veriler hiyerarşik kümeleme olmadan kısımlara ayrılma yöntemleri ile de parçalanabilir. Hiyerarşik kümeleme görsel açıdan ve verilerin özetlenmesi bakımından daha faydalıdır. Hiyerarşik kümelemede grupları parçalama ya da birleştirme yaptıktan sonra geri dönüş olmamaktadır. Bu yüzden bu işlemi yaparken iyi karar vermek gerekmektedir. Yanlış yapılacak bir seçim algoritmanın kalitesini düşürecektir.

Hiyerarşik kümeleme metotlarına örnek olarak BIRCH ve Chamelon gösterilebilir. Algoritmik, istatistiksel ya da bayes yaklaşımları ile hiyerarşik kümeleme yapılabilir. Algoritmik yaklaşım veri seti içerisindeki uzaklıkları kullanarak kümeleme yapar. İstatistiksel yaklaşım kümelerin kalitesini ve uygunluğunu istatistiksel yöntemler ile belirler. Bayes yaklaşımı ise olası birçok grup önerisi yapar. Bu grupların içerisinde en uygunu seçilir.

Hiyerarşik metotlar agglomerative (birleştirici) ya da divisive (parçalayıcı) şeklinde olabilir. Agglomerative yaklaşım aşağıdan yukarıya doğru verileri birleştirerek büyük bir grup oluşturmayı hedefler. Divisive yaklaşım ise yukarıdan aşağıya doğru büyük kümeleri küçük parçalara ayırmak için kullanılır. Her iki yöntemde de küme sayısı önceden belirtilmelidir. Şekil 3.10'da AGNES (AGglomerative NESTing) ve DIANA (Diveisive ANALysis) metotlarının $\{a,b,c,d,e\}$ veri kümesi için nasıl çalıştığı gösterilmiştir.




Şekil 3.10. Agnes ve Diana metotları

3.4.3.2.3. Yoğunluk Bazlı Kümeleme

Kısımlara ayırma ve hiyerarşik kümeleme yöntemleri daha çok küresel kümelemeler yapmaktadır. “S” veya oval şeklindeki kümelemeler gibi farklı şekillerdeki kümeleri bulmak bu algoritmalar için zordur. Bu kümeleme yönteminde küresel olmayan kümelerde farklı şekillerde kümeler bulmak için yoğunluk kullanılır. DBSCAN, OPTICS ve DENCLUE metotları bu kümeleme yöntemlerin en önemlileridir.

3.4.3.2.3.1. DBSCAN (Density Based Spatial Clustering of Applications with Noise) Methodu

Bu yöntemde (Ester vd., 1996) veri seti içerisinde kendisine en fazla yakın örnek taşıyan kayıt yoğunluk merkezi olarak belirlenir. Algoritmanın çalışabilmesi için Eps ve MinPts parametrelerinin başlangıçta belirlenmiş olması gereklidir. Eps değeri noktalar arası mesafeyi, MinPts ise küme içerisinde olabilecek en az eleman sayısını belirtmektedir. Eps hesaplanırken Euclidean veya Manhattan distance gibi mesafe algoritmaları kullanılmaktadır. Şekil 3.11’de Dbscan yöntemi gösterilmiştir.



Şekil 3.11. Dbscan yöntemi

Örnek veri setini D ile adlandırılacak olursak, öncelikle tüm noktalar ziyaret edilmemiş olarak belirlenir. İlk olarak rastgele daha önce ziyaret edilmemiş bir p noktası seçilir ve bu nokta ziyaret edilmiş olarak atanır. Bu noktaya olan mesafesi Eps değerinden küçük an az MinPts kadar nokta aranır. Eğer bulunamaz ise bu veri gürültülü veri olarak

işaretlenir. Eğer MinPts den fazla veri bulunursa, yeni bir küme oluşturulur ve daha önce herhangi bir kümeye atanmamış olan tüm bulunan veriler bu kümeye eklenir. Bu durum tüm elemanlar için tekrar edilir ve oluşan kümenin genişlemesi durunca biter. DBSCAN, küme dışında kalan elemanlardan birini daha seçerek aynı işlemleri tekrar eder. Tüm elemanlar ziyaret edilene kadar bu işlem devam eder.

3.4.3.2.3.2. OPTICS (Ordering Points To Identify Clustering Structure)

DBSCAN algoritması için Eps ve MinPts parametrelerini seçmek çok kolay bir işlem değildir. Seçilen bu parametrelere göre kümelerin şekli değişmektedir. Çok fazla veri bulunan çok boyutlu verilerde bu değerleri saptamak çok zordur. Bu zorluktan dolayı OPTICS yöntemi geliştirildi (Ankerst vd., 1999). Bu algoritma, kümeleri belirlemek yerine verileri bu verileri insanların yorumlayabilecekleri çıktılar haline getirir. Bu çıktılar üretilirken DBSCAN algoritmasında olduğu gibi Eps ve MinPts değerleri hesaplanarak gösterilir. Böylelikle bu çıktıdan faydalanılarak manuel bir kümeleme yapılabilir.

3.4.3.2.4. Grid bazlı kümeleme

Diğer kümeleme algoritmaları veri setindeki verileri kullanarak belirli yöntemlerle kümeler oluşturmaktadır. Bu yöntemde ise veri setinden bağımsız olarak alan hücrelere bölünür. Algoritmanın en temel avantajı çok hızlı işlem süresidir. Veri setindeki veri sayısından bağımsız olarak her boyuttaki hücre sayısına bağlı olarak çalışır. STING ve CLIQUE algoritmaları grid tabanlı kümeleme algoritmalarına örnek olarak gösterilebilir.

3.4.3.3. Bağlantı Analizi

Birbiri ile ilişkili durumların tespit edilmesinde kullanılan yöntemlerdir. Aralarında tekrar eden bir ilişki bulunan nesnelerin tespitinde kullanılır. Örneğin bir marketten ekmek ve sütün birlikte alınması veya bir elektronik marketten bilgisayar ve kameranın birlikte alınması gibi durumlar bu yöntemlerle tespit edilebilir. Bu yöntemleri kullanan çoğu market raf dizilimlerini bu bağlantı analizlerini yaparak şekillendirmektedir. Böylelikle müşterilerine daha fazla ürün satabilmektedirler. En çok kullanılan yöntem Apriori algoritmasıdır (Agrawal & Srikant, 1994).

3.5. Algoritmalar

Veri madenciliği alanında kullanım alanlarına göre birçok algoritma geliştirilmiştir. Tez kapsamında veri setimiz için mevcut verilere ait fire miktarları belli olduğu için danışmanlı öğrenme teknikleri kullanılacaktır. Aşağıda tez kapsamında veri setine uygulanacak olan algoritmalar detaylı olarak açıklanmıştır. Bu algoritmalar Weka ile veri setine uygulanarak sonuçlar değerlendirilecektir.

3.5.1. J48

Bu algoritma Quinlan tarafından geliştirilmiş olan ID3 (Quinlan, 1986) algoritmasının yine Quinlan tarafından iyileştirilmiş hali olan C4.5 (Quinlan, 1993) algoritmasının açık kaynak kodlu versiyonudur. Karar ağacı algoritmasıdır. Veri seti için Entropy ve Gain değerlerini hesaplayarak ağaç oluşturmayı hedefler. Algoritma temel olarak karar ağacını oluşturabilmek için öncelikle en önemli özelliği tespit eder. Daha sonrasında bu özelliğe göre kalan verileri tekrar aynı yöntem ile kendi arasında parçalayarak tüm ağacı oluşturur. Özellikler arasından hangisinin kök olarak kullanılacağını bulabilmek için her bir özelliğe ait Entropi değeri ve Bilgi Kazanımı değerleri hesaplanarak birbirleri ile kıyaslanır. En yüksek Bilgi Kazanımı değerine sahip olan özellik karar ağacının kökünü oluşturur. Sonrasında aynı yöntem ile ağacın dalları meydana getirilir.

Entropi değeri özelliğin belirsizlik ölçütü olarak tanımlanır.

Entropisi hesaplanacak olan özelliğimize S dersek;

c = sınıflandırma özelliğimizdeki toplam sınıf sayısı

$$\text{Entropi}(S) = \sum_{i=1}^c -P_i * \log_2(P_i)$$

Özelliği ait Entropi hesaplandıktan sonra özelliğin içerdiği değerlerin çıkış sınıfına göre entropisi hesaplanır.

t = Özelliğin içerdiği farklı veri sayısı.

$$\text{Entropi}(A) = \sum_{i=1}^t -P_i * \log_2(P_i)$$

Son olarak Bilgi Kazancı hesaplanır.

$$\text{GAIN}(S, A) = \text{Entropi}(S) - \text{Entropi}(A)$$

Her özellik için Bilgi kazanımı hesaplandıktan sonra en büyük özellik seçilerek ağacın tepesine yerleştirilir.

Tenis oyunu veri seti için entropi ve özelliklerin bilgi kazançlarını hesaplayalım.

Öncelikle genel entropi değeri hesaplanır

$$\begin{aligned} Entropi &= -\frac{9}{14} * \log_2\left(\frac{9}{14}\right) - \frac{5}{14} * \log_2\left(\frac{5}{14}\right) \\ &= 0,94 \end{aligned}$$

Şimdi tek tek Hava, sıcaklık, nem ve rüzgar özellikleri için entropi hesaplayalım.

$$\begin{aligned} Entropi(Hava) &= \frac{4}{14} \left(-\frac{4}{4} * \log_2\left(\frac{4}{4}\right) - \frac{0}{4} * \log_2\left(\frac{0}{4}\right) \right) \\ &+ \frac{5}{14} \left(-\frac{2}{5} * \log_2\left(\frac{2}{5}\right) - \frac{3}{5} * \log_2\left(\frac{3}{5}\right) \right) \\ &+ \frac{5}{14} \left(-\frac{3}{5} * \log_2\left(\frac{3}{5}\right) - \frac{2}{5} * \log_2\left(\frac{2}{5}\right) \right) \\ &= 0,69 \end{aligned}$$

$$Gain(Hava) = 0,94 - 0,69 = 0,25$$

$$\begin{aligned} Entropi(Sıcaklık) &= \frac{6}{14} \left(-\frac{4}{6} * \log_2\left(\frac{4}{6}\right) - \frac{2}{6} * \log_2\left(\frac{2}{6}\right) \right) \\ &+ \frac{4}{14} \left(-\frac{3}{4} * \log_2\left(\frac{3}{4}\right) - \frac{1}{4} * \log_2\left(\frac{1}{4}\right) \right) \\ &+ \frac{4}{14} \left(-\frac{2}{4} * \log_2\left(\frac{2}{4}\right) - \frac{2}{4} * \log_2\left(\frac{2}{4}\right) \right) \\ &= 0,91 \end{aligned}$$

$$Gain(Sıcaklık) = 0,94 - 0,91 = 0,03$$


$$\begin{aligned} Entropi(Nem) &= \frac{7}{14} \left(-\frac{6}{7} * \log_2\left(\frac{6}{7}\right) - \frac{1}{7} * \log_2\left(\frac{1}{7}\right) \right) \\ &+ \frac{7}{14} \left(-\frac{3}{7} * \log_2\left(\frac{3}{7}\right) - \frac{4}{7} * \log_2\left(\frac{4}{7}\right) \right) \\ &= 0,79 \end{aligned}$$

$$\text{Gain (Nem)} = 0,94 - 0,79 = 0,15$$

$$\begin{aligned} \text{Entropi(Rüzgar)} &= \frac{6}{14} \left(-\frac{3}{6} * \log_2 \left(\frac{3}{6} \right) - \frac{3}{6} * \log_2 \left(\frac{3}{6} \right) \right) \\ &+ \frac{8}{14} \left(-\frac{6}{8} * \log_2 \left(\frac{6}{8} \right) - \frac{2}{8} * \log_2 \left(\frac{2}{8} \right) \right) \\ &= 0,89 \end{aligned}$$

$$\text{Gain (Rüzgar)} = 0,94 - 0,89 = 0,05$$

Burada en büyük bilgi kazancı 0,25 ile Hava özelliğinde olduğu için ağacımız Hava özelliğine göre dallanmaya başlayacaktır. Dolayısı ile bu durumda ağacımızın şekli Şekil 3.12’de gibi olacaktır.



Şekil 3.12. J48 algoritma özellik seçim adımı

Hava bulutlu iken veri setimizde bulunan 4 örneğin tamamı için Evet kararı olduğu için ağacın bu dalı Evet olarak sonlanır. Havanın güneşli ve Yağmurlu olmasına göre eğitim kümesindeki veriler süzülerek tekrar aynı işlemler yapılır. Havanın güneşli olduğu durumlara göre veri seti filtrelendiğinde Çizelge 3.5’teki gibi bir veri seti elde ederiz. Toplam 5 adet kaydolan bu veri setine göre ağacın dallanma durumu tekrar hesaplanır.

Çizelge 3.5. J48 ilk adım sonrası veri seti

NO	HAVA	SICAKLIK	NEM	RÜZGAR	TENİS
1	GUNESLI	SICAK	YUKSEK	YOK	HAYIR
2	GUNESLI	SICAK	YUKSEK	VAR	HAYIR
3	GUNESLI	NORMAL	YUKSEK	YOK	HAYIR
4	GUNESLI	SERIN	NORMAL	YOK	EVET
5	GUNESLI	NORMAL	NORMAL	VAR	EVET

Öncelikle genel entropi değeri hesaplanır

$$Entropi = -\frac{2}{5} * \log_2\left(\frac{2}{5}\right) - \frac{3}{5} * \log_2\left(\frac{3}{5}\right)$$

$$= 0,97$$

Şimdi sıcaklık, nem ve rüzgar özellikleri için entropi ve bilgi kazancı hesaplanacaktır.

$$Entropi(Sıcaklık) = \frac{2}{5} \left(-\frac{2}{2} * \log_2\left(\frac{2}{2}\right) - \frac{0}{2} * \log_2\left(\frac{0}{2}\right) \right)$$

$$+ \frac{2}{5} \left(-\frac{1}{2} * \log_2\left(\frac{1}{2}\right) - \frac{1}{2} * \log_2\left(\frac{1}{2}\right) \right)$$

$$+ \frac{1}{5} \left(-\frac{1}{1} * \log_2\left(\frac{1}{1}\right) - \frac{0}{1} * \log_2\left(\frac{0}{1}\right) \right)$$

$$= 0,4$$

$$Gain(Sıcaklık) = 0,97 - 0,4 = 0,57$$

$$Entropi(Nem) = \frac{3}{5} \left(-\frac{0}{3} * \log_2\left(\frac{0}{3}\right) - \frac{3}{3} * \log_2\left(\frac{3}{3}\right) \right)$$

$$+ \frac{2}{5} \left(-\frac{2}{2} * \log_2\left(\frac{2}{2}\right) - \frac{0}{2} * \log_2\left(\frac{0}{2}\right) \right)$$

$$= 0$$

$$Gain(Nem) = 0,97 - 0 = 0,97$$


$$Entropi(Rüzgar) = \frac{2}{5} \left(-\frac{1}{2} * \log_2\left(\frac{1}{2}\right) - \frac{1}{2} * \log_2\left(\frac{1}{2}\right) \right)$$

$$+ \frac{3}{5} \left(-\frac{1}{3} * \log_2\left(\frac{1}{3}\right) - \frac{2}{3} * \log_2\left(\frac{2}{3}\right) \right)$$

$$= 0,95$$

$$\text{Gain (Rüzgar)} = 0,97 - 0,95 = 0,02$$

Bu durumda Nem özelliği 0,97 değeri ile en yüksek bilgi kazancına sahiptir. Dolayısı ile havanın güneşli olduğu durumlarda ağacımız Nem özelliğine göre dallanacaktır. Nem özelliğine bakılırsa toplam 5 kayıttan eğer nem Normal ise daima Evet, Yüksek ise daima Hayır sonucu çıkmıştır. Bu sebeple ağaç bu dallarda son bulur. Ağacın son hali Şekil 3.13'teki gibi olacaktır.




Şekil 3.13. J48 algoritma devamı

Geriye yalnızca havanın yağmurlu olma durumu kaldı. Bu durumdaki veriler filtrelendiğinde Çizelge 3.6 elde edilir.

Çizelge 3.6. J48 seçim sonrası veri seti durumu

NO	HAVA	SICAKLIK	NEM	RÜZGAR	TENİS
1	YAGMURLU	NORMAL	YUKSEK	YOK	EVET
2	YAGMURLU	SERIN	NORMAL	YOK	EVET
3	YAGMURLU	SERIN	NORMAL	VAR	HAYIR
4	YAGMURLU	NORMAL	NORMAL	YOK	EVET
5	YAGMURLU	NORMAL	YUKSEK	VAR	HAYIR

Tablo incelendiğinde havanın yağmurlu olduğu 5 adet veri bulunmaktadır. Ağacımızda tekrar entropi hesabı yapıldığında Rüzgar özelliğinin bilgi kazancının yüksek olduğu görülecektir. Rüzgar durumuna bakıldığında 3 adet Yok durumu olduğunda sonucun tamamen Evet olduğu, 2 adet Var durumu olduğunda ise sonucun Hayır olduğu görülmektedir. Bu durumda ağacımızın son hali Şekil 3.14'teki gibi olacaktır.



Şekil 3.14. J48 algoritma sonucu

3.5.2. Naive Bayes

Bu algoritma istatistik tabanlı çalışan bir sınıflandırma algoritmasıdır. Algoritmanın en temel özelliği tüm özelliklerin birbirinden bağımsız olduğunu varsaymasıdır. Temel Bayes teoremini baz alır. Çok yalın bir tasarıma sahip olmasına rağmen gerçek dünyada karşılaşılan birçok durumda iyi sonuçlar vermektedir (Domingos & Pazzani, 1997; Rish & Rish, 2001). Her özellik için olasılıklar hesaplanacağından küçük veri setleri için hızlı sonuç üretse de çok büyük veri setleri için bu olasılıkların sürekli tekrar hesaplanması zaman alacaktır. Denklem 3.10'da Naive Bayes denklemi verilmiştir.

$$P(S|X) = \frac{P(X|S)P(S)}{P(X)} \quad (3.10)$$

$$P(S|X) = P(X_1|S) * P(X_2|S) * ... * P(X_n|S) * P(S)$$

$P(S|X)$ = X özelliğinin S sınıfı için olasılığı

$P(S)$ = S sınıfının olasılığı

$P(X|S)$ = S sınıfı için X özelliğinin olasılığı

$P(X)$ = X sınıfının olasılığı

Tenis oyunu örnek veri setimiz için algoritmanın nasıl çalışacağı aşağıda anlatılmıştır.

Öncelikle tenis oynama durumuna göre evet ve hayır sonuçları için olasılıklar hesaplanır.

$$P(\text{Tenis} = \text{Evet}) = 9 / 14 = 0,64$$

$$P(\text{Tenis} = \text{Hayır}) = 5 / 14 = 0,36$$

Çizelge 3.7. Tenis oyununun durumlara göre oynanma olasılıkları

Hava	Tenis Oynama			
	Evet	Hayır	P(Evet)	P(Hayır)
Güneşli	2	3	$2/9 = 0,22$	$3/5 = 0,60$
Yağmurlu	3	2	$3/9 = 0,33$	$2/5 = 0,4$
Bulutlu	4	0	$4/9 = 0,44$	$0/5 = 0$
Toplam	9	5		

Sıcaklık	Tenis Oynama			
	Evet	Hayır	P(Evet)	P(Hayır)
Normal	4	2	$4/9 = 0,44$	$2/5 = 0,4$
Serin	3	1	$3/9 = 0,33$	$1/5 = 0,2$
Sıcak	2	2	$2/9 = 0,22$	$2/5 = 0,4$
Toplam	9	5		

Rüzgar	Tenis Oynama			
	Evet	Hayır	P(Evet)	P(Hayır)
Var	3	3	$3/9 = 0,33$	$3/5 = 0,6$
Yok	6	2	$6/9 = 0,67$	$2/5 = 0,4$
Toplam	9	5		

Nem	Tenis Oynama			
	Evet	Hayır	P(Evet)	P(Hayır)
Normal	6	1	$6/9 = 0,67$	$1/5 = 0,2$
Yüksek	3	4	$3/9 = 0,33$	$4/5 = 0,8$
Toplam	9	5		

$P(\text{Hava=Güneşli, Sıcaklık = Sıcak, Nem = Normal, Rüzgar = Yok}) = ?$

Örnek veri setimizin 15. Satırındaki veri için Naive Bayes algoritmasına göre sonuç hesaplanırsa;

Her bir durum için olasılıklar hesaplanacaktır. Havanın güneşli olması durumunda evet çıkma olasılığı aşağıdaki gibi hesaplanır.

