



Bilgisayar Programlamayı Öğrenme Sürecindeki Öğrencilerin Duyguları, Yetkilendirilmeleri ve Bilgi İşlemsel Kimliklerinin Metin Madenciliği Algoritmalarını Kullanarak Tahmin Edilmesi

Yazılım Mühendisliği Ana Bilim Dalı

Yüksek Lisans Tezi

Nilüfer ATMAN USLU

ORCID 0000-0003-2322-4210

Tez Danışmanı: Doç. Dr. Aytuğ ONAN

Temmuz 2023

İzmir Kâtip Çelebi Üniversitesi Fen Bilimleri Enstitüsü öğrencisi **Nilüfer ATMN USLU** tarafından hazırlanan **Bilgisayar Programlamayı Öğrenme Sürecindeki Öğrencilerin Duyguları, Yetkilendirilmeleri ve Bilgi İşlemsel Kimliklerinin Metin Madenciliği Algoritmalarını Kullanarak Tahmin Edilmesi** başlıklı bu çalışma tarafımızca okunmuş olup, yapılan savunma sınavı sonucunda kapsam ve nitelik açısından başarılı bulunarak jürimiz tarafından **YÜKSEK LİSANS** olarak kabul edilmiştir.

ONAYLAYANLAR:

Tez Danışmanı: **Doç. Dr. Aytuğ ONAN**
İzmir Kâtip Çelebi Üniversitesi

Jüri Üyeleri:

Doç. Dr. Vahide BULUT
İzmir Katip Çelebi Üniversitesi

Dr. Öğr. Üyesi Emin BORANDAĞ
Manisa Celal Bayar Üniversitesi

Savunma Tarihi: 03.07.2023

Yazarlık Beyanı

Ben, Nilüfer ATMAN USLU, başlığı **Bilgisayar Programlamayı Öğrenme Sürecindeki Öğrencilerin Duyguları, Yetkilendirilmeleri ve Bilgi İşlemsel Kimliklerinin Metin Madenciliği Algoritmalarını Kullanarak Tahmin Edilmesi** olan bu tezimin ve tezin içinde sunulan bilgilerin şahsıma ait olduğunu beyan ederim.

Ayrıca:

- Bu çalışmanın bütünü veya esası bu üniversitede Yüksek Lisans / Doktora derecesi elde etmek üzere çalıştığım süre içinde gerçekleştirilmiştir.
- Daha önce bu tezin herhangi bir kısmı başka bir derece veya yeterlik almak üzere bu üniversiteye veya başka bir kuruma sunulduysa bu açık biçimde ifade edilmiştir.
- Başkalarının yayımlanmış çalışmalarına başvurduğum durumlarda bu çalışmalara açık biçimde atıfta bulundum.
- Başkalarının çalışmalarından alıntıladığımda kaynağı her zaman belirttim. Tezin bu alıntılar dışında kalan kısmı tümüyle benim kendi çalışmamdır.
- Kayda değer yardım aldığım bütün kaynaklara teşekkür ettim.
- Tezde başkalarıyla birlikte gerçekleştirilen çalışmalar varsa onların katkısını ve kendi yaptıklarımı tam olarak açıkladım.

Tarih: 03.07.2023

Bilgisayar Programlamayı Öğrenme Sürecindeki Öğrencilerin Duyguları, Yetkilendirilmeleri ve Bilgi İşlemsel Kimliklerinin Metin Madenciliği Algoritmalarını Kullanarak Tahmin Edilmesi

ÖZ

Bu çalışmada, programlama eğitimi alan öğrencilerin açık uçlu sorulara verdikleri yanıtların, duygu/görüş analizi ile tahminlenmesi ve farklı algoritmaların performanslarının karşılaştırılması amaçlanmıştır. Böylece, programlama eğitiminde duygu, bilgi işlemsel kimlik ve programlamada yetkilendirme ile ilgili metin tabanlı verilerin analiz edilmesi ile ilgili bir girişim yapılmasına çalışılmıştır. Araştırmada veri setinin oluşturulması için açık uçlu sorulardan oluşan elektronik bir form hazırlanmıştır. Bu formda, programlama eğitimi alan öğrencilerin duyguları, bilgi işlemsel kimlikleri ve programlamada yetkinliklerine ilişkin görüşlerinin toplanması için 14 açık uçlu soru bulunmaktadır. Araştırmaya, programlama eğitimi gören ve yaş aralığı 12-20 arasında değişen 646 öğrenci katılmıştır. Öğrencilerin sorulara verdikleri yanıtlar neticesinde 9044 cümlelik bir veri seti oluşturulmuştur. Duygu analizi kapsamında makine öğrenme algoritmalarından, karar ağaçları, destek vektör makineleri, lojistik regresyon, yapay sinir ağları ve rasgele orman algoritmaları kullanılmıştır. Ayrıca BERTurk ile öğrenci görüşleri tahminlenerek, söz konusu algoritmaların performansları karşılaştırılmıştır. Analizler, Python 3.10 programlama dili kullanılarak yapılmıştır. Araştırmanın sonuçları, duyguları tahminleme sürecinde,

destek vektör makineleri ve rasgele orman algoritmalarının %94 doğruluk değeri ürettiğini göstermiştir. BERTurk ile %96'lık bir tahminleme performansına ulaşılmıştır. Lojistik regresyon ve yapay sinir ağları ile birlikte TF-IDF temsili bilgi işlemsel kimlik için en yüksek doğruluk oranını elde etmiştir (%93). Programlamada yetkilendirme için en yüksek doğruluk oranları destek vektör makineleri ve rasgele orman algoritmasından elde edilmiştir (%94). BERTurk ile elde edilen doğruluk değerleri; bilgi işlemsel kimlik ve programlamada yetkilendirme için %96 olarak bulunmuştur. Öğrencilerin programlama eğitime yönelik duygularının, sınıflandırılmasında BERTurk'ün, makine öğrenmesi algoritmalarının tamamından daha yüksek doğruluk değerlerini ortaya çıkardığı tespit edilmiştir.

Anahtar Sözcükler: Duygu, bilgi işlemsel kimlik, programlamada yetkilendirme, metin madenciliği.

Predicting emotions, empowerment, and computational identity of students in the process of learning computer programming using text mining algorithms

Abstract

It is aimed to predict the answers of the students who receive programming education to open-ended questions by emotion/opinion analysis and to compare the performances of different algorithms in this study. Thus, an attempt has been made to analyze text-based data in on emotion in programming education, computational identity, and programming empowerment. An electronic form consisting of open-ended questions was prepared for the creation of the data set in the research. In this form, there are 14 open-ended questions to collect the opinions of the students who receive programming education about their emotions, computational identities, and their programming empowerment. A total of 646 students, aged between 12 and 20, studying programming, participated in the research. As a result of the answers given by the students to the questions, a data set of 9044 sentences was created. Within the scope of sentiment analysis, decision trees, support vector machines, logistic regression, artificial neural networks, and random forest algorithms from machine learning algorithms were used. In addition, students' opinions were estimated with BERTurk and the performances of these algorithms were compared. Analyzes were made using the Python 3.10 programming language. The results of the research showed that the support vector machines, and random forest algorithms produced 94% accuracy in the process of predicting emotions in general. With BERTurk, an estimation performance of 96% has been achieved. Logistic regression and neural

networks with TF-IDF achieved the highest accuracy rate (93%) for computational identity. The highest accuracy rates for programming empowerment were obtained from support vector machines and random forest algorithm (94%). The accuracy values obtained with BERTurk were found to be 96% for computational identity and programming empowerment. It has been determined that BERTurk reveals higher accuracy values than all machine learning algorithms in classifying students' emotions towards programming education.

Keywords: Emotion, computational identity, programming empowerment, text-mining.

Hayattaki en deęerli varlıklarım;

Oęlum Mehmet Ata ve Kızım Duru Ela'ya

Teşekkür

Uzun yıllar önce başladığım akademik yaşantımda öğrenme serüvenime destek olan pek çok kişi oldu. Öncelikle ebeveynlerim, daha sonra eşim, dostlarım, çocuklarım ve kıymetli meslektaşlarımın desteği olmadan yeni bir şey öğrenme isteğimi ve motivasyonumu sürdüremezdim. Bu bağlamda, bu çalışmanın ortaya konmasında teşekkür edeceğim çok fazla kişi; minnettarlık duyacağım pek olay ve durumla karşılaştım. Hepsini burada dile getirmek çok uzun bir listeye neden olsa da özellikle bazı isimlerin varlığını ve desteğini anmak isterim.

Öncelikle, birlikte çalışmaktan gurur duyduğum değerli tez danışmanım Doç. Dr. Aytuğ ONAN'a, beni bu alanla tanıştırdığı, deneyimini ve bilgisini benimle paylaştığı ve çalışmam sürecinden bana verdiği destek için çok teşekkür ederim. Kıymetli jüri üyelerine, araştırmamı titizlikle inceledikleri ve iyileştirilmesi için sundukları değerli geri bildirimleri için teşekkürü bir borç bilirim.

Lisans eğitimimden beri dostum Figen EĞİN'in desteği, ilgisi ve birlikte bu süreci yürütmenin verdiği güç olmadan, bu çalışma bu noktaya gelemezdi. Ayrıca, kıymetli dostum Doç. Dr. Hatice YILDIZ DURAK, araştırma ve raporlama dahil olmak üzere pek çok aşamada yanımda oldu. Desteğini, ilgisini ve özenini esirgemeyen her iki dostuma da sonsuz teşekkürlerimi sunuyorum. İyi ki varsınız...

Çalışmamın ortaya konmasında, aileme özellikle şükranlarımı sunmak isterim. Değerli ebeveynlerim, ilkokuldan bugüne kadar eğitim yaşantım da dahil olmak üzere beni her açıdan desteklediniz. Sizin desteğiniz olmasaydı pek çok şey yarım kalırdı. Uzun süren çalışmalarım da beni yalnız bırakmayan, yanımda olan ve beni cesaretlendiren sevgili eşim Engin USLU'ya ne kadar teşekkür etsem azdır. Onun desteği ve anlayışı olmadan bu noktaya gelemezdim. Tabi ki hayattaki en büyük mutluluk kaynağım olan çocuklarım, tüm araştırma sürecini neredeyse benimle birlikte yaşadınız. Her şey için size minnettarım. İyi ki benim ailemsiniz...

İçindekiler

Yazarlık Beyanı.....	ii
Öz.....	iii
Abstract.....	v
Teşekkür.....	viii
Bölüm 1.....	1
Giriş.....	1
1.1 Programlama Eğitimi	2
1.2 Bilgi işlemsel Düşünme.....	3
1.3 Duygu	5
1.4 Bilgi İşlemsel Kimlik	9
1.5 Programlamada Yetkilendirme.....	9
1.6 Araştırmanın Amacı ve Önemi.....	10
Bölüm 2.....	12
İlgili Araştırmalar.....	12
2.1 Eğitiminde Duygu Analizi ile İlgili Araştırmalar.....	12
2.2 Bilgi İşlemsel Kimlik ve Programlamada Yetkilendirme ile İlgili Araştırmalar.....	15
Bölüm 3.....	18
Metin Madenciliği.....	18
3.1 Metin Ön İşleme.....	19

3.2 Kelime Gösterim Modelleri.....	21
3.2.1 Geleneksel Gösterim Modelleri.....	22
3.2.2 Dağıtık Gösterim Modelleri.....	23
3.2.3 Bağlamsal Gösterim Modelleri.....	26
3.3 Duygu Analizi	27
3.3.1 Duygu Analizinde Kullanılan Makine Öğrenmesi Yaklaşımları.....	31
3.3.2 BERT	35
3.4 Değerlendirme Metrikleri.....	36
Bölüm 4.....	38
Materyal ve Yöntem.....	38
4.1 Veri Setinin Oluşturulması.....	39
4.2 Ön işleme.....	41
4.3 Programlama Yaparken Deneyimlenen Duyguların Tahmin Edilmesi.....	42
4.3.1 Keyif Duygusunun Tahmin Edilmesi	44
4.3.2 Umut Duygusunun Tahmin Edilmesi	48
4.3.3 Kaygı Duygusunun Tahmin Edilmesi	52
4.3.4 Sıkılma Duygusunun Tahmin Edilmesi.....	55
4.3.5 Genel Olarak Duyguların Tahmin Edilmesi	59
4.4 Bilgi İşlemsel Kimlikle İlgili Görüşlerin Tahmin Edilmesi.....	61
4.5 Programlamada Yetkilendirme İle İlgili Görüşlerin Tahmin Edilmesi.....	66
Bölüm 5.....	71

Bulgular ve Tartışma.....	71
Bölüm 6.....	74
Sonuçlar.....	74
Kaynaklar	76
Ekler	91
Ek A	92
Özgeçmiş.....	93

Şekiller Listesi

Şekil 1.1: Bilgi işlemsel düşünme çerçevesi	4
Şekil 1.2: Akademik başarı duyguları taksonomisi	7
Şekil 3.1:Metin Madenciliğinin Adımları	19
Şekil 3.2: Kelime Gösterim Modelleri	21
Şekil 3.3: Word2vec Modeli	24
Şekil 3.4: Word2vec Modeli	25
Şekil 3.5: GPT ve BERT kelime yerleştirme gösterimleri	27
Şekil 3.6 : Duygu analizi yaklaşımları	28
Şekil 3.7: Karar ağaçları yapısı	31
Şekil 3.8: Destek vektör makineleri yapısı	32
Şekil 3.9: Yapay sinir ağları yapısı	33
Şekil 3.10: Yapay sinir ağları yapısı	34
Şekil 4.2 : Duygu ile ilgili pozitif ve negatif cümlelerin frekansları	44
Şekil 4.3: Keyif duygusuna ilişkin pozitif etiketlenmiş cümleler için unigramlar	45
Şekil4.4: Keyif duygusuna ilişkin negatif etiketlenmiş cümleler için unigramlar.....	45
Şekil 4.5: Word2Vec kelime temsil yönteminin kullanıldığı makine öğrenmesi algoritmalarının bulguları (Keyif Duygusu)	47

Şekil 4.6: TF-IDF kelime temsil yönteminin kullanıldığı makine öğrenmesi algoritmalarının bulguları (Keyif Duygusu)	47
Şekil 4.7: Umut duygusuna ilişkin pozitif etiketlenmiş cümleler için unigramlar	48
Şekil 4.8: Umut duygusuna ilişkin negatif etiketlenmiş cümleler için unigramlar	49
Şekil 4.9: Word2Vec kelime temsil yönteminin kullanıldığı makine öğrenmesi algoritmalarının bulguları (Umut duygusu)	50
Şekil 4.10: TF-IDF kelime temsil yönteminin kullanıldığı makine öğrenmesi algoritmalarının bulguları (Umut duygusu)	51
Şekil 4.11: Kaygı duygusuna ilişkin pozitif etiketlenmiş cümleler için unigramlar ..	52
Şekil 4.12: Kaygı duygusuna ilişkin negatif etiketlenmiş cümleler için unigramlar .	52
Şekil 4.13: Word2Vec kelime temsil yönteminin kullanıldığı makine öğrenmesi algoritmalarının bulguları (Kaygı duygusu)	54
Şekil 4.14: TF-IDF kelime temsil yönteminin kullanıldığı makine öğrenmesi algoritmalarının bulguları (Kaygı duygusu)	54
Şekil 4.15: Sıkılma duygusuna ilişkin pozitif etiketlenmiş cümleler için unigramlar	55
Şekil 4.16: Kaygı duygusuna ilişkin negatif etiketlenmiş cümleler için unigramlar .	56
Şekil 4.17: Word2Vec kelime temsil yönteminin kullanıldığı makine öğrenmesi algoritmalarının bulguları (Sıkılma duygusu).....	57
Şekil 4.18: TF-IDF kelime temsil yönteminin kullanıldığı makine öğrenmesi algoritmalarının bulguları (Sıkılma duygusu).....	58
Şekil 4.19: Word2Vec kelime temsil yönteminin kullanıldığı makine öğrenmesi algoritmalarının bulguları (Duygular- genel).....	60
Şekil 4.20: TF-IDF kelime temsil yönteminin kullanıldığı makine öğrenmesi algoritmalarının bulguları (Duygular- genel).....	60
Şekil 4.21: Bilgi işlemsel kimlik ile ilgili pozitif ve negatif cümlelerin frekansları ..	63

Şekil 4.22: Word2Vec kelime temsil yönteminin kullanıldığı makine öğrenmesi algoritmalarının bulguları (Bilgi işlemsel kimlik)	64
Şekil 4.23: TF-IDF kelime temsil yönteminin kullanıldığı makine öğrenmesi algoritmalarının bulguları (Bilgi işlemsel kimlik)	65
Şekil 4.24: Programlamada yetkilendirme ile ilgili pozitif ve negatif cümlelerin frekansları.....	67
Şekil 4.25: Word2Vec kelime temsil yönteminin kullanıldığı makine öğrenmesi algoritmalarının bulguları (Duygular- genel).....	68
Şekil 4.26: TF-IDF kelime temsil yönteminin kullanıldığı makine öğrenmesi algoritmalarının bulguları (Duygular- genel).....	69

Tablolar Listesi

Tablo 1.1: Kontrol, değer ve başarı duyguları ile ilgili temel varsayımlar	8
Tablo 3.1: Metin ön işleme kavramları ve tanımları.....	20
Tablo 3.2: Makine öğrenmesi, sözlük tabanlı ve hibrit yaklaşımların özellikleri, avantajları ve sınırlılıkları	30
Tablo 4.1: Duygular ile ilgili pozitif ve negatif alıntı örnekleri.....	42
Tablo 4.2: Keyif duygusunun tahminlenmesinde kullanılan makine öğrenme algoritmaları sonuçları	46
Tablo 4.3: Keyif duygusunun tahmin edilmesinde BERTurk bulguları	48
Tablo 4.4: Umut duygusunun tahminlenmesinde kullanılan makine öğrenme algoritmaları sonuçları	49
Tablo 4.5: Umut duygusunun tahmin edilmesinde BERTurk bulguları	51
Tablo 4.6: Kaygı duygusunun tahminlenmesinde kullanılan makine öğrenme algoritmaları sonuçları	53
Tablo 4.7: Kaygı duygusunun tahmin edilmesinde BERTurk bulguları.....	55
Tablo 4.8: Sıkılma duygusunun tahminlenmesinde kullanılan makine öğrenme algoritmaları sonuçları	56
Tablo 4.9: Sıkılma duygusunun tahmin edilmesinde BERTurk bulguları.....	58
Tablo 4.10: Genel olarak duyguların tahminlenmesinde kullanılan makine öğrenme algoritmaları sonuçları	59
Tablo 4.11: Genel olarak duyguların tahmin edilmesinde BERTurk bulguları.....	61

Tablo 4.12: Bilgi işlemsel kimlik ile ilgili pozitif ve negatif alıntı örnekleri	62
Tablo 4.13: Bilgi işlemsel kimliğin tahminlenmesinde kullanılan makine öğrenme algoritmaları sonuçları	63
Tablo 4.14: Bilgi işlemsel kimliğin tahmin edilmesinde BERTurk bulguları	65
Tablo 4.15: Programlamada yetkilendirme ile ilgili pozitif ve negatif alıntı örnekleri	66
Tablo 4.16: Programlamada yetkilendirmenin tahminlenmesinde kullanılan makine öğrenme algoritmaları sonuçları	68
Tablo 4.17: Programlamada Yetkilendirmenin Tahmin Edilmesinde BERTurk Bulguları.....	69

Kısaltmalar Listesi

DDİ	Doğal dil işleme
DVM	Destek Vektör Makineleri
LR	Lojistik Regresyon
TF-IDF	Terim Belge Sıklığı – Ters Belge Sıklığı
YSA	Yapay Sinir Ağları

Bölüm 1

Giriş

Günümüz dijitalleşme hızında yazılım ve teknoloji, toplumun ve hayatın her alanında giderek artan bir rol oynamaktadır [1]. Bilgi çağında, çocukların ve genç yetişkinlerin programlama becerilerinin geliştirilmesi konusunda küresel olarak artan bir eğilim bulunmaktadır. Bu eğilim özellikle son on yılda araştırmalara da yansımıştır. Buna göre, programlama eğitimine yönelik araştırmalar, erken çocukluk [2]–[4], ilk ve ortaöğretimden [5], [6], lise [7]ve üniversite düzeyine [8], [9] değin geniş bir aralıkta yürütülmektedir. Alanyazında, programlama eğitiminde kullanılması gereken platform ve araçların neler olması gerektiği konusunda pek çok çalışma bulunmaktadır [10]–[12]). Bunun yanı sıra, pedagojik yaklaşımlar [13], [14]) ve değerlendirme süreçlerine odaklanıldığı görülmektedir [15], [16]. Bilgi işlemsel düşünme ile ilgili ana araştırma konularından biri de bu becerinin tanımlanması ve içerdiği alt bileşenlerin ortaya konması ile ilgilidir. Alanyazında, bilgi işlemsel düşünme becerisinin içerdiği bileşenler ile ilgili pek çok çerçeve ileri sürülmektedir [17], [18], [19], [20]. Bu çerçevelerde bir problemi küçük parçalara ayırma, soyutlama, test etme vb. bilişsel bileşenlerin yanında; son yıllarda eğilimler, tutumlar ve perspektifler gibi özelliklere odaklanılmaya başlanmıştır. Ancak öğrencilerin duyuşsal özellikleri ve eğilimleri konusundaki çalışmaların sınırlılığı dikkati çekmektedir [21]. Mevcut çalışma, bilgi işlemsel düşünme ve programlama eğitiminde, öğrencilerin hissettikleri duygular, bu süreçte daha yetkin olabilmeleri, bir kimlik ve aidiyet oluşturma ile ilgili görüşlerini metin madenciliği algoritmaları ile inceleyerek, alanyazındaki boşluğu doldurmak üzere bir adım atmaktadır. Nitekim, öğrenme ve öğretme süreçlerinin dijitalleşmesi ile birlikte, forumlar, sohbet ya da sosyal ağlardan elde edilen büyük miktarda metin verisinden anlamlı ve yararlı bilgiler çıkarmak pek çok zorluğu beraberinde getirmektedir [22]. Söz konusu bağlamda, bu zorlukların üstesinden gelinmesinde, eğitimsel metin madenciliği çalışmalarına artan bir ilgi olduğu görülmektedir.

