

ANKARA ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

DERS SONU DEĞERLENDİRME SÜREÇLERİNDE DUYGU ANALİZİ  
YAKLAŞIMI

İlker KOCAOĞLU

ENFORMATİK ANABİLİM DALI

ANKARA  
2024

Her hakkı saklıdır

## ÖZET

Yüksek Lisans Tezi

### DERS SONU DEĞERLENDİRME SÜREÇLERİNDE DUYGU ANALİZİ YAKLAŞIMI

İlker KOCAOĞLU

Ankara Üniversitesi  
Fen Bilimleri Enstitüsü  
Enformatik Anabilim Dalı

Danışman: Doç. Dr. Erinç KARATAŞ

Son yıllarda Sürdürülebilir Kalkınma Amaçlarından olan “Nitelikli Eğitim” konusunda yapılan çalışmalar neticesinde yükseköğretim kurumlarında eğitimin niteliğinin artırılmasında dijitalleşmenin rolü önemli bir odak noktası haline gelmiştir. Bu bağlamda gerçekleştirilen araştırmalar, dijital unsurların eğitim-öğretim süreçlerine entegrasyonunun öğrenme deneyimini kolaylaştırdığı ve niteliğinin arttırdığını göstermektedir. Yapılan çalışmada yükseköğretim kurumlarında geleneksel ders değerlendirme sürecine farklı teknolojiler entegre ederek dijitalleştirilmesi hedeflenmiştir. Bir üniversitenin son yıllardaki anket sonuçları manuel olarak etiketlenerek oluşturulan veri seti, duygu analizi amacı ile gözetimli makine öğrenimi algoritmalarının eğitimi aşmasında kullanılmıştır. Duygu analizi sonuçlarına göre anket sonuçlarında tutarlı ve tutarsız veriler belirlenerek sadece tutarlı veriler üzerinden bir nihai rapor oluşturulmuştur. Nihai rapor ilgili ders ve öğretim elemanı hakkında bizlere güvenilir bilgiler sunmaktadır. Bu rapor doğrultusunda ders kazanımlarının gerçekleştirilme yüzdesi, dersin içeriğinin güncellenmesi veya öğretim elemanının kendini hangi konularda geliştirmesi gerektiği hususlarında yönlendirici bir rol üstlenmektedir.

**Haziran 2024, 53 sayfa**

**Anahtar Kelimeler:** Duygu Analizi, Makine Öğrenmesi, Ders Değerlendirme, OpenAI

## ABSTRACT

Master Thesis

SENTIMENT ANALYSIS APPROACH IN COURSE EVALUATION PROCESSES

İlker KOCAOĞLU

Ankara University  
Graduate School of Natural and Applied Science  
Department of Informatics

Supervisor: Assoc. Prof. Erinç KARATAŞ, PhD

In recent years, as a result of studies on the Sustainable Development Goal of 'Quality Education,' the role of digitization has become a significant focal point in improving the quality of education in higher education institutions. Research in this context indicates that the integration of digital elements into educational processes facilitates learning experiences and enhances their quality. In the conducted study, the aim was to digitize the traditional course evaluation process in higher education institutions by integrating different technologies. A dataset, created by manually labeling survey results from a university in recent years, was used to train supervised machine learning algorithms for sentiment analysis. Based on the sentiment analysis results, consistent and inconsistent data in the survey results were identified, and a final report was generated only using consistent data. The final report provides reliable information about the relevant course and teaching staff. In accordance with this report, it plays a guiding role in determining the percentage of course objectives achieved, updating the course content, or identifying areas in which the teaching staff need to improve themselves.

**June 2024, 53 pages**

**Keywords:** Sentiment Analysis, Machine Learning, Course Evaluation, OpenAI

## TEŐEKKÜR

Öncelikle, bu tez alıőmasının her aőamasında bana rehberlik eden, deęerli bilgi ve tecrübelerini paylaőarak sürecin en verimli őekilde ilerlemesini saęlayan danıőman hocam Sayın Do. Dr. Erin KARATAŐ'a en iten teőekkürlerimi sunarım. Ayrıca, bu süreçte bana destek veren ve akademik gelişimime katkıda bulunan bölüm hocalarım Sayın Do. Dr. Esmâ ERGÜNER ÖZKO, Prof. Dr. Erdem KIRKBEŐOęLU, Dr. Öğr. Üyesi Gizem ÖęÜTÜ ULAŐ, Prof. Dr. Murat Paőa UYSAL ve Dr. Öğr. Gör. Gülten őENKUL'a teőekkür ederim. Onların yönlendirmeleri ve teşvikleri olmadan bu alıőmanın tamamlanması mümkün olamazdı.

Bu zorlu süreçte yanımda olan ve bana her zaman destek olan sevgili aileme de teőekkürlerimi sunmak istiyorum. Ailemin göstermiş oldukları sabır, anlayıő ve sürekli destekleri için minnettarım. Onların manevi desteęi ve inancı, bu tezin tamamlanmasında en büyük motivasyon kaynaęım oldu. Tezimin her aőamasında yanımda oldukları ve bana güç verdikleri için kendilerine sonsuz teőekkürler.

İlker KOCAOęLU  
Ankara, Haziran 2024

## İÇİNDEKİLER

TEZ ONAY SAYFASI	
ETİK.....	i
ÖZET.....	i
ABSTRACT .....	ii
TEŞEKKÜR .....	iii
KISALTMALAR DİZİNİ.....	vi
ŞEKİLLER DİZİNİ .....	vii
ÇİZELGELER DİZİNİ .....	viii
1. GİRİŞ .....	1
2. KURAMSAL TEMELLER.....	4
2.1 Duygu Analizi .....	4
2.1.1 Gözetimli makine öğrenimi temelli duygu analizi.....	5
2.1.1.1 Destek vektör makineleri algoritması .....	6
2.1.1.2 Naive bayes algoritması .....	6
2.1.1.3 Rastgele orman algoritması.....	7
2.1.1.4 Karar ağaçları algoritması .....	7
2.1.1.5 K-en yakın komşu algoritması .....	7
2.1.2 Yapay zekâ araçları ile duygu analizi openai.....	8
2.1.3 BERT .....	8
2.1.4 Model başarımlar ölçütleri.....	8
2.2 Doğal Dil İşleme .....	10
2.2.1 Metin temizleme .....	11
2.2.2 Tokenizasyon.....	11
2.2.3 Metin vektörleştirme.....	11
2.2.4 Durak kelimeler.....	12
2.3 Değerlendirme Anketleri .....	12
3. KAYNAK ÖZETLERİ .....	13
4. MATERYAL VE YÖNTEM .....	22
4.1 Aşama 1: Kavramsal ve Makine Öğrenmesi Modelinin Geliştirilmesi .....	22
4.1.1 Veri etiketleme .....	23
4.1.2 Veri ön işleme.....	24
4.1.3 Veri vektörleştirme.....	25

4.1.4 Gözetimli makine öğrenimi algoritmalarının eğitilmesi.....	26
4.1.4.1 Destek vektör makineleri.....	27
4.1.4.2 Naive bayes .....	29
4.1.4.3 Rastgele orman .....	30
4.1.4.4 Karar ağaçları .....	34
4.1.4.5 K-en yakın komşu .....	34
4.1.5 Dönüştürücü temelli çift yönlü kodlayıcı (BERT).....	36
4.1.6 OpenAI.....	36
4.1.7 Anketler ve algoritmalar.....	37
4.1.8 Nihai çıktı tasarımı.....	40
4.2 Aşama 2: Modelin Uygulanması ve Değerlendirilmesi.....	40
4.2.1 Duygu analizi.....	41
4.2.2 Anket ve duygu analizi sonuçlarının karşılaştırılması.....	41
4.2.3 Kelime bulutu ve konu modellemenin uygulamaları.....	42
4.2.4 Nihai raporun oluşturulması.....	43
5. BULGULAR VE TARTIŞMA .....	44
6. SONUÇ.....	47
KAYNAKLAR.....	49
EK 1 NİHAİ RAPOR.....	52
ÖZGEÇMİŞ.....	53

## KISALTMALAR DİZİNİ

ANN	Yapay Sinir Ağları (Artificial Neural Network)
ABSA	Duruma Dayalı Duygu Analizi (Aspect-Based Sentiment Analysis)
API	Uygulama Programlama Arayüzü (Application Programming Interface)
BERT	İki Yönlü Kodlayıcı Temsilleri ile Dönüştürücüler (Bidirectional Encode Representations from Transformers)
BiLSTM	Çift Yönlü Uzun Kısa Bellek (Bidirectional Long Short-Term Memory)
CNN	Evrışimsel Sinir Ağı (Convolution Neural Network)
COVID	Korona Virüs Hastalığı (Corona Virus Disease)
DB	Dağıtılmış Bellek (Distributed Memory)
DBOW	Dağıtılmış Kelime Torbası (Distributed Bag Of Words)
DNN	Derin Sinir Ağları (Deep Neural Networks)
DT	Karar Ağaçları (Decision Trees)
GRU	Kapılı Tekrarlama Ünitesi (Gated Recurrent Unit)
KNN	K En Yakın Komşu (K-Nearest Neighbour)
LTSM	Uzun Kısa Süreli Bellek (Long Short-Term Memory)
NB	Naive Bayes
RNN	Tekrarlayan Sinir Ağları (Recurrent Neural Network)
RF	Rastgele Orman (Random Forest)
SO-CAL	Anlamsal Yönelim Hesaplayıcı (Semantic Orientation Calculator)
SVM	Destek Vektör Makineleri (Support Vector Machines)
TF-IDF	Terim Frekansı – Ters Belge Frekansı (Term-Frequency-Inverse Document Frequency)

## ŞEKİLLER DİZİNİ

Şekil 2.1 Duygu analizi .....	5
Şekil 4.1 Ham veri setinden elde edilen kelime bulutu.....	22
Şekil 4.2 Makine öğrenimi aşamaları .....	23
Şekil 4.3 Veri ön işleme aşaması sonrası oluşan kelime bulutu .....	26
Şekil 4.4 Model uygulama adımları .....	41
Şekil 4.5 Nihai veriden elde edilen kelime bulutu .....	43
Şekil 5.1 Destek vektör makineleri algoritmasının eğitim değerleri.....	44
Şekil 5.2 Naive bayes algoritmasının eğitim değerleri .....	44
Şekil 5.3 Rastgele orman algoritmasının eğitim değerleri .....	45
Şekil 5.4 Karar ağaçları algoritmasının eğitim değerleri .....	45
Şekil 5.5 K-en yakın komşu algoritmasının eğitim değerleri .....	46

## ÇİZELGELER DİZİNİ

Çizelge 3.1 Karşılık matrisi.....	9
Çizelge 4.1 Etiketleme işlemi örneği .....	24
Çizelge 4.2 Durak kelimeler .....	25
Çizelge 4.3 Matris örneği.....	25
Çizelge 4.4 Kullanılan kütüphaneler.....	27
Çizelge 4.5 BERT kullanımı için gerekli kütüphaneler .....	36
Çizelge 4.6 BERT modeli kullanımı için gerekli kodlar .....	36
Çizelge 4.7 OpenAI ile duygu analizi için kullanılan kütüphane .....	37
Çizelge 4.8 Anket soruları.....	38
Çizelge 4.9 Model .....	39
Çizelge 4.10 Varsayılan duygu değerleri .....	39
Çizelge 4.11 Örnek sonuç karşılaştırması .....	40
Çizelge 4.12 Duygu analizi sonuçlarının doğruluk oranları .....	41
Çizelge 4.13 Örnek normalizasyon işlemi .....	42
Çizelge 4.14 Nihai veriye uygun hazırlanan konu modelleme sonuçları.....	43
Çizelge 5.1 OpenAI platformu ile duygu analizi bulguları.....	46

## 1. GİRİŞ

Eğitimde dijitalleşmenin adımları internetin hayatımıza girmesiyle başlamıştır. Kâğıt üzerinde yürütülen eğitim-öğretim süreçleri dijital ortama taşınmış ve erişimi olan herkes için bilgi alışveriş hızı artmıştır. Gelişen teknoloji ile birlikte artık günümüzde sadece internetten ziyade yapay zekâ teknolojilerinin kullanımının yaygınlaşması ile hayatımızdaki neredeyse tüm süreçlerde yapay zekanın etkisi olduğunu görmekteyiz. Kimi alanlarda yeni iş kolları yaratsa da kimi alanlarda bazı mesleklerin yok olmasına sebep olmaktadır. Gündelik hayatımızdaki süreçleri hızlandırarak istediğimiz bilgiye daha hızlı bir şekilde ulaşmamızı sağlayan bu yapı, ilerideki hayatımızda yaptığımız işleri de kolaylaştıracak ve geliştirecektir. Bu gelişimi hayatımızdaki süreçlere adapte etmek hayat konforumuzun artmasına neden olmaktadır. Sadece bir soru sorarak istediğimiz cevaplara anında ve herhangi bir araştırma yapmadan ulaşabilmek bu duruma bir örnektir. Geçmiş zamanlarda ihtiyacımız olan bir bilgiye ulaşmak için kütüphanelere gitmek, saatlerce okumak gerekirken günümüzde yapay zekâ teknolojileri sayesinde bu süreç için gerekli zaman çok kısalmıştır.

Sağlık hizmetleri, eğitim, finansal hizmetler, otomotiv endüstrisi, e-ticaret, savunma sanayi, üretim, oyun endüstrisi ve enerji sektörü gibi birçok alanda yapay zekâ uygulamaları kullanılmaktadır. Tıbbi teşhis, portföy yönetimi, otonom araçlar, ticarete talep tahmini gibi örnekler günümüzde en yaygın olarak kullanılan teknolojilerdir. Yapay zekâ birçok sektörde sürekli olarak yeni uygulama alanlarına uyarlanmaktadır.

Yapay zekâ teknolojileri, büyük veri analizinde de önemli bir rol oynamaktadır. Büyük veri, klasik veri işleme teknikleri ile yönetilemeyecek kadar büyük ve karmaşık veri kümesidir (Gandomi, 2015). Yapay zekâ bu büyük veriyi anlamlı ve kullanılabilir hale getirebilmek için çeşitli yöntemler/metotlar kullanmaktadır. Derin öğrenme, makine öğrenmesi ve doğal dil işleme gibi teknikler kullanarak veriler arasında bir ilişki ağı kurularak anlamlı hale getirilmesine yardımcı olmaktadır. Sektörde kullanılmak üzere kurumların stratejik karar alma süreçlerinde, üretim planlamalarında, satış stratejilerinde daha isabetli kararlar almasına yardımcı olabilmektedir. Büyük veri analizi, yöneticilerin daha isabetli ve veriye dayalı kararlar almasını sağlayarak işletmelerin rekabet gücünü

arttırmaktadır (McAfee, 2012). Bu analizlerden biri de Duygu Analizi olarak karşımıza çıkmaktadır. Duygu analizi sosyal medyadan, e-ticaret sitelerindeki ürün yorumlarından, kişisel değerlendirmelerden elde edilen verilerin analizini yaparak kurumlara insanların ne hakkında konuştuklarını, duygularını belirterek kurumlara ne doğrultuda hareket etmeleri konusunda karar verme sürecinde yardımcı bir araç olarak kullanılmaktadır. Duygu analizi, özellikle eğitim kurumlarında, öğrenci geri bildirimleri, eğitim kalitesinin iyileştirilmesi için kritik veriler sunmaktadır. Üniversitelerde uygulanan anketler, öğrenci memnuniyetini ve öğretim kalitesini ölçmek amacı ile uygulanan faaliyetlerden faydalanılabilir.