Evet için;

$$P(\text{Evet}) * P(\text{Güneşli}|\text{Evet}) * P(\text{Sıcak}|\text{Evet}) * P(\text{Yüksek}|\text{Evet}) * P(\text{Var}|\text{Evet})$$

$$0,64 * 0,22 * 0,22 * 0,33 * 0,33$$

$$= 0,0034$$

Hayır için

$$P(\text{Hayır}) * P(\text{Güneşli}|\text{Hayır}) * P(\text{Sıcak}|\text{Hayır}) * P(\text{Yüksek}|\text{Hayır}) * P(\text{Var}|\text{Hayır})$$

$$0,36 * 0,6 * 0,4 * 0,8 * 0,6$$

$$= 0,0415$$

Sonuçlara göre

$$P(\text{Hava=Güneşli, Sıcaklık = Sıcak, Nem = Normal, Rüzgar = Yok}) = \text{HAYIR}$$

olacaktır.

Hayır gelme olasılığı ise;

$$\frac{0,0415}{0,0415 + 0,0034} = 0,9248$$

Verilen değerlere göre %92,48 olasılık ile verilen durum için tenis oynanmayacağı sonucu çıkacaktır.

3.5.3. K-NN (K-Nearest Neighborhood, En Yakın K Komşu) Algoritması

K-NN algoritması ilk olarak 1951 yılında Fix ve Hodges (Fix & Hodges, 1989) tarafından geliştirilmiş ve sonrasında 1967 yılında Cover ve Hart (Cover & Hart, 1967) tarafından geliştirilmiştir. İbk algoritması, Weka içerisinde k en yakın komşu algoritması için yapılmış olan uyarlamadır. Algoritmanın çalışabilmesi için öncelikle sabit bir k değeri seçilir. Sonrasında tüm kayıtların birbirlerine uzaklıkları Öklid veya manhattan algoritmaları kullanılarak hesaplanır ve k adet en yakın kayıt seçilir. Algoritmanın çalışmasını beş adım ile açıklayabiliriz. Elimizde Çizelge 3.8’teki gibi veriler olsun.

Çizelge 3.8. K-NN için örnek veri seti

No	Nesne	Sınıf
1	Kalem	Eşya
2	Elma	Meyve
3	Armut	Meyve
4	Kedi	Hayvan
5	Nar	?

1. k değeri seçilir. Örnek olarak 3 değerini seçelim.
2. Yeni eklenecek olan nesnenin diğer kayıtlar ile olan uzaklıkları öklid veya manhattan algoritması ile hesaplanır.
- 3.

Çizelge 3.9. Verilerin uzaklıkları

	Uzaklık
Kalem	4
Elma	3
Armut	2
Kedi	5

4. Uzaklıklara göre sıralama yapılır.

$k = 3$ olduğu için en yakın 3 adet nesne ve sınıfları aşağıdaki gibidir.

5.

Çizelge 3.10. Örnek nesneler ve sınıfları

	Uzaklık	Sınıf
Nar- Armut	2	Meyve
Nar- Elma	3	Meyve
Nar- Kalem	4	Eşya

6. En yakın kategoriler toplanır.


Uzaklıklarına göre nesneler sıralandığında iki adet meyve ve bir adet eşya sınıfının olduğu görülmektedir.

7. Uygun sınıf seçilir.

Bu durumda Nar nesnesin Meyve sınıfında olduğu tespit edilir.

3.5.4. SVM (Support Vector Machine)

Bu algoritmada her bir sınıfı birbirinden ayıracak şekilde sınır değerlerde destek vektörler seçilir. Tüm sınıfları birbirinden ayıracak şekilde doğrusal ayırtaç fonksiyonu oluşturulur. Bu örnek tabanlı yaklaşım lineer sınırlardaki limitleri aşarak daha iyi kararlar vermesini sağlar. Veri setini ayıracak bir doğru çizilir. Doğru ile verileri ayıran kısımlara vektör adı verilir. Her bir vektör ile doğru arasında kalan bölgeye margin adı verilir. Marginin geniş olması örneklerin iyi ayrıldığını göstermektedir(Cui & Curry, 2005). Şekil 3.15'te SVM vektörleri ve marginler gösterilmiştir.




Şekil 3.15. SVM vektörleri ve marginler

$$\hat{y} = \begin{cases} 0 & \text{if } \mathbf{w}^T \cdot \mathbf{x} + b < 0, \\ 1 & \text{if } \mathbf{w}^T \cdot \mathbf{x} + b \geq 0 \end{cases} \quad (3.11)$$

Denklem 3.11'e göre $\mathbf{w}$ ağırlık vektörü, $\mathbf{x}$ girdi vektörü ve b sapmadır. Değer formül sonucuna göre sıfıra eşit ya da büyük ise siyah noktalara, aksi durumda beyaz noktalara daha yakındır.

Her zaman margin grupları istenildiği gibi düzgün ayırmayabilir. Şekil 3.16'de verilerin vektörlere göre ayrılması gösterilmiştir.




Şekil 3.16. Verilerin vektörlere göre ayrılması

C, Margin değeri ne kadar büyük ise margin aralığı o kadar dardır.

Doğrusal tek boyutlu doğru, karmaşıklık verisetlerini ayırmada yetmeyebilir. Bu durumda belirli kernel değerleri kullanılarak veriler daha anlamlı hale gelebilir. En sık kullanılan kernel türleri aşağıdaki gibidir.

3.5.4.1. Polynominal Kernel

Bu yöntemde problemin çözümü için çok boyutlu yaklaşımlar kullanılır. Şekil 3.17’de polynominal kernel gösterilmiştir.




Şekil 3.17. Polynominal kernel

Boyutlar arttıkça verileri ayırmak için düzlemler kullanılır.

3.5.4.2. Gaussian Kernel


Bu yöntemde sonsuz sayıdaki destek vektörlerinin her bir noktaya ne kadar benzediği normal dağılım ile hesaplanır. Gamma değeri ile dağılımın genişliği hesaplanır. Gamma değeri küçüldükçe dağılım genişler (Lee & Mangasarian, 2001). Şekil 3.18’de gaussian kernel örneği gösterilmiştir.



Şekil 3.18. Gaussian kernel

3.5.5. Multilayer Perceptron

Bu modelde bir giriş katmanı, bir çıkış katmanı ve ihtiyaca göre belirlenecek olan gizli katmanlar bulunmaktadır. Her katmanın çıkışı, sonraki katmanın girişi olarak çalışır. Bu ilişki en son çıkış katmanına kadar devam eder. Çıkış katmanındaki eleman sayısı, modelden beklenen sınıf sayısına eşittir (Cybenko, 1989). Şekil 3.19’da multilayer perceptron katmanları gösterilmiştir.




Şekil 3.19. Multilayer perceptron katmanları

Sistemin öğrenmesi iki aşamada gerçekleşir.

1. İleri yayılım (Feed Forward)

Veriler (x1, x2, x3) giriş katmanından girerek çıkış katmanına doğru ilerler.

Her işlem elemanına gelindiğinde net girdi hesaplanır. Net girdi, aktivasyon fonksiyonundan geçerek çıktı hesaplanır. Bu çıktı bir sonraki katmana girdi olarak kullanılır. Bu işlemler çıktılar elde edilene kadar devam eder. En çok kullanılan aktivasyon fonksiyonu sigmoiddır (Gardner & Dorling, 1998). Şekil 3.20’de ileri yayılım yönteminde kullanılan sigmoid fonksiyonu gösterilmiştir.



Şekil 3.20. İleri yayılım yöntemi

2. Geri yayılım (Back Propagation)

İkinci aşamada elde edilen çıktı eğitim kümesindeki gerçek çıktı ile karşılaştırılarak oluşan hata hesaplanır. Bu hata değeri geriye doğru dağıtılır. Başlangıçta rastgele verilen girdi katmanı ağırlıkları hatanın dağıtılması ile her aşamada güncellenir (Rosenblatt, 1961; Rumelhart vd., 2013).

3.6. Değerlendirme Kriterleri

Weka ile yapılan sonuçların doğruluğunu ve güvenilirliğini test etmek için aşağıda belirtilen parametreler kullanılmaktadır. Böylelikle elde edilen sonuçların ne kadar doğru

olduğunu, yapılan tahminlerin doğruluğunun modelin doğru çalışmasından mı yoksa tesadüfi olarak mı doğru olduğunu anlayabilmekteyiz.

3.6.1. Accuracy (Doğruluk)

Veri seti için doğru sınıflandırılmış örnek sayısının toplam örnek sayısına bölünerek hesaplanır. Bir performans ölçüsü olarak doğruluk, dengesiz sınıflandırma problemleri için uygun değildir. Eleman sayısı diğer sınıflara göre çok fazla olan veri setlerinde elde edilecek sonuçların %90'larrın üzerine çıkması yanıltıcı olabilir. Aşağıda bulunan matris doğru verilerin doğru ya da yanlış, yanlış verilerin de doğru ya da yanlış tahmin edilme durumlarını göstermektedir. Aşağıdaki tabloya göre belirli durumlarda yağmur yağma olasılığının True / False olarak değerlendirildiği 100 elemanlı bir veri seti düşünelim. Yağmurun yağma durumunu tahmin eden bir model geliştirildiğinde Çizelge 3.11'deki olası durumlar meydana gelmektedir.

Çizelge 3.11. Karışıklık Matrisi

Tahminler (Positive / Negative)

Gerçekleşen (True / False)	Tahminler (Positive / Negative)	
	True Positives (TP)	False Negatives (FN)
True	30	20
False	15	35

Tabloya göre;

True Positive (TP): Gerçekte yağmur yağdı ve model yağmurun yağacağını doğru tahmin etti.

True Negative (TN): Gerçekte yağmur yağmadı ve model yağmur yağmayacak şeklinde doğru tahminde bulundu.

False Positive (FP): Gerçekte yağmur yağmamasına rağmen model yağmur yağacak şeklinde hatalı tahminde bulundu.

False Negative (FN): Gerçekte yağmur yağmasına rağmen model yağmurun yağmayacağı şeklinde hatalı tahminde bulundu.

$$\frac{TP + TN}{TP + FP + TN + FN} \quad (3.12)$$

Denklem 3.12'ye göre doğruluk değeri = $(30 + 35) / (30 + 15 + 35 + 20) = 0,65$ yani %65 dir.

3.6.2. Precision (Kesinlik)

Positive olarak tahmin edilen değerlerin gerçekte ne kadarının positive olduğunu gösteren değere kesinlik denilmektedir.

$$\text{Precision} = \frac{TP}{TP + FP} \quad (3.13)$$

Denklem 3.13'e göre $30 / (30 + 15) = 0,66$ yani %66 lık kesinlik değeri bulunur.

Kesinlik değeri modellerin güvenilirliği ve kullanımı açısından son derece önemlidir. Örneğin, gelen maillerin spam olup olmadığını tahmin eden bir modelde False Positive (FP) lerin oranı çok önemlidir. Spam olarak işaretlenen fakat gerçekte spam olmayan bir mailin kullanıcıya ulaşmaması ciddi problemlere yol açabilir.

3.6.3. ReCall (Duyarlılık)

Duyarlılık, gerçekte pozitif olan durumların kaç tanesini doğru tahmin ettiğimizi gösteren değerdir.

$$\text{Recall} = \frac{TP}{TP + FN} \quad (3.14)$$

Denklem 3.14'e göre $\text{Recall} = 30 / (30 + 20) = 0,6$ yani %60'tır

Burada False Negative(FN) oranı çok önemlidir. Gerçekte kanser hastası olan birine kanser olmadığı tahmininin yapılması hastanın tedavisinde aksamaya ve sağlık durumunda ciddi problemlere sebep olabilir.

3.6.4. F-Measure (F Skor)

Bu değer kesinlik ve duyarlılık değerlerinin harmonik ortalamasıdır. Özellikle eşit dağılmayan verisetlerinde doğruluk değeri uygun sonuçlar üretmemektedir. Bu sebeple F skor daha gerçekçi sonuçlar üretebilmektedir.

$$F_1 = 2 * \frac{precision * recall}{precision + recall} \quad (3.15)$$

Denklem 3.15'e göre $F1 = 2 * (0,66 * 0,6) / (0,66 + 0,6) = 0,63$ dır.

3.6.5. Kappa

Kategorik sınıflandırılmalı modellerin değerlendirilmesinde iki gözlemci arasındaki uyumu ölçen istatistiksel bir değerdir. Kappa testi gözlemciler arasındaki ilişkinin şans eserimi yoksa gerçek bir ilişkiyi olduğunun tespitinde yardımcı olur. Cohenin kappa katsayısı yalnızca iki gözlemci arasındaki uyumu ölçer. İki'den fazla gözlemci olması durumunda ise Fleissin Kappa katsayısı kullanılır. κ (Kappa) -1 ile +1 arasında değer alır(Cohen, 1960). Değer 1'e yaklaştıkça gözlemciler arasındaki uyumun mükemmel olduğu, -1'e yaklaştıkça uyumsuzluğun mükemmel olduğu, sıfır olması durumunda ise ilişkinin tesadüfi olduğu sonucuna varılır(Fleiss, 1971). Bu uyum durumu Çizelge 3.12'de daha detaylı gösterilmiştir.

Çizelge 3.12. Kappa değeri tablosu

Kappa	Yorum
< 0	Hiç uyuşma yok
0.0 — 0.20	Önemsiz uyuşma var
0.21 — 0.40	Orta derecede uyuşma var
0.41 — 0.60	Seyrek uyuşma var
0.61 — 0.80	Önemli derecede uyuşma var
0.81 — 1.00	Mükemmele yakın uyuşma var

BÖLÜM 4

UYGULAMA

4.1. Uygulamanın Amacı

Rekabet koşullarının hızla arttığı, işletmelerin yalnızca kendi ülkelerindeki rakiplerine karşı değil tüm dünyadaki firmalar ile rekabet içinde oldukları bir dönemdeyiz. Bu durumda işletmelerin rekabet güçlerini arttırarak rakiplerine karşı üstünlük sağlamaları gerekmektedir. Hem kaliteli ürün üretmek hem de ürettikleri ürünü daha az maliyet ile üretmek zorundadırlar. Tekstil işletmeleri dahil olmak üzere üretim yapan tüm işletmeler ellerinde bulunan ham maddeden müşterilerine pazarlayabilecekleri ürünler elde etmeye çalışırlar. Üretim aşamasında operatör, hammadde, makine ve çeşitli farklı sebeplerden ötürü üretim fireleri oluşmaktadır. Bu firelerin miktarı ancak üretim sonunda anlaşılabilmektedir. Yapılan uygulama ile bir tekstil işletmesinin geçmiş verileri kullanarak üretim başlamadan evvel ne kadar üretim firesinin çıkabileceği tahmin edilmektedir.

Uygulama Weka programı ile çeşitli algoritmaların karşılaştırılmasını amaçlamaktadır. Böylelikle hangi algoritmanın bu problemin çözümüne daha fazla katkı sağlayacağı tespit edilecektir. Ayrıca elde edilen sonuçların doğruluk testleri ve sonucun tesadüfi mi yoksa doğru bir sonuç mu olup olmadığı tespit edilecektir.

4.2. Verilerin Toplanması


Tez çalışması kapsamında kullanılan veriler Universal Tekstil A.Ş.'nin izni ile gerçek üretim verilerinden oluşmaktadır. 2021 yılına ait üretim verileri satır bazlı olarak alınmıştır. Bu veriler Weka ile analiz yapabilmek için sütun şekline dönüştürülmüştür. Veriler toplandıktan sonra benzer proselere ait ortalama değerlerden çok fazla sapma olan veriler analiz edilecek veri setinden temizlenmiştir. Fire tahmini için kullanılacak olan hata yüzdesi değeri aşağıdaki aralıklarda sınıflandırılmıştır;

0- %2	A
%2- %3	B
%3- %10	C

En fazla %10'luk bir sapma olduđu hem işletme yetkilileri tarafından hem de elde edilen kayıtların analizi sonucunda tespit edilmiştir.


4.3. Verilerin Düzenlenmesi

Doğru analiz yapabilmek için gürültülü verilerin öncelikle veri setinden ayıklanması gerekmektedir. Ham olarak elde edilen veriler Weka ile incelendiğinde şekil 4.1'deki gibi bir dağılım göstermektedir.



Şekil 4.1. Gürültülü verilerin dağılımı

Gürültülü veriler sistemden temizlendikten sonra ise dağılım Şekil 4.2'deki gibi olmuştur.




Şekil 4.2. Gürültülü veriler temizlendikten sonraki dağılım

Tüm gürültülü veriler temizlendikten sonra verilerin dağılımı Çizelge 4.1'deki gibidir.

Çizelge 4.1. Final veri seti

Hata Yüzdesi	Sınıf	Örnek Sayısı
0-1	A	427
1-2	B	1.547
2-3	C	5.596
3-4	D	3.316
4-5	E	133
5-6	F	52
6-7	G	24
7-8	H	10
8-9	I	14
9-10	J	11
Toplam kayıt sayısı:		11.130

Hata yüzdelerinin dağılımı ise şekil 4.3'teki gibidir.



Şekil 4.3. Hataların yüzdesel dağılımı

Veriler incelendiğinde E sınıfından sonraki verilerin çok az olduğu ve anlamlı bir analiz yapılamayacağı görülmektedir. Verilerin çok fazla olması ezberleme problemi oluşturabileceği gibi az olması da analizin doğru yapılmasına sebep olacaktır (Kiliçaslan vd., 2009).

Çizelge 4.2’deki SQL sorgusu kullanılarak veriler analiz edilebilecek şekilde toplanmıştır.