Nitekim, eğitim sistemlerinde, öğrenci görüşlerinin analiz edilmesi, öğrenme deneyimine dayalı olarak uygun öğretim yöntemini sunarak kurumların eğitsel kalitesini iyileştirmesine yardımcı olmak için kullanılabilir [23]. Bu süreçte metin madenciliği, doğal dil metinleri analiz ederek, anlamlı bilgiler çıkarmaya çalışmaktadır [24]. Böylece, yazılı bilgilerin otomatik olarak çıkarılması ve önceden bilinmeyen bilgilerin keşfedilmesi olanaklı kılınmaktadır [25].

Bundan sonraki bölümlerde, araştırmanın çerçevesinde yer alan kavramlara yer verilmiştir. Buna göre sırasıyla, programlama eğitimi, bilgi işlemsel düşünme, duygu, bilgi işlemsel kimlik ve programlamada yetkilendirme kavramları tanıtılmıştır.

1.1 Programlama Eğitimi

İçinde bulunduğumuz çağda pek çok sektörde meydana gelen dijitalleşme adımlarının bir sonucu olarak kullandığımız çok sayıda hizmet ve ürün programlama ile üretilmektedir. Bilgisayarların günlük yaşamdaki işlevi dikkate alındığında, sorunlara çözüm üreten programlara olan talep yoğun bir şekilde artmaktadır [26]. Genel olarak bilgisayar bilimi ve özel olarak programlama, geleneksel olarak yalnızca bilgi teknolojisi uzmanlarıyla ilgili alanlar olarak kabul edilse de son yıllarda bu anlayışın değiştiği görülmektedir [1]. Günümüzde, programlama mühendislik alanının da ötesinde genel olarak temel bir yeterlik olarak kabul edilmektedir [27]. Kullandığımız tüm dijital çözümlerin, yazılımların ve sistemlerin arkasında olan programlama, dijital dünyada yeni bir şeyler yaratmanın, sorunları çözenin ve fikirleri hayata geçirmenin bir aracı olarak görülmektedir [1]. Günümüzde devlet teşviki ya da öğretmen girişimleri ile çocukların bu anlamda yeterliklerin geliştirilmesi için pek çok kodlama projesi başlatılmıştır [27]. Pek çok ülkede olduğu gibi Türkiye’de de ilkökul düzeyinden itibaren çocukların ve gençlerin programlama ile tanışması, bu konuya ilgi duyması ve kariyer planlarını bu doğrultuda yapması yönünde girişimler bulunmaktadır. Dünyada ve Türkiye’de başlatılan bu girişimlerin odağında programlama yoluyla öğrencilerin bilgi işlemsel düşünme becerilerinin geliştirilmesi vardır. Programlama, eğitimi, bilgi işlemsel düşünme kavramlarını uygulamak için gerekli ortamı sağlayarak bilgi işlemsel düşünme becerilerini gelişimini desteklerken,

aynı zamanda bilgi işlemsel düşünme becerisi programlamayı daha yüksek bir role taşımaktadır [21].

1.2 Bilgi işlemsel Düşünme

Bilgi işlemsel düşünme, öğrencilerin programlama ve algoritma uygulayarak geliştirdikleri becerilere odaklanarak, onların soyut düşünme, problem çözme, örüntü tanıma ve mantıksal akıl yürütme gibi niteliklerin geliştirilmesini sağlamaktadır [28]. Jeannette Wing tarafından ilk defa öne sürülen bilgi işlemsel düşünme kavramı, çözümlerin bir bilgi işleme aracı tarafından etkin bir şekilde gerçekleştirilebilecek bir biçimde temsil edilmesi için problemlerin ve çözümlerinin formüle edilmesinde yer alan düşünce süreçleri olarak tanımlanmıştır [29]. Bilgi işlemsel düşünmenin tanımı ve içerdiği alt bileşenler konusunda alanyazında pek çok çerçeve bulunmaktadır. Shute, Sun ve Asbell-Clarke [30], bilgi işlemsel düşünme ile ilgili aşağıdaki bileşenleri tanımlamıştır:

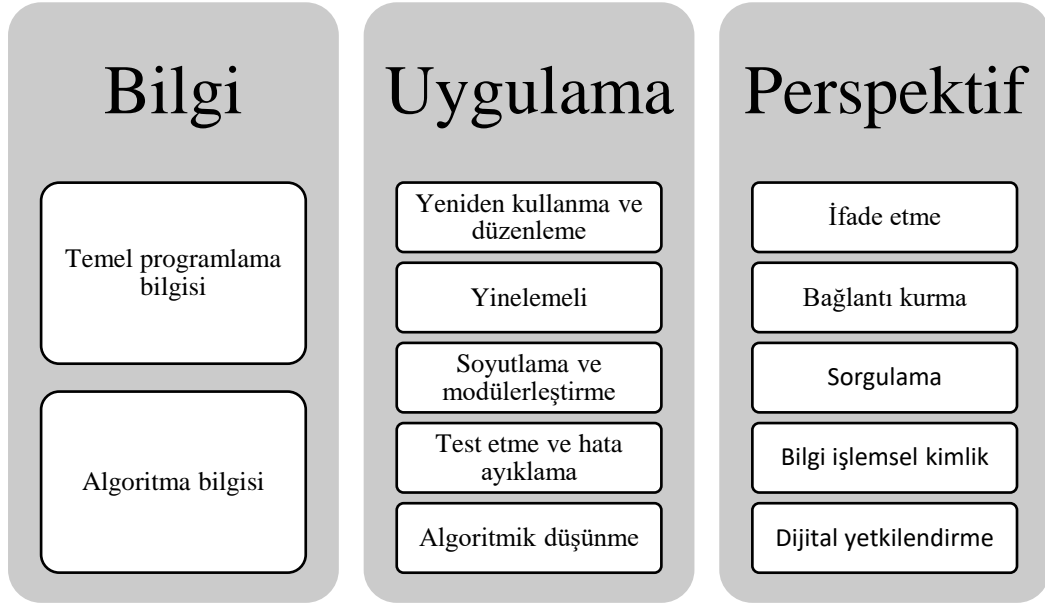
- Ayırıştırma: Karmaşık bir sorunu/sistemi yönetilebilir parçalara ayırma [30].
- Soyutlama: Birkaç örneğin ortak özelliklerini dikkate alma ve bu özelliklerin tümüne sahip bir yapı veya kategori oluşturma fikridir [31]. Soyutlama, veri toplama ve analiz etme, örüntü tanıma ve modellemeyi içermektedir [30].
- Algoritma
- Hata ayıklama
- İterasyon
- Genelleme: Sorunları etkili ve verimli bir şekilde çözmek için bilgi işlemsel düşünme becerilerini çeşitli durumlara veya alanlara aktarma [30].

Bu konudaki bazı çerçevelerde ise, bilgi işlemsel düşünmenin bilişsel süreçlerden daha kapsamlı yönleri olduğu ifade edilmektedir. Brennan ve Resnick [17], bilgi işlemsel düşünme için üç bileşen tanımlamaktadır:

- Bilgi işlemsel düşünme kavramları: Sıralama, döngüler, koşullar, operatör gibi temel programlama ve algoritma bilgisini içermektedir [17].

- Bilgi işlemsel düşünme uygulamaları: Yinemeli süreçler, test etme ve hata ayıklama, soyutlama ve modülerleştirme, yeniden kullanma ve düzenleme ile ilgili uygulamaları içermektedir [17].
- Bilgi işlemsel düşünme perspektifleri: Bilgi işlemsel düşünmenin bir şeyler yaratma, başkaları ile etkileşim kurma yolu olarak algılanması ve gerçek hayat problemlerini çözmek için teknolojinin kullanılmasını içermektedir [17].

Bu çerçeve daha sonra Kong [18] tarafından genişletilmiştir. Bilgi işlemsel düşünme perspektifleri bileşenine, bilgi işlemsel kimlik ve dijital yetkilendirme eklenmiştir (Şekil 1.1).



Şekil 1.1: Bilgi işlemsel düşünme çerçevesi [18].

Bilgi işlemsel düşünme perspektifleri, programcıların kendileri, başkalarıyla ilişkileri ve etraflarındaki teknolojik dünya hakkında sahip oldukları görüşler olarak ele alınmaktadır [17]. Öğrencilerin programlama eğitiminde duyguları da bu kapsamda ele alınabilir. Bu çalışmada, programlama eğitimi alan öğrencilerin duyguları, bilgi işlemsel kimlikleri ve yetkilendirilmeleri ile ilgili görüşlerinin incelenmesine odaklanılmıştır. Nitekim, öğrencilerin bilgi işlemsel düşünme ile ilgili görüşleri, tutum, eğilim ve duyguları gibi tutum ve perspektifler konusundaki çalışmaların sınırlılığı dikkati çekmektedir [21] Bundan sonraki alt bölümler; duygu, bilgi işlemsel

kimlik ve programlamada yetkilendirme kavramlarının tanıtılmasına ve açıklanmasına ayrılmıştır.

1.3 Duygu

Son yıllarda, pek çok disiplinde duyguları tanımak, ölçmek ve tahmin etmek için araştırmalar yapılmaktadır. Davranış, bilgisayar ve eğitim bilimleri de dahil olmak üzere pek çok alanda duygu ile ilgili araştırmalarda hızlı artış olduğu dikkati çekmektedir. Bununla birlikte, alanyazında duygunun nasıl tanımlanacağı konusunda bir fikir birliği olmadığı da göze çarpmaktadır [32] Bu durum, pek çok tartışmaya yol açmakta; araştırmaların kümülatif ilerlemesini engellemekte ve disiplinler arası diyalog ve araştırma işbirliği için büyük bir engel oluşturmaktadır [33]. Duyuşsal yaklaşımlara göre, duygu farklı somatik ve bilişsel bileşenleri içeren, doğası gereği olumlu veya olumsuz, nispeten kısa vadeli bir değerlendirme tepkisidir [34]. Bilişsel yaklaşımlara göre, duygular, kişinin kendi organizmasıyla ilgili durumlarından, harekete geçme dürtülerinden ya da içinde bulunduğu çevresel durumların art arda gelmesinden kaynaklanan bireyin sezgisel değerlendirmelerinin aşamalarıdır [35]. Çoğunlukla duygu kavramının öfke, tiksinti, korku, neşe, üzüntü ve şaşkınlık gibi bir listeye göre tanımlandığı görülmektedir [32]. Bu bağlamda, duygunun tanımı ve hangi duyguları ele alınacağını konusunda çeşitli kuram ve modeller bulunmaktadır. Eliot ve Hirumi [36], duygu kuramlarını üç kategoride incelenebileceğini ifade etmektedir: a) Temel duygu kuramı, b) Çok boyutlu duygu kuramı, c) Akademik duygu kuramı.

Eckman, Cordaro, Izard ve Levenson gibi temel duygu kuramcılarına göre, temel bir duygu subkortikal beyin yapılarından kaynaklanmaları gerektiği için ilkeldir ve sabit bir nöral ve bedensel ifade bileşenine sahiptir [37]. Temel duygular çoğunlukla, mutluluk, üzüntü, korku, öfke ve iğrenme olarak ele alınmaktadır. Bu duyguların yanı sıra, bazen birden fazla temel duygunun eşzamanlı deneyimlenmesi söz konusu olsa da temel duygu kuramı, evrimsel işlevlere sahip yüz ifadeleriyle ilgili olması, kültürel olarak işaretlenmemiş kelimelerle tanımlanması ve az sayıda ayrık, süreksiz duruma dayanması bakımından öne çıkmaktadır [36]

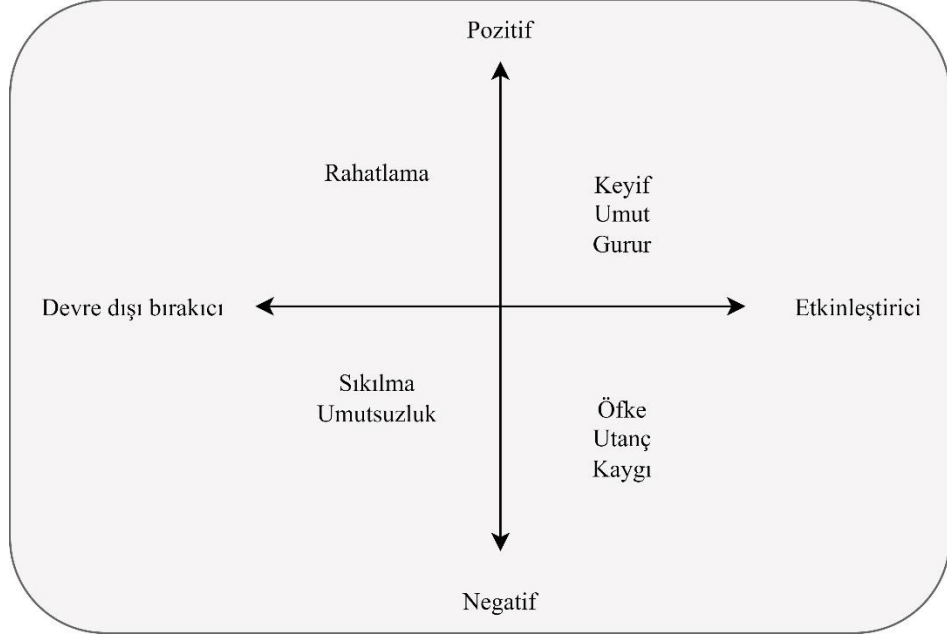
Çok boyutlu duygu kuramları kapsamında en bilinen kuramcı olan Scherer'in Bileşen Süreç Modeline göre, duygu beş ayırt edici işleve karşılık gelen beş bileşenden oluşan teorik bir yapı olarak kabul edilmektedir [38]

- Nesnelerin ve olayların değerlendirilmesi: Bilişsel bileşen
- Sistem regülasyonu: Çevresel etki bileşeni
- Hazırlık ve eylem yönü: Motivasyon bileşeni
- Tepki ve davranışsal niyetin iletişimi: Motor ifade bileşeni
- Dahili durum ve organizma-çevre etkileşiminin izlenmesi: Öznel duygu bileşeni

Temel duygu kuramlarının semantik gelişimi basit cümleler veya kelime denklemleri olarak düşünüldüğünde, çok boyutlu kuramlarında, duyguların minimum bir X ve Y eksenini ile geometrik şekiller veya katı cisimler gibi hayal edildiği ve tasarlandığı bir süreç söz konusudur [36]

Duygu kuramları kapsamında üçüncü kategoride akademik başarı duyguları kuramı yer almaktadır. Bu kurama göre başarı duyguları, doğrudan başarı etkinliklerine veya sonuçlarına yönelik hissedilen duygulardır [39]. Bu kuram, doğası gereği çok boyutlu olmasına rağmen, duyguya öğrenme odaklı bakması nedeniyle ayrı bir kategori altında incelenmektedir [36].

Bu kurama göre başarı duyguları değerlerine ve aktivasyon derecesine göre gruplandırılabilen üç boyutlu bir taksonomide gruplandırılmaktadır [40], [41]. Değerlik açısından duygular pozitif ve negatif olarak sınıflandırılırken; aktivasyon açısından aktive edici ya da gevşeme gibi devre dışı bırakıcı olarak ele alınmaktadır. Şekil 1.2'de akademik başarı duygularının taksonomisine yer verilmiştir.



Şekil 1.2: Akademik başarı duyguları taksonomisi [42]

Buna göre, keyif ve umut değerlik açısından pozitif, aktivasyon açısından etkileştirici duygulardır. Kaygı ve sıkılma değerlik açısından negatif bir duygu olmakla birlikte; sıkılma devre dışı, kaygı etkinleştirici bir duygudur. Durumsal taleplerin bilişsel değerlendirmeleri, kişisel yeterlilikler, başarı ve başarısızlık olasılığı ve bu sonuçların değeri başarı duygularının uyandırılmasında önemli bir rol oynamaktadır [39]. Bu bağlamda kuramda kontrol ve değer algısı ile ilgili değerlendirmeler önemli iki bileşen olarak tanımlanmıştır. Buna göre duyguların üretilmesinde akademik bir görevle ilgili bireyin kontrol ve değer algısı rol oynamaktadır. Bir diğer ifadeyle, başarı duygularının, bireyin öznel olarak önemli olan faaliyetler ve sonuçların kontrolünü elinde tuttuğunu veya kontrolden çıktığını hissettiğinde harekete geçtiğini varsaymaktadır [39]. Pekrun'a göre [40] duyguların odağı, etkinlikle eş zamanlı ve çıktılara yönelik olabilmektedir. Bu bağlamda, duyguların odağı, kontrol ve değer algılarına göre farklılaşması Tablo 1.1'de sunulmuştur.

Tablo 1.1: Kontrol, değer ve başarı duyguları ile ilgili temel varsayımlar [40]

Odak	Değer	Kontrol	Duygu
Çıktı (İleriye dönük)	Pozitif (Başarı)	Yüksek	Beklenen keyif
		Orta	Umut
	Negatif (Başarısızlık)	Düşük	Umutsuzluk
		Yüksek	Rahatlama
Çıktı (Geriye dönük)	Pozitif (Başarı)	Orta	Endişe
		Düşük	Umutsuzluk
		İlgili değil	Keyif, rahatlama
	Negatif (Başarısızlık)	Kendisi	Gurur
		Diğerleri	Minnettarlık
		İlgili değil	Üzüntü
Etkinlik	Pozitif	Kendisi	Utandırma
		Diğerleri	Öfke
	Negatif	Yüksek	Keyif
		Yüksek	Öfke
Pozitif / Negatif	Düşük	Hayal kırıklığı	
	Hiçbiri	Yüksek / Düşük	Sıkılma

Tablo 1.1 incelendiğinde, öznel iç kontrolden kaynaklanan yüksek başarı beklentileri ve başarının ortaya çıkacağına dair kesinlik, ileriye dönük keyif uyandırmakta; başarısızlığın meydana gelmemesine odaklanıldığında ise, beklenen rahatlamanın yaşanacağı tahmin edilmektedir [40]. Umut, kaygı veya umutsuzluk gibi ileriye dönük sonuç duygularında, kontrolle ilgili önemli soru, başarıya ulaşıp ulaşılamayacağı veya başarısızlıktan kaçınıp kaçınılamayacağı ile ilgiliyken; geriye dönük sonuç duygularında, kontrole ilişkin öncül soru, sonucun kişinin kendisinden mi, yoksa diğer kişilerden ve dış koşullardan kaynaklanması ile ilgilidir [36]. Odak etkinlikte olduğunda ise, örneğin ders çalışma ya da öğrenme materyali olumlu bir şekilde değerlendirilirse ve etkinlik kişinin kendisi tarafından yeterince kontrol edilebilir olarak algılanırsa, keyfin teşvik edildiği varsayılmaktadır [40].