Çalışmanın yapıldığı üniversitede her yıl örgün olarak yaklaşık 25 binin üzerinde öğrenci bulunmaktadır. Eğitim ve öğretimin değerlendirilmesi kapsamında öğrenciler her dönem sonunda çoktan seçmeli ve açık uçlu anketler vasıtasıyla aldıkları dersin öğretim elemanını, öğretimin tasarımı ve uygulanmasını değerlendirmektedir. Özellikle açık uçlu soruların değerlendirilmesi yoğun iş gücü ve zaman gerektirmektedir. Ayrıca manuel olarak yapılan bu işlemler bazı önemli konularında gözden kaçabilmektedir. Bu kapsamda açık uçlu değerlendirme anketlerinin otomatik, etkin, verimli ve derinlemesine değerlendirilmesi için yöntem, teknik ve araçların kullanılması gerekmektedir. Bu amaç doğrultusunda açık uçlu anket sonuçlarının daha etkin bir biçimde değerlendirilebilmesi için duygu analizi yapılmıştır. Bu tezin amacı yükseköğretim kurumlarında kullanılan ders veya öğretim elemanı değerlendirme sistemlerine, makine öğrenmesi tabanlı yeni bir model önermektir. Bu doğrultuda nicel ve nitel veriler kullanarak, gözetimli makine öğrenmesi algoritmaları olan destek vektör makineleri, naive bayes, rastgele orman, karar ağaçları, k-en yakın komşu algoritmalarının yanı sıra BERT ve OpenAI teknolojilerini kullanarak bir model oluşturmaktadır. Bu model ile yapılan analizler sonucunda yazılan değerlendirmelerin duygu durumunu ve ne derece tutarlı olduğunu belirleyerek, öğrenci değerlendirmelerinin daha isabetli sonuçlar vermesini sağlayacaktır. Analizler doğrultusunda öğretim elemanın yürütmüş olduğu dersler ile ilgili olarak öğrencilerin açık uçlu sorularda belirttikleri yazılı görüşlerinin daha hızlı değerlendirilmesi sağlanacak böylelikle gerek öğretim elemanının gerekse kurum yöneticilerinin açık uçlu cevaplara ilişkin binlerce veriyi tek tek okumak zorunda kalmalarının önüne geçilecektir. Yapılan analizler sonucunda dersin veya öğretim elemanının ders işleyişi hakkında daha net

dönütler alabilecektir. Bu yaklaşım zamandan tasarruf sağlayarak değerlendirme sonuçlarının daha anlaşılır bir yapıya kavuşturulmasına yardımcı olacaktır. Ayrıca veri içerisindeki tutarsız yorum ve anket sonuçları nihai rapora katılmayacağından dolayı modelimizin çıktısı daha güvenilir ve geçerli olacaktır.

Tezin genel yapısı şu şekildedir: Bölüm 2’de ulusal ve uluslararası olmak üzere duygu analizi ile ilgili yapılan çalışmalar özetlenmiştir. Bölüm 3’te kavramsal olarak duygu analizi ve değerlendirme anketlerine değinilmiştir. Bölüm 4’te tezin yöntemine ve deneysel sonuçlarına yer verilmiştir. 5. bölümde ise tezin sonuçları ve gelecek çalışmalar değerlendirilmiştir.

## 2. KURAMSAL TEMELLER

### 2.1 Duygu Analizi

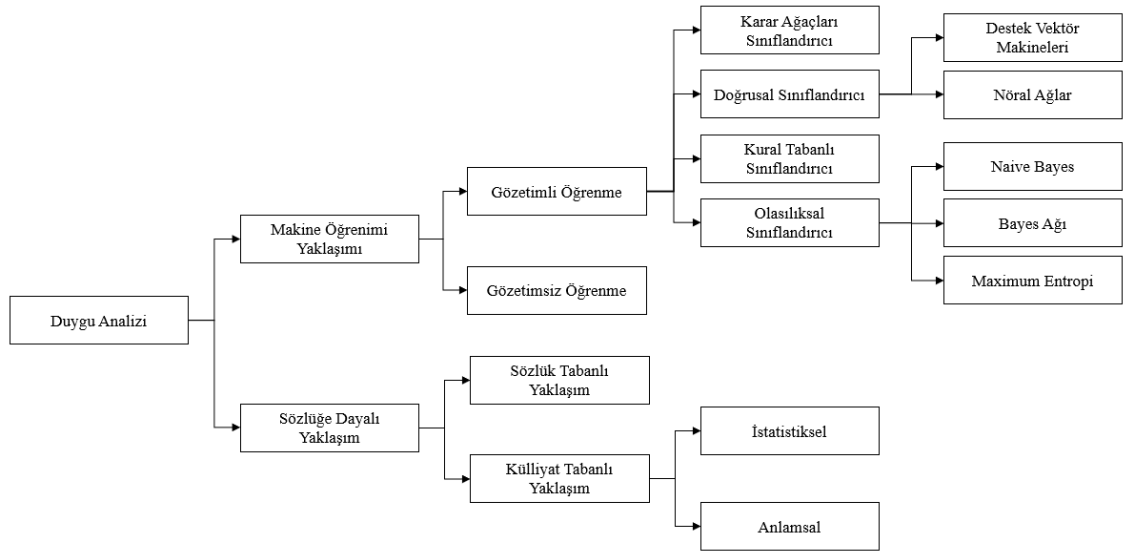
Duygu analizi temel anlamda, belirli bir metnin ifade etmek istediği duyguyu tespit etmeyi amaçlayan bir metin işleme sürecidir (Şeker, 2016). Bir başka deyişle fikir madenciliği olarak da adlandırılan duygu analizi insanların ürün, hizmet, birey vb. konulara yönelik görüşlerini, duygularını, değerlendirmelerini analiz eden çalışma alanıdır (Liu, 2022). Duygu analizinin birçok farklı ismi ve görevi mevcuttur. Bunlar, literatürde duygu analizi, fikir madenciliği, duygu çıkarımı, duygu madenciliği, öznellik analizi, duygu analizi ve inceleme madenciliği olarak yer almaktadır (Liu, 2022).

İnsanların herhangi bir konu hakkındaki düşünceleri, fikirleri, duyguları dünya üzerindeki her konuda öneme sahiptir. Bu düşünceler gündelik hayatımızdaki iş yapış biçimlerimizi dahi etkilemektedir. İnsanlar arasındaki etkileşim yazılı, sözlü olabileceği gibi sanatsal, geleneksel, mimikler ve hareketler ile birçok alternatif yol mevcuttur. Ancak zaman içerisinde insanların duygularını aktarma biçimleri değişmiştir. Eski zamanlarda sadece fiziksel olarak ulaşılabilen kişiler ile veya mektup vb. yazılı belgeler ile insanlar ile etkileşim sağlarken gelişen teknoloji bizlere çok farklı imkânlar tanımıştır. Özellikle Web 3.0'ın hayatımıza girmesi ile insanlar arasında küresel boyutlarda etkileşim artmıştır. Günümüzde insanların duygularını ifade etmek ve diğer insanlar ile etkileşime geçmek için çok farklı imkânları mevcuttur. Bu imkânların başında şüphesiz internet ve sosyal medya platformları gelmektedir. Sosyal medya içerisinde kişiler duygu ve görüşlerini ifade ederek aynı anda birçok kişiye ulaşabilmekte ve onlar ile etkileşime girebilmektedir. Öyle ki günümüzde kamu kurum ve kuruluşları dahi duyurularını, açıklamalarını sosyal medya hesapları üzerinden yapmaktadır.

Duygu analizi, metinleri 3 farklı başlık altında sınıflamaktadır. Metin üzerinde analiz işlemi yapıldıktan sonra duygu durumuna göre olumlu, olumsuz veya nötr olmak üzere 3 farklı sonuca ulaşılabilmektedir. Sonuçların tutarlı biçimde elde edilebilmesi için metin içerisinde duygu ögesi barındırmayan unsurların veri setinden çıkarılması gerekmektedir. Bu durum Türkçe üzerinde yapılan analizleri zorlaştırmaktadır. Türkçe sondan eklemeli

bir dil olduğu için kelimenin sonuna eklenen bir hece dahi duygu durumunu değiştirebilmektedir.

Duygu analizi yöntemlerini temelde Makine Öğrenmesi Yaklaşımları ve Kural Tabanlı Yaklaşımlar olarak 2 başlık altında toplayabiliriz. Makine öğrenimi tabanlı duygu analizi, sınıflama algoritmaları ile eğitilip tahmin yapmak üzerine inşa edilmiştir. Kural tabanlı yaklaşımlar ise metinler ile ilişkilendirilmiş bir sözlük kullanarak metnin duygusunu belirlemeye çalışmaktadır (Medhat vd. 2014).



Şekil 2.1 Duygu analizi (Medhat vd. 2014)

### 2.1.1 Gözetimli makine öğrenimi temelli duygu analizi

Makine öğrenmesi yapay zekâ alanının önemli bir alt dalıdır ve bilgisayar sistemlerinin veri yoluyla öğrenme ve keşif yapma yeteneğini araştıran bir disiplindir (Mitchell, 1997). Makine öğrenmesi bilgisayarlara öğrenme kabiliyeti kazandıran bir yapay zekâ tekniğidir. Makine öğrenmesi ile ilgili araştırma konuları genellikle bilgisayarlara karmaşık verileri algılatma ve bu veriler ışığında karar verme yeteneği kazandırma yönündedir. Makine öğrenmesi, bilgisayarlara eğitebilen ve yeni gelen veriler ile kara yapısını değiştirerek daha akılcı çıktılar üretebilen programların geliştirilmesi üzerinde yoğunlaşmaktadır. Algoritmayı eğitmek amacı ile kullanılacak veri ne kadar çok ise o algoritma ile

geliştirilen bir program o kadar isabetli çıktılar üretebilmektedir. Algoritma eğitiminin en temel yaklaşımlarından biri gözetimli makine öğrenmesidir. Bu öğrenmede algoritma, veri kümesindeki girdi-çıkı ilişkilerini keşfetmeye yönelik bir öğrenme süreci izler. Eğitim aşamasında, algoritmaya etiketlenmiş veriler sunulur, başka bir ifade ile girdi verileri ve bu verilere karşılık gelen hedef çıktılar beraber verilir. Bu adım, algoritmanın verilerindeki desenleri tanımlayabilmesini sağlar (Mitchell, 1997). Desenlerin tanımlanmasından sonra algoritmalar eğitilerek test aşamasına geçirilir. Destek Vektör Makineleri, Naive Bayes, Karar Ağaçları, Rastgele Orman algoritmaları gözetimli makine öğrenimi algoritmalarına örneklerdir.

### **2.1.1.1 Destek vektör makineleri algoritması**

Destek vektör makineleri Cortes ve Vapnik (1995) tarafından geliştirilmiştir. İstatistiksel öğrenme modeline dayalı bir gözetimli makine öğrenmesi modelidir. Doğrusal (lineer) ve doğrusal olmayan (nonlineer) sınıflandırma ve regresyon problemleri için kullanılan bir makine öğrenimi modelidir. Bir destek vektör makinesi modeli verileri birçok sınıfa bölmek için bir hiper düzlem oluşturarak bu sınıfları birbirinden ayırt etmeye çalışmaktadır.

### **2.1.1.2 Naive bayes algoritması**

Naive Bayes algoritması, olasılık tabanlı ve sınıflandırma problemleri için kullanılan basit ancak etkili bir gözetimli makine öğrenimi algoritmasıdır. Her bir özelliğin sınıfları belirleme aşamasında katkısı olduğu varsayılır. Algoritma Bayes teoremi kullanarak çalışmaktadır. Bayes teoremi, olasılıkların birbirlerine olan bağlantılarını ifade etmektedir. Sınıflandırmanın amacı her bir eleman için olasılıkları hesapladıktan sonra en yüksek olasılık değerine sahip olan değere göre sınıflama işlemini gerçekleştirmektedir.

### **2.1.1.3 Rastgele orman algoritması**

Rastgele orman algoritması, torbalama metodu ile eğitilmiş karar ağaçlarının bir araya gelmesiyle bir orman oluşturan denetimli makine öğrenmesi algoritmasıdır. Genellikle sınıflandırma ve regresyon problemlerinde kullanılmaktan olan rastgele orman algoritması duygu analizi için de sıkça kullanılmaktadır. Rastgele Orman Algoritması her algoritma gibi verinin özniteliklerine göre kendi kararını vererek sınıflandırma yapmaktadır. En çok üyeye sahip ağaç ise son kararı belirlemektedir. Sınıflama işlemi tamamlandığında kararlar birleştirilerek sonuç ortaya çıkmaktadır. Bu durum algoritmanın güvenilirliğini arttırmaktadır. Algoritmanın parametreleri ile birçok eşik, düğüm sayısı vb. değer ayarlanabilmektedir.

### **2.1.1.4 Karar ağaçları algoritması**

Karar ağaçları algoritması, genellikle sınıflama problemlerinde kullanılmakta olup veriyi sınıflandırmak için etiketlenmiş özelliklere dayanan bir yaklaşımdır. Veri setinin özniteliklerine göre alt düğümlere ayrılarak bir ağaç oluşturmaktadır. Ağaçların altındaki düğümler verinin her bir özneliğini, düğümlerin altındaki değerler ise o özneliğe ait bir değeri ifade etmektedir. Veri seti algoritma yardımı ile sürekli bölünerek dalları ve düğümleri oluşturmaktadır. Algoritma, veri türü ayrımı yapmadan etkili bir sınıflama performansı sunmaktadır. Duygu analizi için tercih edilen bir algoritmadır.

### **2.1.1.5 K-en yakın komşu algoritması**

K-En Yakın Komşu Algoritması, veri setindeki özniteliklerin benzerliklerine dayanarak tahminler yapmaktadır. Genellikle sınıflandırma problemlerinde kullanılmakta olup regresyon konularında da kullanılmaktadır. Çeşitli parametreler ile komşu sayısı, gözlem değerleri belirlenerek algoritma tasarlanır. Devamında bir nokta ile oluşturulan komşular arasındaki mesafeye bakılarak bir uzaklık listesi oluşturulur. Örneğin bir noktanın sınıfını belirlemek istiyorsak diğer noktalar ile arasındaki mesafeye bakarak bu işlemi yapabiliriz. Mesafe olarak en kısa olan noktanın aynı sınıf içerisinde olması olasıdır.

### **2.1.2 Yapay zekâ araçları ile duygu analizi openai**

OpenAI platformu altında birçok analiz yapay zekâ yardımı ile yapılabilmektedir. Mevcut platform altında birçok motor bulunmakta ve ihtiyaca göre bir API yardımı ile kullanılabilir. API ile iletişim kurulduktan sonra kod yardımı ile bir sorgulama işlemi yapılarak cevap alınabilmektedir. Duygu analizi içinde bu yapay zekâ araçları kullanılabilir.