Çizelge 4.2. Veri seti SQL sorgusu

```
SELECT tblTEZ.[SARDON SONU YIKAMA], tblTEZ.[ROTASYON ASINDIRMA BASKI], tblTEZ.[RAM FIXE],
      tblTEZ.[SANTEX APRE+KURUTMA], tblTEZ.YIKAMA, tblTEZ.[OPTIK+KASAR],
tblTEZ.[SANTEX EGALIZE+KURUTMA], tblTEZ.EGALIZE,
      tblTEZ.[ROTASYON REAKTIF+PIGMENT BASKI], tblTEZ.[YAKMA+HASIL SOKME],
tblTEZ.SANFOR, tblTEZ.[RAM EMUSYON], tblTEZ.[YAKMA+SOGUK KASAR],
      tblTEZ.[SUPER BEYAZ], tblTEZ.[SANTEX FIXE], tblTEZ.KASAR,
tblTEZ.NATUREL, tblTEZ.[BALON SIKMA], tblTEZ.[RAM SEKER KASAR],
      tblTEZ.[DISPERS YIKAMA], tblTEZ.[TEK TARAFLI SARDON 8X0],
tblTEZ.[EKRU SARARTMA], tblTEZ.SANTRIFUJ, tblTEZ.[105 SOGUK KASAR],
      tblTEZ.BUHARLAMA, tblTEZ.[KOYU RENK YIKAMA], tblTEZ.LISA,
tblTEZ.[FLAT REAKTIF YALDIZLI BASKI], tblTEZ.[TUP KESME], tblTEZ.APRE,
      tblTEZ.[ROTASYON REAKTIF MATWEISS BASKI], tblTEZ.[DISPERS BOYAMA],
tblTEZ.[FLAT ASINDIRMA BASKI], tblTEZ.[ROTASYON DISPERS BASKI],
      tblTEZ.[YARIM KASAR], tblTEZ.[PIGMENT ZB], tblTEZ.[DISPERS YIKAMA2],
tblTEZ.YAKMA, tblTEZ.[ROTASYON PIGMENT BASKI], tblTEZ.[REAKTIF BOYAMA],
      tblTEZ.[OPTIK+EGALIZE], tblTEZ.[FLAT PIGMENT BASKI], tblTEZ.[GOLLER
MERSERIZE OPTIK], tblTEZ.[FLAT REAKTIF+PIGMENT BASKI],
      tblTEZ.[BASKIALTI SEKER KASAR], tblTEZ.FIXE, tblTEZ.MERSERIZE,
tblTEZ.[RAM BEYAZ], tblTEZ.[SEKER KASAR], tblTEZ.[FLAT REAKTIF BASKI],
      tblTEZ.[ROTASYON REAKTIF YALDIZ BASKI], tblTEZ.[TURBANG+EGALIZE],
tblTEZ.[SANTEX TUP KURUTMA], tblTEZ.[FLAT DISPERS BASKI],
      tblTEZ.[PIGMENT DB], tblTEZ.[GOLLER MERSERIZE], tblTEZ.[ACIK RENK
YIKAMA], tblTEZ.[REAKTIF ZB], tblTEZ.TURBANG, tblTEZ.SARDON,
      tblTEZ.[HASIL SOKME], tblTEZ.KALANDIR, tblTEZ.[DIJITAL REAKTIF
BASKI], tblTEZ.[ROTASYON REAKTIF BASKI], tblTEZ.[ACIK EN SANFOR],
      tblTEZ.[KASAR+EMUSYON], tblTEZ.[REAKTIF DB], tblTEZ.[DIJITAL
EGALIZE], tblTEZ.[REAKTIF YIKAMA], tblTEZ.KOSTIKLEME,
      tblTEZ.[DISPERS / REAKTIF BOYAMA], tblTEZ.[TUP SANFOR],
tblTEZ.[LEVENT KASAR],
      HATASINIF = CASE
      WHEN tblTEZ.HATAYUZDESI >= 0 AND tblTEZ.HATAYUZDESI <= 2 THEN 'A'
```

```

        WHEN tblTEZ.HATAYUZDESI > 2 AND tblTEZ.HATAYUZDESI <= 3 THEN 'B'

        WHEN tblTEZ.HATAYUZDESI > 3 AND tblTEZ.HATAYUZDESI <= 10 THEN 'C'

END

FROM tblTEZ3 INNER JOIN
        tblTEZ ON tblTEZ3.[SARDON SONU YIKAMA] = tblTEZ.[SARDON SONU YIKAMA]
AND
        tblTEZ3.[ROTASYON ASINDIRMA BASKI] = tblTEZ.[ROTASYON ASINDIRMA
BASKI] AND tblTEZ3.[RAM FIXE] = tblTEZ.[RAM FIXE] AND
        tblTEZ3.[SANTEX APRE+KURUTMA] = tblTEZ.[SANTEX APRE+KURUTMA] AND
tblTEZ3.YIKAMA = tblTEZ.YIKAMA AND
        tblTEZ3.[OPTIK+KASAR] = tblTEZ.[OPTIK+KASAR] AND tblTEZ3.[SANTEX
EGALIZE+KURUTMA] = tblTEZ.[SANTEX EGALIZE+KURUTMA] AND
        tblTEZ3.EGALIZE = tblTEZ.EGALIZE AND tblTEZ3.[ROTASYON
REAKTIF+PIGMENT BASKI] = tblTEZ.[ROTASYON REAKTIF+PIGMENT BASKI] AND
        tblTEZ3.[YAKMA+HASIL SOKME] = tblTEZ.[YAKMA+HASIL SOKME] AND
tblTEZ3.SANFOR = tblTEZ.SANFOR AND
        tblTEZ3.[RAM EMUSYON] = tblTEZ.[RAM EMUSYON] AND
tblTEZ3.[YAKMA+SOGUK KASAR] = tblTEZ.[YAKMA+SOGUK KASAR] AND
        tblTEZ3.[SUPER BEYAZ] = tblTEZ.[SUPER BEYAZ] AND tblTEZ3.[SANTEX
FIXE] = tblTEZ.[SANTEX FIXE] AND tblTEZ3.KASAR = tblTEZ.KASAR AND
        tblTEZ3.NATUREL = tblTEZ.NATUREL AND tblTEZ3.[BALON SIKMA] =
tblTEZ.[BALON SIKMA] AND tblTEZ3.[RAM SEKER KASAR] = tblTEZ.[RAM SEKER KASAR] AND
        tblTEZ3.[DISPERS YIKAMA] = tblTEZ.[DISPERS YIKAMA] AND tblTEZ3.[TEK
TARAF LI SARDON 8X0] = tblTEZ.[TEK TARAF LI SARDON 8X0] AND
        tblTEZ3.[EKRU SARARTMA] = tblTEZ.[EKRU SARARTMA] AND
tblTEZ3.SANTRIFUJ = tblTEZ.SANTRIFUJ AND
        tblTEZ3.[105 SOGUK KASAR] = tblTEZ.[105 SOGUK KASAR] AND
tblTEZ3.BUHARLAMA = tblTEZ.BUHARLAMA AND
        tblTEZ3.[KOYU RENK YIKAMA] = tblTEZ.[KOYU RENK YIKAMA] AND
tblTEZ3.LISA = tblTEZ.LISA AND
        tblTEZ3.[FLAT REAKTIF YALDIZLI BASKI] = tblTEZ.[FLAT REAKTIF
YALDIZLI BASKI] AND tblTEZ3.[TUP KESME] = tblTEZ.[TUP KESME] AND
        tblTEZ3.APRE = tblTEZ.APRE AND tblTEZ3.[ROTASYON REAKTIF MATWEISS
BASKI] = tblTEZ.[ROTASYON REAKTIF MATWEISS BASKI] AND
        tblTEZ3.[ROTASYON REAKTIF MATWEISS BASKI] = tblTEZ.[DISPERS BOYAMA]
AND tblTEZ3.[FLAT ASINDIRMA BASKI] = tblTEZ.[FLAT ASINDIRMA BASKI] AND
        tblTEZ3.[ROTASYON DISPERS BASKI] = tblTEZ.[ROTASYON DISPERS BASKI]
AND tblTEZ3.[YARIM KASAR] = tblTEZ.[YARIM KASAR] AND
        tblTEZ3.[PIGMENT ZB] = tblTEZ.[PIGMENT ZB] AND tblTEZ3.[DISPERS
YIKAMA2] = tblTEZ.[DISPERS YIKAMA2] AND tblTEZ3.YAKMA = tblTEZ.YAKMA AND
        tblTEZ3.[ROTASYON PIGMENT BASKI] = tblTEZ.[ROTASYON PIGMENT BASKI]
AND tblTEZ3.[REAKTIF BOYAMA] = tblTEZ.[REAKTIF BOYAMA] AND

```

```

        tblTEZ3.[OPTIK+EGALIZE] = tblTEZ.[OPTIK+EGALIZE] AND tblTEZ3.[FLAT
PIGMENT BASKI] = tblTEZ.[FLAT PIGMENT BASKI] AND
        tblTEZ3.[GOLLER MERSERIZE OPTIK] = tblTEZ.[GOLLER MERSERIZE OPTIK]
AND
        tblTEZ3.[FLAT REAKTIF+PIGMENT BASKI] = tblTEZ.[FLAT REAKTIF+PIGMENT
BASKI] AND
        tblTEZ3.[BASKIALTI SEKER KASAR] = tblTEZ.[BASKIALTI SEKER KASAR] AND
tblTEZ3.FIXE = tblTEZ.FIXE AND tblTEZ3.MERSERIZE = tblTEZ.MERSERIZE AND
        tblTEZ3.[RAM BEYAZ] = tblTEZ.[RAM BEYAZ] AND tblTEZ3.[SEKER KASAR] =
tblTEZ.[SEKER KASAR] AND
        tblTEZ3.[FLAT REAKTIF BASKI] = tblTEZ.[FLAT REAKTIF BASKI] AND
tblTEZ3.[ROTASYON REAKTIF YALDIZ BASKI] = tblTEZ.[ROTASYON REAKTIF YALDIZ BASKI] AND
        tblTEZ3.[TURBANG+EGALIZE] = tblTEZ.[TURBANG+EGALIZE] AND
tblTEZ3.[SANTEX TUP KURUTMA] = tblTEZ.[SANTEX TUP KURUTMA] AND
        tblTEZ3.[FLAT DISPERS BASKI] = tblTEZ.[FLAT DISPERS BASKI] AND
tblTEZ3.[PIGMENT DB] = tblTEZ.[PIGMENT DB] AND
        tblTEZ3.[GOLLER MERSERIZE] = tblTEZ.[GOLLER MERSERIZE] AND
tblTEZ3.[ACIK RENK YIKAMA] = tblTEZ.[ACIK RENK YIKAMA] AND
        tblTEZ3.[REAKTIF ZB] = tblTEZ.[REAKTIF ZB] AND tblTEZ3.TURBANG =
tblTEZ.TURBANG AND tblTEZ3.SARDON = tblTEZ.SARDON AND
        tblTEZ3.[HASIL SOKME] = tblTEZ.[HASIL SOKME] AND tblTEZ3.KALANDIR =
tblTEZ.KALANDIR AND
        tblTEZ3.[DIJITAL REAKTIF BASKI] = tblTEZ.[DIJITAL REAKTIF BASKI] AND
tblTEZ3.[ROTASYON REAKTIF BASKI] = tblTEZ.[ROTASYON REAKTIF BASKI] AND
        tblTEZ3.[ACIK EN SANFOR] = tblTEZ.[ACIK EN SANFOR] AND
tblTEZ3.[KASAR+EMUSYON] = tblTEZ.[KASAR+EMUSYON] AND
        tblTEZ3.[REAKTIF DB] = tblTEZ.[REAKTIF DB] AND tblTEZ3.[DIJITAL
EGALIZE] = tblTEZ.[DIJITAL EGALIZE] AND
        tblTEZ3.[REAKTIF YIKAMA] = tblTEZ.[REAKTIF YIKAMA] AND
tblTEZ3.KOSTIKLEME = tblTEZ.KOSTIKLEME AND
        tblTEZ3.[DISPERS / REAKTIF BOYAMA] = tblTEZ.[DISPERS / REAKTIF
BOYAMA] AND tblTEZ3.[TUP SANFOR] = tblTEZ.[TUP SANFOR] AND
        tblTEZ3.[LEVENT KASAR] = tblTEZ.[LEVENT KASAR]
WHERE tblTEZ.Durum = 1 AND tblTEZ.HATAYUZDESI <= 10 AND (tblTEZ.HATAYUZDESI BETWEEN
tblTEZ3.HATAYUZDESI -0.4 AND tblTEZ3.HATAYUZDESI + 0.4)

```

Sorgu çalıştırıldığında çizelge 4.3'teki sonuç kümesi elde edilmektedir. Burada yalnızca 9 adet proses ekrana sığdırılmıştır. Veri seti, toplamda 73 proses, 11.130 adet veriden oluşmaktadır.

Çizelge 4.3. SQL sorgunun çalıştırılmasından sonra edilen sonuç

	HATASINIF	EGALIZE	SARDON SONU YIKAMA	KASAR	ROTA...	YAKMA+HASIL SOKME	RAM FIXE	SANFOR	SANT...	YIKAMA	(
1	C	1	0	0	0	1	0	0	0	0	
2	B	0	0	1	0	1	0	0	0	0	
3	C	1	0	1	0	1	0	0	0	0	
4	B	1	0	1	0	1	0	0	0	0	
5	B	0	0	1	0	1	0	0	0	0	
6	C	0	0	1	0	1	0	0	0	0	
7	C	0	0	1	0	1	0	0	0	0	
8	C	0	0	1	0	1	0	0	0	0	
9	C	0	0	1	0	1	0	0	0	0	
10	B	0	0	1	0	1	0	0	0	0	
11	C	1	0	1	0	1	0	1	0	0	
12	B	1	0	1	0	1	0	1	0	0	
13	B	1	0	1	0	1	0	1	0	0	
14	B	1	0	1	0	1	0	1	0	0	
15	C	1	0	1	0	1	0	1	0	0	
16	B	1	0	1	0	1	0	1	0	0	
17	B	1	0	1	0	1	0	1	0	0	
18	B	1	0	1	0	1	0	0	0	0	
<											

4.4. Algoritma Testleri


Tez çalışması kapsamında veri seti aşağıdaki algoritmalar ile test edilmiştir. Testler her algoritma için iki şekilde yapılmıştır.

1. Çapraz doğrulama: Bu yöntem ile veri seti 10 parçaya ayrılmaktadır. Bunlardan 9 parçası eğitim, 1 parçası ise test olarak kullanılmaktadır.
2. Yüzdesel parçalama: Bu yöntemde verilerin %66 sı eğitim, %34 ü test için kullanılmıştır.

4.4.1. J48

Çapraz doğrulama yöntemi

Şekil 4.4'te çapraz doğrulama J48 algoritmasının weka'daki sonucu gösterilmiştir.



Şekil 4.4. Çapraz doğrulama J48 algoritmasının Weka'daki sonucu

Çizelge 4.4'te çapraz doğrulama J48 algoritmasının Weka'daki sonuç adımları gösterilmiştir.

Çizelge 4.4. Çapraz doğrulama J48 algoritmasının Weka'daki sonuç adımları

=== Run information ===

Scheme: weka.classifiers.trees.J48 -C 0.25 -M 2
Relation: TezData
Instances: 11130
Attributes: 74

SARDON SONU YIKAMA
ROTASYON ASINDIRMA BASKI
RAM FIXE
SANTEX APRE+KURUTMA
YIKAMA
OPTIK+KASAR
SANTEX EGALIZE+KURUTMA
EGALIZE
ROTASYON REAKTIF+PIGMENT BASKI
YAKMA+HASIL SOKME
SANFOR
RAM EMUSYON
YAKMA+SOGUK KASAR
SUPER BEYAZ
SANTEX FIXE
KASAR
NATUREL
BALON SIKMA
RAM SEKER KASAR
DISPERS YIKAMA
TEK TARAFLI SARDON 8X0
EKRU SARARTMA
SANTRIFUJ
105 SOGUK KASAR
BUHARLAMA
KOYU RENK YIKAMA
LISA
FLAT REAKTIF YALDIZLI BASKI
TUP KESME
APRE
ROTASYON REAKTIF MATWEISS BASKI
DISPERS BOYAMA
FLAT ASINDIRMA BASKI
ROTASYON DISPERS BASKI
YARIM KASAR
PIGMENT ZB
DISPERS YIKAMA2
YAKMA
ROTASYON PIGMENT BASKI
REAKTIF BOYAMA
OPTIK+EGALIZE
FLAT PIGMENT BASKI
GOLLER MERSEERIZE OPTIK
FLAT REAKTIF+PIGMENT BASKI
BASKIALTI SEKER KASAR

FIXE
 MERSERIZE
 RAM BEYAZ
 SEKER KASAR
 FLAT REAKTIF BASKI
 ROTASYON REAKTIF YALDIZ BASKI
 TURBANG+EGALIZE
 SANTEX TUP KURUTMA
 FLAT DISPERS BASKI
 PIGMENT DB
 GOLLER MERSERIZE
 ACIK RENK YIKAMA
 REAKTIF ZB
 TURBANG
 SARDON
 HASIL SOKME
 KALANDIR
 DIJITAL REAKTIF BASKI
 ROTASYON REAKTIF BASKI
 ACIK EN SANFOR
 KASAR+EMUSYON
 REAKTIF DB
 DIJITAL EGALIZE
 REAKTIF YIKAMA
 KOSTIKLEME
 DISPERS / REAKTIF BOYAMA
 TUP SANFOR
 LEVENT KASAR
 HATASINIF

Test mode: 10-fold cross-validation

=== Classifier model (full training set) ===

J48 pruned tree

```

APRE <= 0
|  FIXE <= 0
|  |  ROTASYON REAKTIF BASKI <= 0
|  |  |  SARDON SONU YIKAMA <= 0
|  |  |  |  EGALIZE <= 0
|  |  |  |  |  RAM BEYAZ <= 0
|  |  |  |  |  |  TURBANG <= 0
|  |  |  |  |  |  |  SANFOR <= 0
|  |  |  |  |  |  |  |  ACIK RENK YIKAMA <= 0

```

										KASAR <= 0
										LISA <= 0
										NATUREL <= 0
										YARIM KASAR <= 0: A (89.0/1.0)
										YARIM KASAR > 0: B (2.0)
										NATUREL > 0: B (2.0)
										LISA > 0: C (4.0)
										KASAR > 0: A (159.0/16.0)
										ACIK RENK YIKAMA > 0
										RAM SEKER KASAR <= 0
										SUPER BEYAZ <= 0
										RAM EMUSYON <= 0
										NATUREL <= 0: A (7.0)
										NATUREL > 0: B (3.0/1.0)
										RAM EMUSYON > 0: C (2.0)
										SUPER BEYAZ > 0: C (6.0)
										RAM SEKER KASAR > 0: B (21.0/10.0)
										SANFOR > 0
										KALANDIR <= 0: A (440.0/10.0)
										KALANDIR > 0
										KASAR <= 0
										MERSERIZE <= 0
										OPTIK+KASAR <= 0: B (7.0/2.0)
										OPTIK+KASAR > 0: C (2.0)
										MERSERIZE > 0: C (4.0)
										KASAR > 0: A (57.0)
										TURBANG > 0
										PIGMENT DB <= 0
										OPTIK+KASAR <= 0
										RAM SEKER KASAR <= 0: A (30.0/5.0)
										RAM SEKER KASAR > 0: C (2.0)
										OPTIK+KASAR > 0: C (2.0)
										PIGMENT DB > 0: B (2.0/1.0)
										RAM BEYAZ > 0
										KALANDIR <= 0
										KASAR <= 0: B (6.0)
										KASAR > 0
										YAKMA+HASIL SOKME <= 0: A (3.0)
										YAKMA+HASIL SOKME > 0: B (7.0/3.0)
										KALANDIR > 0: A (191.0/54.0)
										EGALIZE > 0
										KALANDIR <= 0
										RAM BEYAZ <= 0
										SANFOR <= 0
										REAKTIF DB <= 0: C (34.0/6.0)

					REAKTIF ZB > 0: C (3.0)
					SANFOR > 0
					ROTASYON PIGMENT BASKI <= 0
					YAKMA+HASIL SOKME <= 0: A (2.0)
					YAKMA+HASIL SOKME > 0: B (4.0/1.0)
					ROTASYON PIGMENT BASKI > 0
					YAKMA+HASIL SOKME <= 0: B (34.0/13.0)
					YAKMA+HASIL SOKME > 0
					KALANDIR <= 0: A (4.0/1.0)
					KALANDIR > 0: B (2.0/1.0)
					SARDON > 0
					SANFOR <= 0: C (3.0/1.0)
					SANFOR > 0: A (2.0)
					TURBANG > 0
					YAKMA+SOGUK KASAR <= 0
					ROTASYON PIGMENT BASKI <= 0: C (8.0/1.0)
					ROTASYON PIGMENT BASKI > 0: B (4.0/1.0)
					YAKMA+SOGUK KASAR > 0: B (2.0)
					APRE > 0
					BUHARLAMA <= 0
					MERSERIZE <= 0
					REAKTIF YIKAMA <= 0
					GOLLER MERSERIZE <= 0
					FIXE <= 0
					RAM FIXE <= 0
					REAKTIF DB <= 0
					FLAT PIGMENT BASKI <= 0
					EKRU SARARTMA <= 0
					OPTIK+KASAR <= 0
					OPTIK+EGALIZE <= 0
					RAM BEYAZ <= 0
					YAKMA+HASIL SOKME <= 0
					KALANDIR <= 0
					PIGMENT DB <= 0: A (18.0/2.0)
					PIGMENT DB > 0: C (2.0)
					KALANDIR > 0: C (8.0/1.0)
					YAKMA+HASIL SOKME > 0: A (42.0/5.0)
					RAM BEYAZ > 0
					YAKMA <= 0: C (7.0/2.0)
					YAKMA > 0: A (2.0)
					OPTIK+EGALIZE > 0: B (5.0/2.0)
					OPTIK+KASAR > 0
					ACIK RENK YIKAMA <= 0
					YAKMA+SOGUK KASAR <= 0: B (25.0/8.0)
					YAKMA+SOGUK KASAR > 0: A (19.0/5.0)

									SANFOR <= 0: B (42.0/16.0)
									SANFOR > 0
									TEK TARAFLI SARDON 8X0 <= 0: C (159.0/1.0)
									TEK TARAFLI SARDON 8X0 > 0
									RAM EMUSYON <= 0
									FLAT REAKTIF BASKI <= 0: B (17.0/6.0)
									FLAT REAKTIF BASKI > 0: C (6.0)
									RAM EMUSYON > 0: B (3.0)
									FIXE > 0
									FLAT REAKTIF BASKI <= 0: B (6.0/2.0)
									FLAT REAKTIF BASKI > 0: A (3.0/1.0)
									YAKMA+HASIL SOKME > 0
									ROTASYON REAKTIF YALDIZ BASKI <= 0
									FIXE <= 0
									GOLLER MERSERIZE <= 0
									MERSERIZE <= 0
									FLAT REAKTIF BASKI <= 0: C (52.0/18.0)
									FLAT REAKTIF BASKI > 0
									KASAR <= 0: C (6.0)
									KASAR > 0: B (56.0)
									MERSERIZE > 0: C (995.0/299.0)
									GOLLER MERSERIZE > 0
									ROTASYON REAKTIF BASKI <= 0
									FLAT REAKTIF BASKI <= 0: B (14.0/1.0)
									FLAT REAKTIF BASKI > 0: C (277.0/103.0)
									ROTASYON REAKTIF BASKI > 0: C (708.0/155.0)
									FIXE > 0
									FLAT REAKTIF+PIGMENT BASKI <= 0
									KASAR <= 0: C (3.0)
									KASAR > 0
									ROTASYON ASINDIRMA BASKI <= 0
									REAKTIF ZB <= 0
									FLAT PIGMENT BASKI <= 0
									REAKTIF YIKAMA <= 0: C (2.0)
									REAKTIF YIKAMA > 0: B (100.0/39.0)
									FLAT PIGMENT BASKI > 0: C (2.0)
									REAKTIF ZB > 0: C (12.0/3.0)
									ROTASYON ASINDIRMA BASKI > 0: B (5.0/1.0)
									FLAT REAKTIF+PIGMENT BASKI > 0
									MERSERIZE <= 0: B (11.0/2.0)
									MERSERIZE > 0: C (5.0)
									ROTASYON REAKTIF YALDIZ BASKI > 0: C (75.0)
									FLAT REAKTIF YALDIZLI BASKI > 0
									REAKTIF ZB <= 0: C (118.0)
									REAKTIF ZB > 0: B (4.0)

```

| | | DIJITAL EGALIZE > 0
| | | | KALANDIR <= 0: B (16.0/5.0)
| | | | KALANDIR > 0
| | | | YAKMA+HASIL SOKME <= 0: A (6.0)
| | | | YAKMA+HASIL SOKME > 0
| | | | YAKMA <= 0
| | | | MERSERIZE <= 0
| | | | SANFOR <= 0: B (58.0/10.0)
| | | | SANFOR > 0: A (2.0)
| | | | MERSERIZE > 0: A (4.0)
| | | | YAKMA > 0: B (11.0/1.0)
| | KOYU RENK YIKAMA > 0
| | | FLAT ASINDIRMA BASKI <= 0
| | | | FLAT REAKTIF YALDIZLI BASKI <= 0
| | | | FLAT REAKTIF BASKI <= 0: A (69.0/24.0)
| | | | FLAT REAKTIF BASKI > 0
| | | | FIXE <= 0: C (3.0/1.0)
| | | | FIXE > 0: B (4.0/1.0)
| | | | FLAT REAKTIF YALDIZLI BASKI > 0: B (9.0)
| | | FLAT ASINDIRMA BASKI > 0: C (8.0)

```

Number of Leaves : 173

Size of the tree : 345

Time taken to build model: 0.64 seconds

=== Stratified cross-validation ===

=== Summary ===

Correctly Classified Instances	8750	78.6164 %
Incorrectly Classified Instances	2380	21.3836 %
Kappa statistic	0.6526	
Mean absolute error	0.1947	
Root mean squared error	0.3203	
Relative absolute error	47.6087 %	
Root relative squared error	70.8313 %	
Total Number of Instances	11130	


=== Detailed Accuracy By Class ===

	TP Rate	FP Rate	Precision	Recall	F-Measure	MCC	ROC Area	PRC
Area Class								

		0,777	0,181	0,812	0,777	0,794	0,596	0,875	0,874
B									
		0,788	0,151	0,710	0,788	0,747	0,621	0,887	0,765
C									
		0,809	0,025	0,874	0,809	0,840	0,808	0,955	0,881
A									
Weighted Avg.		0,786	0,144	0,791	0,786	0,787	0,641	0,893	0,841
=== Confusion Matrix ===									
<pre> a b c <-- classified as 4347 1092 157 a = B 681 2806 73 b = C 323 54 1597 c = A </pre>									

Yüzdesel parçalama yöntemi

Şekil 4.5'te yüzdesel parçalama J48 algoritmasının weka'daki sonucu gösterilmiştir.