Bu üç duygu kuramı yaklaşımı içinde, öğrenme etkinlikleri ve sonuçlarına odaklandığı için bu araştırma bağlamında akademik başarı kuramının temel alınmasına karar verilmiştir. Mevcut araştırma, pozitif etkileştirici duygulardan keyif ve umut duygusunu; negatif etkinleştirici duygulardan kaygı duygusunu ve negatif devre dışı bırakıcı duygulardan sıkılma duygusunu ele almıştır. Böylece programlama eğitimi ile ilgili öğrenci duygularının çeşitliliğinin yansıtılmasına çalışılmıştır.

1.4 Bilgi İşlemsel Kimlik

Kong ve Lai [42], bilgi işlemsel kimlik kavramı okuldaki programlama ve bilgi işlemsel etkinliklere kişisel ve toplu katılımı ile ilgili olarak benliğin devam eden zihinsel inşası olarak tanımlamaktadır. Bilgi işlemsel kimlik, öğrencilerin programlama ile ilgilenmeleri için motivasyonu sağlamada göz önünde bulundurulması gereken bir bileşendir [43]. Bu çalışmada Kong ve Lai [42] çalışmasından hareketle bilgi işlemsel kimliğin üç bileşeni temel alınmıştır: (a) Katılım (b) İmgeleme, (c) Bağlılık:

- Katılım, bireyin programlama ile ilgili etkinliklere aktif bir şekilde katılımını ifade etmektedir [44].
- İmgeleme, gelecekte bir kariyer yönelimi olarak programlama etkinliklerine olan bağlantı ile ilgilidir [45],[46].
- Bağlılık, programlama ile ilgili bir gruba olan bağlılık ve ait olma hissini ifade etmektedir [44].

Bilgi işlemsel kimlik, grup içi üyelerle bilgi işlemsel düşünme etkinliklerinde ağ oluşturma ve bilgi-deneyim paylaşımı yoluyla kişisel temsillerin bireysel ve kolektif bakış açılarını vurgulamaktadır [18]. Tissenbaum ve diğerlerine göre [47], bilgi işlemsel kimliğin oluşumunu desteklemek öğrencilerin önceden belirlenmiş “doğru” cevaplar için çalışmalarını yerine; çözümlerini ifade etmekten ve tasarlamaktan sorumlu olduklarını deneyimlemeleri gerekmektedir. Ayrıca, çalışmalarının daha geniş bilgi işlem ve mühendislik topluluklarının uygulamalarına gereksinim duymaktadırlar[47].

1.5 Programlamada Yetkilendirme

Programlama eğitimi, öğrencilerin bilgi işlemsel kimliklerini oluşturulmasının yanında yetkilendirilmeleri de odaklanmalıdır [42]. Page ve Czuba’ya göre [48], yetkilendirme bir değişim süreci içeren genişletilebilir gücü ifade etmektedir. Yetkilendirilmiş öğrenciler, kendilerini daha yetkin hisseder; öğrenme görevlerini gerçekleştirmede motivasyonları daha yüksektir ve karşılaştıkları görevleri anlamlı bulmaktadır [49]. Programlama eğitiminde öğrenenlerin yetkilendirilmesinde üç

bileşen bulunmaktadır: a) Anlamlılık, b) Etki, c) Öz yeterlik [42], [50] Kong ve diğerleri [50], programlamada yetkilendirmenin, bireyin programlama ile ilgili bir görevi anlamlı görme, bu görevi tamamlamanın bir etkisi olduğuna ve tamamlayabileceklerine inanmayı içerdiğini ifade etmektedir. Ayrıca, Tissenbaum ve diğerleri [47], yetkilendirilmenin geliştirilmesi için aşağıdaki önerileri sunmuştur:

- Otantik ve kişisel olarak alakalı bağlamlarda önemli sayıda faaliyetlerde öğrenciler yer almalıdır [47].
- Öğrencilerin, çalışmalarının kendi yaşamlarında veya topluluklarında bir etki yaratma potansiyeline sahip olduğunu hissetmeleri gerekmektedir [47].
- Öğrenciler, mevcut çalışmalarının bir sonucu olarak yeni programlama ve bilgi işlemsel etkinlikleri takip edebileceklerini hissetmelidirler [47].

Bilgi işlemsel kimlik ve programlamada yetkilendirmenin geliştirilmesine yardımcı olmak için öğrenme görevlerinin tasarımında, öğrencilerin başkalarına katkıda bulunmasına ve bir tatmin duygusu kazanmalarına dikkat edilmesi gerektiği ifade edilmektedir [18]

1.6 Araştırmanın Amacı ve Önemi

Bu çalışmada, programlama eğitimi alan öğrencilerin açık uçlu soruları verdikleri yanıtların, duygu/görüş analizi tahminlenmesi ve farklı algoritmaların performanslarının karşılaştırılması amaçlanmıştır. Böylece, programlama eğitiminde duygu, bilgi işlemsel kimlik ve programlamada yetkilendirme ile ilgili araştırmalarda metin tabanlı verilerin analiz edilmesi ile ilgili bir girişim yapılmasına çalışılmıştır.

Çalışmada, öğrencilerin programlama ve bilgi işlemsel düşünme ile ilgili görüş ve duygularının analiz edilerek yüksek performans gösteren bir sınıflandırma şemasının üretilmesi amaçlanmaktadır. Böylece, eğitimcilerin öğrencilerin duyguları ve eğilimleri konusunda bilgilendirilmeleri için bir adım atılmaktadır. Nitekim duygu analizi, doğal dildeki ifadeleri otomatik olarak analiz eden, temel iddiaları veya görüşleri keşfeden ve bunları duygusal tutumlarına göre sınıflandıran bir süreci içermektedir [51]. Duygu analizi, öğrenciler ve öğretmenler arasındaki etkileşimleri karakterize etmeye ve zamanında, kişiselleştirilmiş geri bildirim yoluyla öğrenmeyi

geliřtirmeye yardımcı olsa da bu yöntemin eğitim alanında kullanımının sınırlı olduđu ifade edilmektedir [52]. Mevcut araştırma ile, programlama eğitimi bağlamında duygu analizi kullanılarak alanyazına katkı sağlanması beklenmektedir.

Bölüm 2

İlgili Araştırmalar

2.1 Eğitiminde Duygu Analizi ile İlgili Araştırmalar

Bu bölümde, eğitim alanında duygu analizi ile ilgili araştırmalara yer verilmiştir. Sangeetha ve Prabha [53], 16175 öğrenciden elde edilen geri bildirim cümlesinden oluşan bir veri seti üzerinde duygu tabanlı veri sınıflandırma sürecini gerçekleştirmeyi amaçlamıştır. Çalışmada, Uzun Kısa Süreli Hafıza (Long Short-Term Memory Network – LSTM), bu yöntemin dikkat katmanı ile birleştirilmesi (LSTM + ATT), Çok başlı dikkat (Multi head attention) sınıflandırma modelleri kullanılmıştır. Ayrıca araştırmacılar, çok başlı dikkat, Glove kelime gömme ve LSTM modellerini bir araya getirerek füzyon olarak isimlendirdikleri bir modeli test etmiştir. Çalışmanın bulgularına göre doğruluk değerleri LSTM için %89,15; LSTM + ATT için %91,18; çoklu başlı dikkat modeli için %95,95 ve füzyon modeli için %97,89 olarak bulunmuştur.

Onan [54], derin öğrenme yaklaşımlarını kullanarak eğitmen değerlendirme incelemeleri için duygu sınıflandırma şeması oluşturmayı amaçlamıştır. Çalışmada, geleneksel makine öğrenimi algoritmaları, toplu öğrenme yöntemleri ve derin öğrenme mimarileri kullanılarak 154000 inceleme içeren bir derlem analiz edilmiştir. Naive Bayes, destek vektör makineleri, lojistik regresyon, K en yakın komşu ve rasgele orman algoritmaları geleneksel denetimli öğrenme modelleri kapsamında uygulanmıştır. Geleneksel makine öğrenimi algoritmalarıyla birlikte üç geleneksel metin temsil şeması (TP, TF ve TF-IDF ağırlıklandırma) kullanılmıştır. Ayrıca, topluluk öğrenme yöntemleri (AdaBoost, Bagging ve rastgele alt uzay) ve derin öğrenme algoritmalarından (CNN, RNN, RNN-AM, GRU ve LSTM) elde edilen

sonular karřılařtırılmıřtır Derin ğrenme mimarileri ile birlikte word2vec, GloVe, fastText ve LDA2vec kelime gmme řemaları kullanılmıřtır. Deneysel sonular, derin ğrenmeye dayalı bulguların geleneksel makine ğrenmesi ve topluluk ğrenme yntemlerinden daha yksek deęerler rettięini gstermiřtir. alıřmada en yksek tahmin performansı, %98,29'luk bir sınıflandırma doęruluęu ile GloVe kelime yerleřtirme řeması tabanlı temsil ile birlikte dikkat mekanizmasına sahip RNN tarafından elde edilmiřtir.

Lai [55], ğretmenlerin bilgi iřlemsel dřünmeyi nasıl kavramsallařtırdıklarını incelemeyi ve bu kavramlar ile ilgili alt grupları belirlemeyi amalamıřtır. Arařtırmaya, 105 bilgisayar bilimi ğretmeni katılmıřtır. Verilerin toplanması iin, ğretmenlerin bilgi iřlemsel dřünmeyi nasıl kavramsallařtırdıklarına ynelik aık ulu sorulardan oluřan bir form hazırlanmıřtır. Toplanan metinler TF-IDF kelime temsil yntemi ile R programı kullanılarak analiz edilmiřtir. Metnin zetlenmesi iin terim sıklık analizi, kelime iliřkilendirme, kelime bulutu ve semantik aęlar kullanılmıřtır. Bilgi iřlemsel dřünmenin kavramsallařtırması ile ilgili alt grupları belirlemek iin hiyerarřik kme analizi uygulanmıřtır. Arařtırmanın bulguları, bilgi iřlemsel dřünmenin kavramsallařtırılması ile ilgili beř kmenin ortaya ıktıęını gstermiřtir. Sonu olarak, ğretmenler bilgi iřlemsel dřünmeyi, problem zme baęlamıyla ilgili eřitli disiplinlere uygulanabilir ve aktarılabilir bir yeterlilik alanı olarak grmektedir.

Bringula ve dięerleri [56], niversite ğrencilerinin  smestr boyunca verilen veri analitięi derslerine iliřkin beklentilerini ve kaygılarını incelemek zere metin madencilięi yntemlerini uygulamıřtır. Veriler 91 ğrencinin toplam 2.893 kelimelik makalelerinden elde edilmiřtir. Hiyerarřik kme analizi kullanılarak, ğrencilerin kurs beklentileri  tema altında sınıflandırılmıřtır: a) Veri analitięinin amacı, b) Kursta kazanılacak beceriler, c) Veri analitięinin uygulanması. Duygu analizi kapsamında, Bing szlę kullanılarak 185 kelime, duygularla etiketlenmiřtir. Arařtırmanın sonuları, dersin karmařık, titiz ve matematiksel yapısından dolayı ğrencilerin ders hakkında endiřeleri olduęunu ortaya koymuřtur.

Onan [57], kitlesel evrim ii aık dersler (KAD) ile ilgili inceleme ve deęerlendirmelerin tahminlenmesinde duygu analizi yntemlerini kullanmıřtır.

Veriler, KAÇD'ler ile ilgili incelemelerin yer aldığı coursetalk.com üzerinden alınarak 66000 KAÇD incelemesini içeren bir metin derlemi oluşturulmuştur. Araştırmada, geleneksel denetimli öğrenme yöntemleri, toplulukla öğrenme yöntemleri ve derin öğrenme yöntemlerinin öngörü performansı değerlendirilmiştir. Çalışmanın deneysel sonuçları, derin öğrenmeye dayalı mimarilerin topluluk öğrenimi yöntemlerinden ve denetimli öğrenimden daha iyi performans gösterdiğini ortaya koymuştur. Karşılaştırılan tüm yapılandırmalar içinde, en yüksek tahmin performansı, %95,80'lik bir sınıflandırma doğruluğu ile GloVe kelime gömme şeması tabanlı temsil ile birlikte LSTM tarafından elde edilmiştir.

Umar [23], programlama ile ilgili öğrenci görüşlerini duygu analizi ile incelemiştir. Araştırmanın amacı, Naïve Bayes algoritmasının küçük veri seti üzerinde pozitif ve negatif olmak üzere iki duygu sınıflandırma şeması üzerindeki etkinliğini araştırarak bir çerçeve tasarlamaktır. Ayrıca destek vektör makineleri algoritması ve sözlük tabanlı yaklaşımı kullanılarak karşılaştırmalı bir performans ölçümü yapılmıştır. Çalışmada veriler, birinci sınıfta öğrenim gören 175 lisans öğrencisinin beceri tabanlı değerlendirme testleri ile ilgili deneyimlerine ilişkin görüşleri ile elde edilmiştir. Öğrencilerin görüşleri Naïve Bayes algoritması kullanılarak sınıflandırıldığında, %92'lik bir negatif tahmin doğruluğuna ve %75'lik bir pozitif tahmin doğruluğuna ulaşılmıştır. Çalışmada ayrıca, Naïve Bayes algoritmasının küçük veri kümesinde destek vektör makineleri ve Lexicon tabanlı yaklaşımdan daha iyi sonuçlar ürettiği görülmüştür. Anketin analizinden elde edilen bulgular, öğrenciler tarafından beceriye dayalı testin zor olarak algılandığını ve korkutucu duygular deneyimlediklerini göstermiştir.

Alanyazında eğitimde duygu analizinin kullanıldığı çalışmaları kategorize eden ve sistematik olarak inceleyen araştırmalar da bulunmaktadır. Zhou ve Ye [58], eğitimde duygu analizi araştırmalarının genel özelliklerini, kullanılan yaklaşımları ve duygu kategorilerini, araştırma hedeflerini ve temel bulgularını derlemeyi amaçlamıştır. Beş çevrimiçi bibliyografik veri tabanı sistematik olarak tarandıktan sonra 41 ilgili makale araştırmada irdelenmiştir. Sonuçlar, çoğu çalışmanın yüksek öğretime odaklandığını ve küçük veri kümelerini benimsediğini göstermiştir. Kullanılan duygu analizi yöntemleri açısından incelenen araştırmalarda hibrid yaklaşımların, makine öğrenmesi, sözlük tabanlı ve manuel metotlara göre daha fazla kullanıldığı

görülmüştür. Çalışmada, ayrıca eğitimde duygu analizinde dört araştırma eğilimi olduğu tespit edilmiştir: a) Duygu analizi yöntemleri/sistemleri tasarlama, b) Öğrencilerin memnuniyetini/tutumunu/ilgili konuları araştırma, c) Öğretmenlerin öğretme performansını değerlendirme, d) Duygu, davranış, performans ve başarı arasındaki ilişkiyi inceleme.

Grimalt-Álvaro ve Usart [52], duygu analizinin yüksek öğretimde çevrimiçi ve hibrit öğrenme bağlamlarında öğrenme değerlendirmesi için nasıl uygulandığını incelemeyi amaçlamıştır. Araştırmadan elde edilen bulgular, makalelerin çoğunun teknik bir bakış açısıyla yazıldığını ve dijital teknolojilerle ilgili dergilerde yayınlanmış olsa da duygu analizinin büyüyen bir araştırma alanı olduğunu göstermektedir. Çalışmada, öğrenme performansını tahmin etmeye, geri bildirim artırmaya ve öğretmenlere görsel araçlar sağlamaya yardımcı olabilecek farklı duygu analiz tekniklerini içeren çözümler olduğu görülmüştür. Ancak bu tekniklerin eğitimsel uygulamaları ve kullanılabilirliğinin sınırlı olduğu ifade edilmektedir. Ayrıca, cinsiyet veya kültürel bağlam gibi katılımcıların farklı duygu ifadelerini etkileyebilecek değişkenlerin rolünün yeterince incelenmediğini ve gelecekteki gelişmelerde dikkate alınması gerektiği belirtilmiştir.

2.2 Bilgi İşlemsel Kimlik ve Programlamada Yetkilendirme ile İlgili Araştırmalar

Kong ve Lai [42], bilgi işlemsel kimlik ölçeğini geliştirilmesini ve programlamada yetkilendirme bileşenleri üzerindeki etkisini yapısal eşitlik modeli ile incelemeyi amaçlamıştır. Araştırmaya programlama eğitimi göre 1066 son sınıf ilkökul öğrencisi katılmıştır. Analizler sonucunda, programlamada yetkilendirme ve bilgi işlemsel kimlik arasında pozitif yönde bir ilişki olduğu tespit edilmiştir. Bilgi işlemsel kimliği alt boyutları olan katılım, imgelem ve bağlılık ile yetkilendirmenin alt bileşenlerinden anlamlılık ve öz yeterliliği algısı arasındaki ilişkiler doğrulanmıştır.

Atman-Uslu [59], ortaokul öğrencilerinin bilgi işlemsel kimlik ve programlamada akademik yılmazlık özelliklerine göre profillenmesine odaklanmıştır. Araştırmaya ortaokul beşinci ve altıncı sınıfta öğrenim gören ve programlama eğitimi alan 601 öğrenci katılmıştır. Araştırmanın sonucunda öğrenciler bilgi işlemsel kimlik ve

akademik yılmazlık özelliklerine göre dört profilde karakterize edilmiştir: a) düşük, b) düşük – orta, c) orta- yüksek, d) yüksek. Ortaya çıkan alt popülasyonlardaki öğrencilerin cinsiyete ve profile göre bilgi işlemsel düşünme becerisi ve öz yeterlik algılarındaki farklılaşma incelenmiştir. Araştırmanın sonucunda, daha yüksek yüksek bilgi işlemsel kimlik ve yılmazlık ile karakterize edilen profillerin bilgi işlemsel düşünme performansı ve öz yeterlik puanlarının anlamlı bir şekilde yüksek olduğunu göstermiştir.

Kong ve Wang [44], bilgi işlemsel perspektiflerinin bilgi işlemsel kimlik üzerindeki rolünü incelemeyi amaçlamıştır. Çalışmada bilgi işlemsel perspektifler, bağlantı kurma yeteneği, sorgulama yeteneği ve ifade etme yeteneği boyutlarında ele alınmıştır. Bilgi işlemsel kimlik için dört boyut tanımlanmıştır: a) programlama bağlantısı, b) programlama katılımı c) programlama gerçekleştirme, d) programlama hedefi belirleme. Programlama eğitimi alan öğrenciler ile yürütülen çalışmada, yapısal eşitlik modeli kullanılmıştır. Çalışmanın sonuçları, ilkökul öğrencileri arasında bilgi işlemsel düşünme perspektifleri ile bilgi işlemsel kimlik oluşumu arasında pozitif ilişkiler olduğunu göstermiştir. Aracılık etkisi sonuçları ayrıca, sorgulama yeteneğinin ifade etme yeteneği yoluyla bilgi işlemsel kimlik oluşumunu destekleyebileceğini, bağlantı kurma yeteneğinin ise doğrudan kimlik oluşumu üzerinde pozitif rolü olduğunu göstermiştir.