### **2.1.3 BERT**

Devlin vd. 2018 yılında BERT’i tanıtmışlardır. “Transformatörlerden Çift Yönlü Enkoder Gösterimleri” anlamına gelen BERT metinleri anlamlandırmak ve işlemek için kullanılan bir dil modelidir. BERT’i diğer dil modellerinden ayıran en belirgin özelliği kelimenin anlamını sadece o kelimenin temel anlamı ile kısıtlamayı bulduğu bağlamı dikkate alarak anlamlandırmasıdır. Bu bağlam bir cümle, bir paragraf veya belgenin tümü olabilir. BERT maskeli bir dil modeli olarak da bilinmektedir, modelde kelimenin tahmin edilmesi soldan sağa ve sağdan sola olmak üzere iki yönlü olarak yapılmaktadır (Wiedemann vd. 2019).

BERT modeli daha önceki eğitilmiş modellerdir. Bundan dolayı yapılan analizler de veri seti küçük olmasına rağmen başarılı sonuçlar üretebilmektedir. Model gereği veriler çok detaylı olarak incelenmektedir. Hem kelime bazında hem de bağlam bazında kullanılan vektörlerin birbirleri ile karmaşık ilişkileri vardır. Bu sebepten dolayı BERT verilere çok duyarlı olarak yaklaşmaktadır.

### **2.1.4 Model başarımları ölçütleri**

Eğitilen algoritmaların başarımları değerlendirilirken kullanılan birçok terim mevcuttur. Bu terimler bize modelin ne derecede doğru eğitildiğini göstererek güvenilirliğini saptamamıza olanak sağlamaktadır. Eğitim aşamasında sonra test verisi ile yapılan

analizler sonucunda elimizde doğruluk, kesinlik, duyarlılık ve f-skoru değerleri gelmektedir.

Çizelge 3.1 Karşılık matrisi

	Pozitif	Negatif
Pozitif	TruePositive	FalseNegative
Negatif	FalsePositive	TrueNegative

- True Positive: Gerçekte ve tahminde pozitif olan sayı
- False Negative: Gerçekte pozitif ancak tahminde negatif olan sayı
- False Positive: Gerçekte negatif ancak tahminde pozitif olan sayı
- True Negative: Gerçekte ve tahminde negatif olan sayı

Sınıflandırma tahmin performanslarını değerlendirebilmemiz için Çizelge 3.1'deki değerlere ihtiyacımız vardır. Bu değerler doğrultusunda doğruluk, kesinlik, duyarlılık ve f-skorları incelenmektedir. Sütunlar tahminleri satırlar ise gerçek değerleri ifade etmektedir.

Doğruluk: Modelin başarısını ölçmekte kullanılan en yaygın yöntemdir. Doğru tahminleri tüm tahminlere oranlayarak bulunan bir değerdir.

$$\text{Doğruluk} = \frac{\text{TruePositive} + \text{TrueNegative}}{\text{TruePositive} + \text{FalsePositive} + \text{FalseNegative} + \text{TrueNegative}}$$

Kesinlik: Sınıflama işleminde pozitif olarak tahmin edilmiş 'TruePositive' örnek sayısının, tahmin edilmiş tüm doğru örnek sayısına oranını temsil etmektedir.

$$Keskinlik = \frac{TruePositive}{TruePositive + TrueNegative}$$

Duyarlılık: Duyarlılık oranı 'TruePositive' deęerinin, 'TruePositive' ve 'FalseNegative' deęerleri oranlandığında elde edilmektedir.

$$Duyarlılık = \frac{TruePositive}{TruePositive + FalseNegative}$$

F1-Skoru: Duyarlılık ve kesinlik deęerlerinin harmonik ortalamasıdır. Duyarlılık ve kesinlik deęerlerinin de iyi olduęu durumlarda yüksek deęer almaktadır.

$$F = \frac{2 * Duyarlılık * Keskinlik}{Duyarlılık + Keskinlik}$$

## 2.2 Doęal Dil İşleme

Doęal dil işleme, dilin matematiksel olarak modellenerek bir anlam çıkarılmasını ifade etmektedir. Konu ile ilgili ilk çalışmalar bilgisayar ile iletişime geçmek amacı ile yapılmaktaydı ancak zamanla konuşulan, yazılan tüm verileri anlamlandırmaya ve deęerlendirmeye çalışılmıştır (Adalı, 2012). Bilgisayarların insanların dilinden anlaması ve insanlar ile iletişim içerisinde olabilmeleri için doęal dil işleme tekniklerini kullanmaları gerekmektedir (Seker, 2015). Doęal dil işlenmenin kendine özgü temel kurallarını çözümleyerek, daha anlaşılabilir bir yapıya sokması amacını barındırmaktadır. Günümüzde sohbet botlarında, otomatik çeviri araçlarında, soru-cevap mantığı ile çalışan tüm web unsurlarında ve duygu analizi gibi birçok alanda doęal dil işleme teknikleri kullanılmaktadır.

Doęal dil işlemenin temel amacı, bilinçli bir planlama olmaksızın zaman içerisinde tekrar edilerek evrimleşmiş doęal(tabii) dilleri anlama, yorumlama, analiz etme ve cevaplama eylemlerini gerçekleştirmek ve bilgisayar tarafından anlaşılabilir hale getirmektir. Doęal

dil işleme alanının veri kaynaklarına sosyal medya uygulamalarında bulunan metinler, çevrimiçi platformlardaki kullanıcı yorumları, insanlar ile etkileşime geçebilen sohbet botları, arama motorlarının daha iyi sonuçlar vermesi için yapılan çalışmalar gibi birçok alanda örnekler verilebilir. Bu noktada “Külliyat” (lexicon) kavramı önem kazanmaktadır. Doğal dil işleme esnasında kullandığımız tüm cümleler, kelimeler, paragraflar bizim külliyatımızı oluşturmaktadır. Doğal dil işleme konusunda için birçok teknik ve yöntem vardır. Bunlar yapılan çalışmaya göre değişiklik gösterebilmektedir. Bazı teknikler yapılacak olan analizlerden önce veya sonra kullanılabilen ve veri ön işleme adımları olarak geçmektedir.

### **2.2.1 Metin temizleme**

Veriler işlenmeye başlanmadan önce yapılan bir hazırlık aşamasıdır. Metin içerisindeki semboller, boşluklar, HTML başlıkları gibi analiz esnasında hatalı sonuçlar doğurabilecek etmenleri ortadan kaldırmak için yapılmaktadır. Temizleme sonrasında metin işlenmeye daha uygun bir yapıda olmaktadır.

### **2.2.2 Tokenizasyon**

Metinleri daha küçük parçalara ayırmak için kullanılan temel bir adımdır. Metinleri cümlelere, kelimelere veya daha küçük parçalara ayırmaktadır. Örneğin “İyi Günler!” metnini tokenlere böldüğünde [“İyi”, “Günler”, “!”] şeklinde bir demet elde etmektedir. Bu aşamanın amacı yapılacak duygu analizine göre verimizi hazırlamaktır. Analiz cümle bazında yapılacak ise bu aşamada veriler kelime olarak değil, cümle olarak bölünmelidir.

### **2.2.3 Metin vektörleştirme**

Kelimeleri sayısal vektörler şeklinde işlenmesi anlamına gelmektedir. Bu sayede kelimenin diğer kelimeler ile olan ilişkisi daha net anlaşılabilir. Benzer bağlamlarda kullanılan kelimeler bu işlem ile daha kolay bir şekilde tespit edilerek gerekli işlemlerde daha hızlı sonuçlar elde edilmesini sağlamaktadır. Bu işlem makine öğrenmesi

algoritmaları için önem teşkil etmektedir. Bir kelimededen sonra başka bir kelimenin kaç defa arka arkaya geldiğini hesaplayarak bir vektör oluşturulmaktadır. Bu vektörlere göre tahmin veya analiz yapılabilmektedir.

#### **2.2.4 Durak kelimeler**

Bu tür kelimeler metin içerisinde genel akışı düzenlemek amacı ile kullanılan ancak ana fikre bir etkisi olmayan kelimelerdir. Örnek olarak “bu”, “ve”, “bazı”, “aslında” verilebilir. Cümleyi anlamak için önemli olsalar dahi ancak veri analizi esnasında makine için önemli kelimeler değildir. Analiz esnasında işlem hızını pozitif yönde etkilemesi amacı ile analiz öncesinde bu kelimelerin metin içerisinden çıkartılması gerekebilmektedir. Durak kelimelerin cümle içerisinde tespiti için dil bazında hazır sözlükler de kullanılmaktadır ancak yapılacak analize ve dile olan hakimiyete göre gerekli durak kelimeler eklenebilir veya çıkartılabilir.

### **2.3 Değerlendirme Anketleri**

Eğitim kurumunun kalitesinin yüksek olabilmesi için, kurum içerisindeki en önemli işlev olan öğretim işlevinin niteliğinin yüksek olması gerekmektedir. Şüphesiz bu niteliği azaltıp/arttırabilecek kişilerde öğretmenler/öğretim elemanlarıdır. Çoğunlukla yüksek öğretim kurumlarında kullanılan performans değerlendirme anketleri öğrencilerin aldıkları dersleri ve derslerin öğretim elemanlarını değerlendirmelerine olanak tanımaktadır. Öğrenciler tarafından doldurulan anket sonuçları ise nitel veya nicel olabilmektedir. Sonuçlar incelendiğinde öğretim elemanlarının performansları hakkında bir fikir edinilebilir. Bu durum kurumda verilen eğitimin kalitesini gözler önüne sermektedir. Ancak öğrenci değerlendirmelerinin güvenilirliği tartışılmaktadır, yapılan değerlendirmeleri, öğrenci tarafından öğretim elemanı veya ders ile alakası olmaksızın yapılan değerlendirmeyi etkileyen dersi sevme, ön yargı, not beklentisi, öğrencinin dersi seçme amacı, öğretim elemanının cinsiyeti gibi birçok unsur vardır (Yurtkoru vd. 2001).

### 3. KAYNAK ÖZETLERİ

Literatür incelendiğinde duygu analizi ile ilgili yapılan çalışmalar aşağıdaki gibidir:

Jimmy ve Prasetyo (2022) araştırma çalışmalarında lisans öğrencilerinin öğretim davranışlarına ilişkin geribildirimleri sınıflandırmak için duygu analizi kullanılmıştır. Bu amaç doğrultusunda Endonezya'da bulunan bir yükseköğretim kurumundan verileri toplanmıştır ve Naive Bayes, Destek Vektör Makineleri ve Karar Ağaçları olmak üzere 3 farklı duygu analizi yöntemi ile değerlendirilmiştir. Bu metinler arasında Endonezce metinlerde en iyi sonuç veren yöntemin Destek Vektör Makinesi yöntemi olduğu sonucuna ulaşılmıştır.

Almosawi ve Mahmood (2022) öğrencilerin geri bildirimlerini pozitif ve negatif olduğunu belirlemek için bir sözcük temelli bir duygu analizi yaklaşımı geliştirmiştir. Açık uçlu bir elektronik anket aracılığı ile veriler toplanmıştır. Veri setinde farklı Arap lehçelerinde mevcuttur. Araştırmada Naive Bayes, Destek Vektör Makineleri ve k-En Yakın Komşu makine öğrenme algoritmaları kullanılmıştır. Bulguların 60% oranında olumlu, %40 oranında olumsuz olduğu ortaya çıkmıştır.

Baragash vd. (2022) üniversite öğrencilerinin e-öğrenme sistemlerinin kalitesine ilişkin görüşleri hakkında bilgi edinmek amacı ile Twitter üzerinden topladıkları veriyi analiz etmişlerdir. Öğrencilerin görüşlerini sınıflandırabilmek amacı ile duygu analizi tabanlı makine öğrenmesi modeli olan Destek Vektör Makineleri algoritmasını kullanmışlardır. Algoritmanın doğruluğunu belirlemek için de veri madenciliği ve veri analizi için kullanılan açık kaynaklı bir yazılım olan RapidMiner'ı kullanılmıştır. Çalışmanın bulguları 65% oranında olumlu olarak sınıflandırılması sebebiyle öğrencilerin e-öğrenme sistemlerini hakkında olumlu düşünceye sahip olduğu sonucuna ulaşılmıştır.

Umair vd. (2021) pandemi öncesinde ve sonrasında yapılan öğrenci değerlendirmelerinin karşılaştırmalı bir analizini gerçekleştirilmiştir. Bu araştırmanın amacı öğrenci geri bildirimlerine dayanarak duygu analizine yönelik karma bir yaklaşım sunmaktır.

Verilerini Google formları (Google Forms) ve sosyal medya platformları aracılığıyla toplanmıştır. Ardından sınıflandırma için denetimli makine öğrenmesi algoritmalarından Naive Bayes ve Destek Vektör Makineleri algoritmalarını kullanılmış ve K-Fold çapraz doğrulamalı Destek Vektör Makineleri algoritmasının ortalama %85,62 oranında doğruluk elde edilmiştir. Ayrıca pandemi esnasında yürütülen çevrimiçi eğitimdeki öğrenci değerlendirmelerinin, örgün eğitim dönemine kıyasla daha olumsuz olduğu ortaya çıkmıştır.

Jiménez (2021), öğrencilerin öğretim elemanları performansları hakkındaki yorumlarına yönelik bir duygu analizi modelini araştırmıştır. Araştırmada ilk olarak üniversitenin öğrencilerine bir anket gönderilmiştir ve öğrencilerin geri bildirimlerini Transformatörlerden Çift Yönlü Enkoder (BERT) kullanarak analiz edilmiştir. Daha sonra aynı modeli pandemi öncesi ve sonrası olarak 2 farklı senaryoda uygulamıştır. Sonuçlar profesörlerin çevrimiçi derslerdeki performansını yüz yüze derslere göre daha iyi değerlendirdiğini göstermektedir.

Mabunda vd. (2021) öğretme ve öğrenme etkililiğini değerlendirmek için öğrenci geri bildirimlerini analiz etmek amacı ile bir duygu analizi model geliştirmiştir. Verilerini veri bilimi ve yapay zekâ alanında bir platform olan Kaggle'dan elde edilmiştir. Bu veri seti üzerinde çeşitli makine öğrenimi modellerini eğittikten sonra veriler tekrardan örneklendirilmiştir. K En yakın komşu modelinin, öğretim uygulamalarına yönelik öğrenci duygularını tahmin etmede diğer modellere göre %81'lik bir doğruluk oranıyla daha iyi doğrulukta olduğu bulunmuştur. Verilerin yeniden örneklenmesinin ardından ise Sınır Ağları %84'lük bir doğrulama oranıyla daha iyi bir performans göstermiştir.

Xu vd. (2019), geleneksel kelime frekansı-ters doküman frekansı (TF-IDF) algoritmasının içine duygu bilgisinin katkısını entegre eden ve ağırlıklı kelime vektörleri üreten geliştirilmiş bir kelime temsili yöntemi önermektedir. Mevcut duygu analizi teknolojisi, yapay zekânın bir parçasıdır ve yorumların duygu eğilimini elde etmek için oldukça anlamlı bir konudur. Duygu analizinin özü metin sınıflandırma görevidir ve farklı kelimeler sınıflandırmaya farklı katkılar sağlanmaktadır. Önerilen yöntem, geleneksel kelime frekansı-ters doküman frekansı algoritmasıyla birleştirir ve ağırlıklı kelime

vektörleri oluşturmaktadır. Bu vektörler, bağlantılı uzun ve kısa dönemli hafıza (BiLSTM) modelini besleyerek yorumların duygusal eğilimini daha iyi ortaya çıkarmaktadır. Önerilen yöntem, diğer duygu analizi yöntemleriyle karşılaştırıldığında daha yüksek kesinlik ve f-skorlarına sahiptir.