Şekil 4.5. Yüzdesel parçalama J48 algoritmasının Weka'daki sonucu

Çizelge 4.5'te yüzdesel parçalama J48 algoritmasının Weka'daki sonuç adımları gösterilmiştir.

Çizelge 4.5. Yüzdesel parçalama J48 algoritmasının Weka'daki sonuç adımları

=== Run information ===

Scheme: weka.classifiers.trees.J48 -C 0.25 -M 2
Relation: TezData
Instances: 11130
Attributes: 74
SARDON SONU YIKAMA

ROTASYON ASINDIRMA BASKI
RAM FIXE
SANTEX APRE+KURUTMA
YIKAMA
OPTIK+KASAR
SANTEX EGALIZE+KURUTMA
EGALIZE
ROTASYON REAKTIF+PIGMENT BASKI
YAKMA+HASIL SOKME
SANFOR
RAM EMUSYON
YAKMA+SOGUK KASAR
SUPER BEYAZ
SANTEX FIXE
KASAR
NATUREL
BALON SIKMA
RAM SEKER KASAR
DISPERS YIKAMA
TEK TARAFLI SARDON 8X0
EKRU SARARTMA
SANTRIFUJ
105 SOGUK KASAR
BUHARLAMA
KOYU RENK YIKAMA
LISA
FLAT REAKTIF YALDIZLI BASKI
TUP KESME
APRE
ROTASYON REAKTIF MATWEISS BASKI
DISPERS BOYAMA
FLAT ASINDIRMA BASKI
ROTASYON DISPERS BASKI
YARIM KASAR
PIGMENT ZB
DISPERS YIKAMA2
YAKMA
ROTASYON PIGMENT BASKI
REAKTIF BOYAMA
OPTIK+EGALIZE
FLAT PIGMENT BASKI
GOLLER MERSERIZE OPTIK
FLAT REAKTIF+PIGMENT BASKI
BASKIALTI SEKER KASAR
FIXE

MERSERIZE
 RAM BEYAZ
 SEKER KASAR
 FLAT REAKTIF BASKI
 ROTASYON REAKTIF YALDIZ BASKI
 TURBANG+EGALIZE
 SANTEX TUP KURUTMA
 FLAT DISPERS BASKI
 PIGMENT DB
 GOLLER MERSERIZE
 ACIK RENK YIKAMA
 REAKTIF ZB
 TURBANG
 SARDON
 HASIL SOKME
 KALANDIR
 DIJITAL REAKTIF BASKI
 ROTASYON REAKTIF BASKI
 ACIK EN SANFOR
 KASAR+EMUSYON
 REAKTIF DB
 DIJITAL EGALIZE
 REAKTIF YIKAMA
 KOSTIKLEME
 DISPERS / REAKTIF BOYAMA
 TUP SANFOR
 LEVENT KASAR
 HATASINIF

Test mode: split 66.0% train, remainder test

=== Classifier model (full training set) ===

J48 pruned tree

```

APRE <= 0
|  FIXE <= 0
|  |  ROTASYON REAKTIF BASKI <= 0
|  |  |  SARDON SONU YIKAMA <= 0
|  |  |  |  EGALIZE <= 0
|  |  |  |  |  RAM BEYAZ <= 0
|  |  |  |  |  |  TURBANG <= 0
|  |  |  |  |  |  |  SANFOR <= 0
|  |  |  |  |  |  |  |  ACIK RENK YIKAMA <= 0
|  |  |  |  |  |  |  |  |  KASAR <= 0

```


					SANFOR	>	0
					ROTASYON PIGMENT BASKI	<=	0
					YAKMA+HASIL SOKME	<=	0: A (2.0)
					YAKMA+HASIL SOKME	>	0: B (4.0/1.0)
					ROTASYON PIGMENT BASKI	>	0
					YAKMA+HASIL SOKME	<=	0: B (34.0/13.0)
					YAKMA+HASIL SOKME	>	0
					KALANDIR	<=	0: A (4.0/1.0)
					KALANDIR	>	0: B (2.0/1.0)
					SARDON	>	0
					SANFOR	<=	0: C (3.0/1.0)
					SANFOR	>	0: A (2.0)
					TURBANG	>	0
					YAKMA+SOGUK KASAR	<=	0
					ROTASYON PIGMENT BASKI	<=	0: C (8.0/1.0)
					ROTASYON PIGMENT BASKI	>	0: B (4.0/1.0)
					YAKMA+SOGUK KASAR	>	0: B (2.0)
					APRE	>	0
					BUHARLAMA	<=	0
					MERSERIZE	<=	0
					REAKTIF YIKAMA	<=	0
					GOLLER MERSERIZE	<=	0
					FIXE	<=	0
					RAM FIXE	<=	0
					REAKTIF DB	<=	0
					FLAT PIGMENT BASKI	<=	0
					EKRU SARARTMA	<=	0
					OPTIK+KASAR	<=	0
					OPTIK+EGALIZE	<=	0
					RAM BEYAZ	<=	0
					YAKMA+HASIL SOKME	<=	0
					KALANDIR	<=	0
					PIGMENT DB	<=	0: A (18.0/2.0)
					PIGMENT DB	>	0: C (2.0)
					KALANDIR	>	0: C (8.0/1.0)
					YAKMA+HASIL SOKME	>	0: A (42.0/5.0)
					RAM BEYAZ	>	0
					YAKMA	<=	0: C (7.0/2.0)
					YAKMA	>	0: A (2.0)
					OPTIK+EGALIZE	>	0: B (5.0/2.0)
					OPTIK+KASAR	>	0
					ACIK RENK YIKAMA	<=	0
					YAKMA+SOGUK KASAR	<=	0: B (25.0/8.0)
					YAKMA+SOGUK KASAR	>	0: A (19.0/5.0)
					ACIK RENK YIKAMA	>	0

									OPTIK+KASAR > 0: B (2.0)
									RAM SEKER KASAR > 0: C (2.0)
									ROTASYON PIGMENT BASKI > 0: A (102.0/1.0)
									KOYU RENK YIKAMA > 0: B (13.0/2.0)
									SANFOR > 0
									KOYU RENK YIKAMA <= 0: C (54.0/25.0)
									KOYU RENK YIKAMA > 0: A (2.0)
									REAKTIF YIKAMA > 0
									YAKMA+SOGUK KASAR <= 0
									ACIK RENK YIKAMA <= 0
									SANFOR <= 0
									GOLLER MERSEERIZE <= 0
									KASAR <= 0: C (13.0/2.0)
									KASAR > 0: B (216.0/8.0)
									GOLLER MERSEERIZE > 0: B (726.0/2.0)
									SANFOR > 0
									SARDON <= 0
									KALANDIR <= 0: C (42.0/20.0)
									KALANDIR > 0: A (8.0/1.0)
									SARDON > 0: B (247.0/6.0)
									ACIK RENK YIKAMA > 0
									KALANDIR <= 0: A (11.0)
									KALANDIR > 0
									SANFOR <= 0: B (7.0/1.0)
									SANFOR > 0: C (30.0/9.0)
									YAKMA+SOGUK KASAR > 0
									GOLLER MERSEERIZE <= 0
									KASAR <= 0: C (9.0/1.0)
									KASAR > 0
									FIXE <= 0: B (6.0/1.0)
									FIXE > 0: C (2.0)
									GOLLER MERSEERIZE > 0
									REAKTIF DB <= 0: B (2.0/1.0)
									REAKTIF DB > 0: C (24.0/2.0)
									MERSEERIZE > 0
									KALANDIR <= 0
									ROTASYON PIGMENT BASKI <= 0
									SANFOR <= 0
									KASAR <= 0: B (14.0/6.0)
									KASAR > 0: C (8.0/2.0)
									SANFOR > 0: A (3.0)
									ROTASYON PIGMENT BASKI > 0: B (241.0/43.0)
									KALANDIR > 0
									REAKTIF YIKAMA <= 0
									ROTASYON PIGMENT BASKI <= 0

									SANFOR > 0
									TEK TARAFLI SARDON 8X0 <= 0: C (159.0/1.0)
									TEK TARAFLI SARDON 8X0 > 0
									RAM EMUSYON <= 0
									FLAT REAKTIF BASKI <= 0: B (17.0/6.0)
									FLAT REAKTIF BASKI > 0: C (6.0)
									RAM EMUSYON > 0: B (3.0)
									FIXE > 0
									FLAT REAKTIF BASKI <= 0: B (6.0/2.0)
									FLAT REAKTIF BASKI > 0: A (3.0/1.0)
									YAKMA+HASIL SOKME > 0
									ROTASYON REAKTIF YALDIZ BASKI <= 0
									FIXE <= 0
									GOLLER MERSEERIZE <= 0
									MERSEERIZE <= 0
									FLAT REAKTIF BASKI <= 0: C (52.0/18.0)
									FLAT REAKTIF BASKI > 0
									KASAR <= 0: C (6.0)
									KASAR > 0: B (56.0)
									MERSEERIZE > 0: C (995.0/299.0)
									GOLLER MERSEERIZE > 0
									ROTASYON REAKTIF BASKI <= 0
									FLAT REAKTIF BASKI <= 0: B (14.0/1.0)
									FLAT REAKTIF BASKI > 0: C (277.0/103.0)
									ROTASYON REAKTIF BASKI > 0: C (708.0/155.0)
									FIXE > 0
									FLAT REAKTIF+PIGMENT BASKI <= 0
									KASAR <= 0: C (3.0)
									KASAR > 0
									ROTASYON ASINDIRMA BASKI <= 0
									REAKTIF ZB <= 0
									FLAT PIGMENT BASKI <= 0
									REAKTIF YIKAMA <= 0: C (2.0)
									REAKTIF YIKAMA > 0: B (100.0/39.0)
									FLAT PIGMENT BASKI > 0: C (2.0)
									REAKTIF ZB > 0: C (12.0/3.0)
									ROTASYON ASINDIRMA BASKI > 0: B (5.0/1.0)
									FLAT REAKTIF+PIGMENT BASKI > 0
									MERSEERIZE <= 0: B (11.0/2.0)
									MERSEERIZE > 0: C (5.0)
									ROTASYON REAKTIF YALDIZ BASKI > 0: C (75.0)
									FLAT REAKTIF YALDIZLI BASKI > 0
									REAKTIF ZB <= 0: C (118.0)
									REAKTIF ZB > 0: B (4.0)
									DIJITAL EGALIZE > 0

```

| | | | KALANDIR <= 0: B (16.0/5.0)
| | | | KALANDIR > 0
| | | | YAKMA+HASIL SOKME <= 0: A (6.0)
| | | | YAKMA+HASIL SOKME > 0
| | | | YAKMA <= 0
| | | | MERSERIZE <= 0
| | | | SANFOR <= 0: B (58.0/10.0)
| | | | SANFOR > 0: A (2.0)
| | | | MERSERIZE > 0: A (4.0)
| | | | YAKMA > 0: B (11.0/1.0)
| | KOYU RENK YIKAMA > 0
| | | FLAT ASINDIRMA BASKI <= 0
| | | FLAT REAKTIF YALDIZLI BASKI <= 0
| | | FLAT REAKTIF BASKI <= 0: A (69.0/24.0)
| | | FLAT REAKTIF BASKI > 0
| | | FIXE <= 0: C (3.0/1.0)
| | | FIXE > 0: B (4.0/1.0)
| | | FLAT REAKTIF YALDIZLI BASKI > 0: B (9.0)
| | | FLAT ASINDIRMA BASKI > 0: C (8.0)

```

Number of Leaves : 173

Size of the tree : 345

Time taken to build model: 0.48 seconds

=== Evaluation on test split ===

Time taken to test model on test split: 0.01 seconds

=== Summary ===

Correctly Classified Instances	2947	77.8805 %
Incorrectly Classified Instances	837	22.1195 %
Kappa statistic	0.6403	
Mean absolute error	0.1978	
Root mean squared error	0.3251	
Relative absolute error	48.3451 %	
Root relative squared error	71.8456 %	
Total Number of Instances	3784	


=== Detailed Accuracy By Class ===

		TP Rate	FP Rate	Precision	Recall	F-Measure	MCC	ROC Area	PRC
Area	Class								
	B	0,774	0,190	0,802	0,774	0,787	0,584	0,872	0,864
	C	0,773	0,156	0,707	0,773	0,739	0,604	0,880	0,756
	A	0,804	0,025	0,870	0,804	0,836	0,804	0,949	0,861
	Weighted Avg.	0,779	0,150	0,783	0,779	0,780	0,629	0,888	0,828
=== Confusion Matrix ===									
	a	b	c	<-- classified as					
	1458	372	54		a = B				
	257	960	25		b = C				
	104	25	529		c = A				

4.4.2. Naive Bayes

Çapraz doğrulama yöntemi

Şekil 4.6’da çapraz doğrulama Naive Bayes algoritmasının weka’daki sonucu gösterilmiştir.



Şekil 4.6. Çapraz doğrulama Naive Bayes algoritmasının Weka’daki sonucu

Çizelge 4.6’da Çapraz doğrulama Naive Bayes algoritmasının weka’daki sonuç adımları gösterilmiştir.

Çizelge 4.6. Çapraz doğrulama Naive Bayes algoritmasının Weka’daki sonuç adımları

=== Run information ===

Scheme: weka.classifiers.bayes.NaiveBayes
Relation: TezData
Instances: 11130

Attributes: 74

SARDON SONU YIKAMA
ROTASYON ASINDIRMA BASKI
RAM FIXE
SANTEX APRE+KURUTMA
YIKAMA
OPTIK+KASAR
SANTEX EGALIZE+KURUTMA
EGALIZE
ROTASYON REAKTIF+PIGMENT BASKI
YAKMA+HASIL SOKME
SANFOR
RAM EMUSYON
YAKMA+SOGUK KASAR
SUPER BEYAZ
SANTEX FIXE
KASAR
NATUREL
BALON SIKMA
RAM SEKER KASAR
DISPERS YIKAMA
TEK TARAFLI SARDON 8X0
EKRU SARARTMA
SANTRIFUJ
105 SOGUK KASAR
BUHARLAMA
KOYU RENK YIKAMA
LISA
FLAT REAKTIF YALDIZLI BASKI
TUP KESME
APRE
ROTASYON REAKTIF MATWEISS BASKI
DISPERS BOYAMA
FLAT ASINDIRMA BASKI
ROTASYON DISPERS BASKI
YARIM KASAR
PIGMENT ZB
DISPERS YIKAMA2
YAKMA
ROTASYON PIGMENT BASKI
REAKTIF BOYAMA
OPTIK+EGALIZE
FLAT PIGMENT BASKI
GOLLER MERSEERIZE OPTIK
FLAT REAKTIF+PIGMENT BASKI

BASKIALTI SEKER KASAR
 FIXE
 MERSERIZE
 RAM BEYAZ
 SEKER KASAR
 FLAT REAKTIF BASKI
 ROTASYON REAKTIF YALDIZ BASKI
 TURBANG+EGALIZE
 SANTEX TUP KURUTMA
 FLAT DISPERS BASKI
 PIGMENT DB
 GOLLER MERSERIZE
 ACIK RENK YIKAMA
 REAKTIF ZB
 TURBANG
 SARDON
 HASIL SOKME
 KALANDIR
 DIJITAL REAKTIF BASKI
 ROTASYON REAKTIF BASKI
 ACIK EN SANFOR
 KASAR+EMUSYON
 REAKTIF DB
 DIJITAL EGALIZE
 REAKTIF YIKAMA
 KOSTIKLEME
 DISPERS / REAKTIF BOYAMA
 TUP SANFOR
 LEVENT KASAR
 HATASINIF

Test mode: 10-fold cross-validation

=== Classifier model (full training set) ===

Naive Bayes Classifier

Attribute	Class		
	B	C	A
	(0.5)	(0.32)	(0.18)
=====			
SARDON SONU YIKAMA			
mean	0.1642	0.1045	0.0329
std. dev.	0.3705	0.3059	0.1784
weight sum	5596	3560	1974
precision	1	1	1

ROTASYON ASINDIRMA BASKI

mean	0.0014	0.0006	0.0046
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1

RAM FIXE

mean	0.0002	0.002	0
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1

SANTEX APRE+KURUTMA

mean	0	0.0037	0.001
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1

YIKAMA

mean	0.0007	0.0056	0.001
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1

OPTIK+KASAR

mean	0.0064	0.0039	0.0193
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1

SANTEX EGALIZE+KURUTMA

mean	0.0011	0.0045	0.04
std. dev.	0.1667	0.1667	0.196
weight sum	5596	3560	1974
precision	1	1	1

EGALIZE

mean	0.7564	0.8924	0.4022
std. dev.	0.4292	0.3099	0.4903
weight sum	5596	3560	1974
precision	1	1	1

ROTASYON REAKTIF+PIGMENT BASKI

mean	0.0079	0.0087	0.0005
------	--------	--------	--------

std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1
YAKMA+HASIL SOKME			
mean	0.6746	0.7921	0.8075
std. dev.	0.4685	0.4058	0.3943
weight sum	5596	3560	1974
precision	1	1	1
SANFOR			
mean	0.2957	0.157	0.3354
std. dev.	0.4564	0.3638	0.4721
weight sum	5596	3560	1974
precision	1	1	1
RAM EMUSYON			
mean	0.0007	0.0028	0.0041
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1
YAKMA+SOGUK KASAR			
mean	0.0892	0.057	0.0679
std. dev.	0.285	0.2319	0.2515
weight sum	5596	3560	1974
precision	1	1	1
SUPER BEYAZ			
mean	0.0013	0.0045	0.04
std. dev.	0.1667	0.1667	0.196
weight sum	5596	3560	1974
precision	1	1	1
SANTEX FIXE			
mean	0	0	0
std. dev.	0.0017	0.0017	0.0017
weight sum	5596	3560	1974
precision	0.01	0.01	0.01
KASAR			
mean	0.753	0.8309	0.6849
std. dev.	0.4312	0.3748	0.4646
weight sum	5596	3560	1974
precision	1	1	1

NATUREL

mean	0.002	0.0008	0.0091
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1

BALON SIKMA

mean	0	0	0.0035
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1

RAM SEKER KASAR

mean	0.0075	0.0073	0.1256
std. dev.	0.1667	0.1667	0.3314
weight sum	5596	3560	1974
precision	1	1	1