Kong ve diğerleri [50], ilgi, iş birliğine yönelik tutum ve programlamada yetkilendirme değişkenleri arasındaki ilişkileri incelemeyi amaçlamıştır. Araştırmada veriler, dördüncü ve altıncı sınıfta öğrenim gören 287 öğrenciden oluşan bir örneklemden toplanmıştır. Doğrulayıcı faktör analizi, programlamada yetkilendirme aracının önerilen bileşenlerini doğrulamıştır. İleri sürülen yapısal eşitlik modeli test sonuçları, programlamaya daha fazla ilgi duyan öğrencilerin programlamayı daha anlamlı olarak algıladıklarını, programlamanın etkisini daha yüksek düzeyde gördüklerini, daha fazla yaratıcılığa ve programlamaya ilişkin özyeterliğine sahip olduklarını göstermiştir. Çalışma, iş birliği ve ilgi yapılarının programlamada yetkilendirme bileşenleri üzerindeki pozitif rolünü ortaya koymuştur. Ayrıca, iş birliğine yönelik tutumları diğerlerinden daha yüksek olan öğrencilerin yaratıcı öz-yeterliklerinin daha yüksek olduğu bulunmuştur. Erkek öğrencilerin, programlamaya yönelik ilgileri kızlardan daha yüksek olduğu tespit edilmiştir. Daha üst kademedeki


öğrencilerin, programlama etkinliklerini daha az anlamlı gördükleri ve daha düşük programlama öz-yeterliğine sahip oldukları belirlenmiştir.

Bu çalışmalar, bilgi işlemsel kimlik, yetkilendirme ve diğer değişkenler arasındaki ilişkileri ortaya koyarak, programlama eğitimindeki rolünü vurgulasa da, bu konudaki çalışmaların erken evrede olduğu ileri sürülebilir. Nitekim, bu konudaki nitel çalışmaların sınırlılığı da dikkati çekmektedir. Bu bağlamda metin madenciliği ile bu değişkenlerin irdelenmesi, konuyla ilgili daha derin bir anlayış kazanılmasında ilgi çekici yollar açabileceği ileri sürülebilir.

Bölüm 3

Metin Madenciliği

Günümüzde, çevrimiçi platformlar, gazete içerikleri, sosyal medya gönderileri, müşterilerin ürünler ve deneyimleri hakkındaki yorumları, bilimsel makaleler ve basın bültenleri de dahil olmak üzere çok büyük miktarlarda dijitalleştirilmiş metin bulunmaktadır [60]. Bu yapılandırılmamış metinlerin, bilgisayar tarafından kullanılabilmesi ve bu metinlerden önemli ve anlamlı bilgilerin çıkarılması için yeni tekniklere gereksinim duyulmaktadır [61]. Bu bağlamda, metin madenciliği, dil bilimi, istatistik ve bilgisayar bilimini içeren yaklaşımları bir araya getirerek; büyük ölçekli metinlerden oluşan bilgileri otomatik olarak keşfetmeyi, sınıflandırmayı ve anlamını ortaya çıkarmayı amaçlar [62]. Dolayısıyla, metin madenciliği, doğal dil metinlerini analiz ederek, anlamlı bilgiler çıkarmaya çalışır [24]. Böylece, kullanıcının belirli bir metin parçasından yüksek kalitede bilgi elde ettiği bir süreç ortaya çıkar [63]. Metin madenciliğinde, kimsenin bilmediği ve dolayısıyla henüz yazmadığı bilinmeyen bilgilerin keşfedilmesi amaçlanır [64]. Metin madenciliği bir dizi adımı içeren bir süreci takip eder. Bu süreçte izlenen adımlar Şekil 3.1’de gösterilmiştir [64]. Şekil 3.1 incelendiğinde, metin madenciliği sürecinin bir belge koleksiyonunun elde edilmesiyle başladığı görülmektedir. Daha sonra, bu belgenin biçim ve karakter kümelerinin kontrol edildiği ön işleme aşamasına geçilmektedir [64]. Girdi metin verileri mevcut olduğunda, yapılandırılmamış metni yapılandırılmış ve makine tarafından işlenebilen temsili bir formata dönüştürmek gerekmektedir [65].



Şekil 3.1:Metin Madenciliğinin Adımları [64].

Metin çeşitli yöntemler ile analiz edildikten sonra, ortaya çıkan bilgiler, bir yönetim bilgi sistemine yerleştirilebilir ve bu sistemin kullanıcısı için bol miktarda bilgi sağlar [64].

3.1 Metin Ön İşleme

Metin ön işleme, kullanılacak birimlerin belirlenmesi, bazı görevler için alakasız içeriğin kaldırılmasını, anlamsal olarak ilişkili terimlerin bir araya toplanmasını ve yakalanan anlamsal bilgi miktarının artırılması için metin dönüşüm işlemidir [66]. Metin ön işlemenin, metin dokümanlarının dosya boyutunu düşürme ve algoritmaların verimliliğini ve etkililiğini artırma olmak üzere pek çok avantajı vardır [67]. Metin ön işleme kavramları ve tanımları Tablo 3.1’de sunulmuştur.

Metin ön işlemede kullanılan işlemlerden biri belirteçleştirmedir. Belirteçleştirme, metin dizisini ayrı ayrı sözcüklere, anahtar sözcüklere, ifadelere; belirteç adı verilen sembollere bölme işlemidir [68]. Böylece, anlamlı anahtar kelimeler belirlenebilir [67]. Diğer bir deyişle, belirteçleştirmenin amacı, fazladan boşlukların kaldırılması ve belirteç adı verilen anlamlı birimleri tanımlanmasıdır [66].

Tablo 3.1: Metin ön işleme kavramları ve tanımları

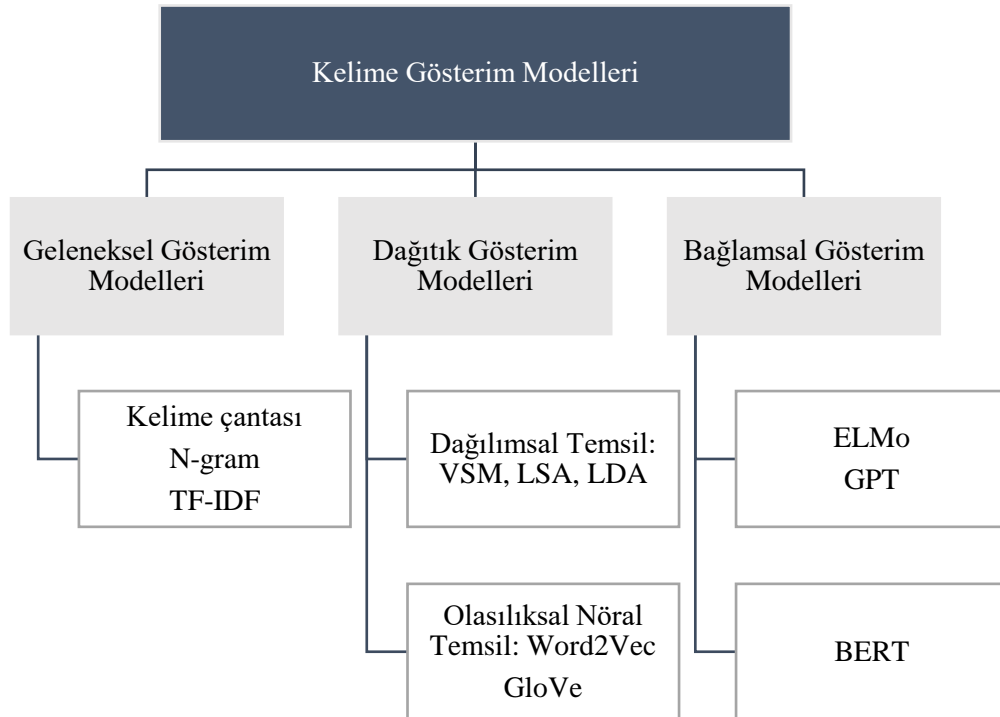
Ön işleme	Tanım
Belirteçleştirme (<i>Tokenization</i>)	Belirteçleştirme, bir metin akışını sözcüklere, ifadelere, sembollere veya belirteç adı verilen diğer anlamlı öğelere ayırma işlemidir [67]
Durdurma Kelimleri (<i>Stopwords</i>)	Durdurma sözcükleri 've', 'veya', 'bu' gibi çok sık kullanılan ortak sözcüklerdir. Bu sözcüklerin kaldırılması, metin verilerini azaltır ve sistem performansını artırır [67].
Büyük – küçük harf dönüşümü (<i>Capitalization</i>)	Analiz edilecek metinde, farklı büyük harf kullanımı sorununun üstesinden gelmek için tüm harfleri küçük harfe indirgeme yaklaşımı kullanılmaktadır [69]
Argo ve kısaltmalar (<i>Slang and Abbreviation</i>)	Kısaltmalar, bir metin dizisinin baş harflerinin kullanılarak ifade edilmesidir (Ör. Bilgi ve İletişim Teknolojileri yerine BİT ifadesinin kullanılması), Argo, resmi olmayan konuşmalarda veya farklı anlamlara sahip metinlerde kullanılan dilin bir alt kümesidir [69]. Argo kelimelerin daha iyi işlenmesi için bu kelimeler doğru anlamlı kelimelerle değiştirilir [68]
Yazım kontrolü (<i>Spelling Correction</i>)	Metin, belge ya da sosyal medya metin verilerindeki yazım yanlışlarının düzeltilmesidir [69]
Kök oluşturma (<i>Stemming</i>)	Bir kelimenin değişken biçimlerini ortak bir temsilde, kökte birleştirme işlemidir [67]
Lemmatizasyon (<i>Lemmatization</i>)	Bir kelimenin çekimli kısımlarını, kelimenin tek bir öge olarak tanınabilecek şekilde bir araya getirme işlemidir [70]

Ayrıca, dokümanlarda, temel olarak içeriğin ya da bağlamın anlamına katkısı olmayan tekrar eden kelimelerin çıkarılması gerekmektedir [67]. Metin ön işleme süreci aynı zamanda, tüm harflerin belirli bir düzende olması için küçük harfe dönüştürülmesini, argo ve kısaltmalardan kaynaklanabilecek metin anomalilerinin düzenlenmesini ve yazım

kontrollünün yapılmasını içerir. Bu işlemlerden sonraki adımda, belirteçleri veya kelimeleri kök kelimelere dönüştürülmesini içeren kök oluşturma süreci takip edilmektedir [68]. Bu süreçte, tüm kelimeler kök kelimesine indirgenir [71]. Böylece, özellik uzayındaki öznitelik sayısını azaltılması ve özniteliklerin farklı formlarının tek bir öznitelikte toplanması sağlanarak, sınıflandırıcının performansı artırılır [72]. Kök oluşturmak için o dile özgü kural tabanlı ya da dilden bağımsız istatistiksel yöntemler kullanılabilir [73]. Metin ön işleme sürecinde takip edilen adımlardan biri de lemmatizasyondur. Lemmatizasyon, Bu kök çıkarma sürecine benzetmekle birlikte, benzer anlamlara sahip metni tek bir kelimeye bağlama özelliğini içermektedir [71]. Lemmatizasyon yöntemleri, fiil ve isimleri tekil biçimle eşlemeye çalışır [74].

3.2 Kelime Gösterim Modelleri

Kelime gösterim modelleri, Asudani ve diğerlerine göre [75] üçe ayrılmaktadır: a) Geleneksel gösterim modelleri, b) Dağıtık gösterim modelleri, c) Bağlamsal gösterim modelleri (Şekil 3.2).



Şekil 3.2: Kelime Gösterim Modelleri [75]

3.2.1 Geleneksel Gösterim Modelleri

Geleneksel gösterim modelleri kapsamında kelime çantası, N-gram ve Terim sıklığı-Ters belge sıklığı (*Term Frequency-Inverse Document Frequency* - TF-IDF) yöntemleri bulunmaktadır.

Kelime çantası gösterimi, nesne sınıflandırılmasında içeriğini temsil etmek için kullanılan popüler yöntemlerden biridir [76]. Metin sınıflandırması için, bir belgedeki bir kelimeye, belgede ne sıklıkta geçtiğine ve farklı belgelerde ne sıklıkta geçtiğine bağlı olarak bir ağırlık verilir [75]. Kelime çantası yönteminde, çıkarılan her anahtar nokta görsel kelimelerden birine nicelleştirir ve ardından her görüntü görsel kelimelerin histogramı ile temsil edilir [76]. Bu yöntem, uzun bir cümle söz konusu olduğunda, vektör temsilini oluşturmak ve cümle benzerliğini elde etmek için daha fazla zaman gerektirir [75]

N-gram tekniği, bir metin setinde geçen ve bir metni temsil eden bir özellik olarak kullanılabilir n-sözcük kümesidir [69]. Genel olarak, metin madenciliği, $n = 1$ (unigram), 2 (bigram) veya 3'ün (trigram) olduğu n-gramları kullanır [77]. N-gram modeli, cümleyi kelime veya karakter düzeyinde belirteçlere bölmektedir [75].

Geleneksel gösterim modelleri kapsamında değerlendirilen diğer bir yöntem TF-IDF'dir. Bu yöntem genellikle bilgi geri getirme ve metin madenciliğinde bir ağırlıklandırma faktörü olarak kullanılmaktadır [78]. TF-IDF, terim sıklığı ve ters terim sıklığı yöntemlerinin kombinasyonudur. Terim sıklığı, bir terimin bir belgede ne sıklıkta geçtiğini ölçmektedir ([75]. Bir diğer deyişle, bir kelimenin terim sıklığı, belgedeki toplam kelime sayısına bölünerek hesaplanmaktadır [79]. Ters terim sıklığı, bir kelime veya terimin belgelerde ne kadar seyrek olduğu üzerinden hesaplanmaktadır [80]

Bu iki yöntemin kombinasyonu olan TF-IDF modeli denklem 3.1'de görülmektedir.

$$TF - IDF(t, d, D) = TF(t, d) \times \log\left(\frac{D}{df_t}\right) \quad (3.1)$$

Denklem 3.1’de ifade edilen t , terimleri; d , her bir belgeyi; D belgelerin toplanmasını, ve df_t , içinde t terimi olan belgelerin toplamını belirtmektedir [79]. Geleneksel olarak, TF-IDF değeri, bir kelimenin bir belgede görünme sayısı ile orantılı olarak artar, ancak kelimenin derlemdeki sıklığıyla dengelenir; bu da bazı kelimelerin diğerlerinden daha yaygın olduğu gerçeğini kontrol etmeye yardımcı olmaktadır [78].

3.2.2 Dağıtık Gösterim Modelleri

Dağıtık gösterim modellerinde, bir kelimenin kullanıldığı bağlamın cümle içindeki anlamını belirlediği yöntemler kullanılmaktadır [75]. Dağıtık gösterim modellerinde, olasılıksal ve dağıtımsal yöntemler kullanılabilir.

3.2.2.1 Dağıtımsal Modeller

Dağıtımsal modeller kapsamında vektör uzay modelleri (Vector Space Model - VSM), gizil semantik analiz (Latent Semantic Analysis - LSA) ve gizil dirichlet ayırma (Latent Dirichlet Analysis - LDA) gibi teknikler bulunmaktadır.

VSM, kelimelerin anlamsal ve sözdizimsel bilgilerini yakalayan vektörlerle kelime anlamlarını temsil etmektedir [81]. Böylece, her bir boyutun, sözcüklerin anlamsal veya sözdizimsel bilgisine karşılık geldiği vektörlerle sözcük anlamları gösterilmektedir [82]. Kullanışlı olmalarına rağmen, çoğu VSM, her kelimeyi yalnızca bir vektörle temsil ettiği için eş anlamlılık ve çok anlamlılığı yakalamakta güçlüklerle karşılaşmaktadır [81]. Ayrıca, VSM, bir belgeyi kelime çantası olarak ele aldığı ve terimler arasındaki bağımlılığı göz ardı ettiği için, geniş veri setlerinde yüksek boyutlu vektörlerin belleği fazla kullanmasına neden olabilmektedir [83].

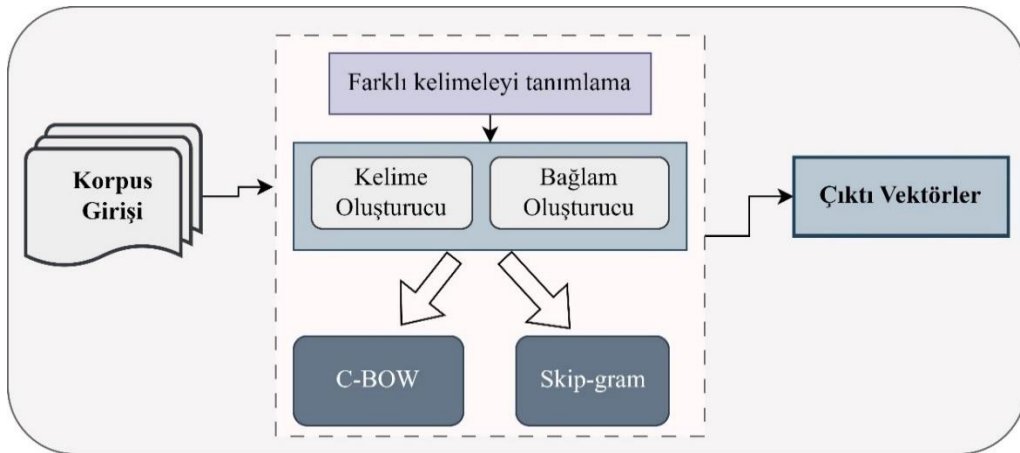
LSA, söylem dizilerindeki kelimelerin tahmin edilen bağlamsal kullanım ilişkilerini çıkarmak ve çıkarım yapmak için kullanılan otomatik bir istatistiksel tekniktir [75]. LSA algoritması, büyük bir metin veri setinde bir kelime birlikte oluşum matrisi oluşturur ve ardından tekil değer ayrıştırma kullanarak bu sayım matrisinin boyutlarını azaltır [84]. Diğer bir deyişle, LSA, bir kelime-belge matrisi oluşturduktan sonra matrisin tekil değer ayrıştırmasını ve ardından faktör analizini uygulamaktadır [85].

LDA, olasılıksal bir derlem modelidir [85], [75]. LDA ile her belge, konuların kümelerine benzer daha yüksek düzeyli kavramlar olarak görülebildiği çok terimli bir konu dağılımı olarak temsil edilmektedir [86]. Böylece, her koleksiyon ögesinin bir dizi temel tema boyunca sonlu bir karışım olarak temsil edildiği üç katmanlı hiyerarşik bir Bayes modeli kullanılmaktadır [75].

3.2.2.2 Olasılıksal Nöral Modeller

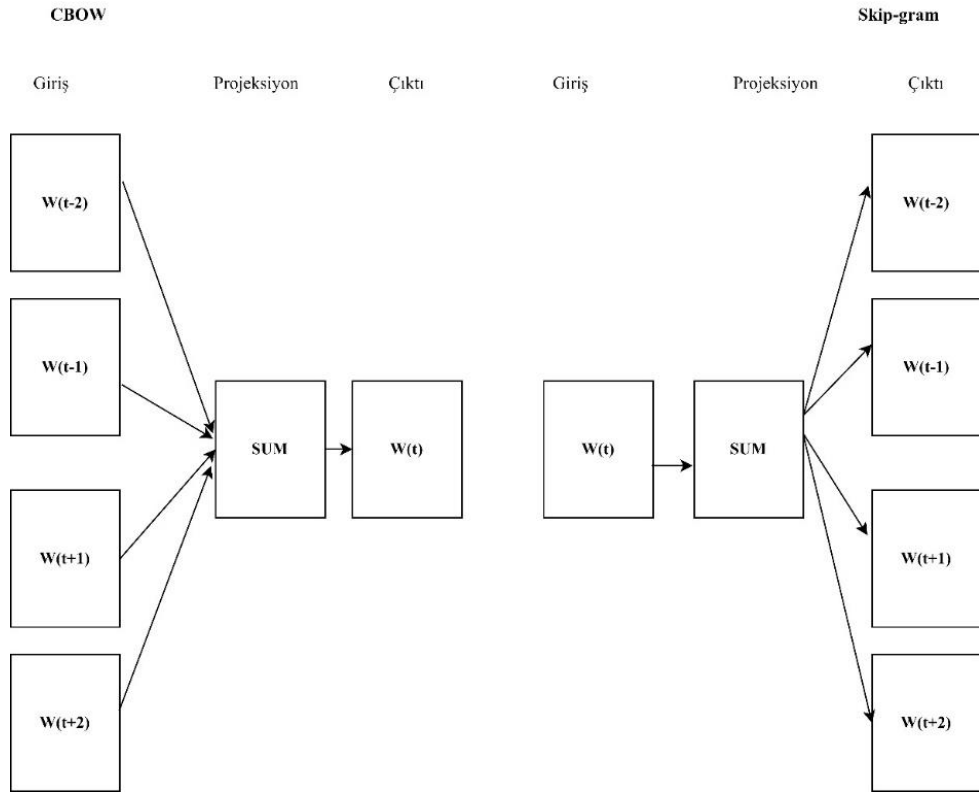
Word2vec ve GloVe modelleri olasılıksal nöral modeller kapsamında ele alınmaktadır.