Jianqiang vd. (2018) büyük bir Twitter veri kümesi üzerinde gözetimsiz öğrenme ile elde edilen bir kelime gömme yöntemini tanıtmıştır. Mevcut araştırmalar, duygusal özellikleri elde etmeye odaklanmakta, leksikal ve sentaktik özellikleri analiz ederek duygusal kelimeler, ifadeler, ünlem işaretleri gibi açıkça ifade edilen metinsel özellikleri elde edilmektedir. Bu yöntem kelimeler arasındaki anlamsal ilişkileri ve tweetlerdeki kelimelerin birlikte geçme özelliklerini kullanmaktadır. Bu kelime gömme özellikleri, n-gram özellikleri ve kelime özelliklerini kullanmaktadır ve duygu durum skorunu özellikleriyle birleştirerek tweetlerin duygu özellik setini oluşturmaktadır. Bu özellik seti, derin sinir ağına eğitilir ve duygu sınıflandırma sonuçlarını tahmin edebilir. Model, kelime n-gram modeli ile karşılaştırıldığında daha iyi doğruluk ve F1 ölçüsü sonuçları elde etmektedir.

Chen vd. (2017) cümleleri farklı türlere göre sınıflandıran, devamında her türden cümleler üzerinden duygu analizi yapan “Böl ve Fethet” modeli önerilmiştir. Birden fazla duygu durumu olan cümleler daha karmaşık anlamlar ifade edebilir ve farklı cümle türlerini duyguları çok farklı bağlamlarda ifade edebilmektedir. Bu nedenle cümleleri üç tipe sınıflandırarak sinir ağı tabanlı bir model uygulama önerilmiştir. Her cümle grubu duygu sınıflandırması için ayrı ayrı tek boyutlu bir Evrişimsel Sinir Ağını beslemektedir. Deneysel sonuçlar cümle türü sınıflandırmasının duygu analizinin performansını arttırabildiğini göstermektedir.

Hassan vd. (2016) SentiCircles adlı bir sözlük tabanlı yaklaşım sunmaktadır. Klasik sözlük tabanlı yöntemlerden farklı olarak SentiCircles kelimelerin tweetlerde farklı bağlamlarda bir araya gelme desenlerini dikkate alarak anlam yapılarını yakalar ve duygu hazinelerinde önceden belirlenmiş kalıpları güncellemektedir. Bu yaklaşım sayesinde hem mevcut varlık düzeyinde hem de tweet düzeyinde duygu tespit etmek mümkün olmaktadır. Önerilen yöntem üç farklı duygu hazinesi kullanarak üç Twitter veri seti

üzerinde değerlendirildi. Sonuçlar, yöntemin temel yöntemlere göre doğruluk ve f-skoru açısından önemli ölçüde üstün olduğunu göstermektedir.

Akgül vd. (2016) çalışmalarında, Duygusal Twitter isminde bir yazılım geliştirmiş ve bu programı farklı yöntemler ile değerlendirmiştir. Duygusal Twitter programı, basit arayüzü ve kullanım kolaylığı sayesinde hem bireysel hem de kurumsal amaçlar doğrultusunda rahat bir kullanıcı deneyimi sunmaktadır. Twitter'dan aldığı veriyi hızlı bir şekilde analiz ederek, raporlayabilen bir programdır. Çalışmada hem sözlük tabanlı hem de n-gram yöntemleri geliştirilmiş ve kullanılmıştır. Sözlük tabanlı yaklaşım n-gram modeline göre daha pozitif sonuçlar ortaya çıkarılmıştır.

Fang ve Zhan (2015) duygu durumu kategorizasyonu problemini çözmeyi amaçlamıştır. Açık kaynak makine öğrenmesi yazılımı kullanılmıştır ve birçok algoritma kullanılmıştır. Kullanılan veriler bir web sitesinden alınan çevrimiçi ürün incelemeleridir. Hem cümle düzeyinde kategorizasyon hem de inceleme üzerinde kategorizasyon için olumlu sonuçlar elde edilmiştir.

Gitari vd. (2015), çalışmasında web formları ve bloglar gibi web söylemlerinde tespit edilmesi amacıyla kullanılacak bir sınıflandırıcı fikrini inceledi. Nefret söylemi problemi ırk, ulusal köken ve din gibi üç ana tematik alana ayrılmıştır. Araştırmanın hedefi duygu analizi tekniklerini kullanarak verilen bir cümlenin duygu durumunu belirlemek ve derecelendirmek için bir model sınıflandırıcı oluşturmaktır. İlk adım olarak, belge boyutunda objektif cümleler çıkarılmıştır. Daha sonra, nefret söylemi ile ilgili öznel ve anlamsal özellikleri kullanılarak, nefret söylemi tespiti için bir sınıflandırıcı inşa etmek amacı ile bir kelime hazinesi oluşturulmuştur. Nefret korpusu ile gerçekleştirilen deneyler, gerçek dünya web söylemleri için pratik uygulamaları yansıtmaktadır.

Kim (2014) önceden eğitilmiş kelime vektörleri temel alınarak geliştirilen Evrişimsel Sinir Ağlarını, cümlenin seviye sınıflandırma görevlerindeki performansını incelediği bir dizi deneyi detaylandırmıştır. Az miktarda parametre ayarı ve sabit vektörler kullanılarak dahi, basit bir Evrişimsel Sinir Ağı modelinin olağanüstü sonuçlar elde etme yeteneğini

vurgulamıştır. Görev özgü vektörlerin fine-tuning yöntemi ile öğrenilmesi, işlem performansında daha büyük gelişmelere olanak sağlamıştır.

Kiritchenko vd. (2014) yeni bir duygu analizi sistemi tanıtmışlardır. Bu sistemin, kısa metinlerin duygusunu belirlemede etkili olduğu görüşmüştür. Sistem aynı zamanda bir mesaj içerisindeki bir kelimenin ifadesini veya duygusunu tespit edebilmektedir. Metin sınıflandırma konusunda betimsel istatistik kullanılmıştır. Bu sistem duyarlılık özelliklerini, öncelikle yeni ve yüksek kapsamlı tweetlerden elde ettiği duygulu sözlüklerden elde etmektedir. Bu sözlükler etiketler veya ifade simgeleri içeren tweetlerden oluşmaktadır. Olumsuz bağlamdaki duyguları yakalamak için ayrı bir duygu sözlüğü oluşturulmuştur. Otomatik olarak oluşturulan sözlüklerin kullanımı, genel performansta belirgin bir artış sağlamıştır.

Wöllmer vd. (2013), film incelemeleri içeren çevrimiçi videolarda konuşmacının duygusunu otomatik olarak analiz etmeye odaklanmıştır. Metinsel bilgilerin yanı sıra, bu yaklaşım konuşma tabanlı duygu tanıma için tipik olarak kullanılan ses özelliklerini ve konuşmacının ilettiği değerli valans bilgisini kodlayan video özelliklerini eklemeyi içermektedir. Yapılan deneyler, yazılı film incelemeleri üzerinde eğitim vermenin, konuşulan film incelemesi videolarını analiz eden bir sistem oluşturmak için yalnızca alana özgü veri kullanımına alternatif umut vadeden bir yol olduğunu ve dil bağımsız ses-görsel analizin dil analizi ile rekabet edebileceğini göstermektedir.

Thelwall vd. (2012) duygu gücü tespiti için özellikle duygunun doğrudan işaretlerini kullanan SensiStrength algoritmasının geliştirilmiş bir versiyonunu değerlendirilmiştir. 6 farklı veri setinden (Twitter, YouTube, Digg, Runners World, MySpace, BBC Forums) elde edilen sonuçlar SentiStrength 2'nin tüm veri setleri için temel bir yaklaşıma kıyasla daha iyi bir performans sergilediğini göstermiştir.

Taboada vd. (2011) metin içinden duygu çıkarımı konusunda bir sözlük tabanlı yaklaşım sunmuşlardır. Semantik Yönetim Hesaplayıcı (SO-CAL), anlamsal yönelimleriyle birlikte açıklamalı kelimelerin sözlüklerini kullanır ve yoğunlaştırma, olumsuzlamayı içermektedir. Semantik yönetim hesaplayıcı, metnin ana konusuna yönelik görüşünü

yakalayarak metne olumlu veya olumsuz bir etiket atama süreci olan polarite sınıflandırma görevini uygulamaktadır. Semantik yönetim hesaplayıcının performansının etki alanları arasında tutarlı olduğu görülmüştür.

Wilson ve Hoffmann (2009) duygu analizi işleminde tümce düzeyinde çalışmalar yapmıştır. Otomatik duyarlılık analizi çalışmaları, genellikle bir kelimenin duygusal anlamını tespit etmek için geniş bir kelime sözlüğü kullanmaktadır. Ancak bir kelimenin belirli bir bağlam içindeki anlamını, genel anlamdan farklı olabilmektedir. Örnek olarak anlamca olumsuz ancak bağlam içerisinde biçimce olumlu kelimeler verilebilir. Birden fazla makine öğrenimi algoritması yapılan değerlendirmeler sonucunda ortaya çıkan en iyi sonucun tüm özelliklerin birleşimini kullanılmasıyla elde edildiği saptanmıştır. Nötr örneklerin varlığının, pozitif veya negatif duygusal tonları ayırt etme performansını nasıl etkilediği gözlemlendi ve performansı düşürdüğü tespit edilmiştir.

Boiy ve Moens (2009), internet üzerinde bulunan İngilizce, Flemenkçe ve Fransızca dillerinde yazılmış, blog, inceleme ve forumlardan elde edilmiş metinler üzerinde duygu analizi yapan makine öğrenimi yöntemi sunmaktadır. Manuel etiketleme işlemi için etkin bir öğrenme tekniği çalışılmıştır. Öncelikle belirli bir varlıklar ilgili olumlu, olumsuz veya nötr ifadeler manuel olarak etiketlenerek örnek cümlelerden öğrenilen sınıflandırma modelleri kullanılmıştır. Giriş metinlerinin gürültülü yapısı, duygu atama ve küçük eğitim kümesi gibi sorunlarla başa çıkılmıştır. İngilizce metinlerin %83, Hollandaca metinlerin %70 ve Fransızca metinlerin %68 doğrulukla duyguları tespit edebilmiştir. Modelin farklı alanlar ve diller arasında taşınabilirliği incelenmiştir.

Türkçe metinler üzerinde uygulanan duygu analizi temelde makine öğrenimi tabanlı ve sözlük tabanlı ve çok az sayıda da olsa hem makine öğrenimi hem de sözlük tabanlı olmak üzere hibrit modeller çalışılmıştır. Literatür incelendiğinde makine öğrenimi tabanlı yapılan çalışmalar sözlük tabanlı yapılan çalışmalara göre daha fazladır. Makine öğrenimi tabanlı yapılan çalışmalar ise aşağıdaki gibidir.

Tocoglu vd. (2019) Türkçe metinlerde duygu analizi yaparken hangi makine öğrenmesi yönteminin daha iyi sonuçlar verdiğine yönelik bir çalışma yapılmıştır. TREMO veri seti

üzerinden farklı makine öğrenmesi sınıflama algoritmaları ele alınmıştır. Bunlar yapay sinir ağları, destek vektör makineleri, rastgele orman ve k-en yakın komşu algoritmalarıdır. Veri ön işleme yapıldıktan sonra analize geçilmiştir. Sonuç olarak yapay sinir ağları sınıflama algoritması en iyi sonucu vermiştir. Devamında sırasıyla destek vektör makineleri, rastgele orman ve k-en yakın komşu sınıflandırma algoritmaları gelmektedir.

Karcıoğlu ve Aydın (2019) çalışmalarında Word2Vec modelini kullanarak Türkçe ve İngilizce metinler duygu analizini yapmıştır. Çalışmada Türkçe ve İngilizce olarak 2 farklı veri seti bulunmaktadır. Çalışmada etiketli verilerin sınıflandırmasında Word2Vec modelinin uygulanması ve bu modelin kök alma işlemine olan etkisi araştırılmaktadır. Python programlama dili kullanılarak yapılan çalışmada doğal dil işleme uygulamalarında kök alma işleminin duygu analizi araştırmalarında kullanılmaması gerektiği anlaşılmıştır.

Shehu vd. (2019) makalelerinde Kutupsallık Sözlüğü ile Yapay Zekâ'ya dayalı iki yöntemi benimseyerek Türkçe tweetlere ilişkin duygu tahmini yapabilen bir model önerilmiştir. Kutupsallık yöntemi bir sözlük barındırmaktadır. Daha sonra bu sözlük ile tweetler arasında bir eşleştirme işlemi gerçekleştirilmektedir ve sonuca göre olumlu olumsuz veya nötr olarak sınıflandırma yapılmış olur. Yapay zekâ yönteminde ise tweetleri sınıflandırabilmek için Destek Vektör Makineleri ve Rastgele Orman sınıflandırıcıları kullanılmaktadır. Deneysel sonuçlara göre Destek Vektör Makineleri %76'lık doğruluk oranı ile köklü verilerde daha iyi sonuç vermiştir. Rastgele Orman ise %88 doğruluk oranı ile ham verilerde daha iyi sonuç verdiği ortaya çıkmıştır. Veriler ham veriden köklü verilere dönüştükçe Kutupsallık Sözlüğü yönteminin performansı yükselmektedir.

Bayraktar vd. (2019) çalışmalarında Türkçe yönelim tabanlı duygu analizi için istatistiksel, dilbilgisel ve kurallara dayalı yaklaşımları kullanan bütünsel bir yöntem önermektedir. Yöntemde SemEval Aspect-Based Sentiment Analysis (ABSA) kapsamında oluşturulan Türk restoran veri seti üzerinde test edilmiştir. İlk olarak çeşitli yöntemler kullanılarak aday yönetim terimleri elde edilmiştir. Daha sonra ise kural tabanlı yaklaşım ile yönelim terimleri bulunmuştur ve yönelim-terim çiftleri belirlenmiştir.

Yönelim terimi çıkarma aşamasında %56,28 F-skoru elde edilirken, yönelim-terim eşleştirme aşamasında %52,05 doğruluk elde edilmiştir.

Santur (2019) çalışmasında Türkçe metinlerde duygu analizi konusunda farklı bir yaklaşım ile Kapalı Tekrarlama Ünitesi (GRU) kullanarak bir analiz yapılmıştır. Araştırmanın verisi Türk e-ticaret platformlarından sağlanmıştır. Analiz sonucu %95 oranında doğruluk elde edilmiştir.

Ciftci ve Apaydın (2018) araştırmalarında Türkçe metinlerde duygu analizi için derin öğrenme kullanımı önermektedir. Çalışmada Türk alışveriş ve film sitelerinden elde edilen bir veri kümesinde, Uzun Kısa Süreli Bellek (LSTM) birimlerini kullanarak Rekürrensöral Ağlar (RNN) adlı modern bir teknikle karşılaştırılmıştır. Sonuçlar, RNN tabanlı yaklaşımların sınıflandırma doğruluklarını artırdığını göstermektedir.