DISPERS YIKAMA

mean	0	0.0006	0
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1

TEK TARAFLI SARDON 8X0

mean	0.0025	0.0059	0.0005
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1

EKRU SARARTMA

mean	0.002	0.0008	0.0137
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1

SANTRIFUJ

mean	0	0	0
std. dev.	0.0017	0.0017	0.0017
weight sum	5596	3560	1974
precision	0.01	0.01	0.01

105 SOGUK KASAR

mean	0	0.0025	0.0051
------	---	--------	--------

std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1
BUHARLAMA			
mean	0.2337	0.5994	0.0613
std. dev.	0.4232	0.49	0.2399
weight sum	5596	3560	1974
precision	1	1	1
KOYU RENK YIKAMA			
mean	0.0095	0.0056	0.0279
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1
LISA			
mean	0.0009	0.0034	0
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1
FLAT REAKTIF YALDIZLI BASKI			
mean	0.0023	0.0331	0
std. dev.	0.1667	0.179	0.1667
weight sum	5596	3560	1974
precision	1	1	1
TUP KESME			
mean	0.0011	0.0039	0.0025
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1
APRE			
mean	0.9557	0.9511	0.4696
std. dev.	0.2058	0.2156	0.4991
weight sum	5596	3560	1974
precision	1	1	1
ROTASYON REAKTIF MATWEISS BASKI			
mean	0	0	0
std. dev.	0.0017	0.0017	0.0017
weight sum	5596	3560	1974
precision	0.01	0.01	0.01

DISPERS BOYAMA

mean	0	0	0
std. dev.	0.0017	0.0017	0.0017
weight sum	5596	3560	1974
precision	0.01	0.01	0.01

FLAT ASINDIRMA BASKI

mean	0.0005	0.0037	0
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1

ROTASYON DISPERS BASKI

mean	0	0.0011	0
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1

YARIM KASAR

mean	0.0004	0.002	0.002
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1

PIGMENT ZB

mean	0.0013	0.0011	0.0111
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1

DISPERS YIKAMA2

mean	0	0	0
std. dev.	0.0017	0.0017	0.0017
weight sum	5596	3560	1974
precision	0.01	0.01	0.01

YAKMA

mean	0.0018	0.002	0.0056
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1

ROTASYON PIGMENT BASKI

mean	0.359	0.193	0.3521
------	-------	-------	--------

std. dev.	0.4797	0.3946	0.4776
weight sum	5596	3560	1974
precision	1	1	1
REAKTIF BOYAMA			
mean	0	0.0003	0.0005
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1
OPTIK+EGALIZE			
mean	0.2019	0.0792	0.0988
std. dev.	0.4014	0.2701	0.2984
weight sum	5596	3560	1974
precision	1	1	1
FLAT PIGMENT BASKI			
mean	0.1338	0.1264	0.0137
std. dev.	0.3405	0.3323	0.1667
weight sum	5596	3560	1974
precision	1	1	1
GOLLER MERSEIZE OPTIK			
mean	0	0	0
std. dev.	0.0017	0.0017	0.0017
weight sum	5596	3560	1974
precision	0.01	0.01	0.01
FLAT REAKTIF+PIGMENT BASKI			
mean	0.0023	0.002	0.001
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1
BASKIALTI SEKER KASAR			
mean	0.0007	0.0048	0.001
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1
FIXE			
mean	0.5154	0.3966	0.3688
std. dev.	0.4998	0.4892	0.4825
weight sum	5596	3560	1974
precision	1	1	1

MERSERIZE				
mean	0.1455	0.2865	0.2376	
std. dev.	0.3526	0.4521	0.4256	
weight sum	5596	3560	1974	
precision	1	1	1	

RAM BEYAZ				
mean	0.0143	0.0067	0.0942	
std. dev.	0.1667	0.1667	0.2921	
weight sum	5596	3560	1974	
precision	1	1	1	

SEKER KASAR				
mean	0.0009	0.0006	0.0056	
std. dev.	0.1667	0.1667	0.1667	
weight sum	5596	3560	1974	
precision	1	1	1	

FLAT REAKTIF BASKI				
mean	0.0449	0.136	0.0071	
std. dev.	0.207	0.3427	0.1667	
weight sum	5596	3560	1974	
precision	1	1	1	

ROTASYON REAKTIF YALDIZ BASKI				
mean	0.0009	0.0219	0.0005	
std. dev.	0.1667	0.1667	0.1667	
weight sum	5596	3560	1974	
precision	1	1	1	

TURBANG+EGALIZE				
mean	0.0002	0	0	
std. dev.	0.1667	0.1667	0.1667	
weight sum	5596	3560	1974	
precision	1	1	1	

SANTEX TUP KURUTMA				
mean	0	0	0.0035	
std. dev.	0.1667	0.1667	0.1667	
weight sum	5596	3560	1974	
precision	1	1	1	

FLAT DISPERS BASKI				
mean	0	0.0003	0	

std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1
PIGMENT DB			
mean	0.0021	0.0037	0.0182
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1
GOLLER MERSEIZE			
mean	0.2194	0.2638	0.1089
std. dev.	0.4139	0.4407	0.3115
weight sum	5596	3560	1974
precision	1	1	1
ACIK RENK YIKAMA			
mean	0.0159	0.0374	0.196
std. dev.	0.1667	0.1896	0.397
weight sum	5596	3560	1974
precision	1	1	1
REAKTIF ZB			
mean	0.0164	0.011	0.0289
std. dev.	0.1667	0.1667	0.1675
weight sum	5596	3560	1974
precision	1	1	1
TURBANG			
mean	0.0021	0.0138	0.0152
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1
SARDON			
mean	0.2252	0.109	0.0694
std. dev.	0.4177	0.3116	0.2541
weight sum	5596	3560	1974
precision	1	1	1
HASIL SOKME			
mean	0.0086	0.0576	0.0187
std. dev.	0.1667	0.233	0.1667
weight sum	5596	3560	1974
precision	1	1	1

KALANDIR

mean	0.6846	0.7916	0.6297
std. dev.	0.4647	0.4062	0.4829
weight sum	5596	3560	1974
precision	1	1	1

DIJITAL REAKTIF BASKI

mean	0.0155	0.0042	0.0162
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1

ROTASYON REAKTIF BASKI

mean	0.158	0.3893	0.0314
std. dev.	0.3647	0.4876	0.1744
weight sum	5596	3560	1974
precision	1	1	1

ACIK EN SANFOR

mean	0.0011	0.0039	0.0025
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1

KASAR+EMUSYON

mean	0.2271	0.1129	0.0537
std. dev.	0.419	0.3165	0.2254
weight sum	5596	3560	1974
precision	1	1	1

REAKTIF DB

mean	0.2364	0.0503	0.04
std. dev.	0.4249	0.2185	0.196
weight sum	5596	3560	1974
precision	1	1	1

DIJITAL EGALIZE

mean	0.0125	0.002	0.0127
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1

REAKTIF YIKAMA

mean	0.4643	0.6354	0.076
------	--------	--------	-------

std. dev.	0.4987	0.4813	0.265
weight sum	5596	3560	1974
precision	1	1	1

KOSTIKLEME

mean	0.0004	0	0
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1

DISPERS / REAKTIF BOYAMA

mean	0	0	0
std. dev.	0.0017	0.0017	0.0017
weight sum	5596	3560	1974
precision	0.01	0.01	0.01

TUP SANFOR

mean	0	0	0.0035
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1

LEVENT KASAR

mean	0	0	0
std. dev.	0.0017	0.0017	0.0017
weight sum	5596	3560	1974
precision	0.01	0.01	0.01

Time taken to build model: 0.11 seconds

=== Stratified cross-validation ===

=== Summary ===


Correctly Classified Instances	7588	68.1761 %
Incorrectly Classified Instances	3542	31.8239 %
Kappa statistic	0.4797	
Mean absolute error	0.2502	
Root mean squared error	0.4185	
Relative absolute error	61.1898 %	
Root relative squared error	92.5586 %	
Total Number of Instances	11130	

=== Detailed Accuracy By Class ===

		TP Rate	FP Rate	Precision	Recall	F-Measure	MCC	ROC Area	PRC
Area	Class								
	B	0,731	0,313	0,702	0,731	0,716	0,418	0,771	0,756
	C	0,573	0,151	0,640	0,573	0,605	0,435	0,776	0,618
	A	0,740	0,073	0,687	0,740	0,713	0,648	0,887	0,659
	Weighted Avg.	0,682	0,219	0,680	0,682	0,680	0,464	0,793	0,695
=== Confusion Matrix ===									
	a	b	c	<-- classified as					
	4088	1047	461		a = B				
	1317	2040	203		b = C				
	415	99	1460		c = A				

Yüzdesel parçalama yöntemi

Şekil 4.7’de yüzdesel parçalama Naive Bayes algoritmasının weka’daki sonucu gösterilmiştir.



Şekil 4.7. Yüzdesel parçalama Naive Bayes algoritmasının Weka’daki sonucu

Çizelge 4.7’de yüzdesel parçalama Naive Bayes algoritmasının weka’daki sonuç adımları gösterilmiştir.

Çizelge 4.7. Yüzdesel parçalama Naive Bayes algoritmasının Weka’daki sonuç adımları

=== Run information ===

Scheme: weka.classifiers.bayes.NaiveBayes
Relation: TezData
Instances: 11130

Attributes: 74

SARDON SONU YIKAMA
ROTASYON ASINDIRMA BASKI
RAM FIXE
SANTEX APRE+KURUTMA
YIKAMA
OPTIK+KASAR
SANTEX EGALIZE+KURUTMA
EGALIZE
ROTASYON REAKTIF+PIGMENT BASKI
YAKMA+HASIL SOKME
SANFOR
RAM EMUSYON
YAKMA+SOGUK KASAR
SUPER BEYAZ
SANTEX FIXE
KASAR
NATUREL
BALON SIKMA
RAM SEKER KASAR
DISPERS YIKAMA
TEK TARAFLI SARDON 8X0
EKRU SARARTMA
SANTRIFUJ
105 SOGUK KASAR
BUHARLAMA
KOYU RENK YIKAMA
LISA
FLAT REAKTIF YALDIZLI BASKI
TUP KESME
APRE
ROTASYON REAKTIF MATWEISS BASKI
DISPERS BOYAMA
FLAT ASINDIRMA BASKI
ROTASYON DISPERS BASKI
YARIM KASAR
PIGMENT ZB
DISPERS YIKAMA2
YAKMA
ROTASYON PIGMENT BASKI
REAKTIF BOYAMA
OPTIK+EGALIZE
FLAT PIGMENT BASKI
GOLLER MERSEERIZE OPTIK
FLAT REAKTIF+PIGMENT BASKI

BASKIALTI SEKER KASAR
 FIXE
 MERSERIZE
 RAM BEYAZ
 SEKER KASAR
 FLAT REAKTIF BASKI
 ROTASYON REAKTIF YALDIZ BASKI
 TURBANG+EGALIZE
 SANTEX TUP KURUTMA
 FLAT DISPERS BASKI
 PIGMENT DB
 GOLLER MERSERIZE
 ACIK RENK YIKAMA
 REAKTIF ZB
 TURBANG
 SARDON
 HASIL SOKME
 KALANDIR
 DIJITAL REAKTIF BASKI
 ROTASYON REAKTIF BASKI
 ACIK EN SANFOR
 KASAR+EMUSYON
 REAKTIF DB
 DIJITAL EGALIZE
 REAKTIF YIKAMA
 KOSTIKLEME
 DISPERS / REAKTIF BOYAMA
 TUP SANFOR
 LEVENT KASAR
 HATASINIF

Test mode: split 66.0% train, remainder test

=== Classifier model (full training set) ===

Naive Bayes Classifier

Attribute	Class		
	B	C	A
	(0.5)	(0.32)	(0.18)
=====			
SARDON SONU YIKAMA			
mean	0.1642	0.1045	0.0329
std. dev.	0.3705	0.3059	0.1784
weight sum	5596	3560	1974
precision	1	1	1

ROTASYON ASINDIRMA BASKI

mean	0.0014	0.0006	0.0046
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1

RAM FIXE

mean	0.0002	0.002	0
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1

SANTEX APRE+KURUTMA

mean	0	0.0037	0.001
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1

YIKAMA

mean	0.0007	0.0056	0.001
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1

OPTIK+KASAR

mean	0.0064	0.0039	0.0193
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1

SANTEX EGALIZE+KURUTMA

mean	0.0011	0.0045	0.04
std. dev.	0.1667	0.1667	0.196
weight sum	5596	3560	1974
precision	1	1	1

EGALIZE

mean	0.7564	0.8924	0.4022
std. dev.	0.4292	0.3099	0.4903
weight sum	5596	3560	1974
precision	1	1	1

ROTASYON REAKTIF+PIGMENT BASKI

mean	0.0079	0.0087	0.0005
------	--------	--------	--------

std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1
YAKMA+HASIL SOKME			
mean	0.6746	0.7921	0.8075
std. dev.	0.4685	0.4058	0.3943
weight sum	5596	3560	1974
precision	1	1	1
SANFOR			
mean	0.2957	0.157	0.3354
std. dev.	0.4564	0.3638	0.4721
weight sum	5596	3560	1974
precision	1	1	1
RAM EMUSYON			
mean	0.0007	0.0028	0.0041
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1
YAKMA+SOGUK KASAR			
mean	0.0892	0.057	0.0679
std. dev.	0.285	0.2319	0.2515
weight sum	5596	3560	1974
precision	1	1	1
SUPER BEYAZ			
mean	0.0013	0.0045	0.04
std. dev.	0.1667	0.1667	0.196
weight sum	5596	3560	1974
precision	1	1	1
SANTEX FIXE			
mean	0	0	0
std. dev.	0.0017	0.0017	0.0017
weight sum	5596	3560	1974
precision	0.01	0.01	0.01
KASAR			
mean	0.753	0.8309	0.6849
std. dev.	0.4312	0.3748	0.4646
weight sum	5596	3560	1974
precision	1	1	1

NATUREL

mean	0.002	0.0008	0.0091
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1

BALON SIKMA

mean	0	0	0.0035
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1

RAM SEKER KASAR

mean	0.0075	0.0073	0.1256
std. dev.	0.1667	0.1667	0.3314
weight sum	5596	3560	1974
precision	1	1	1

DISPERS YIKAMA

mean	0	0.0006	0
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1

TEK TARAFLI SARDON 8X0

mean	0.0025	0.0059	0.0005
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1

EKRU SARARTMA

mean	0.002	0.0008	0.0137
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1

SANTRIFUJ

mean	0	0	0
std. dev.	0.0017	0.0017	0.0017
weight sum	5596	3560	1974
precision	0.01	0.01	0.01

105 SOGUK KASAR

mean	0	0.0025	0.0051
------	---	--------	--------

std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1
BUHARLAMA			
mean	0.2337	0.5994	0.0613
std. dev.	0.4232	0.49	0.2399
weight sum	5596	3560	1974
precision	1	1	1
KOYU RENK YIKAMA			
mean	0.0095	0.0056	0.0279
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1
LISA			
mean	0.0009	0.0034	0
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1
FLAT REAKTIF YALDIZLI BASKI			
mean	0.0023	0.0331	0
std. dev.	0.1667	0.179	0.1667
weight sum	5596	3560	1974
precision	1	1	1
TUP KESME			
mean	0.0011	0.0039	0.0025
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1
APRE			
mean	0.9557	0.9511	0.4696
std. dev.	0.2058	0.2156	0.4991
weight sum	5596	3560	1974
precision	1	1	1
ROTASYON REAKTIF MATWEISS BASKI			
mean	0	0	0
std. dev.	0.0017	0.0017	0.0017
weight sum	5596	3560	1974
precision	0.01	0.01	0.01

DISPERS BOYAMA

mean	0	0	0
std. dev.	0.0017	0.0017	0.0017
weight sum	5596	3560	1974
precision	0.01	0.01	0.01

FLAT ASINDIRMA BASKI

mean	0.0005	0.0037	0
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1

ROTASYON DISPERS BASKI

mean	0	0.0011	0
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1

YARIM KASAR

mean	0.0004	0.002	0.002
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1

PIGMENT ZB

mean	0.0013	0.0011	0.0111
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1

DISPERS YIKAMA2

mean	0	0	0
std. dev.	0.0017	0.0017	0.0017
weight sum	5596	3560	1974
precision	0.01	0.01	0.01

YAKMA

mean	0.0018	0.002	0.0056
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1

ROTASYON PIGMENT BASKI

mean	0.359	0.193	0.3521
------	-------	-------	--------

std. dev.	0.4797	0.3946	0.4776
weight sum	5596	3560	1974
precision	1	1	1
REAKTIF BOYAMA			
mean	0	0.0003	0.0005
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1
OPTIK+EGALIZE			
mean	0.2019	0.0792	0.0988
std. dev.	0.4014	0.2701	0.2984
weight sum	5596	3560	1974
precision	1	1	1
FLAT PIGMENT BASKI			
mean	0.1338	0.1264	0.0137
std. dev.	0.3405	0.3323	0.1667
weight sum	5596	3560	1974
precision	1	1	1
GOLLER MERSEIZE OPTIK			
mean	0	0	0
std. dev.	0.0017	0.0017	0.0017
weight sum	5596	3560	1974
precision	0.01	0.01	0.01
FLAT REAKTIF+PIGMENT BASKI			
mean	0.0023	0.002	0.001
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1
BASKIALTI SEKER KASAR			
mean	0.0007	0.0048	0.001
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1
FIXE			
mean	0.5154	0.3966	0.3688
std. dev.	0.4998	0.4892	0.4825
weight sum	5596	3560	1974
precision	1	1	1

MERSERIZE				
mean	0.1455	0.2865	0.2376	
std. dev.	0.3526	0.4521	0.4256	
weight sum	5596	3560	1974	
precision	1	1	1	

RAM BEYAZ				
mean	0.0143	0.0067	0.0942	
std. dev.	0.1667	0.1667	0.2921	
weight sum	5596	3560	1974	
precision	1	1	1	

SEKER KASAR				
mean	0.0009	0.0006	0.0056	
std. dev.	0.1667	0.1667	0.1667	
weight sum	5596	3560	1974	
precision	1	1	1	

FLAT REAKTIF BASKI				
mean	0.0449	0.136	0.0071	
std. dev.	0.207	0.3427	0.1667	
weight sum	5596	3560	1974	
precision	1	1	1	

ROTASYON REAKTIF YALDIZ BASKI				
mean	0.0009	0.0219	0.0005	
std. dev.	0.1667	0.1667	0.1667	
weight sum	5596	3560	1974	
precision	1	1	1	

TURBANG+EGALIZE				
mean	0.0002	0	0	
std. dev.	0.1667	0.1667	0.1667	
weight sum	5596	3560	1974	
precision	1	1	1	

SANTEX TUP KURUTMA				
mean	0	0	0.0035	
std. dev.	0.1667	0.1667	0.1667	
weight sum	5596	3560	1974	
precision	1	1	1	

FLAT DISPERS BASKI				
mean	0	0.0003	0	

std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1
PIGMENT DB			
mean	0.0021	0.0037	0.0182
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1
GOLLER MERSEIZE			
mean	0.2194	0.2638	0.1089
std. dev.	0.4139	0.4407	0.3115
weight sum	5596	3560	1974
precision	1	1	1
ACIK RENK YIKAMA			
mean	0.0159	0.0374	0.196
std. dev.	0.1667	0.1896	0.397
weight sum	5596	3560	1974
precision	1	1	1
REAKTIF ZB			
mean	0.0164	0.011	0.0289
std. dev.	0.1667	0.1667	0.1675
weight sum	5596	3560	1974
precision	1	1	1
TURBANG			
mean	0.0021	0.0138	0.0152
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1
SARDON			
mean	0.2252	0.109	0.0694
std. dev.	0.4177	0.3116	0.2541
weight sum	5596	3560	1974
precision	1	1	1
HASIL SOKME			
mean	0.0086	0.0576	0.0187
std. dev.	0.1667	0.233	0.1667
weight sum	5596	3560	1974
precision	1	1	1

KALANDIR

mean	0.6846	0.7916	0.6297
std. dev.	0.4647	0.4062	0.4829
weight sum	5596	3560	1974
precision	1	1	1

DIJITAL REAKTIF BASKI

mean	0.0155	0.0042	0.0162
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1

ROTASYON REAKTIF BASKI

mean	0.158	0.3893	0.0314
std. dev.	0.3647	0.4876	0.1744
weight sum	5596	3560	1974
precision	1	1	1

ACIK EN SANFOR

mean	0.0011	0.0039	0.0025
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1

KASAR+EMUSYON

mean	0.2271	0.1129	0.0537
std. dev.	0.419	0.3165	0.2254
weight sum	5596	3560	1974
precision	1	1	1

REAKTIF DB

mean	0.2364	0.0503	0.04
std. dev.	0.4249	0.2185	0.196
weight sum	5596	3560	1974
precision	1	1	1

DIJITAL EGALIZE

mean	0.0125	0.002	0.0127
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1

REAKTIF YIKAMA

mean	0.4643	0.6354	0.076
------	--------	--------	-------

std. dev.	0.4987	0.4813	0.265
weight sum	5596	3560	1974
precision	1	1	1
KOSTIKLEME			
mean	0.0004	0	0
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1
DISPERS / REAKTIF BOYAMA			
mean	0	0	0
std. dev.	0.0017	0.0017	0.0017
weight sum	5596	3560	1974
precision	0.01	0.01	0.01
TUP SANFOR			
mean	0	0	0.0035
std. dev.	0.1667	0.1667	0.1667
weight sum	5596	3560	1974
precision	1	1	1
LEVENT KASAR			
mean	0	0	0
std. dev.	0.0017	0.0017	0.0017
weight sum	5596	3560	1974
precision	0.01	0.01	0.01

Time taken to build model: 0.05 seconds

=== Evaluation on test split ===

Time taken to test model on test split: 0.16 seconds

=== Summary ===

Correctly Classified Instances	2609	68.9482 %
Incorrectly Classified Instances	1175	31.0518 %
Kappa statistic	0.492	
Mean absolute error	0.243	
Root mean squared error	0.4141	
Relative absolute error	59.39 %	
Root relative squared error	91.5146 %	

Total Number of Instances

3784

=== Detailed Accuracy By Class ===

	TP Rate	FP Rate	Precision	Recall	F-Measure	MCC	ROC Area	PRC
Area Class								
B	0,738	0,310	0,703	0,738	0,720	0,429	0,776	0,764
C	0,585	0,151	0,654	0,585	0,618	0,447	0,782	0,629
A	0,746	0,064	0,710	0,746	0,727	0,669	0,906	0,699
Weighted Avg.	0,689	0,215	0,688	0,689	0,688	0,477	0,801	0,709


=== Confusion Matrix ===

	a	b	c	<-- classified as
1391	360	133		a = B
447	727	68		b = C
142	25	491		c = A

4.4.3. K-NN (K-Nearest Neighborhood, En Yakın K Komşu) Algoritması

Çapraz doğrulama yöntemi

Şekil 4.8’de çapraz doğrulama K-NN algoritmasının weka’daki sonucu gösterilmiştir.