Geleneksel kelime temsili yöntemleri, kelimeleri bir sözlükte dizinler olarak gösterilen birimler olarak ele almakta ve kelimeler arasındaki benzerliği temsil edememektedir [75]. Word2vec modelleri tarafından öğrenilen kelime vektör temsillerinin semantik anlamlar taşıdığı ve çeşitli doğal dil işleme görevlerinde kullanışlı olduğu bilinmektedir [87]. Word2Vec ile kullanılan dağıtılmış gösterim tekniği, kelime benzerliğini ifade etmek için sinir ağlarını kullanmaktadır [75]. Bu modelde, her kelimenin bir vektörünü oluşturmak için sığ bir sinir ağında kullanılan iki gizli katman bulunmaktadır [79]. Mikolov ve diğerlerine göre [88], kelimelerin semantik anlamlarını etkin bir şekilde açıklamak için sürekli kelime çantası (Continuous Bag of words - CBOW) ve Skip-Gram modelleri gibi Word2Vec modellerinden, yararlanılır [88]. CBOW ve Word2vec'in Skip-gram modelleri tarafından yakalanan kelime vektörlerinin, kelimelerin semantik ve sözdizimsel bilgilerine sahip olduğu varsayılmaktadır [79]. Word2Vec modeli Şekil 3.3'de verilmiştir.



Şekil 3.3: Word2vec Modeli [75]

Şekil 3.3’de görüldüğü üzere, modelde öncelikle farklı sözcük tanımlanır, bir kelime dağarcığı ve bağlam oluşturur; eğitim verileri kullanılarak sözcüklerin vektör uzayındaki vektör temsilleri öğrenilir [75]. Bu modelin mimarisi Şekil 3.4’de verilmiştir.



Şekil 3.4: Word2vec Modeli [75]

Şekil 3.4’e göre, CBOW, bazı bağlam sözcükleri verildiğinde hedef sözcüğü, bir diğer ifadeyle merkez kelimeyi tahmin etmeye çalışırken, Skig-gram hedef sözcük temelinde bağlam sözcüklerini öngörmektedir [89].

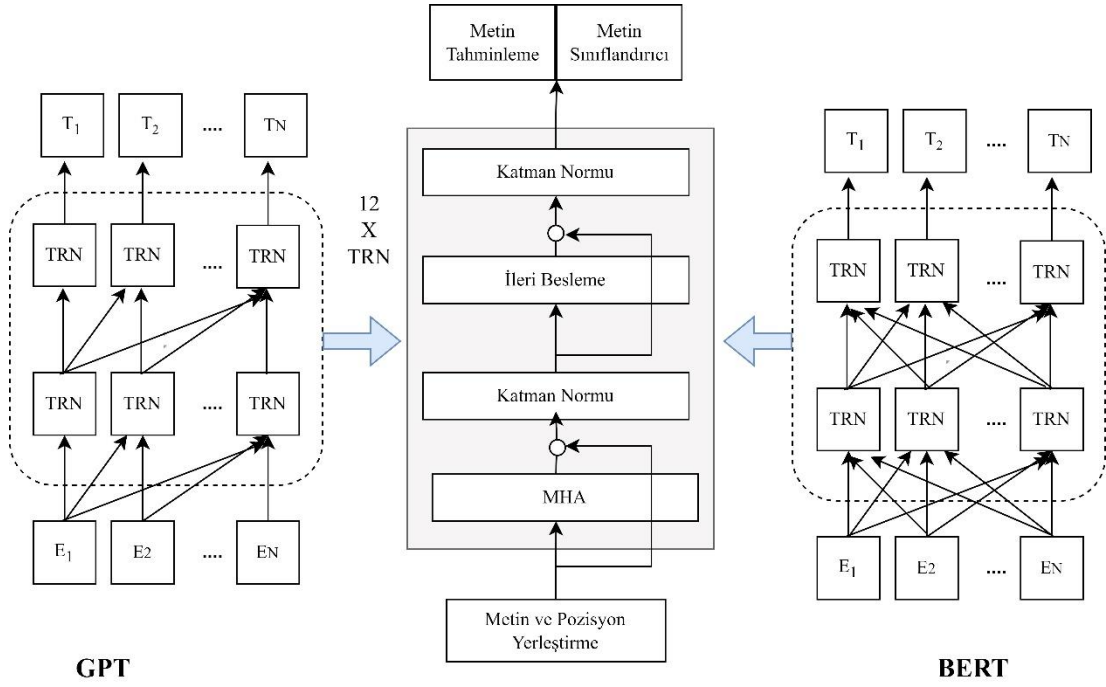
Bu bölümde ayrıca global vektörler (Global Vectors -GloVe) kelime temsil modeline yer verilmiştir. GloVe, metin belgelerinden kelime yerleştirmelerini etkili bir şekilde öğrenmek için word2vec tabanlı bir kelime temsili olarak tanımlanmaktadır ([90] GloVe, Word2vec modelinden farklı olarak, birlikte olma olasılıklarının oranına odaklanmaktadır [91]. Word2Vec modelinde, yalnızca yerel bağlam penceresinden toplanan bilgilere odaklanıldığı için, genel istatistik verileri göz ardı edilebilmektedir [75]. GloVe’de olasılıkların oranı vektör farklılıkları olarak kodlanmaktadır [91].

Modelde, derlemeden üretilen birlikte oluşum matrisinin oluşturulması ve vektörlerin elde edilmesi için faktörleştirme olmak üzere iki adım takip edilmektedir [79].

3.2.3 Bağlamsal Gösterim Modelleri

Bu bölümde bağlamsal gösterim modelleri kapsamında ELMo, GPT ve BERT yöntemlerine yer verilmiştir. Her üç model de büyük miktarda etiketlenmemiş metinle önceden eğitilmiştir [92]. ELMo, kelimenin söz dizimi ve anlambilimle ilgili karmaşık özelliklerini temsil eden bağlama duyarlı bir tekniktir [91]. Bu teknikte, tüm cümle dikkate alınarak her kelimeye bir yerleştirme atanmaktadır [75]. Bu modeldeki işleyiş, hem kelimelerin karmaşık özelliklerinin (sözdizimi ve anlambilim) hem de dilsel bağlamların (çok anlamlılık) modellenmesindeki zorlukları ele almaya çalışmaktadır [93]. ELMo, aynı kelime için farklı temsillerin kullanılmasını sağlayarak çift yönlü dil modelinden öğrenilen gösterimleri doğrusal olarak birleştirmektedir [79]. Bu süreçte, büyük bir derlemeden önceden eğitilmiş derin bir çift yönlü dil modelinden öğrenerek, kelime yerleştirmesi yapmaktadır [93].

Üretken ön eğitim modeli (Generative Pre-training - GPT), ELMo'daki gibi önceden eğitilmiş bir dil modeli kullanılmaktadır. Ancak, ELMo'dan farklı olarak, GPT'de tek yönlü bir dil modeli (soldan sağa) söz konusudur [94]. GPT, büyük bir derlem kullanılarak önceden eğitilmiş ve ardından çeşitli doğal dil işleme görevleri kullanılarak ince ayar yapılmış ön eğitilmiş bir modeldir [95]. Bu bölümde incelenen bir diğer model olan BERT, hem ELMo'nun hem de GPT'nin faydalarını elde etmek üzere geliştirilmiştir. BERT ve GPT'nin kelime yerleştirme gösterimleri Şekil 3.5'de verilmiştir.



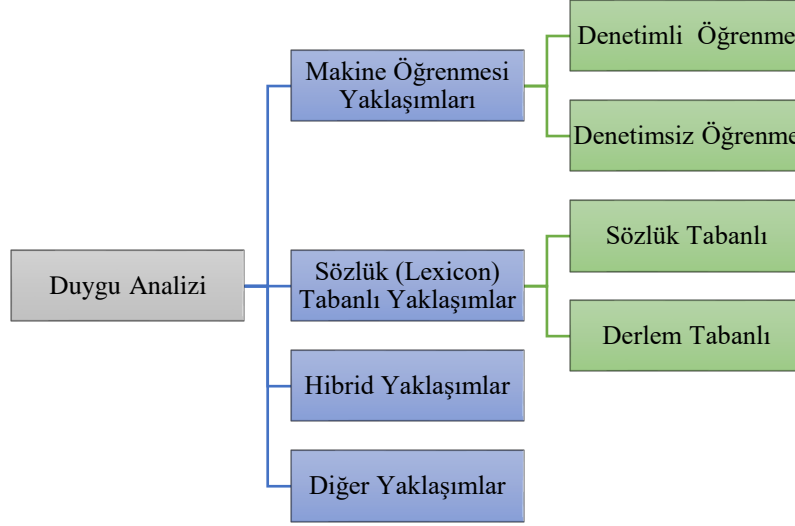
Şekil 3.5: GPT ve BERT kelime yerleştirme gösterimleri [96]

Şekil 3.5 incelendiğinde, GPT ve BERT kelime gösterimlerinin benzerlikler taşıdığı görülmektedir. Ancak, BERT’de ELMo modeline benzer şekilde, bağlam sözcüklerinin çift yönlü dil modellemesi dikkate alınırken [96]; GPT’de, tek yönlü (soldan sağa) bir bağlam kullanmaktadır [95]. Ayrıca, BERT, konum yerleştirmeyi optimize etmek ve model girdileri olarak statik kelime yerleştirmelerle birleştirmek için maskelenmiş dil modellemesinden yararlanmaktadır [75].

3.3 Duygu Analizi

Metin madenciliği, sınıflandırma, kümeleme, özetleme, konu tanımlama ve duygu analizi gibi birçok işlem ve tekniği içermektedir. Metin madenciliğinin bir türü olan duygu analizi, metinlerin içerdikleri fikirlerin duygusal yönelimine göre sınıflandırmaktadır [68]. Duygu analizi insanların ürünler, hizmetler, kuruluşlar, bireyler, sorunlar, olaylar, konular ve bunların niteliklerine yönelik görüşlerinin, duygularının, değerlendirmelerinin ve tutumlarının hesaplamalı yöntemler kullanarak çözümlenmektedir [97]. Temel olarak olumlu ve olumsuz kelimeleri belirlemeye ve duygusal durumu olumlu veya olumsuz olarak sınıflandırmak amacıyla metni işlemeye dayanmaktadır [65]. Bu teknik, metin verilerinin altında yatan görüşleri

ortaya çıkardığı için görüş madenciliği olarak da adlandırılır [98], [68]. Serrano-Guerrero ve diğerlerine göre [99], duygu analizi, duyguların çıkarılması, duygu sınıflandırması, öznellik sınıflandırması, fikir özetleme veya fikir spam tespiti gibi birçok görevi kapsayan bir kavramdır. Duygu analizi, doküman, cümle ve özellik düzeyinde yapılabilmektedir. Duygu analizinin yaklaşımlarına Şekil 3.6'da yer verilmiştir.



Şekil 3.6 : Duygu analizi yaklaşımları [100]

Şekil 3.6 incelendiğinde, duygu analizi ile ilgili dört yaklaşımın olduğu görülmektedir. Bu yaklaşımlardan biri olan makine öğrenmesi yaklaşımlarında, denetimli, denetimsiz ve yarı denetimli öğrenme yöntemleri kullanılmaktadır. Makine öğrenmesi yaklaşımları, bir eğitim ve test veri kümelerine dayalı olarak duyarlılık kutuplarını (ör. negatif, pozitif ve nötr) sınıflandırmak için kullanılmaktadır [100]. En yaygın olarak bilinen makine öğrenimi yöntemi denetimli öğrenmedir. Denetimli öğrenme yöntemleri, doğru sonuçları nedeniyle daha yaygın olarak kullanılmaktadır [51]. Bu yaklaşımda, etiketli kaynak verileri olan bir model eğitildikten sonra yeni etiketlenmemiş girdi verileri göz önünde bulundurarak bir çıktı için tahminler yapılabilmektedir [101]. Bir diğer ifadeyle, bu algoritmaların, gerçek verilere uygulanmadan önce bir eğitim seti üzerinde eğitilmesi gerekmektedir [51]. Ancak, yapılandırılmamış metinleri etiketleme sürecinin mümkün olmadığı durumlarda kümeleri belirlemedeki güçlükler nedeniyle denetimsiz yaklaşımların kullanılması söz konusu olmaktadır [100]. Denetimsiz öğrenme yöntemleri, etiketlenmemiş verileri

birbirine benzer kümeler halinde gruplandırmaya dayalıdır [101]. Duygu analizi alanındaki denetimsiz yaklaşımlar genellikle, her bir kategori tarafından tam olarak hangi duyarlılığın temsil edildiğini belirtmeden verileri farklı kategorilerde sınıflandırabilen kümelemeyi kullanmaktadır [100].

Duygu analizinde, makine öğrenmesi yaklaşımlarının yanı sıra sözlük tabanlı yöntemlerde kullanılmaktadır. Sözlüğe dayalı yaklaşımlar temel olarak geleneksel iletişim türleri için geliştirilmiş ve önceden derlenmiş duygu terimleri ve deyimlerden oluşan bir koleksiyona dayanır [99]. Önceden eğitilmiş bir veri seti gerektirmediği için denetimsiz bir yaklaşım olarak kabul edilmektedir [100]. Sözlük (Lexicon) yaklaşımları, sözlük tabanlı ya da derlem tabanlı olmak üzere iki kategoride ele alınmaktadır. İlk kategoride genellikle manuel bir şekilde toplanan ve açıklama eklenen bir dizi ilk terim kullanımı söz konusudur [99]. Bu yaklaşımın arkasındaki birincil varsayım, eş anlamlıların temel kelime ile aynı kutuplarda, zıt anlamlıların zıt kutuplarda olmasına dayanır [51]. Derlem tabanlı tekniklerde ise, belirli bir alanla ilgili sözlükler, istatistiksel veya anlamsal teknikler kullanılarak ilgili kelimelerin aranmasıyla gelişen bir dizi görüş teriminden üretilmektedir [99].

Makine öğrenimi yaklaşımlarıyla karşılaştırıldığında, sözlük yaklaşımları daha az kaynak gerektirmekte ve dolayısıyla açıklamalı derlemelerin olmadığı durumlar için uygun hale getirmektedir [102]. Öte yandan, kelimelerin farklı alanlarda farklı anlamlarda kullanılması nedeniyle dezavantajları bulunmaktadır [51]

Duygu analizinde kullanılan bir diğer yöntem hibrit yaklaşımlardır. Hibrit yaklaşımlar, duygu analizi performansını iyileştirmek için makine öğrenmesi ile sözlük tabanlı yaklaşımları birleştirmektedir [100], [51]. Böylece, makine öğreniminden yüksek doğruluk ve sözlük tabanlı yaklaşımdan kararlılık özelliklerini alabilmektedir [100]. Makine öğrenmesi, sözlük tabanlı ve hibrit yaklaşımların özellikleri, avantajları ve sınırlılıkları Tablo 3.2’de verilmiştir.

Tablo 3.2: Makine öğrenmesi, sözlük tabanlı ve hibrit yaklaşımların özellikleri, avantajları ve sınırlılıkları [100]

Yaklaşım	Özellik / Teknik	Avantajlar	Sınırlılıklar
Makine Öğrenmesi	Terim varlığı ve sıklığı Konuşma bilgilerinin bir kısmı Olumsuzluklar Görüş sözcükleri ve deyimleri	Eğitilmiş modelleri belirli amaçlar ve bağlamlar için uyarlama ve oluşturma yeteneği	Maliyetli ve hatta engelleyici olabilecek etiketli verilerin mevcudiyeti gerektiğinden yeni verilere düşük uygulanabilirlik
Sözlük Tabanlı	Manuel yapı Derlem tabanlı Sözlük Tabanlı	Daha geniş terim kapsamı	Sözlüklerdeki sınırlı sayıda kelime ve kelimelere sabit bir duygu yönelimi ve puanı atanması
Hibrid	İlk duygu tespiti için kamu kaynakları kullanılarak oluşturulan duygu sözlüğü Makine öğrenimi yöntemindeki özellikler olarak duygu sözcükleri	Sözlük/öğrenme simbiyozu, kavram düzeyinde duyarlılığın saptanması ve ölçülmesi ve konu alanındaki değişikliklere karşı daha az hassasiyet	İncelemelerdeki güçlükler

Makine öğrenmesi, sözlük tabanlı ve hibrit yaklaşımların özellikleri, avantajları ve sınırlılıkları [103].

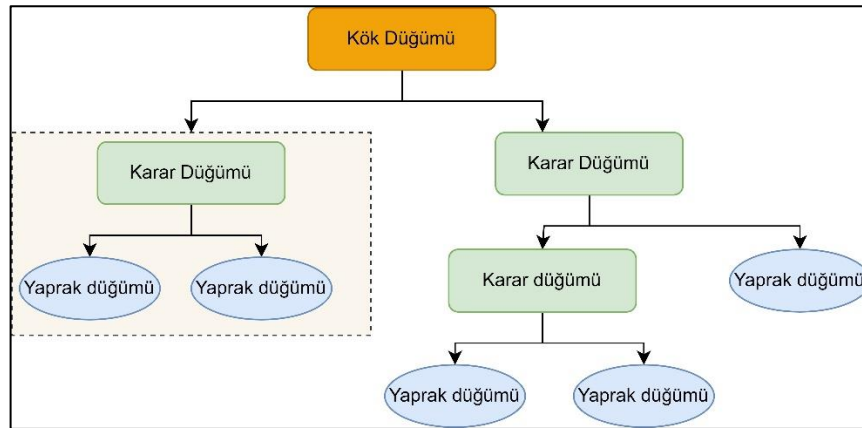
Söz konusu bu yöntemlerin yanı sıra, son yıllarda transformer tabanlı yöntemler öne çıkmaktadır. Transformer tabanlı yöntemlerden biri olan BERT, maskeli dil modellemesi ve sonraki cümle tahmini mekanizmaları üzerine eğitim alarak dili anlayabilmek için geliştirilmiştir [104]. Bu çalışmada, makine öğrenmesi algoritmaları ve BERT kullanılarak öğrencilerin programlama eğitimindeki duyguları, bilgi işlemsel kimlik ve programlamada yetkilendirmeye ilişkin görüşlerinin tahmin edilmesine odaklanılmıştır. Araştırma kapsamında yararlanılan bu algoritmalar ile ilgili açıklamalar bir sonraki alt bölümlerde sunulmuştur.

3.3.1 Duygu Analizinde Kullanılan Makine Öğrenmesi Yaklaşımları

Bu çalışmada makine öğrenmesi algoritmalarından, Karar ağacı, Destek Vektör Makineleri, Lojistik regresyon, Yapay Sinir Ağı, Rastgele Orman kullanılmıştır. Bu seçim, söz konusu algoritma köklü etkinliğine ve metin sınıflandırma görevlerinde yaygın kullanımına dayanmaktadır [105], [69].

3.3.1.1 Karar Ağaçları

Karar ağaçları, metindeki kutupluluğu sınıflandırmak için eğitim örneği kullanarak bir ağacın oluşturulduğu denetimli bir öğrenme tekniğidir [51]. Şekil 3.7’de karar ağaçlarının yapısı gösterilmektedir.




Şekil 3.7: Karar ağaçları yapısı [106]

Karar ağacı tabanlı sınıflandırma teknikleri, karar ağaçları biçiminde örneklerden öğrenerek oluşturulan temel bilgileri temsil etmektedir [106]. Karar ağaçları, verileri yinelemeli olarak parçalara bölmek için koşulları kullanmaktadır [51]. Karar ağacının, regresyon ve sınıflandırma problemlerine uygun olması, yorumlama kolaylığı, kategorik ve nicel değerleri işleme kolaylığı, niteliklerdeki eksik değerleri en olası değerle doldurabilmesi, ağacın etkinliğinden dolayı yüksek performans göstermesi açısından avantajları bulunmaktadır [107]. Karar ağacı yaklaşımı, büyük veri kümelerinde çok iyi performans göstermekte ve küçük veri kümeleri için önerilmemektedir [100].