Bilgin ve Şentürk (2017) araştırmalarında Twitter verileri üzerinde yarı denetimli bir öğrenme algoritması kullanarak sistemi eğitmeye ve test etmeye çalışmışlardır. Model olarak Doc2Vec algoritmasının Dağıtılmış Bellek ve Dağıtılmış Sözlük Torbası olmak üzere 2 farklı versiyonunu kullanılmıştır. Araştırmanın sonucunda Dağıtılmış Sözlük Torbası yönteminin Dağıtılmış Bellek yönteminden daha iyi sonuç verdiği gözlemlenmiştir.

Seyfioğlu ve Demirezen (2017) çalışmalarında müşteri geri bildirimlerinden elde ettiği veri ile bir duyarlılık analizi ve verilerin daha ayrıntılı bir şekilde sınıflandırılabilmesi için hiyerarşik bir yaklaşım önerilmiş ve Word2Vec ve Doc2Vec yöntemleri uygulanmıştır. Modelde ilk olarak Word2Vec kullanılarak veriler analiz edilmiştir. Daha sonra “xgboost” sınıflandırıcı kullanılmış ve %92,5 doğruluk oranı bulunmuştur. Negatif duyguların 12 sınıfta kategorize edilmesi için Doc2Vec kullanılmış ve %71,16 doğruluk oranı elde edilmiştir. Bu da baz modelden %19,1 daha yüksektir.

Kaynar vd. (2016) çalışmalarında, Türkçe film yorumlarını içeren bir veri seti kullanmışlardır. Bu veri setine Naive Bayes, Destek Vektör Makineleri, Merkez Tabanlı

Sınıflayıcı ve Çok Katmanlı Yapay Sinir Ağları algoritmaları kullanılarak bir sınıflanma işlemi yapılmıştır. Devamında ise duygu analizi işlemi gerçekleştirilmiştir. Yapılan analizlere sonucunda Türkçe metinlerde duygu analizi yapıldığında en iyi sonuçları veren sınıflama algoritmaları Yapay Sinir Ağları ve Destek Vektör Makineleri sınıflama algoritmaları olmuştur.

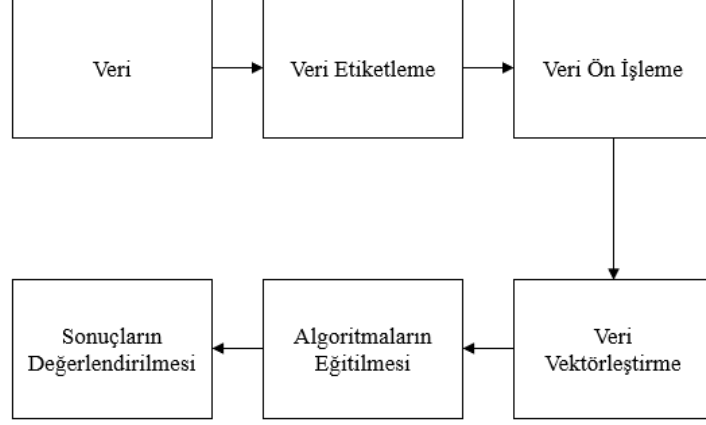
Nalçakan vd. (2015) çalışmalarında, bir sosyal medya platformu üzerinde, belli markalar için yapılan yorumları makine öğrenmesi yöntemi ile analiz ederek bir geri bildirim almayı hedeflenmektedir. Verilerin duygu durumu pozitif, nötr veya negatif olmak üzere manuel olarak işaretlenmiştir. Daha sonra veri Python programlama dili ile düzenlenerek makine öğrenimine hazır hale getirilmiştir. Makine öğrenimi algoritmalarından Naive Bayes, Rastgele Orman, LibSVM, J48 ve KStar sınıflandırıcıları kullanılmıştır. Sınıflandırma işlemleri ve analizler sonrasında en iyi sonucu Naive Bayes sınıflandırma algoritması göstermektedir.

Çoban vd. (2015) Türkçe Twitter mesajlarında duygu analizi yapmıştır. Türkçe Twitter mesajlarından oluşan veri setlerini farklı sınıflandırma modellerinde analiz ederek duygu durumları pozitif veya negatif olarak incelenmiştir. Kullanılan algoritmalar Destek Vektör Makinesi, Naive Bayes, K-en Yakın Komşu ve Çok Terimli Naive Bayes algoritmalarıdır. Vektör Space modeli ile öznitelikler kelime torbası ve N-Gram model olmak üzere iki farklı şekilde elde edilmiştir. Sonuçlar, duygu analizi çalışmalarında başarı oranını arttırmak için dışsal yöntemlere başvurulabileceğini işaret etmektedir.

Catal ve Nangir (2015) araştırmalarında Türkçe metinlerde kullanılmak üzere yeni bir sınıflandırma tekniği önemişlerdir. Vote algoritması, Naive Bayes, Destek Vektör Makineleri ve Bagging sınıflandırıcıları ile birlikte kullanılmaktadır. Destek Vektör Makinelerinin parametreleri bireysel sınıflandırıcı olarak optimize edilmiştir. Deneysel sonuçlar Türkçe metinlerde sınıflandırma işlemi yaparken çoklu algoritma kullanımının performansı arttırdığını göstermektedir. Önerilen Vote algoritması Naive Bayes ve Destek Vektör Makineleri sınıflandırıcılarından daha iyi bir performans göstermiştir.



Makine öğrenimi aşamaları şekil 4.2’de gösterildiği gibidir.



Şekil 4.2 Makine öğrenimi aşamaları

#### 4.1.1 Veri etiketleme

Duygu analizi alanında çalışabilmek için gözetimli makine öğrenimi algoritmalarından olan Destek Vektör Makinesi, Naive Bayes, Rastgele Orman ve Karar Ağaçları algoritmaları kullanılacaktır. Bu durumda elimizdeki ham veri üzerinde bir etiketleme yapılması gerekmektedir.

Veriler duygu durumuna göre Pozitif (1), Negatif (-1) veya Nötr (0) olmak üzere 3 farklı durumda işaretlenmektedir. Gözetimli makine öğrenimi algoritmalarını en doğru şekilde eğitebilmek için verileri manuel olarak etiketlemek gerekmektedir. Veri setindeki her satır tek tek okunarak duygu durumu bir kişi tarafından tespit edilip işaretlenmiştir. Bu konu anlamca olumlu, yapıcı olumsuz veya anlamca olumsuz, yapıcı olumlu cümleleri tespiti hususunda önem arz etmektedir. Algoritmaların etiketli veriye göre eğitilip, başka verilerde yüksek doğruluk oranı ile tahminler yapması beklenmektedir. Çizelge 4.1’de örnek bir etiketleme gösterilmiştir.

Çizelge 4.1 Etiketleme işlemi örneği

Etiket	Yorumlar
1	“Dersin işleyişi gayet güzeldi”
0	“Ders çevrimiçi işlendi”
-1	“Ders verimsizdi”

#### 4.1.2 Veri ön işleme

Duygu analizi amacıyla kullanılacak gözetimli makine öğrenmesi algoritmalarının doğru ve sağlıklı bir şekilde çalışabilmesi için verilerinde temizlenmiş olması gerekmektedir. Tahminlerin tutarlı olabilmesi makinenin eğitilmesi aşamasında kullanılan verilerin gerçeğe en yakın olması ile ilişkilidir. Veriler ilk alındığı hali ile kullanılır ise makineler doğru sonuç vermeyebilirler. Duygu analizi için anlamsız olan tüm noktalama işaretlerinin, durak kelimelerin, sayıların, özel simgelerin, emojilerin, HTML unsurların, çıkarılması gerekmektedir. Ön işlem aşamaları aşağıdaki gibidir:

- Veriler ilk olarak küçük harfe dönüştürülmüştür. Ancak bu işlem esnasında Türkçe büyük harflere küçükleri işe dönüştürülmesinde hazır fonksiyonlar tam olarak doğru çalışmamaktadır. Bu sebepten dolayı bazı Türkçe büyük harf dönüşümleri hazır fonksiyon ile dönüştürme işleminden hemen önce yer değiştirme fonksiyonu ile kullanılmıştır.
- Veri seti içerisinde bulunan sayıların duygu durumuna bir etkisi bulunmamaktadır. Bu sebepten dolayı veri setinden çıkarılmıştır.
- Noktalama işaretleri, simgeler, html unsurları, Url, emojiler vb. duyguya etkisi olmayan karakterler veri setinden çıkarılmıştır.
- Veri seti içerisinde cümlenin duygusuna herhangi bir etkisi olmayan durak kelimeler belirtilmiştir. Çizelge 4.2’de yer alan toplamda 53 adet durak kelime veriden çıkarılmıştır. Durak kelimelerin çıkarılmasında Python NLTK kullanılmıştır.

Çizelge 4.2 Durak kelimeler

acaba	de	ki	şey
ama	defa	kim	siz
aslında	diye	mı	şu
az	eğer	mu	tüm
bazı	en	mü	ve
belki	gibi	nasıl	veya
biri	hem	ne	ya
birkaç	hep	neden	yani
bir şey	hepsi	nerde	
biz	her	nerede	
bu	hiç	nereye	
çok	için	niçin	
çünkü	ile	niye	
da	ise	o	
daha	kez	sanki	

Veri ön işleme aşaması tamamlandıktan sonra duygu durum analizi yapmak için uygun bir veri seti elde edilmiştir. Makine öğrenimi algoritmalarının eğitimi aşamasına geçilmiştir.

#### 4.1.3 Veri vektörleştirme

Veri setini vektörel olarak temsil etmek duygu analizi için önemli bir araçtır. Terim Sıklığı-Ters Belge Frekansı (TF-IDF) metni vektörleştirmek amacı ile kullanılmıştır. TF-IDF belgedeki kelimelerin önemini ve nadir kelimeleri belirler. TF-IDF cümlelerdeki kelimelerin ağırlık değerlerine odaklanır ve metin içerisindeki her kelimeyi bir özellikmişçesine tanımlayarak kullanmaktadır. TF-IDF kullanılarak oluşturulan matris örnekleri Çizelge 4.3’te verilmiştir.

Çizelge 4.3 Matris örneği

Cümleler	Matrisler
“Çok iyi bir dersti keyif aldım”	[0.37796447 0.37796446 0.37796447 0.37796447 0.37796448]
“Verimsiz bir dersti”	[0.57535027 0.57535027 0.57535027 0.57535027]



Çizelge 4.4 Kullanılan kütüphaneler

Kullanılan Kütüphaneler
<code>from sklearn import svm</code>
<code>from sklearn.naive_bayes import MultinomialNB</code>
<code>from sklearn.ensemble import RandomForestClassifier</code>
<code>from sklearn.tree import DecisionTreeClassifier</code>
<code>from sklearn.neighbors import KNeighborsClassifier</code>

#### 4.1.4.1 Destek vektör makineleri

Destek vektör makineleri içerisinde birçok parametre kullanılmaktadır. Modelin doğru bir şekilde eğitilebilmesi için bu parametrelerin modelin amacına uygun olarak düzenlenmesi gerekmektedir.

kernel: Destek vektör makineleri doğrusal olmayan problemleri çözmek için veri noktalarını eşleştiren bir çekirdek fonksiyon kullanmaktadır. Kernel parametresi bu fonksiyonu temsil etmektedir. 'linear', 'poly', 'rbf', 'sigmoid' veya 'precomputed' olarak farklı fonksiyonlar bulunmaktadır. Geliştirilen modelde kernel değeri 'linear' olarak kullanılmıştır.

nu: Marj hatası fraksiyonunun üst sınırı ve destek vektörlerin fraksiyonunun alt sınırını belirler. Marj hatası, bir veri noktasının doğru sınıflandırılması ile karar sınırı arasındaki uzaklıktır. Destek vektörler karar sınırına en yakın olan örneklerdir. Geliştirilen modelde nu değeri '0.5' olarak kullanılmıştır.

degree: Çekirdek fonksiyonu 'poly' ise kullanılan bir parametredir. Bu parametre polinomun değerine belirtmektedir. Geliştirilen modelde kullanılmamıştır.

gamma: RBF, poly ve sigmoid çekirdek fonksiyonları kullanıldığında kullanılan bir parametredir. Fonksiyonun ne kadar esnek veya karmaşık olacağını kontrol etmektedir.

'scale' olarak belirlenir ise veri özelliklerine bağılı olarak otomatik hesaplanmaktadır, 'auto' olarak belirlenir ise gamma değeri sabit bir orana bağılı olarak otomatik olarak hesaplanmaktadır.

coef0: Polinom ve sigmoid çekirdek fonksiyonları için bağımsız bir parametredir.

Küçülme (shrinking): Destek vektör makineleri modelinin eğitimi sırasında kullanılan bir küçülmenin etkinleştirilip etkinleştirilmeyeceğinin belirlendiği parametredir. Küçülme, çekirdek fonksiyonun önbelleği büyüklüğünün azaltılmasına ve çözücünün daha hızlı çalışmasına yardımcı olabilir. Küçülme değeri geliştirilen modelde 'True' olarak belirlenmiştir.

Olasılık (probability): Destek vektör makineleri modellerinde olasılık tahminlerinin hesaplama amacı ile kullanılıp kullanılmayacağını belirleyen parametredir. Geliştirilen modelde olasılık tahmini yapılması istenmediği için 'false' olarak belirlenmiştir.

tol: Modelin optimize edildiği kayıp fonksiyonunun değişimini belirleyen parametredir. Optimize edici algoritmanın durması gereken miktarı olarak değerlendirilmektedir. Geliştirilen modelde bu parametrenin varsayılan değeri olan 0.001 olarak belirlenmiştir.

Önbellek Boyutu (cache\_size): Kernel önbelleğinin boyutunu belirten parametredir. Bu bellek işlem sürecini hızlandırmak için kullanılan bellektir. Geliştirilen modelde önbellek boyutu 200 olarak belirlenmiştir.

Sınıf Ağırlığı (class\_weight): Algoritmadaki sınıfların ağırlarını belirlemeye yarayan parametredir. Geliştirilen modelde bu parametre 'None' olarak belirlenmiştir.

Ayrıntı (verbose): Ayrıntılı çıktıyı etkinleştirmeye yarayan parametredir. 'True' olarak değerlendirildiği takdirde algoritmalar daha fazla bilgi vermektedir. Ancak bu ayarlama performansa olumsuz olarak etki etmektedir. Geliştirilen modelde bu parametre 'False' olarak ayarlanmıştır.

Maksimum Yenileme (max\_iter): Algoritma içerişimdeki iterasyonların sınırlandırılmasını saęlayan parametredir. '-1' deęerini alırsa sınırlama ortadan kalkmaktadır. Geliştirilen modelde bu parametre '-1' olarak ayarlanmıştır.

Karar Fonksiyonu Yapısı (decision\_function\_shape): Algoritma içerisinde karar fonksiyonu belirleyen parametredir. 'ovr' (One-vs-Rest) ve 'ovo' (One-vs-One) olmak üzere 2 versiyonu vardır. 'ovo' her zaman için çoklu sınıf stratejisini kullanırken, 'ovr' ise kendi matrisini kullanmaktadır. Geliştirilen modelde varsayılan ayar olan 'ovr' parametresi kullanılmıştır.