Şekil 4.8. Çapraz doğrulama K-NN algoritmasının Weka’deki sonucu

Çizelge 4.8’de Çapraz doğrulama K-NN algoritmasının Weka’daki sonuç adımları gösterilmiştir.

Çizelge 4.8. Çapraz doğrulama K-NN algoritmasının Weka’daki sonuç adımları

=== Run information ===

Scheme: `weka.classifiers.lazy.IBK -K 1 -W 0 -A`
`"weka.core.neighboursearch.LinearNNSearch -A \"weka.core.EuclideanDistance -R first-last\""`

Relation: TezData
Instances: 11130
Attributes: 74

SARDON SONU YIKAMA
ROTASYON ASINDIRMA BASKI
RAM FIXE
SANTEX APRE+KURUTMA
YIKAMA
OPTIK+KASAR
SANTEX EGALIZE+KURUTMA
EGALIZE
ROTASYON REAKTIF+PIGMENT BASKI
YAKMA+HASIL SOKME
SANFOR
RAM EMUSYON
YAKMA+SOGUK KASAR
SUPER BEYAZ
SANTEX FIXE
KASAR
NATUREL
BALON SIKMA
RAM SEKER KASAR
DISPERS YIKAMA
TEK TARAFLI SARDON 8X0
EKRU SARARTMA
SANTRIFUJ
105 SOGUK KASAR
BUHARLAMA
KOYU RENK YIKAMA
LISA
FLAT REAKTIF YALDIZLI BASKI
TUP KESME
APRE
ROTASYON REAKTIF MATWEISS BASKI
DISPERS BOYAMA
FLAT ASINDIRMA BASKI
ROTASYON DISPERS BASKI
YARIM KASAR
PIGMENT ZB
DISPERS YIKAMA2
YAKMA
ROTASYON PIGMENT BASKI
REAKTIF BOYAMA
OPTIK+EGALIZE
FLAT PIGMENT BASKI

GOLLER MERSERIZE OPTIK
FLAT REAKTIF+PIGMENT BASKI
BASKIALTI SEKER KASAR
FIXE
MERSERIZE
RAM BEYAZ
SEKER KASAR
FLAT REAKTIF BASKI
ROTASYON REAKTIF YALDIZ BASKI
TURBANG+EGALIZE
SANTEX TUP KURUTMA
FLAT DISPERS BASKI
PIGMENT DB
GOLLER MERSERIZE
ACIK RENK YIKAMA
REAKTIF ZB
TURBANG
SARDON
HASIL SOKME
KALANDIR
DIJITAL REAKTIF BASKI
ROTASYON REAKTIF BASKI
ACIK EN SANFOR
KASAR+EMUSYON
REAKTIF DB
DIJITAL EGALIZE
REAKTIF YIKAMA
KOSTIKLEME
DISPERS / REAKTIF BOYAMA
TUP SANFOR
LEVENT KASAR
HATASINIF

Test mode: 10-fold cross-validation

=== Classifier model (full training set) ===

IB1 instance-based classifier

using 1 nearest neighbour(s) for classification

Time taken to build model: 0 seconds


=== Stratified cross-validation ===

=== Summary ===

Correctly Classified Instances	8922	80.1617 %						
Incorrectly Classified Instances	2208	19.8383 %						
Kappa statistic	0.6771							
Mean absolute error	0.1699							
Root mean squared error	0.3037							
Relative absolute error	41.543 %							
Root relative squared error	67.1578 %							
Total Number of Instances	11130							
=== Detailed Accuracy By Class ===								
	TP Rate	FP Rate	Precision	Recall	F-Measure	MCC	ROC Area	PRC
Area Class								
B	0,792	0,173	0,822	0,792	0,807	0,619	0,894	0,901
C	0,808	0,143	0,727	0,808	0,765	0,648	0,915	0,821
A	0,819	0,018	0,906	0,819	0,860	0,833	0,983	0,941
Weighted Avg.	0,802	0,136	0,806	0,802	0,803	0,666	0,917	0,882
=== Confusion Matrix ===								
a	b	c	<-- classified as					
4430	1035	131	a = B					
647	2876	37	b = C					
312	46	1616	c = A					

Yüzdesel parçalama yöntemi

Şekil 4.9’da yüzdesel parçalama K-NN algoritmasının Weka’daki sonucu gösterilmiştir.



Şekil 4.9. Yüzdesel parçalama K-NN algoritmasının Weka’daki sonucu

Çizelge 4.9’da yüzdesel parçalama K-NN algoritmasının Weka’daki sonuç adımları gösterilmiştir.

Çizelge 4.9. Yüzdesel parçalama K-NN algoritmasının Weka’daki sonuç adımları

=== Run information ===	
Scheme:	weka.classifiers.lazy.IBk -K 1 -W 0 -A "weka.core.neighboursearch.LinearNNSearch -A \"weka.core.EuclideanDistance -R first-last\""
Relation:	TezData
Instances:	11130
Attributes:	74

SARDON SONU YIKAMA
ROTASYON ASINDIRMA BASKI
RAM FIXE
SANTEX APRE+KURUTMA
YIKAMA
OPTIK+KASAR
SANTEX EGALIZE+KURUTMA
EGALIZE
ROTASYON REAKTIF+PIGMENT BASKI
YAKMA+HASIL SOKME
SANFOR
RAM EMUSYON
YAKMA+SOGUK KASAR
SUPER BEYAZ
SANTEX FIXE
KASAR
NATUREL
BALON SIKMA
RAM SEKER KASAR
DISPERS YIKAMA
TEK TARAFLI SARDON 8X0
EKRU SARARTMA
SANTRIFUJ
105 SOGUK KASAR
BUHARLAMA
KOYU RENK YIKAMA
LISA
FLAT REAKTIF YALDIZLI BASKI
TUP KESME
APRE
ROTASYON REAKTIF MATWEISS BASKI
DISPERS BOYAMA
FLAT ASINDIRMA BASKI
ROTASYON DISPERS BASKI
YARIM KASAR
PIGMENT ZB
DISPERS YIKAMA2
YAKMA
ROTASYON PIGMENT BASKI
REAKTIF BOYAMA
OPTIK+EGALIZE
FLAT PIGMENT BASKI
GOLLER MERSEERIZE OPTIK
FLAT REAKTIF+PIGMENT BASKI
BASKIALTI SEKER KASAR

```
FIXE
MERSERIZE
RAM BEYAZ
SEKER KASAR
FLAT REAKTIF BASKI
ROTASYON REAKTIF YALDIZ BASKI
TURBANG+EGALIZE
SANTEX TUP KURUTMA
FLAT DISPERS BASKI
PIGMENT DB
GOLLER MERSERIZE
ACIK RENK YIKAMA
REAKTIF ZB
TURBANG
SARDON
HASIL SOKME
KALANDIR
DIJITAL REAKTIF BASKI
ROTASYON REAKTIF BASKI
ACIK EN SANFOR
KASAR+EMUSYON
REAKTIF DB
DIJITAL EGALIZE
REAKTIF YIKAMA
KOSTIKLEME
DISPERS / REAKTIF BOYAMA
TUP SANFOR
LEVENT KASAR
HATASINIF
Test mode:    split 66.0% train, remainder test

=== Classifier model (full training set) ===

IB1 instance-based classifier
using 1 nearest neighbour(s) for classification

Time taken to build model: 0 seconds

=== Evaluation on test split ===

Time taken to test model on test split: 3.95 seconds


=== Summary ===
```

Correctly Classified Instances	3008	79.4926 %						
Incorrectly Classified Instances	776	20.5074 %						
Kappa statistic	0.6658							
Mean absolute error	0.1713							
Root mean squared error	0.3093							
Relative absolute error	41.8662 %							
Root relative squared error	68.3443 %							
Total Number of Instances	3784							
=== Detailed Accuracy By Class ===								
	TP Rate	FP Rate	Precision	Recall	F-Measure	MCC	ROC Area	PRC
Area Class								
B	0,789	0,185	0,809	0,789	0,799	0,604	0,890	0,888
C	0,790	0,147	0,725	0,790	0,756	0,630	0,909	0,805
A	0,822	0,017	0,912	0,822	0,865	0,840	0,983	0,937
Weighted Avg.	0,795	0,143	0,799	0,795	0,796	0,654	0,912	0,869
=== Confusion Matrix ===								
a	b	c	<-- classified as					
1486	356	42	a = B					
251	981	10	b = C					
100	17	541	c = A					

4.4.4. SVM (Support Vector Machine)

Çapraz doğrulama yöntemi

Şekil 4.10'da Çapraz doğrulama SVM algoritmasının Weka'daki sonucu gösterilmiştir.



Şekil 4.10. Çapraz doğrulama SVM algoritmasının Weka'daki sonucu

Çizelge 4.10'da çapraz doğrulama SVM algoritmasının Weka'daki sonuç adımları gösterilmiştir.

Çizelge 4.10. Çapraz doğrulama SVM algoritmasının Weka'daki sonuç adımları

```
=== Run information ===
```

```

Scheme:      weka.classifiers.functions.SMO -C 1.0 -L 0.001 -P 1.0E-12 -N 0 -V -1 -W 1 -K
"weka.classifiers.functions.supportVector.PolyKernel -E 1.0 -C 250007" -calibrator
"weka.classifiers.functions.Logistic -R 1.0E-8 -M -1 -num-decimal-places 4"
Relation:    TezData
Instances:   11130
Attributes:  74
SARDON SONU YIKAMA
ROTASYON ASINDIRMA BASKI
RAM FIXE
SANTEX APRE+KURUTMA
YIKAMA
OPTIK+KASAR
SANTEX EGALIZE+KURUTMA
EGALIZE
ROTASYON REAKTIF+PIGMENT BASKI
YAKMA+HASIL SOKME
SANFOR
RAM EMUSYON
YAKMA+SOGUK KASAR
SUPER BEYAZ
SANTEX FIXE
KASAR
NATUREL
BALON SIKMA
RAM SEKER KASAR
DISPERS YIKAMA
TEK TARAFLI SARDON 8X0
EKRU SARARTMA
SANTRIFUJ
105 SOGUK KASAR
BUHARLAMA
KOYU RENK YIKAMA
LISA
FLAT REAKTIF YALDIZLI BASKI
TUP KESME
APRE
ROTASYON REAKTIF MATWEISS BASKI
DISPERS BOYAMA
FLAT ASINDIRMA BASKI
ROTASYON DISPERS BASKI
YARIM KASAR
PIGMENT ZB
DISPERS YIKAMA2
YAKMA
ROTASYON PIGMENT BASKI

```

REAKTIF BOYAMA
OPTIK+EGALIZE
FLAT PIGMENT BASKI
GOLLER MERSERIZE OPTIK
FLAT REAKTIF+PIGMENT BASKI
BASKIALTI SEKER KASAR
FIXE
MERSERIZE
RAM BEYAZ
SEKER KASAR
FLAT REAKTIF BASKI
ROTASYON REAKTIF YALDIZ BASKI
TURBANG+EGALIZE
SANTEX TUP KURUTMA
FLAT DISPERS BASKI
PIGMENT DB
GOLLER MERSERIZE
ACIK RENK YIKAMA
REAKTIF ZB
TURBANG
SARDON
HASIL SOKME
KALANDIR
DIJITAL REAKTIF BASKI
ROTASYON REAKTIF BASKI
ACIK EN SANFOR
KASAR+EMUSYON
REAKTIF DB
DIJITAL EGALIZE
REAKTIF YIKAMA
KOSTIKLEME
DISPERS / REAKTIF BOYAMA
TUP SANFOR
LEVENT KASAR
HATASINIF

Test mode: 10-fold cross-validation

=== Classifier model (full training set) ===

SMO

Kernel used:

Linear Kernel: $K(x,y) = \langle x,y \rangle$

Classifier for classes: B, C

BinarySMO

Machine linear: showing attribute weights, not support vectors.

```
-0.0018 * (normalized) SARDON SONU YIKAMA
+ 0.3857 * (normalized) ROTASYON ASINDIRMA BASKI
+ 3.9961 * (normalized) RAM FIXE
+ 1.3918 * (normalized) SANTEX APRE+KURUTMA
+ 0.1717 * (normalized) YIKAMA
+ -0.8571 * (normalized) OPTIK+KASAR
+ 0.3465 * (normalized) SANTEX EGALIZE+KURUTMA
+ 0.0009 * (normalized) EGALIZE
+ 0.3834 * (normalized) ROTASYON REAKTIF+PIGMENT BASKI
+ -0.3501 * (normalized) YAKMA+HASIL SOKME
+ -1.8248 * (normalized) SANFOR
+ -0.3505 * (normalized) RAM EMUSYON
+ -2.3476 * (normalized) YAKMA+SOGUK KASAR
+ -0.6805 * (normalized) SUPER BEYAZ
+ -1.6503 * (normalized) KASAR
+ -1 * (normalized) NATUREL
+ -0.8577 * (normalized) RAM SEKER KASAR
+ 0.1716 * (normalized) DISPERS YIKAMA
+ -0.0002 * (normalized) TEK TARAFLI SARDON 8X0
+ -0.8573 * (normalized) EKRU SARARTMA
+ 1 * (normalized) 105 SOGUK KASAR
+ 0.9348 * (normalized) BUHARLAMA
+ 0.0001 * (normalized) KOYU RENK YIKAMA
+ 0.1735 * (normalized) LISA
+ 0.3856 * (normalized) FLAT REAKTIF YALDIZLI BASKI
+ -1.6082 * (normalized) TUP KESME
+ -0.0003 * (normalized) APRE
+ 2.3858 * (normalized) FLAT ASINDIRMA BASKI
+ 1.3183 * (normalized) ROTASYON DISPERS BASKI
+ -1 * (normalized) YARIM KASAR
+ -1.9977 * (normalized) PIGMENT ZB
+ -0.0001 * (normalized) YAKMA
+ 1.3183 * (normalized) ROTASYON PIGMENT BASKI
+ 0.9691 * (normalized) REAKTIF BOYAMA
+ -1.9978 * (normalized) OPTIK+EGALIZE
+ 1.3193 * (normalized) FLAT PIGMENT BASKI
+ -1.6144 * (normalized) FLAT REAKTIF+PIGMENT BASKI
+ -0.5192 * (normalized) BASKIALTI SEKER KASAR
+ -0.1775 * (normalized) FIXE
+ -0.0001 * (normalized) MERSERIZE
```

```

+      -0.8573 * (normalized) RAM BEYAZ
+      -1.0341 * (normalized) SEKER KASAR
+       0.2079 * (normalized) FLAT REAKTIF BASKI
+       0.3859 * (normalized) ROTASYON REAKTIF YALDIZ BASKI
+      -1      * (normalized) TURBANG+EGALIZE
+       1      * (normalized) FLAT DISPERS BASKI
+      1.1417 * (normalized) PIGMENT DB
+      0.0001 * (normalized) GOLLER MERSEERIZE
+      0.1743 * (normalized) ACIK RENK YIKAMA
+     -1.9999 * (normalized) REAKTIF ZB
+      0.3462 * (normalized) TURBANG
+     -0.0001 * (normalized) SARDON
+      2.0001 * (normalized) HASIL SOKME
+      0.1732 * (normalized) KALANDIR
+     -1.7927 * (normalized) DIJITAL REAKTIF BASKI
+      0.2075 * (normalized) ROTASYON REAKTIF BASKI
+     -1.6082 * (normalized) ACIK EN SANFOR
+     -2.0003 * (normalized) KASAR+EMUSYON
+     -0.8575 * (normalized) REAKTIF DB
+      0.0005 * (normalized) DIJITAL EGALIZE
+      0.0001 * (normalized) REAKTIF YIKAMA
+      1.6839

```

Number of kernel evaluations: 205163734 (43.451% cached)

Classifier for classes: B, A

BinarySMO

Machine linear: showing attribute weights, not support vectors.

```

      0.2307 * (normalized) SARDON SONU YIKAMA
+      0.7809 * (normalized) ROTASYON ASINDIRMA BASKI
+     -1      * (normalized) RAM FIXE
+       2      * (normalized) SANTEX APRE+KURUTMA
+     -1.2192 * (normalized) YIKAMA
+     -3.735  * (normalized) OPTIK+KASAR
+      3.2555 * (normalized) SANTEX EGALIZE+KURUTMA
+     -0.232  * (normalized) EGALIZE
+      0.7773 * (normalized) ROTASYON REAKTIF+PIGMENT BASKI
+     -0.4387 * (normalized) YAKMA+HASIL SOKME
+     -0.0009 * (normalized) SANFOR
+      1.9519 * (normalized) RAM EMUSYON
+     -0.4393 * (normalized) YAKMA+SOGUK KASAR
+     -1.7976 * (normalized) SUPER BEYAZ

```

+ -1.9981 * (normalized) KASAR
 + -1.9978 * (normalized) NATUREL
 + 0.6666 * (normalized) BALON SIKMA
 + -1.7649 * (normalized) RAM SEKER KASAR
 + -0.6227 * (normalized) TEK TARAFLI SARDON 8X0
 + -1.9976 * (normalized) EKRU SARARTMA
 + 3.5746 * (normalized) 105 SOGUK KASAR
 + -2.5446 * (normalized) BUHARLAMA
 + 2.027 * (normalized) KOYU RENK YIKAMA
 + -2.207 * (normalized) LISA
 + -1.2194 * (normalized) FLAT REAKTIF YALDIZLI BASKI
 + -0.7445 * (normalized) TUP KESME
 + -0.0307 * (normalized) APRE
 + 1.9989 * (normalized) PIGMENT ZB
 + 0.0003 * (normalized) YAKMA
 + -1.7366 * (normalized) ROTASYON PIGMENT BASKI
 + -0.2322 * (normalized) OPTIK+EGALIZE
 + -2.176 * (normalized) FLAT PIGMENT BASKI
 + 0.7777 * (normalized) FLAT REAKTIF+PIGMENT BASKI
 + -1.2192 * (normalized) BASKIALTI SEKER KASAR
 + -1.9986 * (normalized) FIXE
 + 1.9988 * (normalized) MERSERIZE
 + -1.998 * (normalized) RAM BEYAZ
 + -2 * (normalized) SEKER KASAR
 + -1.2202 * (normalized) FLAT REAKTIF BASKI
 + 0.6666 * (normalized) SANTEX TUP KURUTMA
 + -1.7661 * (normalized) PIGMENT DB
 + 1.9989 * (normalized) GOLLER MERSERIZE
 + -1.9672 * (normalized) ACIK RENK YIKAMA
 + -0.0295 * (normalized) REAKTIF ZB
 + 1.7671 * (normalized) TURBANG
 + 1.5283 * (normalized) SARDON
 + 1.9993 * (normalized) HASIL SOKME
 + 1.9981 * (normalized) KALANDIR
 + -1.2204 * (normalized) DIJITAL REAKTIF BASKI
 + -1.2204 * (normalized) ROTASYON REAKTIF BASKI
 + -0.7445 * (normalized) ACIK EN SANFOR
 + -2.1981 * (normalized) KASAR+EMUSYON
 + -3.7653 * (normalized) REAKTIF DB
 + -0.0007 * (normalized) DIJITAL EGALIZE
 + -1.9691 * (normalized) REAKTIF YIKAMA
 + -2 * (normalized) KOSTIKLEME
 + 0.6666 * (normalized) TUP SANFOR
 + 3.4371

Number of kernel evaluations: 74681329 (46.83% cached)

Classifier for classes: C, A

BinarySMO

Machine linear: showing attribute weights, not support vectors.