3.3.1.2 Destek Vektör Makineleri

Destek vektör makineleri, denetimli öğrenme için kullanılan olasılıksal olmayan bir ikili doğrusal sınıflandırıcıdır [65], [51]. Destek vektör makineleri sınıflandırıcısının temel amacı, sınıfları ayırmak için en uygun hiperdüzlemi bulmaktır [100]. Böylece, iki sınıfı maksimum bir marjla ayıran bir hiper düzlem belirlenir [65]. Şekil 3.8'de destek vektör makineleri yapısı görülmektedir.



Şekil 3.8: Destek vektör makineleri yapısı [109]

Destek vektör makinelerinin, hem yarı yapılandırılmış hem de yapılandırılmış verileri işleyebilme ve yüksek boyutlu verilerle ölçeklenebilme gibi avantajları bulunmaktadır [107].

3.3.1.3 Lojistik Regresyon

Lojistik regresyon bir girdi değerini bir ağırlık değeriyle çarparak çalışan, pozitif ve negatif sınıfları belirlemede hangi girdi özelliklerinin en yararlı olduğunu öğrenen bir sınıflandırıcıdır [51]. Girdi değişkenlerinin değerlerine bağlı olarak bir olayın gerçekleşip gerçekleşmeme olasılığını 0 ve 1 cinsinden vermektedir [107]. Lojistik regresyon, bağımlı değişkenin her bir kategorisi için tahmin olasılığın üretildiği ikili sınıflandırma görevleri için parametrik bir maksimum olasılık yöntemidir [109].


Birden çok açıklayıcı değişken olduğunda, lojistik regresyon olasılık oranını hesaplar [51]. Lojistik regresyon, olasılıkları tahmin etmek için matematiksel olarak sigmoid fonksiyonu olarak adlandırılan lojistik fonksiyonu kullanır [110].

$$g(z) = \frac{1}{1+\exp(-z)} \quad (3.2)$$

Lojistik regresyon, uygulama basitliđi, hesaplama ve eđitim aısından verimlilik, dzenleme kolaylıđı gibi avantajlara sahiptir [107]. Aynı zamanda, yksek boyutlu veri kmelerinde uyumlu alıřabilir ve veri kmesi dođrusal olarak ayrılabil-diđinde iyi performans gsterir [110].

3.3.1.4 Yapay Sinir Ađları

Yapay sinir ađları (YSA), insan beyninin sinir ađlarının iřleyiřinden ilham alan bir dizi makine đrenimi algoritmasıdır [111]. Bir sinir ađının ortak mimarisi, birok organize nrondan oluřan girdi, ıktı ve gizli katman olmak zere  katman iermektedir. Ardıřık iki katman arasındaki bađlantı, her bir katmanın nronları arasındaki bađlantılar aracılıđıyla kurulur [100]. Őekil 3.9'da yapay sinir ađlarının yapısı gsterilmektedir.



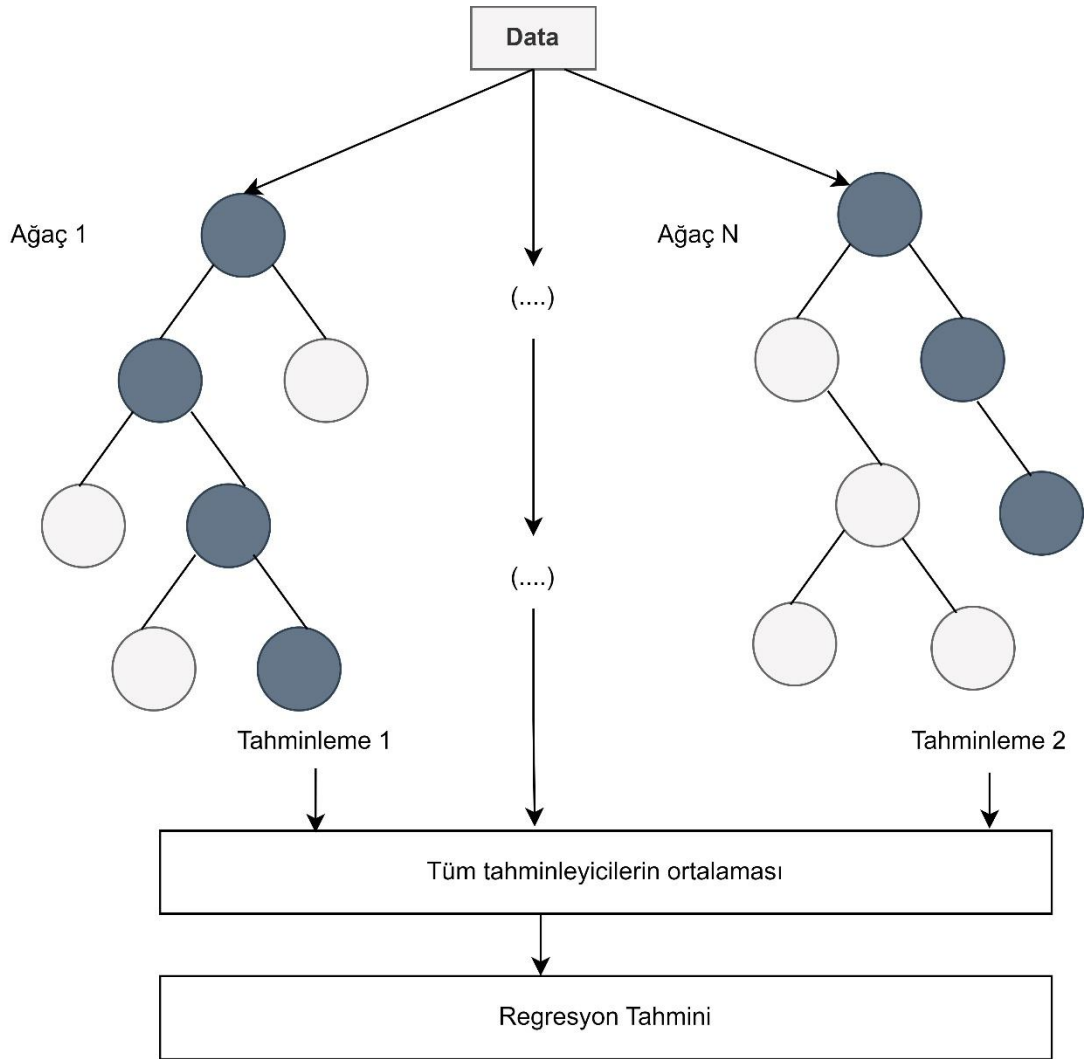
Őekil 3.9: Yapay sinir ađları yapısı [111]

Yapay sinir ađı algoritmaları, birbirine bađlı bir dđm grubu olarak temsil edilmekte; gerekleřtirdikleri dnřme bađlı olarak katman adı verilen bir matriste gruplandırılmaktadır [111]. Yapay sinir ađları, genellikle gl normallik, dođrusallık,

değişken bağımsızlık vb. gibi güçlü varsayımlarla sınırlanan geleneksel tekniklere güçlü bir alternatif sunmaktadır [112].

3.3.1.5 Rasgele Orman Algoritması

Karar ağaçları, genellikle eğitim verilerinin aşırı uyarlanmasına neden olarak, girdi verilerindeki küçük bir değişiklik için sınıflandırma sonucunda yüksek bir varyasyona neden olmaktadır [111]. Rasgele orman algoritması, hızlı, ölçeklenebilir olması, gürültüye karşı dayanıklılığı, yorumlaması ve görselleştirmesi kolay olması nedeniyle sınıflandırmadaki birçok sorunun üstesinden gelebilmektedir [112]. Şekil 3.10'da rasgele orman algoritmasının yapısı verilmiştir.



Şekil 3.10: Yapay sinir ağları yapısı [113]

Rasgele orman algoritmasının farklı karar ağaçları, eğitim veri setinin farklı bölümleri kullanılarak eğitilir. Birçok farklı karar ağacının sonuçlarını dikkate aldığından, aynı veri kümesi için tek bir karar ağacının dikkate alınmasından kaynaklanan varyansı azaltabilmektedir [111]

Bu algoritmalar, duygu analizi, belge sınıflandırması ve metin kategorizasyonu dahil olmak üzere çeşitli doğal dil işleme ve metin madenciliği alanlarında kapsamlı bir şekilde incelenmiş ve uygulanmıştır [64].

3.3.2 BERT

Ardışık müdahalelerde karşılaşılan sorunlara somut bir çözüm sunan dönüştürücü (transformer) modeli, doğal dil işleme alanında son yıllarda sıklıkla kullanılmaktadır [104]. Dönüştürücü modellerin başarısı, tıpta, eğitimde ve diğer önemli doğal dil işleme görevlerinde daha iyi sonuçlara ulaşmak için dili daha iyi anlama yeteneklerine atfedilmektedir. BERT terimi, dönüştürücülerden çift yönlü kodlayıcı gösterimleri anlamına gelen, İngilizce “*Bidirectional Encoder Representations from Transformers*” sözcüklerin baş harflerinden oluşan bir kısaltmadır. Bağlamı tek yönlü olarak yakalayan diğer dil temsil modellerinden farklı olarak BERT, hem sol hem de sağ bağlamda koşullanan sözcükleri tahmin edebilen çift yönlü bir model olarak tasarlanmıştır [114]. BERT, bazı rastgele cümleleri girdi olarak alır, cümlelerdeki bazı kelimeleri maskeler ve çıktıda çevredeki metinlerden maskelenmiş kelimeleri yeniden oluşturur [104].

Türkçenin sondan eklemeli bir dil olması nedeniyle, veri setinde çekim eklerinin ayrıştırılarak kelimenin temel biçiminin elde edilmesi için ön işleme gerektirmektedir. BERT’in Türkçe versiyonu olan BERTurk [115] gibi nöral dil modellerindeki son gelişmeler, birçok dil görevi için başarılı modeller üretirken, ön işleme görevlerine olan ihtiyacı ortadan kaldırmaktadır [116]. BERT'nin, çift yönlü yeteneği nedeniyle bağlamsal bilgi çıkarımı yapma yeteneği, daha hızlı eğitilmesi ve çok çeşitli dil modelleme uygulamalarında kullanılması avantajları arasında yer almaktadır [104].

3.4 Deęerlendirme Metrikleri

Duygu analizinde en ok kullanılan deęerlendirme metrikleri, kesinlik, duyarlılık, F1 skoru ve doęruluk olarak grlmektedir. Bu metrikler hesaplanması iin gerekli deęerler aŐaęıda zetlenmiŐtir:

- Doęru Pozitifler (*True Positive – TP*): Doęru bir Őekilde sınıflandırılan pozitif ifadeler.
- Doęru Negatifler (*True Negative – TN*): Doęru bir Őekilde sınıflandırılan negatif ifadeler.
- YanlıŐ Pozitifler (*False Positive – FP*): Doęru bir Őekilde sınıflandırılmayan pozitif ifadeler.
- YanlıŐ Negatifler (*False Negative – FN*): Doęru bir Őekilde sınıflandırılmayan negatif ifadeler.

Kesinlik: Doęru sınıflandırılmıŐ pozitif rneklerin pozitif olarak tahmin edilen toplam rnek sayısına oranı olarak tanımlanır [51]. Kesinlikle ilgili denklem aŐaęıda verilmiŐtir.

$$Kesinlik = \frac{TP}{TP + FP} \quad (3.3)$$

Duyarlılık: Pozitif olarak doęru tahmin edilen rneklerin tm pozitif rneklere oranı olarak tanımlanır. Geri aęırma, modelin yanlıŐ sınıflandırılmasını lmektedir [100]. Duyarlılık ile ilgili denklem aŐaęıda verilmiŐtir.

$$Duyarlılık = \frac{TP}{TP+FN} \quad (3.4)$$

F1 Skoru: Duyarlılık ve kesinlięin harmonik ortalamasıdır [51]. F1 Skoru ile ilgili denklem aŐaęıda verilmiŐtir.

$$F1 - Score = \frac{2 * (Duyarlılık * Kesinlik)}{Duyarlılık + Kesinlik} \quad (3.5)$$

Doğruluk: Doğruluk, sınıflandırma problemlerinde en sık kullanılan ölçüttür ve doğru tahmin edilen örneklerin toplam örnek sayısına oranını temsil etmektedir [100]. Doğruluk denklemi aşağıda verilmiştir.

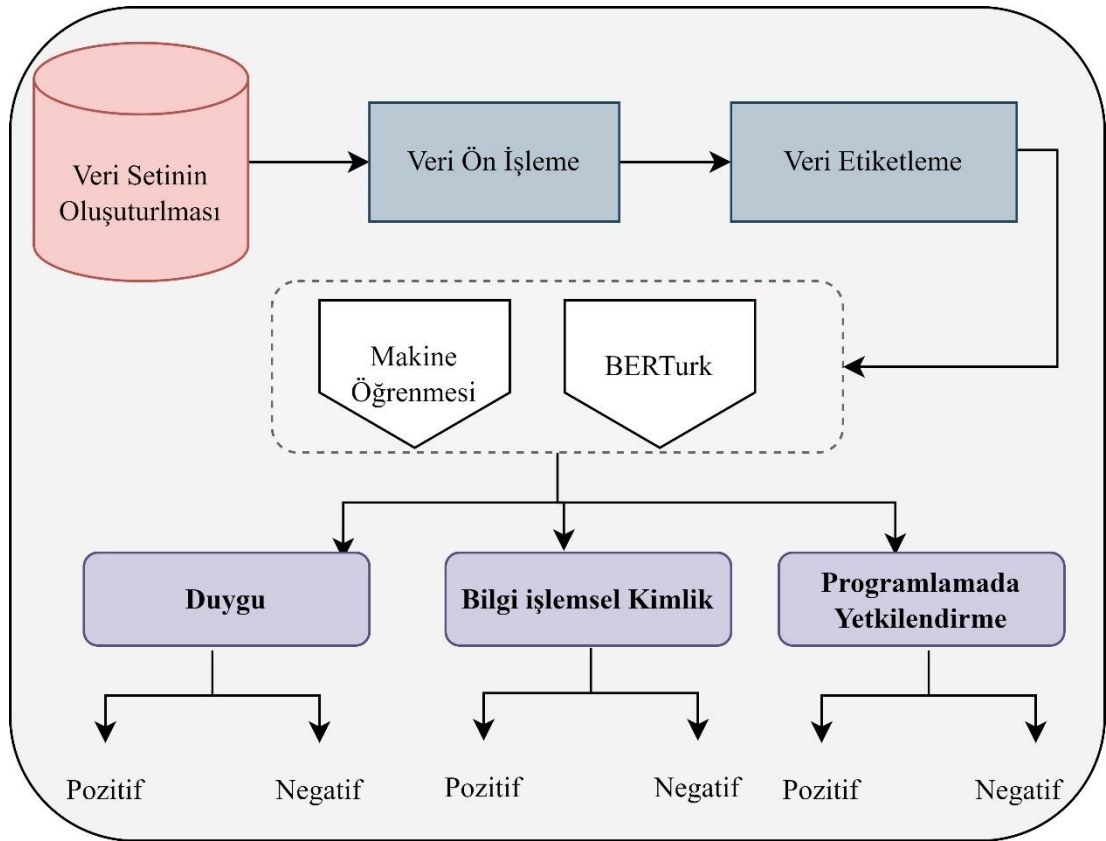
$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN}$$

(3.6)

Bölüm 4

Materyal ve Yöntem

Bu bölümde, programlama eğitimi alan öğrencilerin duygularının, bilgi işlemsel kimlik ve programlamada yetkilendirme ile ilgili görüşlerinin tahminlenmesi için izlenen adımlara yer verilmiştir. Şekil 4.1’de tahminleme sürecinin aşamalarını göstermektedir.



Şekil 4.1: Tahminleme Sürecinin Aşamaları

Şekil 4.1 incelendiğinde, tahminleme aşamasının birinci aşamasında veri setinin oluşturulduğu görülmektedir. Daha sonra veri ön işleme ve veri etiketleme aşamalarına

geçilmiştir. Tahminleme için hazır hale getirilen veri seti makine öğrenmesi algoritmaları ve BERTurk modeli kullanılarak analiz edilmiştir

Analizler, Python 3.10 programlama dili kullanılarak yapılmıştır. Bunun için Anaconda platformu üzerinde Spyder kullanılmıştır. Metin ön işleme, model oluşturma ve kelime gömme ve verilerin görselleştirilmesi için python'da pek çok kütüphane bulunmaktadır. Bu araştırmada, numpy, pandas, seaborn, nltk, SciKit-Learn, gensim, jyppe, matplotlib kütüphanelerinden yararlanılmıştır.

Makine öğrenme algoritmalarından, karar ağaçları, destek vektör makineleri, lojistik regresyon, yapay sinir ağları ve rasgele orman algoritmaları kullanılmıştır. Destek vektör makinelerinde, decision_function_shape parametresi için ovo; probability parametresi için true değeri kullanılmıştır. Lojistik regresyon solver parametresi liblinear; c parametresi olarak 10 değeri; penalty parametresi için l2 değeri atanmıştır. Yapay sinir ağlarında hidden_layer_size parametresi için 10,10,10,10 değerleri kullanılırken; max_iter parametresi için 10000 değeri belirlenmiştir. Rasgele orman algoritması için parametre değerleri şu şekilde tanımlanmıştır: n_estimator:100; criterion:gini; max_depth:none. Kelime temsil yöntemi olarak, Word2Vec ve TF-IDF modellerinden yararlanılmıştır.

Algoritmaların denenmesinde kullanılan bilgisayarın özellikleri özellikleri şu şekildedir: Intel(R) Core(TM) i7-8565U CPU @ 1.80GHz 1.99 GHz; Takılı RAM: 8,00 GB; Sistem türü 64 bit işletim sistemi, x64 tabanlı işlemci.

4.1 Veri Setinin Oluşturulması

Bu araştırmada veri setinin oluşturulması için açık uçlu sorulardan oluşan elektronik bir form hazırlanmıştır. Bu formda, programlama eğitimi alan öğrencilerin duyguları, bilgi işlemsel kimlikleri ve programlamada yetkinliklerine ilişkin görüşlerinin toplanması için 14 açık uçlu soru bulunmaktadır.

Programlama eğitimi sürecinde öğrencilerin deneyimlediği dört duyguya odaklanılmıştır. Bu duygular, keyif, kaygı, sıkılma ve umut olarak belirlenmiştir. Duygular ile ilgili sekiz soru oluşturulmuştur:

- Programlama yaparken keyif alıyorum çünkü,
- Programlama yaparken keyif almıyorum çünkü,
- Programlama yaparken kaygılı olurum çünkü,
- Programlama yaparken kaygılı olmam çünkü,
- Programlama yaparken sıkılırım çünkü,
- Programlama yaparken sıkılmam çünkü,
- Programlama yaparken umutlu olurum çünkü,
- Programlama yaparken umutlu olmam çünkü,

Bu sorular, her bir duygu için olumlu ve olumsuz ifadeleri yansıtacak şekilde hazırlanmıştır. Bilgi işlemsel kimlik ve programlamada yetkilendirme ile ilgili altı adet açık uçlu soru oluşturulmuştur. Bu soruların hazırlanması için, alanyazında bilgi işlemsel kimlik ve programlamada yetkilendirme ile ilgili geliştirilmiş olan ölçme araçları incelenmiştir. Buna göre, Kong ve Lai [42], tarafından geliştirilmiş olan ölçme araçlarındaki faktörler göz önünde bulundurulmuştur. Bilgi işlemsel kimlik ölçme aracında, katılım, imgeleme ve bağlılık olmak üzere üç faktör bulunmaktadır. Bu doğrultuda hazırlanan sorulara aşağıda yer verilmiştir.

Bilgi işlemsel kimlik:

- Programlama yapmayı hangi açılardan ilgi çekici buluyorsunuz? / Programlama niçin ilginizi çeker? (Katılım)
- Programlama ile ilgili gelecekte neler yapmayı hayal ediyorsunuz? (İmgeleme)
- Bir akran ya da akranlarınızdan oluşan bir ekip ile programlama yapma ile ilgili görüşleriniz nelerdir? (Bağlılık)

Programlamada yetkilendirme için Kong ve diğerleri [50] tarafından geliştirilmiş olan ölçme araçlarındaki faktörler göz önünde bulundurulmuştur. Programlamada yetkilendirme ölçeği anlamlılık, etki ve öz yeterlik faktörlerini içermektedir. Bu doğrultuda hazırlanan sorulara aşağıda yer verilmiştir.