Baęları Koparmak (break\_ties): Karar Fonksiyonu Yapısı parametresinin deęerine göre deęerlenen bir parametredir, eęer parametre 'ovr' deęerine sahip ve sınıf sayısı 2'den büyük ise 'predict' işleminin ile karar fonksiyonu ile baęlantılarını kesmektedir. Bunun nedeni ilişkili sınıflar arasında yanlış sınıfların döndürülmesini önlemektir. Geliştirilen modelde bu parametrenin deęeri 'False' olarak belirlenmiştir.

Rastgele Durum (random\_state): Veriyi karıştırmak için kullanılan parametredir. Tekrarlanabilir çıktılar için bir tamsayı deęeri seçilebilmektedir. Geliştirilen modelde bu parametrenin deęeri 'None' olarak belirlenmiştir.

#### **4.1.4.2 Naive bayes**

Naive Bayes algoritmasının eğitimi sırasında 4 tane parametre deęerlerinin belirlenmesi gerekmektedir. Bu parametreler 'alpha', 'forca\_alpha', 'fit\_prior' ve 'class\_prior' parametreleridir.

Alfa (alpha): Bu parametre Laplace ve Lidstone pürüzsüzleştirilmesi için kullanılır. Laplace pürüzsüzleştirilmesi, bir özelliğin eğitim veri setinde hiç bulunmaması durumunda olasılığın 0 olmamasını sağlamaktadır. Pürüzsüzleştirilmenin gücünü kontrol etmektedir. Alpha deęerinin 0'a yaklaşması modelin eğitim verisinde bulunmayan özelliklere karşı nasıl davranacağını belirler. Alpha deęerinin 0 olması durumunda eğitim

veri setinde hiç bulunmayan bir özelliğin olasılık değeri 0 olacaktır. Geliştirilen modelde alphe değeri 1.0 olarak belirlenmiştir.

Kuvvet Alfa (force\_alpha): Parametre alpha değerinin belirli bir eşik altına düşerse nasıl davranması gerektiğini belirleyen parametredir. Alfa değerinin çok düşük olduğu durumlarda sayısal hataları önlemek amacı ile kullanılmaktadır. Geliştirilen modelde kuvvet alfa değeri 'True' olarak belirlenmiştir.

fit\_prior: Sınıf priorlerinin öğrenilip öğrenilmeyeceğini belirleyen parametredir. Örneğin eğitim veri setinde %35 etiketli "pozitif" ve %65 etiketli "negatif" örnekler var ise prior değerleri sırası ile 0.35 ve 0.65 olacaktır. Eğer parametre 'false' olarak belirlenir ise tüm model sınıfları eşit olasılığa sahip olduğunu varsaymaktadır. Eğer 'true' olarak ayarlanır ise model eğitim veri setindeki dağılımı kullanarak prior'ları hesaplar ve bir önceki gözlem sayısına dayalı olarak ne kadar yaygın olduğunu öğrenmektedir. Geliştirilen modelde parametre değeri 'True' olarak belirlenmiştir.

class\_prior: fit\_prior parametresinin 'false' olarak belirlendiğinde sınıfların manuel belirlenmesini sağlayan parametredir. Eğer 'pozitif' sınıfının daha önemli olduğu düşünülüyor ise class\_prior parametresini 0,70 ve 0,30 olarak belirlenebilir.

#### **4.1.4.3 Rastgele orman**

Rastgele orman algoritmasının eğitimi sırasında 18 adet parametre belirlenmesi gerekmektedir. Modelin amaçları doğrultusunda bu parametreleri belirlemek modelin daha doğru sonuçlar doğurmasını sağlayacaktır.

Tahminci (n\_estimators): Algoritmada kullanılacak karar ağaçlarının sayısını belirleyen parametredir. Her bir ağaç veri setinin farklı alt dalları ile eğitilmektedir. Bu parametre algoritmamızda 100 olarak belirlenmiştir.

Kriter (criterion): Rastgele orman algoritmasında her ağaç veri setini bölerek karar almaktadır. Bu bölümlerin ne kadar doğru ayrılmış bölümler olduğunu belirlemek amacı ile kriter parametresi kullanılmaktadır. Bölümlerin kalitesini ölçmek amaçlanmıştır. ‘Ortalama Mutlak Hatası’, ‘Ortalama Kare Hatası’, ‘Freidman’ın Ortalama Kare Hatası’ veya ‘Poisson Sapmalarının Azaltılması’ olarak belirlenebilir. Geliştirilen modelde bu parametre ‘Ortalama Kare Hatası’ olarak belirlenmiştir.

Maksimum Derinlik (max\_depth): Rastgele orman algoritmasının dallanma derinliğini belirlemektedir. Karar ağacı, veri kümesini belirli kriterlere bölerek sınıflandırmaktadır. Maksimum derinlik belirlendikten sonra ağaç dallanması kısıtlanmış olur. Bu durum modelin eğitimi esnasında aşırı uyuma yaparak gereğinde çok daha az sınıflandırma yaparak tahmin doğruluk oranının çok düşük olmasına sebep olabilir. Geliştirilen modelde bu parametre ‘None’ olarak belirlenmiştir. Herhangi bir dallanma sınırı koyulmamıştır.

Minimum Örneklem Bölmesi (min\_samples\_split): Minimum bölme örnek sayısını ayarlamak amacı ile kullanılan parametredir. Ağaç içerisindeki bir düğümü bölmek için gerekli minimum örnek sayısını belirlemektedir. Düğümün bölünmeden önce kaç örneğe sahip olması gerektiğini belirlemektedir. Geliştirilen modelde bu değer 2 olarak belirlenmiştir.

Minimum Örneklem Yaprığı (min\_samples\_leaf): Minimum yaprak örnek sayısını belirlemek için kullanılan parametredir. Bir düğümde olması gereken minimum örnek sayısını temsil etmektedir. Yaprak düğüm ağacın sonunda daha fazla dallanma yapılamayacak noktada olan düğümlerdir. Geliştirilen modelde minimum örneklem yaprağı parametresi 1 olarak belirlenmiştir.

Minimum Ağırlık Fraksiyon Yaprığı (min\_weight\_fraction\_leaf): Bir yaprak düğümünde olması gereken minimum ağırlıklı örnek oranını belirlemektedir. Parametre geliştirilen modelde 0 olarak belirlenmiştir.

Maksimum Özellik (max\_features): Algoritmanın eğitimi esnasında bölümlendirme yaparken göz önünde bulundurulacak maksimum özellik sayısını belirlemektedir. Bu parametre her bölümün rastgele seçilen özelliklerden oluşmasını sağlar. Geliştirilen modelde maksimum özellik parametresi auto olarak belirlenmiştir. Yani belirlenen tüm özellikler model içerisinde öneme sahiptir.

Maksimum Yaprak Düğümleri (max\_leaf\_nodes): Model içerisindeki maksimum yaprak düğüm sayısını belirlemek için kullanılan parametredir. Ağaçtaki maksimum yaprak düğüm sayısını belirler. Parametrenin bir başka görevi ise ağacın büyüklüğünü kontrol altında tutmaktır. Geliştirilen modelde Maksimum yaprak düğümleri parametresi 'None' olarak belirlenmiştir. Herhangi bir kısıt uygulanmamıştır.

Minimum Kirlilik Azaltılması (min\_impurity\_decrease): Minimum iç kirliliğin azalması anlamına gelmektedir. Ağaç içerisinde bir bölme oluşturulurken düğümün bölünüp bölünmemesi gerektiğinin kararını verme aşamasında görev almaktadır. Bu bölünmelerin ağaç içerisinde kirlilik yaratmasından endişe edildiği için kullanılmaktadır. Gereksiz dallanmaların önüne geçilmesine yardımcı olmaktadır. Daha az dallanma modelin sadeleşmesine ve performansına pozitif yönde etki ederken, eksik dallamadan dolayı daha yanlış tahminler yapmasına sebep olabilmektedir. Geliştirilen modelde bu parametre 0 olarak belirlenmiştir. 3 adet bölmemiz olduğundan dolayı kirlilik yapacak bir unsur bulunmamaktadır.

Önyükleme (bootstrap): Modeldeki ağaç yapısı oluşturulurken örneklem yapıp yapılmayacağını belirlemeye yarayan parametredir. Rastgele örnekleme kullanarak ağaçlardaki çeşitliliği arttırmaktadır. Geliştirilen modelde bu parametre 'True' olarak belirlenmiştir.

Oob Skoru (oob\_score): Modelin performansını belirlemek için out-of-bag örneklerinin kullanıp kullanılmayacağını belirlemeye yarayan parametredir. Geliştirilen modelde Oob skoru 'False' olarak belirlenmiştir.

n\_jobs: Modelin eğitimi sırasında kullanılacak olan iş parçacığı sayısını belirlemek amacı ile kullanılan parametredir. Modelin performansına doğrudan etkisi vardır. Bilgisayarın işlemcilerin ve çekirdeklerini (CPU) etkin bir şekilde kullanarak eğitim sürecini hızlandırmaktadır. Geliştirilen modelde bu parametresi 'None' olarak belirlenmiştir.

Rastgele Durum (random\_state): Model rastgele sayı üretirken kullanılan tohum değerlerini belirlemektedir. Bu parametre modelin tekrarlanabilirliğini sağlamaktadır. Geliştirilen modelde Rastgele durum parametresi 'None' olarak belirlenmiştir.

Ayrıntı (verbose): Modelin açıklığı anlamına gelmektedir. Eğitim ve tahmin esnasında ne kadar ayrıntı göstereceğini belirlemektedir. Geliştirilen modelde ayrıntı parametresine 0 değeri verilmiştir.

Sıcak Başlangıç (warm\_start): Modelin tekrardan eğitimi durumunda önceki modelin çözümünü kullanıp kullanmayacağını belirleyen parametredir. Geliştirilen modelde bu parametre 0 olarak belirlenmiştir.

Ccp Alfa (ccp\_alpha): Ağacın karmaşıklığını kontrol etmek amacı ile kullanılan bir parametredir. Parametre modelin karmaşıklığı gidermek için gereksiz dalları budamaktadır. Bu sayede modelin performansını düzeltmektedir. Geliştirilen modelde Ccp Alfa parametresi 0 olarak belirlenmiştir.

Maksimum Örneklem (max\_samples): Modelin eğitimi esnasında her bir ağacın eğitilirken kullanılacak olan maksimum örnek sayısını belirlemektedir. Bu durum ağaçların her birinin rasgele örnekleme yöntemiyle eğitilmesini sağlamaktadır. Modelin çeşitliliğini artırır ve uyumunu kontrol eder. Geliştirilen modelde maksimum örneklem parametresi 'None' olarak belirlenmiştir.

Monoton Cst (monotonic\_cst): Monoton kısıtlama anlamına gelmektedir. Belirli özelliklerin değişmesini zorlar ve kısıtlar. Geliştirilen modelde bu parametresi 'None' olarak kullanılmıştır. Yani herhangi bir kısıtlama uygulanmaz.

#### 4.1.4.4 Karar ağaçları

Karar Ağaçları algoritmasının eğitimi esnasında 4 adet parametre belirlenmesi gerekmektedir. Bunlar: 'X', 'y', 'sample\_weight', 'check\_input' parametreleridir.

X: Eğitim veri setini ifade etmektedir. Bir dizi veya bir matris şeklinde olabilmektedir. Algoritmanın eğitilebilmesi için zorunlu bir parametredir.

y: Hedef değerleri ifade etmektedir. Her bir örnek verinin sınıf etiketini veya hedef değişkeni içeren bir dizi, matris olabilir. Algoritma için zorunlu bir parametredir.

Örnek Ağırlığı (sample\_weight): Örnek ağırlıklarını temsil etmektedir. Her bir örneğin eğitime katkısını belirleyen örnek ağırlıklarını içeren bir dizidir. Örnek ağırlıkları algoritmanın eğitimi ve tahminlerin doğruluğu açısından önem teşkil etmektedir. Geliştirilen modelde örnek ağırlığı parametresi 'None' olarak belirlenmiştir. Örnekler eşit ağırlık öneme sahip olarak kabul edilmiştir.

Giriş Kontrol (check\_input): Parametre giriş verilerinin kontrol edilip edilmeyeceğini belirleyen bir parametredir. 'True' kabul edilir ise giriş verileri belirli kontrol aşamalarından geçerek format bakımından tutarlılığı kontrol edilmektedir. Algoritmanın çalışma süresini olumsuz yönde etkileyebilen bir parametredir. Geliştirilen modelde Giriş kontrol parametresi 'True' olarak belirlenmiştir.

#### 4.1.4.5 K-en yakın komşu

K-En Yakın Komşu algoritmasının eğitimi esnasında 8 adet parametre değeri girilmesi gerekmektedir. Bu parametreler algoritmanın eğitimine direkt etki etmektedir. Parametrelerin amacına uygun bir şekilde düzenlenmesi gerekmektedir.

Komşu (n\_neighbors): Kullanılacak olan komşuların sayısını ifade etmektedir. Geliştirilen modelde 5 olarak belirlenmiştir.

Ağırlıklar (weights): Tahmin esnasındaki olasılıkların ağırlıklarını düzenlemen amacı ile kullanılan bir parametredir. Parametre 'uniform', 'distance', 'callable' ve 'None' olmak üzere 4 farklı değer alabilmektedir. 'Uniform' tüm ağırları kabul ederken, 'distance' noktaların mesafelerinin tersiyle ağırlıklandırmaktadır. 'callable' ise belirlenen mesafeyi esas alarak tüm komşuları aynı oranda ağırlıklandırmaktadır. Geliştirilen modelde ağırlıklar parametresinin değeri 'None' olarak belirlenmiştir.

Algoritma (algorithm): Parametre, eğitim esnasında en yakın komşuları hesaplamak için kullanılan parametredir. Parametre, 'ball\_tree', 'kd\_tree', 'brute' ve 'auto' olmak üzere 4 farklı değer almaktadır. Geliştirilen modelde algoritma parametresi 'auto' olarak belirlenmiştir.

Yaprak Boyutu (leaf\_size): Algoritma parametresinde belirlenen değere göre kararlaştırılması gereken bir parametredir. Eğer algoritma parametresi 'ball\_tree' veya 'kd\_tree' olarak belirlendiyse değerlendirilebilen ve bu iki parametreye iletilen yaprak boyutunu temsil etmektedir. Parametre ağacın temel işlevlerinden olan sorgulama, oluşturulma ve depolama gibi operasyonlarını ihtiyacı olan belleği etkileyebilmektedir. Geliştirilen modelde yaprak boyutu parametresi varsayılan ayarında bırakılmıştır.

Metrik (metric): Mesafe hesaplamasını kullanılan parametredir. Varsayılan ayarı 'minkowski' olarak belirlenmiştir. 'p' parametresinin değerine bağlı olarak Öklid veya Manhattan mesafesi değerlerini alabilmektedir. Geliştirilen modelde metrik parametresi 'minkowski' olarak belirlenmiştir.