0.0001 * (normalized) SARDON SONU YIKAMA
+ 1 * (normalized) ROTASYON ASINDIRMA BASKI
+ -1.9932 * (normalized) RAM FIXE
+ 0.7382 * (normalized) SANTEX APRE+KURUTMA
+ -1.3491 * (normalized) YIKAMA
+ -1.3403 * (normalized) OPTIK+KASAR
+ 1.3621 * (normalized) SANTEX EGALIZE+KURUTMA
+ -1.317 * (normalized) EGALIZE
+ 1 * (normalized) ROTASYON REAKTIF+PIGMENT BASKI
+ 0.6575 * (normalized) YAKMA+HASIL SOKME
+ -0.659 * (normalized) SANFOR
+ 3.3395 * (normalized) RAM EMUSYON
+ 0.6562 * (normalized) YAKMA+SOGUK KASAR
+ -1.3678 * (normalized) SUPER BEYAZ
+ -1.3168 * (normalized) KASAR
+ -0.0006 * (normalized) NATUREL
+ 0.9127 * (normalized) BALON SIKMA
+ -0.0232 * (normalized) RAM SEKER KASAR
+ -2 * (normalized) TEK TARAFLI SARDON 8X0
+ -0.6844 * (normalized) EKRU SARARTMA
+ 2.6588 * (normalized) 105 SOGUK KASAR
+ -1.272 * (normalized) BUHARLAMA
+ 2.0025 * (normalized) KOYU RENK YIKAMA
+ -3.2989 * (normalized) LISA
+ -0.7525 * (normalized) FLAT REAKTIF YALDIZLI BASKI
+ -0.3491 * (normalized) TUP KESME
+ -0.6605 * (normalized) APRE
+ -2.7547 * (normalized) FLAT ASINDIRMA BASKI
+ 2 * (normalized) PIGMENT ZB
+ -0 * (normalized) YAKMA
+ -0.0252 * (normalized) ROTASYON PIGMENT BASKI
+ 0.6069 * (normalized) REAKTIF BOYAMA
+ 0.6832 * (normalized) OPTIK+EGALIZE
+ -2.0253 * (normalized) FLAT PIGMENT BASKI
+ 1.2458 * (normalized) FLAT REAKTIF+PIGMENT BASKI
+ -1.3491 * (normalized) BASKIALTI SEKER KASAR
+ -1.9988 * (normalized) FIXE

```

+      1.9995 * (normalized) MERSERIZE
+     -0.6855 * (normalized) RAM BEYAZ
+     -0.0048 * (normalized) SEKER KASAR
+     -0.7532 * (normalized) FLAT REAKTIF BASKI
+     -0.7521 * (normalized) ROTASYON REAKTIF YALDIZ BASKI
+      0.9127 * (normalized) SANTEX TUP KURUTMA
+    -1.3429 * (normalized) PIGMENT DB
+      1.9997 * (normalized) GOLLER MERSERIZE
+    -1.319  * (normalized) ACIK RENK YIKAMA
+      1.9981 * (normalized) REAKTIF ZB
+      0.0463 * (normalized) TURBANG
+      2.1695 * (normalized) SARDON
+      0.6574 * (normalized) HASIL SOKME
+      1.3402 * (normalized) KALANDIR
+      1.2476 * (normalized) DIJITAL REAKTIF BASKI
+    -0.7529 * (normalized) ROTASYON REAKTIF BASKI
+    -0.3491 * (normalized) ACIK EN SANFOR
+    -0.8305 * (normalized) KASAR+EMUSYON
+    -2.0245 * (normalized) REAKTIF DB
+    -0.001  * (normalized) DIJITAL EGALIZE
+    -1.9989 * (normalized) REAKTIF YIKAMA
+      0.9127 * (normalized) TUP SANFOR
+      2.3212

```

Number of kernel evaluations: 66247483 (55.953% cached)

Time taken to build model: 68.05 seconds

=== Stratified cross-validation ===

=== Summary ===


Correctly Classified Instances	8403	75.4987 %
Incorrectly Classified Instances	2727	24.5013 %
Kappa statistic	0.602	
Mean absolute error	0.2827	
Root mean squared error	0.3664	
Relative absolute error	69.1145 %	
Root relative squared error	81.0257 %	
Total Number of Instances	11130	

=== Detailed Accuracy By Class ===

	TP Rate	FP Rate	Precision	Recall	F-Measure	MCC	ROC Area	PRC
Area Class								
B	0,753	0,213	0,781	0,753	0,767	0,540	0,783	0,722
C	0,747	0,158	0,690	0,747	0,717	0,578	0,819	0,612
A	0,775	0,038	0,813	0,775	0,794	0,751	0,933	0,737
Weighted Avg.	0,755	0,165	0,758	0,755	0,756	0,589	0,821	0,690
=== Confusion Matrix ===								
<pre> a b c <-- classified as 4213 1143 240 a = B 788 2660 112 b = C 392 52 1530 c = A </pre>								

Yüzdesel parçalama yöntemi

Şekil 4.11’de yüzdesel parçalama SVM algoritmasının Weka’daki sonucu gösterilmiştir.



Şekil 4.11. Yüzdesel parçalama SVM algoritmasının Weka’daki sonucu

Çizelge 4.11’de yüzdesel parçalama SVM algoritmasının Weka’daki sonuç adımları gösterilmiştir.

Çizelge 4.11. Yüzdesel parçalama SVM algoritmasının Weka’daki sonuç adımları

=== Run information ===

Scheme: weka.classifiers.functions.SMO -C 1.0 -L 0.001 -P 1.0E-12 -N 0 -V -1 -W 1 -K "weka.classifiers.functions.supportVector.PolyKernel -E 1.0 -C 250007" -calibrator "weka.classifiers.functions.Logistic -R 1.0E-8 -M -1 -num-decimal-places 4"

Relation: TezData

Instances: 11130

Attributes: 74

SARDON SONU YIKAMA
ROTASYON ASINDIRMA BASKI
RAM FIXE
SANTEX APRE+KURUTMA
YIKAMA
OPTIK+KASAR
SANTEX EGALIZE+KURUTMA
EGALIZE
ROTASYON REAKTIF+PIGMENT BASKI
YAKMA+HASIL SOKME
SANFOR
RAM EMUSYON
YAKMA+SOGUK KASAR
SUPER BEYAZ
SANTEX FIXE
KASAR
NATUREL
BALON SIKMA
RAM SEKER KASAR
DISPERS YIKAMA
TEK TARAFLI SARDON 8X0
EKRU SARARTMA
SANTRIFUJ
105 SOGUK KASAR
BUHARLAMA
KOYU RENK YIKAMA
LISA
FLAT REAKTIF YALDIZLI BASKI
TUP KESME
APRE
ROTASYON REAKTIF MATWEISS BASKI
DISPERS BOYAMA
FLAT ASINDIRMA BASKI
ROTASYON DISPERS BASKI
YARIM KASAR
PIGMENT ZB
DISPERS YIKAMA2
YAKMA
ROTASYON PIGMENT BASKI
REAKTIF BOYAMA
OPTIK+EGALIZE
FLAT PIGMENT BASKI
GOLLER MERSEERIZE OPTIK
FLAT REAKTIF+PIGMENT BASKI
BASKIALTI SEKER KASAR

FIXE
MERSERIZE
RAM BEYAZ
SEKER KASAR
FLAT REAKTIF BASKI
ROTASYON REAKTIF YALDIZ BASKI
TURBANG+EGALIZE
SANTEX TUP KURUTMA
FLAT DISPERS BASKI
PIGMENT DB
GOLLER MERSERIZE
ACIK RENK YIKAMA
REAKTIF ZB
TURBANG
SARDON
HASIL SOKME
KALANDIR
DIJITAL REAKTIF BASKI
ROTASYON REAKTIF BASKI
ACIK EN SANFOR
KASAR+EMUSYON
REAKTIF DB
DIJITAL EGALIZE
REAKTIF YIKAMA
KOSTIKLEME
DISPERS / REAKTIF BOYAMA
TUP SANFOR
LEVENT KASAR
HATASINIF

Test mode: split 66.0% train, remainder test

=== Classifier model (full training set) ===

SMO

Kernel used:

Linear Kernel: $K(x,y) = \langle x,y \rangle$

Classifier for classes: B, C

BinarySMO

Machine linear: showing attribute weights, not support vectors.

-0.0018 * (normalized) SARDON SONU YIKAMA

+ 0.3857 * (normalized) ROTASYON ASINDIRMA BASKI
 + 3.9961 * (normalized) RAM FIXE
 + 1.3918 * (normalized) SANTEX APRE+KURUTMA
 + 0.1717 * (normalized) YIKAMA
 + -0.8571 * (normalized) OPTIK+KASAR
 + 0.3465 * (normalized) SANTEX EGALIZE+KURUTMA
 + 0.0009 * (normalized) EGALIZE
 + 0.3834 * (normalized) ROTASYON REAKTIF+PIGMENT BASKI
 + -0.3501 * (normalized) YAKMA+HASIL SOKME
 + -1.8248 * (normalized) SANFOR
 + -0.3505 * (normalized) RAM EMUSYON
 + -2.3476 * (normalized) YAKMA+SOGUK KASAR
 + -0.6805 * (normalized) SUPER BEYAZ
 + -1.6503 * (normalized) KASAR
 + -1 * (normalized) NATUREL
 + -0.8577 * (normalized) RAM SEKER KASAR
 + 0.1716 * (normalized) DISPERS YIKAMA
 + -0.0002 * (normalized) TEK TARAFLI SARDON 8X0
 + -0.8573 * (normalized) EKRU SARARTMA
 + 1 * (normalized) 105 SOGUK KASAR
 + 0.9348 * (normalized) BUHARLAMA
 + 0.0001 * (normalized) KOYU RENK YIKAMA
 + 0.1735 * (normalized) LISA
 + 0.3856 * (normalized) FLAT REAKTIF YALDIZLI BASKI
 + -1.6082 * (normalized) TUP KESME
 + -0.0003 * (normalized) APRE
 + 2.3858 * (normalized) FLAT ASINDIRMA BASKI
 + 1.3183 * (normalized) ROTASYON DISPERS BASKI
 + -1 * (normalized) YARIM KASAR
 + -1.9977 * (normalized) PIGMENT ZB
 + -0.0001 * (normalized) YAKMA
 + 1.3183 * (normalized) ROTASYON PIGMENT BASKI
 + 0.9691 * (normalized) REAKTIF BOYAMA
 + -1.9978 * (normalized) OPTIK+EGALIZE
 + 1.3193 * (normalized) FLAT PIGMENT BASKI
 + -1.6144 * (normalized) FLAT REAKTIF+PIGMENT BASKI
 + -0.5192 * (normalized) BASKIALTI SEKER KASAR
 + -0.1775 * (normalized) FIXE
 + -0.0001 * (normalized) MERSEERIZE
 + -0.8573 * (normalized) RAM BEYAZ
 + -1.0341 * (normalized) SEKER KASAR
 + 0.2079 * (normalized) FLAT REAKTIF BASKI
 + 0.3859 * (normalized) ROTASYON REAKTIF YALDIZ BASKI
 + -1 * (normalized) TURBANG+EGALIZE
 + 1 * (normalized) FLAT DISPERS BASKI

```

+      1.1417 * (normalized) PIGMENT DB
+      0.0001 * (normalized) GOLLER MERSEIZE
+      0.1743 * (normalized) ACIK RENK YIKAMA
+     -1.9999 * (normalized) REAKTIF ZB
+      0.3462 * (normalized) TURBANG
+     -0.0001 * (normalized) SARDON
+      2.0001 * (normalized) HASIL SOKME
+      0.1732 * (normalized) KALANDIR
+     -1.7927 * (normalized) DIJITAL REAKTIF BASKI
+      0.2075 * (normalized) ROTASYON REAKTIF BASKI
+     -1.6082 * (normalized) ACIK EN SANFOR
+     -2.0003 * (normalized) KASAR+EMUSYON
+     -0.8575 * (normalized) REAKTIF DB
+      0.0005 * (normalized) DIJITAL EGALIZE
+      0.0001 * (normalized) REAKTIF YIKAMA
+      1.6839

```

Number of kernel evaluations: 205163734 (43.451% cached)

Classifier for classes: B, A

BinarySMO

Machine linear: showing attribute weights, not support vectors.

```

      0.2307 * (normalized) SARDON SONU YIKAMA
+      0.7809 * (normalized) ROTASYON ASINDIRMA BASKI
+     -1      * (normalized) RAM FIXE
+      2      * (normalized) SANTEX APRE+KURUTMA
+     -1.2192 * (normalized) YIKAMA
+     -3.735  * (normalized) OPTIK+KASAR
+      3.2555 * (normalized) SANTEX EGALIZE+KURUTMA
+     -0.232  * (normalized) EGALIZE
+      0.7773 * (normalized) ROTASYON REAKTIF+PIGMENT BASKI
+     -0.4387 * (normalized) YAKMA+HASIL SOKME
+     -0.0009 * (normalized) SANFOR
+      1.9519 * (normalized) RAM EMUSYON
+     -0.4393 * (normalized) YAKMA+SOGUK KASAR
+     -1.7976 * (normalized) SUPER BEYAZ
+     -1.9981 * (normalized) KASAR
+     -1.9978 * (normalized) NATUREL
+      0.6666 * (normalized) BALON SIKMA
+     -1.7649 * (normalized) RAM SEKER KASAR
+     -0.6227 * (normalized) TEK TARAFLI SARDON 8X0
+     -1.9976 * (normalized) EKRU SARARTMA

```

+ 3.5746 * (normalized) 105 SOGUK KASAR
 + -2.5446 * (normalized) BUHARLAMA
 + 2.027 * (normalized) KOYU RENK YIKAMA
 + -2.207 * (normalized) LISA
 + -1.2194 * (normalized) FLAT REAKTIF YALDIZLI BASKI
 + -0.7445 * (normalized) TUP KESME
 + -0.0307 * (normalized) APRE
 + 1.9989 * (normalized) PIGMENT ZB
 + 0.0003 * (normalized) YAKMA
 + -1.7366 * (normalized) ROTASYON PIGMENT BASKI
 + -0.2322 * (normalized) OPTIK+EGALIZE
 + -2.176 * (normalized) FLAT PIGMENT BASKI
 + 0.7777 * (normalized) FLAT REAKTIF+PIGMENT BASKI
 + -1.2192 * (normalized) BASKIALTI SEKER KASAR
 + -1.9986 * (normalized) FIXE
 + 1.9988 * (normalized) MERSEERIZE
 + -1.998 * (normalized) RAM BEYAZ
 + -2 * (normalized) SEKER KASAR
 + -1.2202 * (normalized) FLAT REAKTIF BASKI
 + 0.6666 * (normalized) SANTEX TUP KURUTMA
 + -1.7661 * (normalized) PIGMENT DB
 + 1.9989 * (normalized) GOLLER MERSEERIZE
 + -1.9672 * (normalized) ACIK RENK YIKAMA
 + -0.0295 * (normalized) REAKTIF ZB
 + 1.7671 * (normalized) TURBANG
 + 1.5283 * (normalized) SARDON
 + 1.9993 * (normalized) HASIL SOKME
 + 1.9981 * (normalized) KALANDIR
 + -1.2204 * (normalized) DIJITAL REAKTIF BASKI
 + -1.2204 * (normalized) ROTASYON REAKTIF BASKI
 + -0.7445 * (normalized) ACIK EN SANFOR
 + -2.1981 * (normalized) KASAR+EMUSYON
 + -3.7653 * (normalized) REAKTIF DB
 + -0.0007 * (normalized) DIJITAL EGALIZE
 + -1.9691 * (normalized) REAKTIF YIKAMA
 + -2 * (normalized) KOSTIKLEME
 + 0.6666 * (normalized) TUP SANFOR
 + 3.4371

Number of kernel evaluations: 74681329 (46.83% cached)

Classifier for classes: C, A

BinarySMO

Machine linear: showing attribute weights, not support vectors.

0.0001 * (normalized) SARDON SONU YIKAMA
+ 1 * (normalized) ROTASYON ASINDIRMA BASKI
+ -1.9932 * (normalized) RAM FIXE
+ 0.7382 * (normalized) SANTEX APRE+KURUTMA
+ -1.3491 * (normalized) YIKAMA
+ -1.3403 * (normalized) OPTIK+KASAR
+ 1.3621 * (normalized) SANTEX EGALIZE+KURUTMA
+ -1.317 * (normalized) EGALIZE
+ 1 * (normalized) ROTASYON REAKTIF+PIGMENT BASKI
+ 0.6575 * (normalized) YAKMA+HASIL SOKME
+ -0.659 * (normalized) SANFOR
+ 3.3395 * (normalized) RAM EMUSYON
+ 0.6562 * (normalized) YAKMA+SOGUK KASAR
+ -1.3678 * (normalized) SUPER BEYAZ
+ -1.3168 * (normalized) KASAR
+ -0.0006 * (normalized) NATUREL
+ 0.9127 * (normalized) BALON SIKMA
+ -0.0232 * (normalized) RAM SEKER KASAR
+ -2 * (normalized) TEK TARAFLI SARDON 8X0
+ -0.6844 * (normalized) EKRU SARARTMA
+ 2.6588 * (normalized) 105 SOGUK KASAR
+ -1.272 * (normalized) BUHARLAMA
+ 2.0025 * (normalized) KOYU RENK YIKAMA
+ -3.2989 * (normalized) LISA
+ -0.7525 * (normalized) FLAT REAKTIF YALDIZLI BASKI
+ -0.3491 * (normalized) TUP KESME
+ -0.6605 * (normalized) APRE
+ -2.7547 * (normalized) FLAT ASINDIRMA BASKI
+ 2 * (normalized) PIGMENT ZB
+ -0 * (normalized) YAKMA
+ -0.0252 * (normalized) ROTASYON PIGMENT BASKI
+ 0.6069 * (normalized) REAKTIF BOYAMA
+ 0.6832 * (normalized) OPTIK+EGALIZE
+ -2.0253 * (normalized) FLAT PIGMENT BASKI
+ 1.2458 * (normalized) FLAT REAKTIF+PIGMENT BASKI
+ -1.3491 * (normalized) BASKIALTI SEKER KASAR
+ -1.9988 * (normalized) FIXE
+ 1.9995 * (normalized) MERSERIZE
+ -0.6855 * (normalized) RAM BEYAZ
+ -0.0048 * (normalized) SEKER KASAR
+ -0.7532 * (normalized) FLAT REAKTIF BASKI
+ -0.7521 * (normalized) ROTASYON REAKTIF YALDIZ BASKI
+ 0.9127 * (normalized) SANTEX TUP KURUTMA

```

+      -1.3429 * (normalized) PIGMENT DB
+      1.9997 * (normalized) GOLLER MERSEIZE
+      -1.319  * (normalized) ACIK RENK YIKAMA
+      1.9981 * (normalized) REAKTIF ZB
+      0.0463 * (normalized) TURBANG
+      2.1695 * (normalized) SARDON
+      0.6574 * (normalized) HASIL SOKME
+      1.3402 * (normalized) KALANDIR
+      1.2476 * (normalized) DIJITAL REAKTIF BASKI
+      -0.7529 * (normalized) ROTASYON REAKTIF BASKI
+      -0.3491 * (normalized) ACIK EN SANFOR
+      -0.8305 * (normalized) KASAR+EMUSYON
+      -2.0245 * (normalized) REAKTIF DB
+      -0.001  * (normalized) DIJITAL EGALIZE
+      -1.9989 * (normalized) REAKTIF YIKAMA
+      0.9127 * (normalized) TUP SANFOR
+      2.3212

```

Number of kernel evaluations: 66247483 (55.953% cached)

Time taken to build model: 70.24 seconds

=== Evaluation on test split ===

Time taken to test model on test split: 0.01 seconds

=== Summary ===

Correctly Classified Instances	2861	75.6078 %
Incorrectly Classified Instances	923	24.3922 %
Kappa statistic	0.6033	
Mean absolute error	0.2815	
Root mean squared error	0.3649	
Relative absolute error	68.7969 %	
Root relative squared error	80.6337 %	
Total Number of Instances	3784	

=== Detailed Accuracy By Class ===

Area	Class	TP Rate	FP Rate	Precision	Recall	F-Measure	MCC	ROC Area	PRC
		0,754	0,218	0,774	0,754	0,764	0,537	0,782	0,716

B

		0,746	0,158	0,698	0,746	0,721	0,578	0,822	0,620
C									
		0,781	0,035	0,826	0,781	0,803	0,764	0,934	0,749
A									
Weighted Avg.		0,756	0,166	0,758	0,756	0,757	0,590	0,821	0,690

=== Confusion Matrix ===


	a	b	c	<-- classified as
1421	381	82		a = B
290	926	26		b = C
124	20	514		c = A



4.4.5. Multilayer Perceptron

4.4.6. Çapraz doğrulama yöntemi

Şekil 4.12’de çapraz doğrulama Multilayer Perceptron algoritmasının Weka’deki sonucu gösterilmiştir.