- Programlamanın size olan yararı ve katkıları nelerdir? (Anlamlılık)

- Programlama yaparken başkalarının hayatını kolaylaştırmada, iyileştirmede ve dünya ile ilgili problemlerin çözümünde nasıl bir fark yaratmak istersiniz? (Etki)
- Programlama konusunda kendinizi hangi açılardan yeterli görüyorsunuz? (Öz yeterlik)

Açık uçlu sorulardan oluşan form hazırlandıktan sonra, araştırmanın yapılabilmesi için İzmir Katip Çelebi Üniversitesinden, etik kurul izni alınmıştır (27.03.2023 / Belge Doğrulama Kodu: 33ECA7T). Formu, programlama eğitimi gören 646 öğrenci doldurmuştur. Öğrencilerin, %68,7'si orta eğitimde öğrenim görmektedir. Eğitim seviyesi açısından geniş aralıkta katılımcı grubundan veri toplanması için bilgisayar bilimi eğitimi alan üniversite birinci sınıf öğrencilerinden de veri toplanmıştır. Buna göre, katılımcıların %31,3'ü lisans eğitimi birinci sınıf öğrencilerinde oluşmuştur. Öğrencilerin yaş aralığı 12-20 arasında değişmektedir. Öğrencilerin sorulara verdikleri yanıtlar neticesinde 9044 cümlelik bir veri seti oluşturulmuştur. Veriler, Google Formlar aracıyla çevrim içi ortamda toplandığı için .xlsx uzantılı dosya olarak indirilmiştir. Veri setinde tahminleme için gerekli işlemlerin yapılabilmesi için daha sonra .csv uzantılı dosyaya dönüştürülmüştür. Veri setine ilişkin istatistikler, duygu, bilgi işlemsel kimlik ve programlamada yetkilendirme ile ilgili tahminleme sürecindeki bölümlerde ayrıntılı bir şekilde verilmiştir.

4.2 Ön işleme

Duygu analizi ya da görüş madenciliğinde, daha sonraki süreçler için verinin niteliğinin artırılmasını ve elde edilen doğruluk değerlerinin daha iyi olmasını sağlamaktadır (Gharatkar et al., 2017). Ön işleme kapsamında, büyük küçük harf dönüşümü yapılmış, metindeki sayısal değerler ve etkisiz kelimeler kaldırılmış, argo ve kısaltmalar kontrol edilmiştir.

Veri setindeki cümleler, olumlular 1; olumsuz ifadeler 0 şeklinde araştırmacı tarafından kodlanmıştır. Veri setinin, bilgisayar bilimi eğitimi alanında araştırma yapan bir uzman tarafından ayrıca kodlanmış ve kodlayıcılar arasındaki uyum Cohen's Kappa değeri ile değerlendirilmiştir. Duygu ile ilgili cümlelerde kodlayıcılar

arasındaki uyum %95,02 olarak hesaplanmıştır. Bilgi işlemsel kimlik (Cohen's Kappa= %97,9) ve programlamada yetkilendirme (Kohen's Kappa=%95,8) ile ilgili cümleler için yapılan kodlamalarda; kodlayıcılar arası uyum yüksek bulunmuştur.

4.3 Programlama Yaparken Deneyimlenen Duyguların Tahmin Edilmesi

Öğrencilerin programlama yaparken hissettikleri duygular ile ilgili cümleler etiketlendikten sonra, iki kodlayıcı arasında uyum sağlanmayan cümleler veri setinden çıkarılmıştır. Sonuç olarak, 4911 cümlelik bir veri seti ile duygu analizi yapılmıştır. Keyif, kaygı, sıkılma ve umut duyguları için pozitif ve negatif etiketlenmiş cümle örnekleri Tablo 4.1 'de verilmiştir.


Tablo 4.1: Duygular ile ilgili pozitif ve negatif alıntı örnekleri

Duygu	Etiket	Örnek Cümleler
Keyif	P	<i>Algoritma çözmek ve bunu kodlama diline dönüştürmek bulmaca çözmek gibi geliyor ve bana göre zevkli bir iş. Bitirdiğimde yasadığım başarımlık hissi çok az şeye değer Eğlenceli ve programlama yapmak çoğu yönden ilgimi çekiyor.</i>
	N	<i>Hiç mutlu değilim çünkü ders aktif olacağımız şekilde işlenmiyor. Yoruluyorum ve yanlış kod yazınca yaptığım her şey boşa gidiyor. Yapamadığım noktalara fazla yoğunlaşmak ve aynı konu üzerinde tekrar tekrar çaba sarf edip uğraş vermek çok bunaltıcı olabiliyor. Bazen nerden başlayacağımı bilmiyorum ve bir yol göstericiye ihtiyaç duyuyorum.</i>
Umut	P	<i>Bir şeyleri başardıkça daha fazlasını başaracağıma olan inancım artıyor. Bitince çok güzel bir sonucu oluyor. Tüm problemleri, hataları çözmüş oluyorum. Yaptığım şeyin beni geliştirdiğini ve aldığım her hatanın bana bir şey kattığını biliyorum.</i>
	N	<i>Programlamayı düşününce karamsarlığa kapılıyorum.</i>

Duygu	Etiket	Örnek Cümleler
		<p><i>Başarabileceğime inanmıyorum</i></p> <p><i>Bazen ne yaptığımı ve neden yaptığımı anlayamıyorum</i></p> <p><i>Bazı programlama derslerinde işin içinden çıkamıyorum.</i></p> <p><i>Bunu yaparak bir yere ulaşabileceğimi sanmıyorum.</i></p>
Kaygı	P	<p>“Çok geniş bir alan olduğu için bir sorunla karşılaştığımda ne olduğunu anlayamadığım zamanlarda kaygılanıyorum.”</p> <p>“Çözümünü bulamayacağım veya zor bulacağım hatalar alabiliyorum.”</p> <p>“Bazen işimi mükemmel yapmadığımı hissediyorum ve daha fazla dili daha hızlı öğrenmek istiyorum.”</p> <p>“Hata yapmak ve projemi bozmak istemiyorum.”</p> <p>“İçime yapamayacakmışım hissi düşüyor .”</p>
	N	<p>“Gerekeni yaptığım sürece sonucunun güzel olacağından eminim.”</p> <p>“Hata aldığımda durumlarda bile üstesinden gelebileceğimi düşünüyorum”</p> <p>“Karşılaştığım veya karşılaşıcağım her hatanın bir çözümü olduğunu biliyorum.”</p>
Sıkılma	P	<p><i>Bazen, yapmak istediğim şeylerin kodlarını bulamıyorum bu da canımı sıkabiliyor.</i></p> <p><i>Somut bir ürün üretene kadar soyut halde sadece ekranda çeşitli yazılarla uğraşıyorum.</i></p> <p><i>İlgilenmediğim alanla ilgili kodlama yaparken sıkılırım</i></p> <p><i>Etkinlikleri iyi yapamıyorum ve böylece motivasyonum düştüğü için sıkılıyorum</i></p>
	N	<p><i>Çünkü sürekli yanlış yapıyorum ve bir ders boyunca bitiremiyorum</i></p> <p><i>Birbiriyle bağlantılı parçaların bütününden doğru sonuçlara ulaşmak beni sıkıyor.</i></p> <p><i>Bütün dikkatimi ona veriyorum</i></p> <p><i>Doğru yapınca emeğimin karşılığını almış hissediyor ve tatmin oluyorum.</i></p> <p><i>Zihnimi programa veriyorum ve programı yapmakta konsantre oluyorum</i></p>

P: Pozitif; N: Negatif

Her bir duygu için pozitif ve negatif cümle sayıları Şekil 4.1’de verilmiştir.




Şekil 4.2 : Duygu ile ilgili pozitif ve negatif cümlelerin frekansları

Şekil 4.2 incelendiğinde, keyif ve umut duygusu ile ilgili pozitif cümlelerin frekanslarının, negatif cümlelerden daha fazla olduğu görülmektedir. Kaygı ve sıkılma duygusunda ise negatif ifadelerin frekansı pozitif ifadelerden daha yüksektir. Bununla birlikte, duygular genelinde pozitif ve negatif cümlelerin frekansları birbirine yakın olduğu görülmektedir. Bundan sonraki alt bölümlerde öncelikle her bir duygu için ayrı ayrı yapılan tahminleme sürecine yer verilmiştir. Daha sonra, duygular ile ilgili ifadeler tek bir veri setinde ele alınarak elde edilen makine öğrenmesi BERTurk sonuçları açıklanmıştır.


4.3.1 Keyif Duygusunun Tahmin Edilmesi

Öğrencilerin programlama yaparken hissettikleri keyif duygusu ile ilgili pozitif ve negatif etiketlenmiş cümlelerde en sık tekrar eden unigramlar Şekil 4.3 ve Şekil 4.4’de verilmiştir.



Şekil 4.3: Keyif duygusuna ilişkin pozitif etiketlenmiş cümleler için unigramlar

Şekil 4.3’de görüldüğü üzere, keyif duygusuna ile ilgili pozitif etiketlenmiş cümlelerde en sık tekrar eden unigram’lar “eğlenceli”, “keyif”, “alıyorum”, “seviyorum”, “yeni”, “hoşlanma”, “gidiyor”, “zevкли”, “güzel”, “beni”, “mutlu”, “yapmak”, “eğleniyorum”, “öğreniyorum” olarak ortaya çıkmıştır. Şekil 4.4’de keyif duygusu ile ilgili negatif etiketlenmiş cümlelerde en sık tekrar eden unigram’lar görülmektedir.



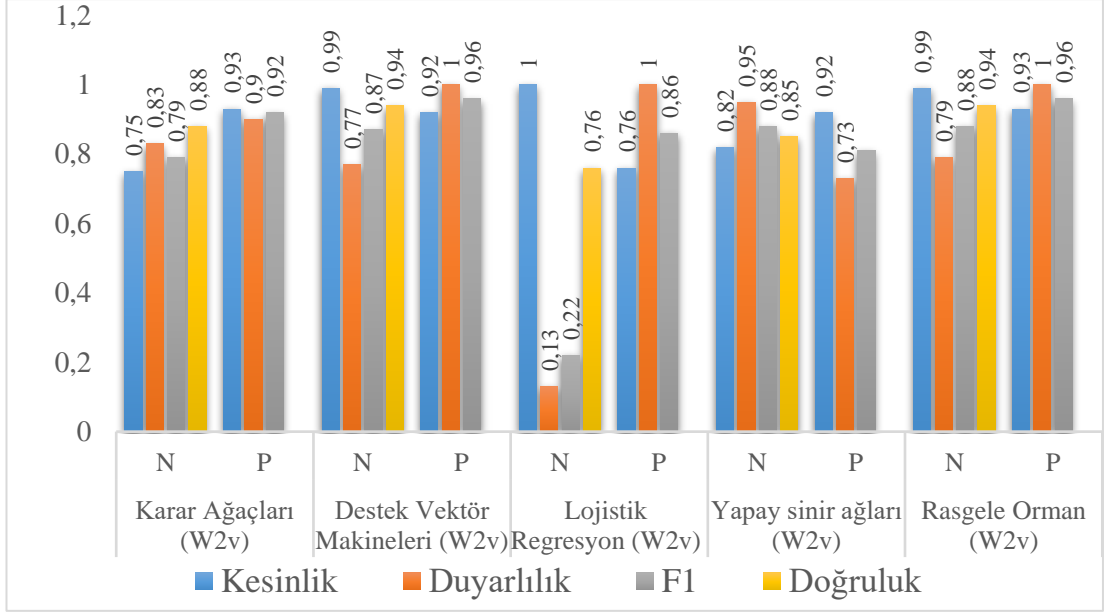
Şekil4.4: Keyif duygusuna ilişkin negatif etiketlenmiş cümleler için unigramlar

Şekil 4.4'e göre, "sıkıcı", "bazen", "keyif", "sevmiyorum", "zor", "geliyor", "almıyorum", "zaman" gibi sözcüklerin unigram frekansları yüksektir. Sonuç olarak, pozitif etiketli cümlelerde eğlence, sevme, keyif, zevk, ilgi ve öğrenme gibi sözcüklerin öne çıkmakta; bununla birlikte negatif etiketli cümlelerde, sıkılma, zor ve zaman gibi kelimeler dikkati çekmektedir. Keyif duygusunun makine öğrenmesi algoritmaları kullanılarak tahmin edilmesi ile ilgili bulgular, Tablo 4.2 verilmiştir. Tablo 4.2 incelendiğinde, karar ağaçları, destek vektör makineleri ve rasgele orman algoritmalarında Word2Vec temsil yöntemleri ile bulunan değerlerin daha yüksek olduğu görülmektedir.


Tablo 4.2: Keyif duygusunun tahminlenmesinde kullanılan makine öğrenme algoritmaları sonuçları

		Kesinlik	Duyarlılık	F1	Doğruluk
Karar Ağaçları (W2V)	Negatif (0)	0,75	0,83	0,79	0,88
	Pozitif (1)	0,93	0,90	0,92	
Karar Ağaçları (TF-IDF)	Negatif (0)	0,65	0,92	0,76	0,84
	Pozitif (1)	0,97	0,81	0,88	
DVM (W2V)	Negatif (0)	0,99	0,77	0,87	0,94
	Pozitif (1)	0,92	1,00	0,96	
DVM (TF-IDF)	Negatif (0)	0,87	0,85	0,86	0,93
	Pozitif (1)	0,95	0,95	0,95	
LR (W2V)	Negatif (0)	1,00	0,13	0,22	0,76
	Pozitif (1)	0,76	1,00	0,86	
LR (TF-IDF)	Negatif (0)	0,94	0,85	0,90	0,95
	Pozitif (1)	0,94	0,98	0,96	
YSA (W2V)	Negatif (0)	0,82	0,95	0,88	0,85
	Pozitif (1)	0,92	0,73	0,81	
YSA (TF-IDF)	Negatif (0)	0,91	0,95	0,93	0,92
	Pozitif (1)	0,94	0,88	0,91	
Rasgele Orman (W2V)	Negatif (0)	0,99	0,79	0,88	0,94
	Pozitif (1)	0,93	1,00	0,96	
Rasgele Orman (TF-IDF)	Negatif (0)	0,90	0,98	0,94	0,93
	Pozitif (1)	0,98	0,87	0,92	

Bununla birlikte, lojistik regresyon ve yapay sinir ağlarında TF-IDF kelime temsil yöntemi ile elde edilen değerler daha yüksek bulunmuştur (Şekil 4.5 ve Şekil 4.6).



Şekil 4.5: Word2Vec kelime temsil yönteminin kullanıldığı makine öğrenmesi algoritmalarının bulguları (Keyif Duygusu)



Şekil 4.6: TF-IDF kelime temsil yönteminin kullanıldığı makine öğrenmesi algoritmalarının bulguları (Keyif Duygusu)

Bu duygunun tahminlenmesinde ayrıca, BERTurk transformer tabanlı dil modeli kullanılmıştır. Bunun için veri seti %80 eğitim, %20 olarak ayrılmıştır. Veri setinden etkisiz kelimeler çıkarılmıştır. BERTurk ile elde edilen kesinlik, duyarlılık, F1 ve doğruluk değerleri Tablo 4.3’de verilmiştir.

Tablo 4.3: Keyif Duygusunun Tahmin Edilmesinde BERTurk Bulguları


	Kesinlik	Duyarlılık	F1	Doğruluk
Negatif	0,96	0,96	0,96	
Pozitif	0,98	0,97	0,97	0,96

AdamW ($\beta_1 = 0.9$; $\beta_2 = 0.999$, $\epsilon = 1e-8$) Öğrenme oranı: $3e-5$

BERTurk ile veri setinin eğitilmesi üç aşamada gerçekleştirilmiştir. Doğruluk değerleri birinci aşama için 0,92, ikinci aşama için 0,93 ve üçüncü aşama için 0,94 olarak bulunmuştur. Sonuç olarak, BERTurk modeli ile %96'lık bir doğruluk değeri elde edilmiştir.


4.3.2 Umut Duygusunun Tahmin Edilmesi

Öğrencilerin programlama yaparken hissettikleri umut duygusu ile ilgili pozitif ve negatif etiketlenmiş cümlelerde en sık tekrar eden unigramlar Şekil 4.7 ve Şekil 4.8'de verilmiştir.



Şekil 4.7: Umut duygusuna ilişkin pozitif etiketlenmiş cümleler için unigramlar

Şekil 4.7'de görüldüğü üzere, umut duygusu ile ilgili pozitif etiketlenmiş cümlelerde en sık tekrar eden unigram'lar "inanıyorum", "düşünüyorum", "umutluyum", "güveniyorum" ve "gelecek" gibi kelimelerdir. Şekil 4.8'de umut duygusu ile ilgili negatif etiketlenmiş cümlelerde en sık tekrar eden unigram'lar görülmektedir.



Şekil 4.8: Umut duygusuna ilişkin negatif etiketlenmiş cümleler için unigramlar


Umut duygusunun makine öğrenmesi algoritmaları kullanılarak tahmin edilmesi ile ilgili bulgular, Tablo 4.4’de verilmiştir.

Tablo 4.4: Umut duygusunun tahminlenmesinde kullanılan makine öğrenme algoritmaları sonuçları


		Kesinlik	Duyarlılık	F1	Doğruluk
Karar Ağaçları (W2V)	Negatif (0)	0,70	0,65	0,67	0,71
	Pozitif (1)	0,73	0,76	0,74	
Karar Ağaçları (TF-IDF)	Negatif (0)	0,98	0,68	0,80	0,85
	Pozitif (1)	0,79	0,99	0,88	
DVM (W2V)	Negatif (0)	0,93	0,65	0,77	0,82
	Pozitif (1)	0,77	0,96	0,85	
DVM (TF-IDF)	Negatif (0)	0,97	0,67	0,79	0,84
	Pozitif (1)	0,78	0,98	0,87	
LR (W2V)	Negatif (0)	0,00	0,00	0,00	0,55
	Pozitif (1)	0,55	1,00	0,71	
LR (TF-IDF)	Negatif (0)	0,94	0,76	0,84	0,87
	Pozitif (1)	0,83	0,96	0,89	
YSA (W2V)	Negatif (0)	0,94	0,54	0,68	0,77
	Pozitif (1)	0,72	0,97	0,82	
YSA (TF-IDF)	Negatif (0)	0,84	0,88	0,86	0,87
	Pozitif (1)	0,90	0,86	0,88	
Rasgele Orman (W2V)	Negatif (0)	0,94	0,54	0,68	0,77
	Pozitif (1)	0,72	0,97	0,82	
Rasgele Orman (TF-IDF)	Negatif (0)	0,97	0,67	0,79	0,84
	Pozitif (1)	0,78	0,98	0,87	

Tablo 4.4 incelendiğinde, elde edilen doğruluk değerlerinin 0,59 ve 0,87 arasında değiştiği görülmektedir.

Şekil 4.9’da Word2Vec kelime temsil yöntemi ile elde edilen makine öğrenme algoritmalarının sonuçlarının karşılaştırılması yapılmıştır. Şekil 4.10’da ise TF-IDF kelime temsil yönteminin kullanıldığı sonuçlara yer verilmiştir. TF-IDF kelime temsil yöntemi ile elde edilen değerlerin daha yüksek olduğu görülmektedir. Umut duygusunun tahminlenmesinde, doğruluk değerinin en yüksek, TF-IDF kelime temsil yöntemi ile yapay sinir ağları ve lojistik regresyon algoritmasından elde edildiği saptanmıştır (%87).



Şekil 4.9: Word2Vec kelime temsil yönteminin kullanıldığı makine öğrenmesi algoritmalarının bulguları (Umut duygusu)



Şekil 4.10: TF-IDF kelime temsil yönteminin kullanıldığı makine öğrenmesi algoritmalarının bulguları (Umut duygusu)

Bu duygunun tahminlenmesinde ayrıca, BERTurk transformer tabanlı dil modeli kullanılmıştır. BERTurk ile veri setinin eğitilmesi üç aşamada gerçekleştirilmiştir. BERTurk ile elde edilen kesinlik, duyarlılık, F1 ve doğruluk değerleri Tablo 4.5’de verilmiştir.