Metrik Parametreleri (metric\_params): Mesafe hesaplama fonksiyonuna iletilen ek bir parametrelerin bir kılavuzu parametredir. Geliştirilen modelde 'None' olarak belirlenmiştir.

p: Metrik olarak 'minkowski' metriği kullanılırken mesafe hesaplamasında kullanılan bir güç parametresidir. Öklid mesafesi için 'p=2', Manhattan mesafesi için de 'p=1' olarak kullanılmaktadır.

n\_jobs: Komşular arasında kullanılan iş yükünü kontrol edebilmemizi sağlayan parametredir. İşlemci yükünü değerlendirebilmemizi sağlamaktadır. Parametre '-1' iken tüm işlemciler kullanılmaktadır, 'None' değerini alır ise yalnızca 1 işlemci kullanılmaktadır. Geliştirilen modelde parametrenin değeri 'None' olarak belirlenmiştir.

#### 4.1.5 Dönüştürücü temelli çift yönlü kodlayıcı (BERT)

Türkçe metinlerde kullanılmak üzere birçok model bulunmaktadır. Tez kapsamında birçok model denenmiş olup sağlıklı sonuçlar alınamamıştır.

Modeli kullanmak için kullandığımız kütüphane ve model kodları Çizelge 4.5 ve Çizelge 4.6'te gösterilmiştir.

Çizelge 4.5 BERT kullanımı için gerekli kütüphaneler

Kullanılan Kütüphaneler
<pre>import torch from transformers import AutoTokenizer,AutoModelForSequenceClassification</pre>

Çizelge 4.6 BERT modeli kullanımı için gerekli kodlar

Model Kodları
<pre>model_name = "-" tokenizer = AutoTokenizer.from_pretrained(model_name) model = AutoModelForSequenceClassification.from_pretrained(model_name)</pre>

Algoritma tutarlı geri dönüşler sağlamadığı için yöntemimizden çıkartılmıştır.

#### 4.1.6 OpenAI

Duygu analizi yapmak amacı ile OpenAI firmasının geliştiriciler için sağladığı "OpenAI Platform" kullanılmıştır. Platformdan bir Uygulama Programlama Arabirimi (Application Programming Interface – API) alınmıştır.

Platformda duygu analizi yapmak amacı ile birçok motor kullanılabilir. Modeller kendi aralarına araştırma amacı, maliyet, işlem yükü vb. başlıklarda farklılaşmaktadır. Modelimizde kullanılmak üzere modeller arasında “gpt-4-turbo-preview” seçilmiştir. Kullanılan motorun kullanılması için gerekli kütüphaneler Çizelge 4.7’de olduğu gibidir.

Çizelge 4.7 OpenAI ile duygu analizi için kullanılan kütüphane

Kullanılan Kütüphane
from openai import OpenAI

Analiz Pycharm derleyicisi üzerinden, Python programlama dili kullanılarak yapılmıştır. Kodlar yardımı ile API bağlantısı üzerinden OpenAI platformuna istekler atılarak, gönderilen metinlerin duygu analizlerinin yapıp geriye duygu durumlarını pozitif (1), negatif (-1) veya nötr (0) olarak dönmesi sağlanmıştır. Bu işlem yapılırken veri ön işleme yapılmadan olduğu gibi platforma gönderilmiştir.

#### **4.1.7 Anketler ve algoritmalar**

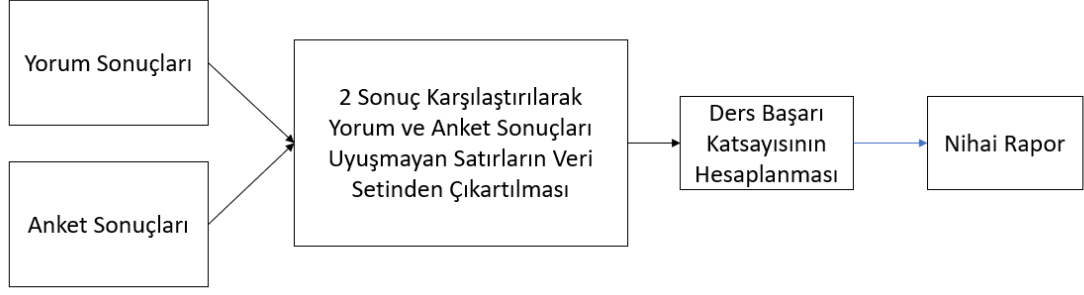
Tezde sonuçları kullanılan ders sonu değerlendirme anketi 16 sorudan oluşmaktadır. Sorular dersin işleyişi, öğretim elemanı ve dersin yürütüldüğü ortam/platformlar hakkındadır. Anket 4 puan üzerinden değerlendirilmiştir. Anket soruları Çizelge 4.8’de verilmiştir.

Çizelge 4.8 Anket soruları

1.	Dersin nasıl yürütüleceğine yönelik ders sorumlusunun bilgilendirmesi.
2.	Dersin kazanımlarına yönelik ders sorumlusunun paylaşımı.
3.	Ders izlencesinde ele alınan konuların kazanımlarla uyumu.
4.	Derste kullanılan materyallerin (ders notları, sunum slaytları, kitap,videolar, görsel öğeler vs.) ders içeriği ile uyumu.
5.	Derste kullanılan materyallerin (ders notları, sunum slaytları, kitap, video,görsel öğeler vs.) anlaşılabilirliği.
6.	Öğretim elemanının derste kullandığı dilin anlaşılabilirliği.
7.	Öğretim elemanının öğrenmelerimize yönelik geri bildirimlerinin öğrenmeye katkısı.
8.	Öğretim elemanının derse hazır oluş düzeyi.
9.	Öğretim elemanının konuya hakimiyeti.
10.	Öğretim elemanının derse ayrılan tüm zamanı etkili kullanması.
11.	Öğretim elemanının derse katılan öğrencilerle olan iletişimi.
12.	Öğretim elemanına ders zamanı dışında farklı platformlarda ulaşılabilirlik düzeyi.
13.	Ödevlerin ve dönem boyunca yapılan değerlendirmelerin öğrenmeye olan katkısı.
14.	Ödevlerin, sınavların, projelerin dersin içeriği ile uyumu.
15.	Öğretim elemanının öğrencileri derse katılmaya teşvik etmesi.
16.	Öğretim elemanının bireysel öğrenme farklılıklarını dikkate alma düzeyi.

Bu aşamada izleyeceğimiz yol haritası Çizelge 4.9’da gösterildiği gibidir.

Çizelge 4.9 Model



Algoritmaların eğitimi neticesinde doğruluk oranı en yüksek algoritma seçilerek modele dahil edilmiştir. Algoritma tarafından duygu durumları belirlenen yorumların, anket sonuçları ile uyuşup uyuşmadığı analiz edilmiştir. Analiz sonucu uyuşmayan satırlar veri setinden çıkarılmıştır.

Algoritmalar sonucunda yorumların duygu durumları 1,-1 veya 0 olarak dönmektedir. Ancak anketin sonuçları ise 4 üzerinden bir sayı ile dönmektedir. Bu iki değer karşılaştırılabilmesi için aynı taban üzerinden değerlendirilmesi gerekmektedir. Bu uyumsuzluğu çözmek üzere anket sonuçlarını sınıflandırma yoluna gidilmiştir. Sınıflandırma kararları Çizelge 4.10’da belirtilmiştir.

Çizelge 4.10 Varsayılan duygu değerleri

Anket Değeri (x)	Duygu Karşılığı
$x \geq 3$	Pozitif (1)
$x < 3 \ \&\& \ x \geq 2$	Nötr (0)
$x < 2$	Negatif (-1)

Anket değerleri Çizelge 4.10’deki değerlere göre anketlerin varsayılan duygu durumları belirlenmiştir.

Sonuçlar aynı tabanda değerlendirildikten sonra karşılaştırılma aşamasına geçilmiştir. Bir öğrenci değerlendirmesinin anket ve yorum kısımlarında çelişki bulunduğu takdirde o öğrencinin yorumu ve anket verisi nihai veri setinden çıkarılmıştır. Örnek bir çalışma Çizelge 4.11’de verilmiştir.

Çizelge 4.11 Örnek sonuç karşılaştırması

Yorum	DA Sonucu	Anket Sonucu	Durum
“Dersimiz çok verimliydi”	1	1.4	Nihai veri setinden çıkarıldı
“Derste materyal kullanımı çok zayıftı”	-1	1	Nihai veri setinde eklendi

#### 4.1.8 Nihai çıktı tasarımı

Yapılan tüm analizler ve işlemler sonucunda elimizde kalan nihai veri ile bir çıktı tasarımı yapılmaktadır. Bu tasarım içerisinde “Ders Başarım Katsayısı”, “Kelime Bulutu” ve “Konu Modellemesi” bulunmaktadır. Bahsi geçen tasarım örneği EK 1’de örneği yer almaktadır.

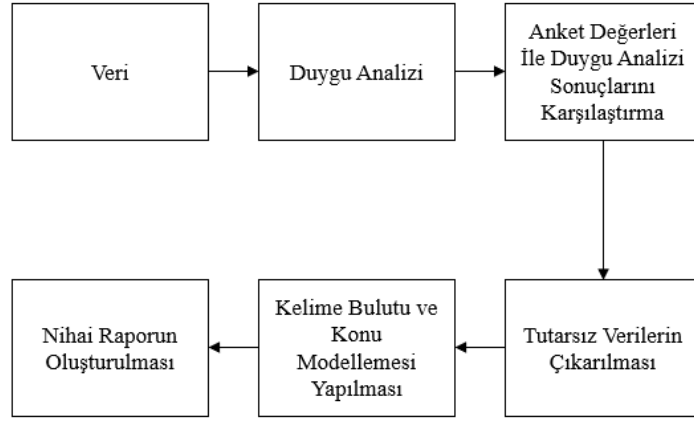
Ders Başarım Katsayısı: Dersin temizlenmiş anket ve makine öğrenimi analizi sonucunda elde edilen elde edilen değerlerin ortalaması alınarak oluşan bir değerdir.

Kelime Bulutu: Dersin yorum kısımlarının ön işleme adımlarından geçirilerek elde edilen kelime sıklık grafiğidir.

Konu Modelleme: Dersin yorum kısımlarından elde edilen veriler ile yapılan yorumların en çok hangi konular üzerinden sınıflandırılabilirdiğini gösteren bir grafikdir.

#### 4.2 Aşama 2: Modelin Uygulanması ve Değerlendirilmesi

Veri setimizi 431 adet anket ve yorum verisi olan bir ders oluşturmaktadır. Uygulama aşamaları Şekil 4.4’te belirtildiği gibidir.



Şekil 4.4 Model uygulama adımları

#### 4.2.1 Duygu analizi

Verimiz ilk olarak eğitilmiş makine öğrenimi algoritmaları ve OpenAI platformu kullanılarak duygu analizi yapılmıştır.

Çizelge 4.12 Duygu analizi sonuçlarının doğruluk oranları

	Destek Vektör Makineleri	Naive Bayes	Rastgele Orman	Karar Ağaçları	K-En Yakın Komşu	OpenAI
Doğruluk Oranları	%83	%79	%81	%76	%68	%84,88

Çizelge 4.12 incelendiğinde en doğru tahminleri OpenAI platformu tarafından yapılan tahminler olduğu tespit edilmiştir. Analizin devamına platformun yaptığı duygu analizi sonuçları esas alınarak devam edilecektir.

#### 4.2.2 Anket ve duygu analizi sonuçlarının karşılaştırılması

Yapılan analizler sonucu anket verileri ile duygu analizi sonuçları karşılaştırılarak bir normalizasyon işlemi gerçekleştirilecektir. Bu işlem esnasında duygu analizi sonucu ile anket sonucu tutarlı olmayan kayıtlar veri setinden çıkarılacaktır. Bu sınama anket

sonucunun Çizelge 4.10’da varsayıldığı gibi duygu karşılığı bulunarak DA sonucu ile karşılaştırılması yolu ile yapılacaktır.

Çizelge 4.13 Örnek normalizasyon işlemi

Örnek Yorum	Duygu Analizi Sonucu	Anket Sonucu	Anketin Duygu Karşılığı	Sonuç
“ders çok verimsizdi”	-1	3.7	1	Tutarsız
“teşekkürler”	1	4	1	Tutarlı

Analiz sonucunda 431 adet veri olan veri setinde 161 adet tutarsız, 270 adet tutarlı veri tespit edilmiştir. Veri setinden tutarsız olarak nitelendirilen yorumlar ve o yorumlara ait anket verileri çıkartılmıştır. Kalan 270 adet tutarlı veri ile diğer aşamaya geçilmiştir.

Tutarsız veriler çıkarıldıktan sonra kalan verilerin anket sonuçları ve duygu analizi sonuçları ortalamaları alınarak nihai raporda kullanılmak üzere bir ders başarı katsayısı oluşturulmuştur.

#### 4.2.3 Kelime bulutu ve konu modellemenin uygulamaları

Tutarlı veriler nihayetinde bir kelime bulutu oluşturulmuştur. Şekil 4.5’te görüldüğü üzere yapılan yorumlardaki sıklık bulut oluşmuştur.



## 5. BULGULAR VE TARTIŞMA

Tezin ilk başında elimdeki verilere ön işleme aşaması uygulanmıştır. Bu aşamada veriden duyguya etkisi olmayan rakamlar, noktalama işaretleri, internet sitesi unsurları vb. öğeler temizlenmiştir. Daha sonra veri duygu durumlarına göre manuel etiketlenerek gözetimli makine öğrenimi algoritmalarını eğitmek üzere hazırlanmıştır. Destek Vektör Makineleri, Naive Bayes, Rastgele Orman, Karar Ağaçları ve K-En Yakın Komşu algoritmaları eğitilerek duygu analizi yapılmıştır.

Destek Vektör Makineleri Algoritması				
	precision	recall	f1-score	support
-1	0.68	0.66	0.67	399
0	0.71	0.70	0.71	593
1	0.90	0.91	0.91	1738
accuracy			0.83	2730
macro avg	0.76	0.76	0.76	2730
weighted avg	0.83	0.83	0.83	2730

Şekil 5.1 Destek vektör makineleri algoritmasının eğitim değerleri

Şekil 5.1’de görüldüğü üzere Destek Vektör Makineleri modeli eğitimi gerçekleştikten sonra test verisi ile yapılan analizler sonucu doğruluk değeri %83 olarak tespit edilmiştir. Algoritmanın kesinlik değerinin ağırlıklı ortalaması %83 olarak tespit edilmiştir. Duyarlılık değerinin ağırlıklı ortalaması ise %83 olarak belirlenmiştir.

Naive Bayes Algoritması				
	precision	recall	f1-score	support
-1	0.68	0.63	0.66	399
0	0.67	0.48	0.56	593
1	0.84	0.94	0.88	1738
accuracy			0.79	2730
macro avg	0.73	0.68	0.70	2730
weighted avg	0.78	0.79	0.78	2730

Şekil 5.2 Naive bayes algoritmasının eğitim değerleri

Şekil 5.2’de görüldüğü üzere Naive Bayes algoritması eğitimi gerçekleştikten sonra yapılan analizler sonucu doğruluk değeri %79 olarak tespit edilmiştir. Algoritmanın duyarlılık oranının ağırlıklı ortalaması %78 olarak belirlenmiştir. Duyarlılık değerinin ağırlıklı ortalaması ise %79 olarak tespit edilmiştir.