Şekil 4.12. Çapraz doğrulama Multilayer Perceptron algoritmasının Weka’deki sonucu

Çizelge 4.12’de çapraz doğrulama Multilayer Perceptron algoritmasının Weka’deki sonuç adımları gösterilmiştir.

Çizelge 4.12. Çapraz doğrulama Multilayer Perceptron algoritmasının Weka'daki sonuç adımları

Time taken to build model: 195.46 seconds

=== Stratified cross-validation ===

=== Summary ===

Correctly Classified Instances	8850	79.5148 %
Incorrectly Classified Instances	2280	20.4852 %
Kappa statistic	0.6679	
Mean absolute error	0.1696	
Root mean squared error	0.3111	
Relative absolute error	41.4654 %	
Root relative squared error	68.798 %	
Total Number of Instances	11130	

=== Detailed Accuracy By Class ===


	TP Rate	FP Rate	Precision	Recall	F-Measure	MCC	ROC Area	PRC
Area Class								
B	0,776	0,167	0,825	0,776	0,799	0,610	0,889	0,892
C	0,812	0,153	0,714	0,812	0,760	0,639	0,905	0,805
A	0,819	0,022	0,891	0,819	0,854	0,825	0,966	0,909
Weighted Avg.	0,795	0,137	0,801	0,795	0,796	0,657	0,908	0,867

=== Confusion Matrix ===

a	b	c	<-- classified as
4342	1107	147	a = B
618	2891	51	b = C
306	51	1617	c = A

4.4.7. Yüzdesel parçalama yöntemi

Şekil 4.13'te yüzdesel parçalama Multilayer Perceptron algoritmasının Weka'daki sonucu gösterilmiştir.



Şekil 4.13. Yüzdesel parçalama Multilayer Perceptron algoritmasının Weka'daki sonucu

Çizelge 4.13'te yüzdesel parçalama Multilayer Perceptron algoritmasının Weka'daki sonuç adımları gösterilmiştir.

Çizelge 4.13. Yüzdesel parçalama Multilayer Perceptron algoritmasının Weka'daki sonuç adımları

```
Time taken to build model: 193.15 seconds  
  
=== Evaluation on test split ===  
  
Time taken to test model on test split: 0.06 seconds
```

=== Summary ===

Correctly Classified Instances	3002	79.334 %
Incorrectly Classified Instances	782	20.666 %
Kappa statistic	0.6668	
Mean absolute error	0.1707	
Root mean squared error	0.3143	
Relative absolute error	41.7279 %	
Root relative squared error	69.4529 %	
Total Number of Instances	3784	

=== Detailed Accuracy By Class ===

Area	Class	TP Rate	FP Rate	Precision	Recall	F-Measure	MCC	ROC Area	PRC
	B	0,761	0,151	0,833	0,761	0,796	0,613	0,888	0,888
	C	0,816	0,165	0,707	0,816	0,757	0,630	0,903	0,796
	A	0,843	0,024	0,881	0,843	0,862	0,834	0,970	0,903
	Weighted Avg.	0,793	0,134	0,800	0,793	0,795	0,657	0,907	0,860

=== Confusion Matrix ===

a	b	c	<-- classified as
1434	396	54	a = B
208	1013	21	b = C
79	24	555	c = A

BÖLÜM 5

SONUÇ VE DEĞERLENDİRME

Gerçek üretim verileri kullanılarak beş farklı makine öğrenme algoritması iki yöntemle denenerek fire sınıflandırması yapılmıştır. İlk yöntemde veri seti 10 eşit parçaya bölünmüş ve bu parçalardan 9 tanesi eğitim verisi 1 tanesi test verisi olarak kullanılmıştır. Daha sonrasında test verisi için farklı bir küme kullanılmıştır. Böylelikle 10 parçadan her bir parçası test verisi olarak kullanılmıştır. Bu yöntem çapraz doğrulama yöntemi olarak adlandırılmaktadır. Diğer yöntemde ise veri seti %66'lık eğitim seti ve %34'lük eğitim seti olarak iki parçaya bölünmüştür.

Her iki yöntem ile yapılan çalışmaların sonuçları birbirine çok yakın çıkmıştır. Bu durum veri setinin doğruluğunu yüksek olduğunu göstermektedir. Tez çalışması kapsamında yapılmış olan gürültülü verilerin temizlenmesi sayesinde çok farklı sonuçların oluşması engellenmiştir.

Tüm algoritmalar aynı veri seti üzerinde çalıştırılarak çizelge 5.1'deki sonuçlar elde edilmiştir.

Çizelge 5.1. Algoritmaların karşılaştırmalı sonuçları

	Doğruluk (%)		Kappa Değeri	
	Çapraz Doğrulama	Yüzdesel Parçalama	Çapraz Doğrulama	Yüzdesel Parçalama
J48	78.6164	77.8805	0.6526	0.6403
Naive Bayes	68.1761	68.9482	0.4797	0.492
KNN	80.1617	79.4926	0.6771	0.6658
SVM	75.4987	75.6078	0.602	0.6033
Multilayer Perceptron	79.5148	79.334	0.6679	0.6668

Sonuçlara göre en yüksek doğruluk oranı %80.1617 ile KNN algoritması ile elde edilmiştir. Ayrıca Kappa değeri 0,6771 ile yine en yüksek KNN algoritmasında çıkmıştır. En düşük sonuçlar ise %68,1761 doğruluk oranı ve 0,4797 ile Naive Bayes algoritmasında ortaya çıkmıştır.

Yapılan çalışma sonucuna göre, üretim süreçlerinin birbiri ile kuvvetli ilişkiye sahip olduğu, verilerin büyük bir doğruluk yüzdesi ve yapılan tahminin tesadüfi olmadığı sonucuna varılmıştır. Bu çalışma ile işletmeler üretim süreçlerine başlamadan önce ne kadarlık bir üretim firesinin oluşabileceğini %80,1617 lik bir yüzde ile tahmin edebileceklerdir. Böylelikle işletmelerin fazla üretim miktarları azalacak, fire oranları düşecek ve böylece maliyetleri büyük oranda azalacaktır.

Tekstil sektörü için yapılan bu çalışma ile işletmelerin fire maliyetleri azaltılabilir. Ayrıca üretim süreçlerindeki kişiye bağımlılığı da ortadan kaldırabilir. Bundan sonra farklı tekstil işletmelerinden de aynı şekilde veriler alınarak elde edilen sonuçların işletmelerde farklılık gösterip göstermeyeceği araştırılabilir. Sonuçlarda farklılık çıkması durumunda bu farklılığın sebebi araştırılabilir. Bu çalışma için kullanılan makine modeli, işlemi yapan operatörlerin bilgileri de veri setine eklenebilir. Böylece makine ve makine operatörlerinin sonuçlara olan etkisi daha net araştırılabilir.

KAYNAKLAR

- Agrawal, R., & Srikant, R. (1994). Fast Algorithms for Mining Association Rules. *Proceedings of the 20th VLDB Conference Santiago, Chile, 1994*.
- Alam, M., & Sadaf, K. (2015). Labeling of Web Search Result Clusters Using Heuristic Search and Frequent Itemset. *Procedia Computer Science*, 46, 216–222. <https://doi.org/10.1016/J.PROCS.2015.02.014>
- Ankerst, M., Breunig, M. M., Kriegel, H., & Sander, J. (1999). OPTICS: Ordering Points To Identify the Clustering Structure. *ACM SIGMOD Record*, 28(2), 49–60.
- Barma, M. C., Saidur, R., Rahman, S. M. A., Allouhi, A., Akash, B. A., & Sait, S. M. (2017). A review on boilers energy use, energy savings, and emissions reductions. *Renewable and Sustainable Energy Reviews*, 79, 970–983. <https://doi.org/10.1016/J.RSER.2017.05.187>
- Bhandari, M., & Joensson, A. (2009). *Clinical research for surgeons*.
- Cohen, J. (1960). A Coefficient of Agreement for Nominal Scales. *Educational and Psychological Measurement*, 20(1), 37–46. <https://doi.org/10.1177/001316446002000104>
- Cover, T. M., & Hart, P. E. (1967). Nearest Neighbor Pattern Classification. *IEEE Transactions on Information Theory*, 13(1), 21–27. <https://doi.org/10.1109/TIT.1967.1053964>
- Cui, D., & Curry, D. (2005). Prediction in Marketing Using the Support Vector Machine. <https://doi.org/10.1287/mksc.1050.0123>, 24(4), 595–615. <https://doi.org/10.1287/MKSC.1050.0123>
- Cybenko, G. (1989). Approximation by superpositions of a sigmoidal function. *Mathematics of Control, Signals and Systems 1989 2:4*, 2(4), 303–314. <https://doi.org/10.1007/BF02551274>
- De Miranda Coelho, J. A. P., Gouveia, V. V., De Souza, G. H. S., Milfont, T. L., & Barros, B. N. R. (2016). Emotions toward water consumption: Conservation and wastage. *Revista Latinoamericana de Psicologia*, 48(2), 117–126. <https://doi.org/10.1016/j.rlp.2015.09.006>

- Domingos, P., & Pazzani, M. (1997). On the Optimality of the Simple Bayesian Classifier under Zero-One Loss. *Machine Learning* 1997 29:2, 29(2), 103–130. <https://doi.org/10.1023/A:1007413511361>
- Ester, M., Kriegel, H.-P., Sander, J., & Xu, X. (1996). *A Density-Based Algorithm for Discovering Clusters in Large Spatial Databases with Noise*. www.aaai.org
- Ethem, A. (2015). Introduction to Machine Learning Second Edition Adaptive Computation and Machine Learning. *Massachusetts Institute of Technology*, 41–470. https://kkpatel7.files.wordpress.com/2015/04/alppaydin_machinelearning_2010.pdf
- Fix, E., & Hodges, J. L. (1989). Discriminatory Analysis. Nonparametric Discrimination: Consistency Properties. *International Statistical Review / Revue Internationale de Statistique*, 57(3), 238. <https://doi.org/10.2307/1403797>
- Flach, P. A. (2012). *Machine learning : the art and science of algorithms that make sense of data*. 396.
- Fleiss, J. L. (1971). Measuring nominal scale agreement among many raters. *Psychological Bulletin*, 76(5), 378–382. <https://doi.org/10.1037/H0031619>
- Forsati, R., Mahdavi, M., Shamsfard, M., & Reza Meybodi, M. (2013). Efficient stochastic algorithms for document clustering. *Information Sciences*, 220, 269–291. <https://doi.org/10.1016/J.INS.2012.07.025>
- Gan, G., & Ng, M. K. P. (2017). k-means clustering with outlier removal. *Pattern Recognition Letters*, 90, 8–14. <https://doi.org/10.1016/J.PATREC.2017.03.008>
- Gardner, M. W., & Dorling, S. R. (1998). Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences. *Atmospheric Environment*, 32(14–15), 2627–2636. [https://doi.org/10.1016/S1352-2310\(97\)00447-0](https://doi.org/10.1016/S1352-2310(97)00447-0)
- Gower, J. C., & Legendre, P. (1986). Metric and Euclidean properties of dissimilarity coefficients. *Journal of Classification* 1986 3:1, 3(1), 5–48. <https://doi.org/10.1007/BF01896809>
- Han, J., Kamber, M., & Pei, J. (2011). *Data Mining. Concepts and Techniques*, 3rd

Edition (The Morgan Kaufmann Series in Data Management Systems).

- Hou, J., Liu, W., E, X., & Cui, H. (2016). Towards parameter-independent data clustering and image segmentation. *Pattern Recognition*, 60, 25–36. <https://doi.org/10.1016/J.PATCOG.2016.04.015>
- Ian H., W., & Eibe, F. (2005). Data Mining: Practical Machine Learning Tools and Techniques 2nd Edition. *The Morgan Kaufmann Series in Data Management Systems*, 560.
- Jurušs, M., & Seile, E. (2017). Application of Loss Rates for Petroleum Products Due to Natural Wastage in Customs Procedures. *Procedia Engineering*, 178, 377–383. <https://doi.org/10.1016/J.PROENG.2017.01.069>
- Kelleher, J. D., Namee, B. M., & D’Arcy, A. (2001). Machine learning for predictive data analytics. *MIT Press*, 43.
- Kiliçaslan, Y., Güner, E. S., & Yildirim, S. (2009). Learning-based pronoun resolution for Turkish with a comparative evaluation. *Computer Speech and Language*, 23(3), 311–331. <https://doi.org/10.1016/J.CSL.2008.09.001>
- Kim, S. Y., & Upneja, A. (2014). Predicting restaurant financial distress using decision tree and AdaBoosted decision tree models. *Economic Modelling*, 36, 354–362. <https://doi.org/10.1016/J.ECONMOD.2013.10.005>
- Kleiner, A., Talwalkar, A., Sarkar, P., & Jordan, M. I. (2011). A Scalable Bootstrap for Massive Data. *Journal of the Royal Statistical Society. Series B: Statistical Methodology*, 76(4), 795–816. <https://doi.org/10.48550/arxiv.1112.5016>
- Lee, Y. J., & Mangasarian, O. L. (2001). SSVM: A Smooth Support Vector Machine for Classification. *Computational Optimization and Applications* 20:1, 20(1), 5–22. <https://doi.org/10.1023/A:1011215321374>
- Li, C., Jiang, L., & Li, H. (2014). Local value difference metric. *Pattern Recognition Letters*, 49, 62–68. <https://doi.org/10.1016/J.PATREC.2014.06.014>
- López-Vallverdú, J. A., Riaño, D., & Bohada, J. A. (2012). Improving medical decision trees by combining relevant health-care criteria. *Expert Systems with Applications*, 39(14), 11782–11791. <https://doi.org/10.1016/J.ESWA.2012.04.073>
- Ohm, S., van Eldik, C., & Egberts, K. (2009). γ /hadron separation in very-high-energy γ -ray astronomy using a multivariate analysis method. *Astroparticle Physics*, 31(5),

383–391. <https://doi.org/10.1016/J.ASTROPARTPHYS.2009.04.001>

- Pagnuco, I. A., Pastore, J. I., Abras, G., Brun, M., & Ballarin, V. L. (2017). Analysis of genetic association using hierarchical clustering and cluster validation indices. *Genomics*, 109(5–6), 438–445. <https://doi.org/10.1016/J.YGENO.2017.06.009>
- Quinlan, J. R. (1986). Induction of decision trees. *Machine Learning 1986 1:1*, 1(1), 81–106. <https://doi.org/10.1007/BF00116251>
- Quinlan, J. R. (1993). J. Ross Quinlan_C4.5_ Programs for Machine Learning.pdf. *Morgan Kaufmann*, 5(3), 302. <http://www.springerlink.com/index/10.1007/BF00993309>
- Reutter, B., Lant, P., Lane, J., Reynolds, C., & Reynolds, C. (2017). Food waste consequences: Environmentally extended input-output as a framework for analysis. *Journal of Cleaner Production*, C(153), 506–514. <https://doi.org/10.1016/J.JCLEPRO.2016.09.104>
- Rish, I., & Rish, I. (2001). *An empirical study of the naive bayes classifier*. <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.330.2788>
- Rosenblatt, F. (1961). Principles OF Neurodynamics Perceptrons And The Theory of Brain Mechanisms. *CORNELL AERONAUTICAL LABORATORY, INC. Buffalo 21, New York*.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (2013). Learning Internal Representations by Error Propagation. *Readings in Cognitive Science: A Perspective from Psychology and Artificial Intelligence*, 399–421. <https://doi.org/10.1016/B978-1-4832-1446-7.50035-2>
- Thangaparvathi, B., & Anandhavalli, D. (2010). An improved algorithm of decision tree for classifying large data set based on rainforest framework. *2010 IEEE International Conference on Communication Control and Computing Technologies, ICCCT 2010*, 800–805. <https://doi.org/10.1109/ICCCCT.2010.5670733>
- Wai, W. K., Ting, L., Pang, L. W., Budihardjo, H., Liang, G. C., Liya, D., Fangming, Z., & T-Howe, C. P. (2016). Decision Support System for Production Scheduling (DSSPS). *Procedia Computer Science*, 96, 315–323. <https://doi.org/10.1016/J.PROCS.2016.08.144>

- Wang, Y., Ma, X., Lao, Y., & Wang, Y. (2014). A fuzzy-based customer clustering approach with hierarchical structure for logistics network optimization. *Expert Systems with Applications*, 41(2), 521–534.
<https://doi.org/10.1016/J.ESWA.2013.07.078>
- Wilson, D. R., & Martinez, T. R. (1997). Improved Heterogeneous Distance Functions. *Journal of Artificial Intelligence Research*, 6, 1–34.
- Witten, Frank, & Eibe. (2005). *Data Mining: Practical Machine Learning Tools and Techniques, Second Edition*.
- Zhao, B., & Xue, B. (2017). Improving prediction accuracy using decision-tree-based meta-strategy and multi-threshold sequential-voting exemplified by miRNA target prediction. *Genomics*, 109(3–4), 227–232.
<https://doi.org/10.1016/J.YGENO.2017.04.003>

ÖZGEÇMİŞ

İlköğrenimini ve ortaöğrenimini İstanbul ilinde tamamladı. 1992 yılında başladığı Pertevniyal Lisesi'nden 1995 yılında mezun oldu. 1996 yılında başladığı lisans öğrenimi için başladığı Trakya Üniversitesi Bilgisayar Mühendisliği Bölümü'nden 2000 yılında mezun oldu. 2002 yılında Trakya Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı'nda başladığı Yüksek Lisans eğitiminden 2005 yılında mezun oldu. 2009 yılında Doktora eğitimine Trakya Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı'nda başladı. Genel Müdür olarak İlgiSoft Bilişim ve Danışmanlık Hizmetleri Ltd. Şti.'nde 2006 yılından itibaren çalışmaya başladığı görevine halen devam etmektedir.

VERİ KULLANIM İZİN BELGESİ

UNIVERSAL

17.01.2022

Trakya Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Anabilim dalı başkanlığına,

EDİRNE

Bölümünüz öğretim üyelerinden Prof. Dr. Erdem UÇAR'ın doktora tez öğrencisi olan Özgür ALTUNSOĞUT'un doktora tez çalışmasında akademik amaçlı kullanmak üzere işletmemize ait olan 2021 yılı üretim verilerinin kullanılmasında işletmemiz açısından bir sakınca yoktur.

Üniversal Tekstil Sanayi ve Tic. Ltd. Şti.

Merkez İkitelli OSB Mh. Eski Turgut Özal Cd. No: 22D Başakşehir İstanbul T: +90 212 671 03 74 F: +90 212 671 03 75

Fabrika Velimeşe Organize Sanayi Bölgesi 117.Sk. No: 6 Ergene / Tekirdağ T: +90 282 674 51 08 F: +90 282 674 51 12

info@universaltextile.com.tr - www.universaltextile.com.tr

TEZ ÖĞRENCİSİNE AİT BİLİMSEL FAALİYETLER

•Altunsöğüt, Ö., Uçar, E., & Kılıçaslan, Y. (2018). Predicting The Amount of Wastage of Finished Goods in Textile Dyeing Factories. International Scientific Conference, 16-17 Kasım 2018, Gabrovo.

•Altunsöğüt, Ö., & Uçar, E. (2018). Fabric Cutting Optimization Application. *International Scientific Conference, 16-17 Kasım 2018, Gabrovo.*

•Uçar, E., & Altunsöğüt, Ö. (2016). Asp.Net Teknolojisini Kullanarak Bir Satın Alma Portalı Uygulaması Geliştirilmesi. Trakya Univ J Sci. <https://dergipark.org.tr/en/pub/tujes>

•Altunsöğüt, Ö., Uçar, E., & Kocailik, A. (2005). Sağlıkta e-İhale ile Malzeme Tedariği Uygulaması. 85–89.

•Altunsöğüt, Ö., & Uçar, E. (2006). Veri Tabanı Bağlantı Ayarlarının Şifrelenerek Xml Dosyasında Saklanması. Pamukkale Üniversitesi Bilgi Teknolojileri Kongresi IV Akademik Bilişim Kongresi 2006 Bildiriler Kitabı:484-487.