Rastgele Orman Algoritması				
	precision	recall	f1-score	support
-1	0.62	0.59	0.61	399
0	0.76	0.65	0.70	593
1	0.87	0.92	0.89	1738
accuracy			0.81	2730
macro avg	0.75	0.72	0.73	2730
weighted avg	0.81	0.81	0.81	2730

Şekil 5.3 Rastgele orman algoritmasının eğitim değerleri

Şekil 5.3’te gözlemlendiği üzere Rastgele Orman algoritmasının eğitimi gerçekleştikten sonra yapılan analizler sonucu doğruluk değeri %81 olarak belirlenmiştir. Algoritmanın kesinlik oranının ağırlıklı ortalaması ise %81 tespit edilmiştir. Duyarlılık değerinin ağırlıklı ortalaması ise %81 olarak bulunmuştur.

Karar Ağaçları Algoritması				
	precision	recall	f1-score	support
-1	0.51	0.48	0.50	399
0	0.64	0.64	0.64	593
1	0.86	0.87	0.86	1738
accuracy			0.76	2730
macro avg	0.67	0.66	0.67	2730
weighted avg	0.76	0.76	0.76	2730

Şekil 5.4 Karar ağaçları algoritmasının eğitim değerleri

Şekil 5.4’te görüldüğü üzere Karar Ağaçları algoritmasının eğitimi gerçekleştikten sonra yapılan analizler sonucu doğruluk değeri %76, ağırlıklı duyarlılık oranı ise %76, ortalama duyarlılık değeri ise %76 olarak tespit edilmiştir.

K-En Yakın Komşu Algoritması				
	precision	recall	f1-score	support
-1	0.71	0.09	0.15	399
0	0.41	0.90	0.56	593
1	0.94	0.75	0.83	1738
accuracy			0.68	2730
macro avg	0.69	0.58	0.51	2730
weighted avg	0.79	0.68	0.67	2730

Şekil 5.5 K-en yakın komşu algoritmasının eğitim değerleri

Şekil 5.5'te görüldüğü üzere K-En Yakın Komşu algoritmasının eğitimi gerçekleştirildikten sonra yapılan analizler sonucu doğruluk değeri %68, kesinlik oranının ağırlıklı ortalaması ise %76, duyarlılık oranının ağırlıklı ortalaması ise %76 olarak tespit edilmiştir.

Çizelge 5.1 OpenAI platformu ile duygu analizi bulguları

	Oranlar
Doğruluk	%85
Kesinlik Değerinin Ağırlıklı Ortalaması	%88
Duyarlılık Değerinin Ağırlıklı Ortalaması	%95

Çizelge 5.1'de yer alan OpenAI platformu ile yapılan duygu analizi sonuçları incelendiğinde doğruluk oranı %85, ağırlıklı kesinlik oranı %88, ağırlıklı duyarlılık oranı ise %84 olarak tespit edilmiştir.

Bulgular incelendiğine en yüksek doğruluk oranının OpenAI platformu ile yapılan duygu analizi olduğu saptanmıştır. Devamında Duygu Analizi sonuçları modelin uygulanması aşamasında anket sonuçları ile karşılaştırılmıştır. 431 yorumu olan bir derste uygulanan model sonucunda öğrencilerin doldurduğu ders sonu değerlendirme anketinin 161 adeti tutarsız, 270 adeti tutarlı olarak tespit edilmiştir. Tutarlı yorumlar ile bir kelime bulutu ve konu modelleme çalışması yapılarak nihai rapor aşamasına geçilmiştir.

## 6. SONUÇ

Tez kapsamında öğrenci ders sonu değerlendirme anketlerine yeni bir bakış sağlanmıştır. Yükseköğretim kurumlarında yürütülen süreçleri dijitalleştirmek ve günümüz teknolojilerine uyum sağlaması amaçlanmıştır. Eğitimde dijitalleşme sürdürülebilirlik hedefi doğrultusunda yapılan çalışmada öğrencilerin ders sonu değerlendirme anketlerinde cevapladıkları açık uçlu sorular ile anketlere verdikleri cevaplar arasında bir tutarlılık analizi gerçekleştirilmiştir. Açık uçlu sorulara verilen cevapların anketler ile karşılaştırılabilmesi için duygu analizi kullanılmıştır. Duygu analizi yapabilmek için veri seti ön işlemeden geçirilerek makine öğrenimi aşamasına hazır hale getirilmiştir. Bu işlemler duygu barındırmayan yazı unsurlarının veri setinden çıkarılmasıdır. Temizleme işlemi sonrasında makinelerin eğitim aşamasına geçilmiştir. Destek Vektör Makineleri, Naive Bayes, Karar Ağaçları, Rastgele Orman ve K-En Yakın Komşu algoritmaları eğitilerek ve OpenAI platformu kullanılarak duygu analizi gerçekleştirilmiştir. Bulgular incelendiğinde en iyi doğruluk oranı OpenAI platformunun yaptığı duygu analizi sonucunda ortaya çıkmıştır. Daha sonra duygu analizi sonuçları ve anket sonuçları karşılaştırılarak hangi ders sonu değerlendirme anketinin tutarlı olup olmadığı belirlenmiştir. Gerçekleştirilen örnek çalışma sonucunda öğrenci ders sonu değerlendirme anketlerinin %37 kadarının tutarsız veriden oluştuğu gözlemlenmiştir. Son aşamada tutarlı veriler ile nihai çıktı tasarımı yapılmıştır. Kullanıcının isteğine göre nihai rapor tasarımı özelleştirilebilmektedir.

Umair vd. (2021) benzer amaçlar ile toplanmış İngilizce bir veri seti kullanarak yaptıkları çalışmada Destek Vektör Makineleri algoritmasını %85,62 doğruluk oranı ile eğitmişlerdir. Almosawi ve Mahmood (2022) Endonezya dilinde yaptıkları çalışmada Destek Vektör Makineleri algoritmasını eğiterek %97 oranında doğruluk oranı elde ettiklerini belirtmişlerdir. Tez’de kullanılan Türkçe veri seti ile eğitilen Destek Vektör Makineleri algoritması %83 doğruluk oranı sağlamıştır. Türkçe’nin karmaşık yapısı ve sondan eklemeli bir dil olması algoritmaların doğruluk oranlarının düşük olmasının sebebi olarak düşünülmektedir.

Literatür incelendiğinde çoğu çalışmanın gözetimli makine öğrenimi algoritmalarını ile farklı veri setleri üzerinde eğitilerek doğruluk oranlarını karşılaştırmak üzerine kurgulanmaktadır. Tezin sonucunda görüldüğü üzere güncel teknolojiler kullanılarak daha yüksek doğruluk oranları elde edilebilmektedir.

Sonuç olarak elde edilen rapor ders kazanımlarının ne oranda gerçekleştiği, dersin ve öğretim elemanın genel değerlendirilmesi, öğrencilerin ders, okul vb. unsurlarda tutumu gibi konularda daha güvenilir sonuçlar sağlamıştır. Sonuçlar doğrultusunda ilgili konu ve başlıklar geliştirilerek daha nitelikli bir eğitim verilmesi sağlanabilir. Öte yandan öğretim elemanlarının kendilerini ne yönde geliştirmesi gerektiğini daha rahat bir şekilde anlayabilir bu doğrultuda gerekli düzenlemeleri yapabilmektedir.

İlerleyen çalışmalarda diğer yapay zekâ platformları kullanılarak duygu analizi yapılması planlanmıştır. Bu sayede diğer yapay zekâ platformların aynı veri üzerinde gösterdikleri performans gözlemlenebilecektir.

## KAYNAKLAR

- Adalı, E. (2012). Doğal dil işleme. Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi, 5(2).
- Akgül, E. S., Ertano, C., & Diri, B. (2016). Twitter verileri ile duygu analizi. Pamukkale University Journal of Engineering Sciences, 22(2).
- Almosawi, M. M., & Mahmood, S. A. (2022). Lexicon-based approach for sentiment analysis to student feedback. Webology (ISSN: 1735-188X), 19(1).
- Baragash, R. S., Aldowah, H., & Umar, I. N. (2022). Students' Perceptions of E-Learning in Malaysian Universities: Sentiment Analysis Based Machine Learning Approach. J. Inf. Technol. Educ. Res., 21, 439-463.
- Bayraktar, K., Yavanoglu, U., & Ozbilen, A. (2019, December). A Rule-Based Holistic Approach for Turkish Aspect-Based Sentiment Analysis. In 2019 IEEE International Conference on Big Data (Big Data) (pp. 2154-2158). IEEE.
- Bilgin, M., & Şentürk, İ. F. (2017, October). Sentiment analysis on Twitter data with semi-supervised Doc2Vec. In 2017 international conference on computer science and engineering (UBMK) (pp. 661-666). IEEE.
- Boiy, E., & Moens, M. F. (2009). A machine learning approach to sentiment analysis in multilingual Web texts. Information retrieval, 12, 526-558.
- Catal, C., & Nangir, M. (2017). A sentiment classification model based on multiple classifiers. Applied Soft Computing, 50, 135-141.
- Chen, T., Xu, R., He, Y., & Wang, X. (2017). Improving sentiment analysis via sentence type classification using BiLSTM-CRF and CNN. Expert Systems with Applications, 72, 221-230.
- Ciftci, B., & Apaydin, M. S. (2018, September). A deep learning approach to sentiment analysis in Turkish. In 2018 International Conference on Artificial Intelligence and Data Processing (IDAP) (pp. 1-5). IEEE.
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. Machine learning, 20, 273-297.
- Çoban, Ö., Özzyer, B., & Özzyer, G. T. (2015, May). Sentiment analysis for Turkish Twitter feeds. In 2015 23rd Signal Processing and Communications Applications Conference (SIU) (pp. 2388-2391). IEEE.
- Devlin, J., Chang, M. W., Lee, K., & Toutanova, K. (2018). Bert: Pre-training of deep bidirectional transformers for language understanding. arXiv preprint arXiv:1810.04805.
- Fang, X., & Zhan, J. (2015). Sentiment analysis using product review data. Journal of Big Data, 2(1), 1-14.

- Gandomi, A., & Haider, M. (2015). Beyond the hype: Big data concepts, methods, and analytics. *International journal of information management*, 35(2), 137-144.
- Gitari, N. D., Zuping, Z., Damien, H., & Long, J. (2015). A lexicon-based approach for hate speech detection. *International Journal of Multimedia and Ubiquitous Engineering*, 10(4), 215-230.
- Harmsen, A. F., Ernst, M., & Twente, U. (1997). *Situational method engineering*. Utrecht: Moret Ernst & Young Management Consultants.
- Jianqiang, Z., Xiaolin, G., & Xuejun, Z. (2018). Deep convolution neural networks for twitter sentiment analysis. *IEEE access*, 6, 23253-23260.
- Jiménez, H. G., Casanova, M. A., Finamore, A. C., & Simões, G. (2021). Sentiment Analysis of Student Surveys--A Case Study on Assessing the Impact of the COVID-19 Pandemic on Higher Education Teaching. *International Educational Data Mining Society*.
- Jimmy, J., & Prasetyo, V. R. (2022, April). Sentiment analysis on feedback of higher education teaching conduct: An empirical evaluation of methods. In *AIP Conference Proceedings* (Vol. 2470, No. 1). AIP Publishing.
- Karcioğlu, A. A., & Aydin, T. (2019, April). Sentiment analysis of Turkish and english twitter feeds using Word2Vec model. In *2019 27th Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE.
- Kaynar, O., Görmez, Y., Yıldız, M., & Albayrak, A. (2016, September). Makine öğrenmesi yöntemleri ile Duygu Analizi. In *International Artificial Intelligence and Data Processing Symposium (IDAP'16)* (Vol. 17, No. 18, pp. 17-18).
- Kim, Y. (2014). Convolutional neural networks for sentence classification. *arXiv preprint arXiv:1408.5882*.
- Kiritchenko, S., Zhu, X., & Mohammad, S. M. (2014). Sentiment analysis of short informal texts. *Journal of Artificial Intelligence Research*, 50, 723-762.
- Liu, B. (2022). *Sentiment analysis and opinion mining*. Springer Nature.
- Mabunda, J. G. K., Jadhav, A., & Ajoodha, R. (2021). Sentiment analysis of student textual feedback to improve teaching. *Interdisciplinary Research in Technology and Management*, 643-651.
- McAfee, A., Brynjolfsson, E., Davenport, T. H., Patil, D. J., & Barton, D. (2012). Big data: the management revolution. *Harvard business review*, 90(10), 60-68.
- Medhat, W., Hassan, A., & Korashy, H. (2014). Sentiment analysis algorithms and applications: A survey. *Ain Shams engineering journal*, 5(4), 1093-1113.
- Mitchell, T. M. (1997). *Machine learning*.
- Nalçakan, Y., Bayramoğlu, Ş. S., & Tuna, S. (2015). Sosyal Medya Verileri Üzerinde Yapay Öğrenme ile Duygu Analizi Çalışması. *Technical Report*.

- Santur, Y. (2019, September). Sentiment analysis based on gated recurrent unit. In 2019 International Artificial Intelligence and Data Processing Symposium (IDAP) (pp. 1-5). IEEE.
- Seker, S. E. (2015). Dođal Dil İşleme (Natural Language Processing). YBS Ansiklopedi, 2(4), 14-31.
- Seyfiođlu, M. S., & Demirezen, M. U. (2017, September). A hierarchical approach for sentiment analysis and categorization of Turkish written customer relationship management data. In 2017 Federated Conference on Computer Science and Information Systems (FedCSIS) (pp. 361-365). IEEE.
- Shehu, H. A., Tokat, S., Sharif, M. H., & Uyaver, S. (2019, December). Sentiment analysis of Turkish Twitter data. In AIP Conference Proceedings (Vol. 2183, No. 1). AIP Publishing.
- Taboada, M., Brooke, J., Tofiloski, M., Voll, K., & Stede, M. (2011). Lexicon-based methods for sentiment analysis. *Computational linguistics*, 37(2), 267-307.
- Thelwall, M., Buckley, K., & Paltoglou, G. (2012). Sentiment strength detection for the social web. *Journal of the American Society for Information Science and Technology*, 63(1), 163-173.
- Tocoglu, M. A., & Alpkocak, A. (2018). TREMO: A dataset for emotion analysis in Turkish. *Journal of Information Science*, 44(6), 848-860.
- Umair, M., Hakim, A., Hussain, A., & Naseem, S. (2021). Sentiment analysis of students' feedback before and after COVID-19 pandemic. *Int. J. Emerg. Technol*, 12(2), 177-182.
- Wiedemann, G., Remus, S., Chawla, A., & Biemann, C. (2019). Does BERT make any sense? Interpretable word sense disambiguation with contextualized embeddings. arXiv preprint arXiv:1909.10430.
- Wilson, T., Wiebe, J., & Hoffmann, P. (2009). Recognizing contextual polarity: An exploration of features for phrase-level sentiment analysis. *Computational linguistics*, 35(3), 399-433.
- Wöllmer, M., Weninger, F., Knaup, T., Schuller, B., Sun, C., Sagae, K., & Morency, L. P. (2013). Youtube movie reviews: Sentiment analysis in an audio-visual context. *IEEE Intelligent Systems*, 28(3), 46-53.
- Yurtkoru, E. S., & Sipahi, B. (2003). Öğretim üyesi performans deđerlendirme kriterinin cinsiyete göre belirlenmesi üzerine analitik bir çalıřma.
- Xu, G., Meng, Y., Qiu, X., Yu, Z., & Wu, X. (2019). Sentiment analysis of comment texts based on BiLSTM. *Ieee Access*, 7, 51522-51532.