Tablo 4.5: Umut Duygusunun Tahmin Edilmesinde BERTurk Bulguları


	Kesinlik	Duyarlılık	F1	Doğruluk
Negatif	0.91	0.90	0.90	
Pozitif	0.93	0.94	0.93	0.92

AdamW ($\beta_1 = 0.9$; $\beta_2 = 0.999$, $\epsilon = 1e-8$) Öğrenme oranı: $3e-5$


Doğruluk değerleri birinci aşama için 0,91, ikinci aşama için 0,97 ve üçüncü aşama için 0,99 olarak bulunmuştur. Sonuç olarak, BERTurk modeli ile %92’lik bir doğruluk değeri elde edilmiştir.

4.3.3 Kaygı Duygusunun Tahmin Edilmesi

Öğrencilerin programlama yaparken hissettikleri kaygı duygusu ile ilgili pozitif ve negatif etiketlenmiş cümlelerde en sık tekrar eden unigramlar, Şekil 4.11 ve Şekil 4.12’de verilmiştir.



Şekil 4.11: Kaygı duygusuna ilişkin pozitif etiketlenmiş cümleler için unigramlar




Şekil 4.12: Kaygı duygusuna ilişkin negatif etiketlenmiş cümleler için unigramlar

Şekil 4.11’de görüldüğü üzere, kaygı duygusu ile ilgili pozitif etiketlenmiş cümlelerde en sık tekrar eden unigram’lar “yanlış”, “korkuyorum”, “hata” ve “zor” gibi kelimelerdir. Kaygı duygusunun makine öğrenmesi algoritmaları kullanılarak tahmin edilmesi ile ilgili bulgular, Tablo 4.6’de verilmiştir. Tablo 4.6 incelendiğinde, elde edilen doğruluk değerlerinin 0,60 ve 0,86 arasında değiştiği görülmektedir.


Tablo 4.6: Kaygı duygusunun tahminlenmesinde kullanılan makine öğrenme algoritmaları sonuçları

		Kesinlik	Duyarlılık	F1	Doğruluk
Karar Ağaçları (W2V)	Negatif (0)	0,71	0,79	0,75	0,71
	Pozitif (1)	0,71	0,61	0,66	
Karar Ağaçları (TF-IDF)	Negatif (0)	0,75	0,93	0,83	0,79
	Pozitif (1)	0,88	0,62	0,73	
DVM (W2V)	Negatif (0)	0,76	0,95	0,85	0,81
	Pozitif (1)	0,91	0,64	0,75	
DVM (TF-IDF)	Negatif (0)	0,81	0,96	0,88	0,85
	Pozitif (1)	0,93	0,72	0,82	
LR (W2V)	Negatif (0)	0,58	1,00	0,73	0,60
	Pozitif (1)	1,00	0,12	0,22	
LR (TF-IDF)	Negatif (0)	0,83	0,94	0,88	0,86
	Pozitif (1)	0,91	0,77	0,83	
YSA (W2V)	Negatif (0)	0,71	0,93	0,81	0,75
	Pozitif (1)	0,87	0,54	0,67	
YSA (TF-IDF)	Negatif (0)	0,83	0,87	0,85	0,83
	Pozitif (1)	0,84	0,79	0,81	
Rasgele Orman (W2V)	Negatif (0)	0,71	0,93	0,81	0,75
	Pozitif (1)	0,87	0,54	0,67	
Rasgele Orman (TF-IDF)	Negatif (0)	0,81	0,96	0,88	0,85
	Pozitif (1)	0,93	0,72	0,82	

Şekil 4.13’de Word2Vec kelime temsil yöntemi ile elde edilen makine öğrenme algoritmalarının sonuçlarının karşılaştırılması yapılmıştır. Şekil 4.14’de ise TF-IDF kelime temsil yönteminin kullanıldığı sonuçlara yer verilmiştir. TF-IDF kelime temsil yöntemi ile elde edilen değerlerin daha yüksek olduğu görülmektedir. Kaygı duygusunun tahminlenmesinde, doğruluk değerinin en yüksek, TF-IDF kelime temsil yöntemi ile lojistik regresyon algoritmasından elde edildiği saptanmıştır (%86).



Şekil 4.13: Word2Vec kelime temsil yönteminin kullanıldığı makine öğrenmesi algoritmalarının bulguları (Kaygı duygusu)



Şekil 4.14: TF-IDF kelime temsil yönteminin kullanıldığı makine öğrenmesi algoritmalarının bulguları (Kaygı duygusu)

Bu duygunun tahminlenmesinde ayrıca, BERTurk transformer tabanlı dil modeli kullanılmıştır. BERTurk ile veri setinin eğitilmesi üç aşamada gerçekleştirilmiştir. BERTurk ile elde edilen kesinlik, duyarlılık, F1 ve doğruluk değerleri Tablo 4.7’de verilmiştir.

Tablo 4.7: Kaygı Duygusunun Tahmin Edilmesinde BERTurk Bulguları


	Kesinlik	Duyarlılık	F1	Doğruluk
Negatif	0.96	0.99	0.97	0.97
Pozitif	0.98	0.94	0.96	

AdamW ($\beta_1 = 0.9$; $\beta_2 = 0.999$, $\epsilon = 1e-8$) Öğrenme oranı: $3e-5$


Doğruluk değerleri birinci aşama için 0,94, ikinci aşama için 0,98ve üçüncü aşama için 0,96 olarak bulunmuştur. Sonuç olarak, BERTurk modeli ile %97’lik bir doğruluk değeri elde edilmiştir.

4.3.4 Sıkılma Duygusunun Tahmin Edilmesi

Öğrencilerin programlama yaparken hissettikleri sıkılma duygusu ile ilgili pozitif ve negatif etiketlenmiş cümlelerde en sık tekrar eden unigramlar, Şekil 4.15 ve Şekil 4.16’da verilmiştir.



Şekil 4.15: Sıkılma duygusuna ilişkin pozitif etiketlenmiş cümleler için unigramlar



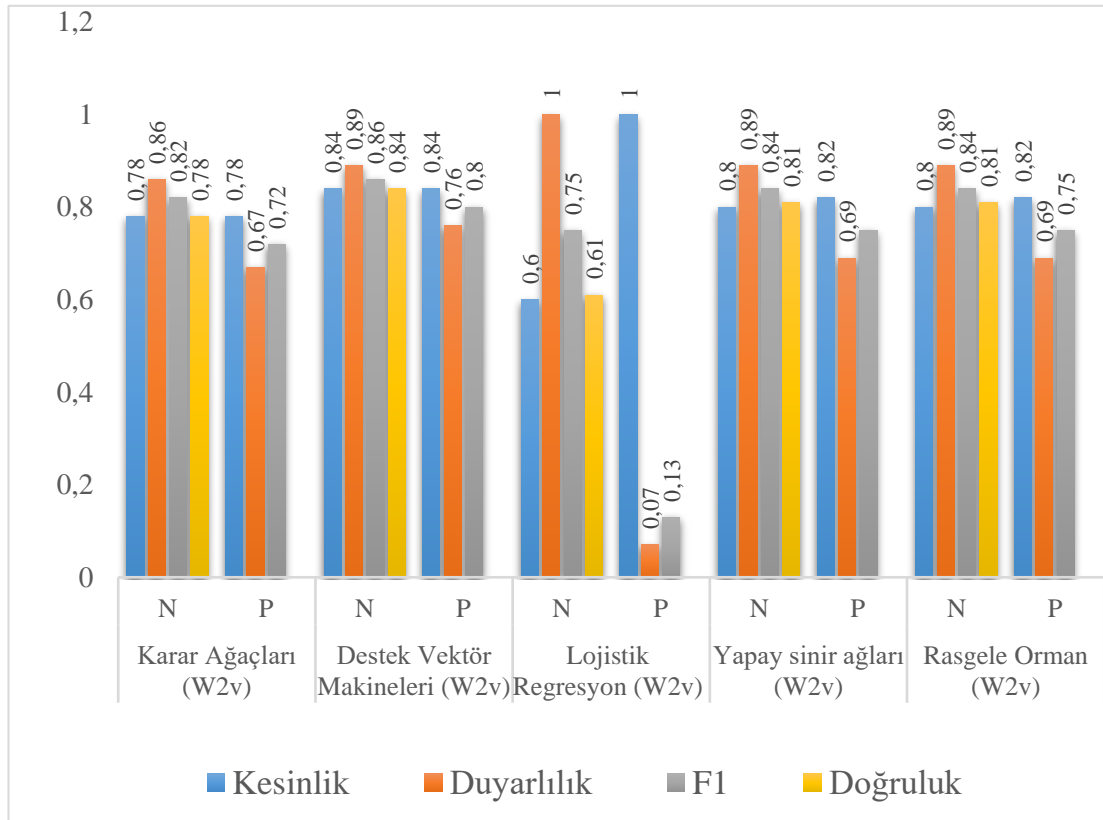
Şekil 4.16: Kaygı duygusuna ilişkin negatif etiketlenmiş cümleler için unigramlar

Sıkılma duygusunun makine öğrenmesi algoritmaları kullanılarak tahmin edilmesi ile ilgili bulgular, Tablo 4.8’de verilmiştir.


Tablo 4.8: Sıkılma duygusunun tahminlenmesinde kullanılan makine öğrenme algoritmaları sonuçları

		Kesinlik	Duyarlılık	F1	Doğruluk
Karar Ağaçları (W2V)	Negatif (0)	0,78	0,86	0,82	0,78
	Pozitif (1)	0,78	0,67	0,72	
Karar Ağaçları (TF-IDF)	Negatif (0)	0,93	0,85	0,89	0,88
	Pozitif (1)	0,82	0,91	0,86	
DVM (W2V)	Negatif (0)	0,84	0,89	0,86	0,84
	Pozitif (1)	0,84	0,76	0,80	
DVM (TF-IDF)	Negatif (0)	0,87	0,96	0,91	0,89
	Pozitif (1)	0,93	0,80	0,86	
LR (W2V)	Negatif (0)	0,60	1,00	0,75	0,61
	Pozitif (1)	1,00	0,07	0,13	
LR (TF-IDF)	Negatif (0)	0,87	0,94	0,90	0,89
	Pozitif (1)	0,91	0,81	0,86	
YSA (W2V)	Negatif (0)	0,80	0,89	0,84	0,81
	Pozitif (1)	0,82	0,69	0,75	
YSA (TF-IDF)	Negatif (0)	0,84	0,97	0,90	0,88
	Pozitif (1)	0,94	0,75	0,84	
Rasgele Orman (W2V)	Negatif (0)	0,80	0,89	0,84	0,81
	Pozitif (1)	0,82	0,69	0,75	
Rasgele Orman (TF-IDF)	Negatif (0)	0,87	0,96	0,91	0,89
	Pozitif (1)	0,93	0,80	0,86	

Tablo 4.8 incelendiğinde, elde edilen doğruluk değerlerinin 0,61 ve 0,89 arasında değiştiği görülmektedir. Şekil 4.17’de Word2Vec kelime temsil yöntemi ile elde edilen makine öğrenme algoritmalarının sonuçlarının karşılaştırılması yapılmıştır. Şekil 4.18’de ise TF-IDF kelime temsil yönteminin kullanıldığı sonuçlara yer verilmiştir. TF-IDF kelime temsil yöntemi ile elde edilen değerlerin daha yüksek olduğu görülmektedir. Sıkılma duygusunun tahminlenmesinde, doğruluk değerinin en yüksek, TF-IDF kelime temsil yöntemi ile lojistik regresyon ve rasgele orman algoritmasından elde edildiği saptanmıştır (%89).



Şekil 4.17: Word2Vec kelime temsil yönteminin kullanıldığı makine öğrenmesi algoritmalarının bulguları (Sıkılma duygusu)



Şekil 4.18: TF-IDF kelime temsil yönteminin kullanıldığı makine öğrenmesi algoritmalarının bulguları (Sıkılma duygusu)

Bu duygunun tahminlenmesinde ayrıca, BERTurk transformer tabanlı dil modeli kullanılmıştır. BERTurk ile veri setinin eğitilmesi üç aşamada gerçekleştirilmiştir. BERTurk ile elde edilen kesinlik, duyarlılık, F1 ve doğruluk değerleri Tablo 4.9'da verilmiştir.

Tablo 4.9: Sıkılma Duygusunun Tahmin Edilmesinde BERTurk Bulguları

	Kesinlik	Duyarlılık	F1	Doğruluk
Negatif	0.97	0.96	0.97	
Pozitif	0.92	0.95	0.94	0.96

AdamW ($\beta_1 = 0.9$; $\beta_2 = 0.999$, $\epsilon = 1e-8$) Öğrenme oranı: $3e-5$

Doğruluk değerleri birinci aşama için 0,93, ikinci aşama için 0,96 ve üçüncü aşama için 0,98 olarak bulunmuştur. Sonuç olarak, BERTurk modeli ile %96'lık bir doğruluk değeri elde edilmiştir.

4.3.5 Genel Olarak Duyguların Tahmin Edilmesi


Duyguların her biri için ayrı ayrı tahminleme yapıldıktan sonra, öğrencilerin deneyimledikleri duygular ile ilgili ifadeleri tamamı bir araya getirilmiştir. Daha sonra, bu ifadeler taşıdıkları anlamlara göre pozitif duygu ve negatif duygu olmak üzere yeniden etiketlenmiştir. Bunun için sıkılma ve kaygı duyguları için pozitif ifadeler negatif olacak şekilde yeniden kodlanmıştır. Keyif ve umut duyguları ile ilgili ifadelerde bir değişiklik yapılmamıştır. Yeniden düzenlenen veri setinde genel olarak duyguların pozitif ve negatif olarak tahmin edilmesinde kullanılan makine öğrenmesi algoritmalarının sonuçları, Tablo 4.10'da verilmiştir.

Tablo 4.10: Genel olarak duyguların tahminlenmesinde kullanılan makine öğrenme algoritmaları sonuçları

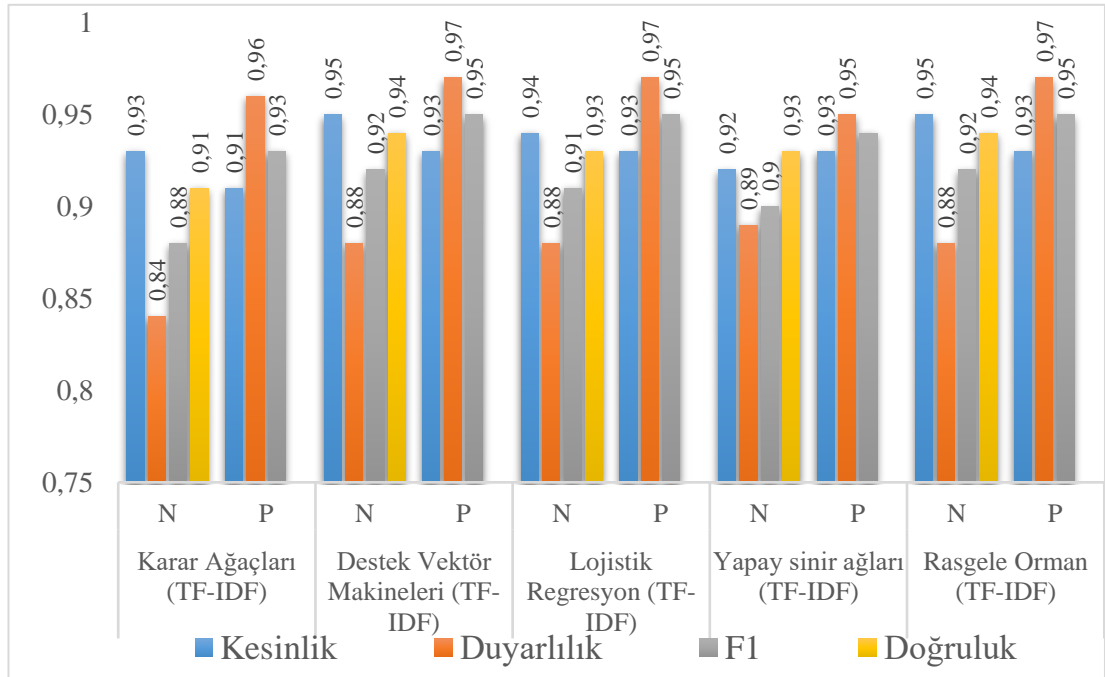
		Kesinlik	Duyarlılık	F1	Doğruluk
Karar Ağaçları (W2V)	Negatif (0)	0,79	0,80	0,79	0,84
	Pozitif (1)	0,88	0,87	0,87	
Karar Ağaçları (TF-IDF)	Negatif (0)	0,93	0,84	0,88	0,91
	Pozitif (1)	0,91	0,96	0,93	
DVM (W2V)	Negatif (0)	0,83	0,70	0,76	0,84
	Pozitif (1)	0,84	0,91	0,87	
DVM (TF-IDF)	Negatif (0)	0,95	0,88	0,92	0,94
	Pozitif (1)	0,93	0,97	0,95	
LR (W2V)	Negatif (0)	0,78	0,45	0,57	0,74
	Pozitif (1)	0,74	0,92	0,82	
LR (TF-IDF)	Negatif (0)	0,94	0,88	0,91	0,93
	Pozitif (1)	0,93	0,97	0,95	
YSA (W2V)	Negatif (0)	0,90	0,78	0,84	0,88
	Pozitif (1)	0,88	0,95	0,91	
YSA (TF-IDF)	Negatif (0)	0,92	0,89	0,90	0,93
	Pozitif (1)	0,93	0,95	0,94	
Rasgele Orman (W2V)	Negatif (0)	0,90	0,78	0,84	0,88
	Pozitif (1)	0,88	0,95	0,91	
Rasgele Orman (TF-IDF)	Negatif (0)	0,95	0,88	0,92	0,94
	Pozitif (1)	0,93	0,97	0,95	

Tablo 4.10 incelendiğinde, elde edilen doğruluk değerlerinin 0,74 ve 0,94 arasında değiştiği görülmektedir.

Şekil 4.19'de Word2Vec kelime temsil yöntemi ile elde edilen makine öğrenme algoritmalarının sonuçlarının karşılaştırılması yapılmıştır. Şekil 4.20'de ise TF-IDF kelime temsil yönteminin kullanıldığı sonuçlara yer verilmiştir.



Şekil 4.19: Word2Vec kelime temsil yönteminin kullanıldığı makine öğrenmesi algoritmalarının bulguları (Duygular- genel)



Şekil 4.20: TF-IDF kelime temsil yönteminin kullanıldığı makine öğrenmesi algoritmalarının bulguları (Duygular- genel)

TF-IDF kelime temsil yöntemi ile elde edilen değerlerin daha yüksek olduğu görülmektedir. Duyguların makine öğrenmesi ile tahminlenmesinde, doğruluk değerinin en yüksek, TF-IDF kelime temsil yöntemi ile destek vektör makineleri ve rasgele orman algoritmasından elde edildiği saptanmıştır (%94).

Duyguların genel olarak tahminlenmesinde ayrıca, BERTurk transformer tabanlı dil modeli kullanılmıştır. BERTurk ile veri setinin eğitilmesi üç aşamada gerçekleştirilmiştir. BERTurk ile elde edilen kesinlik, duyarlılık, F1 ve doğruluk değerleri Tablo 4.11’de verilmiştir.

Tablo 4.11: Genel olarak Duyguların Tahmin Edilmesinde BERTurk Bulguları

	Kesinlik	Duyarlılık	F1	Doğruluk
Negatif	0.96	0.97	0.97	
Pozitif	0.97	0.97	0.97	0.96

AdamW ($\beta_1 = 0.9$; $\beta_2 = 0.999$, $\epsilon = 1e-8$) Öğrenme oranı: $3e-5$

Doğruluk değerleri birinci aşama için 0,94, ikinci aşama için 0,98 ve üçüncü aşama için 0,97 olarak bulunmuştur. Sonuç olarak, BERTurk modeli ile %96’lık bir doğruluk değeri elde edilmiştir.

4.4 Bilgi İşlemsel Kimlikle İlgili Görüşlerin Tahmin Edilmesi


Öğrencilerin bilgi işlemsel kimlikle ilgili açık uçlu sorulara verdikleri yanıtlar etiketlendikten sonra, iki kodlayıcı arasında uyum sağlanmayan cümleleri yeniden değerlendirmek üzere bir toplantı düzenlenmiştir. Bu toplantıda uyum sağlanmayan cümleler iki kodlayıcı tarafından birlikte tekrar okunup, cümlelerin etiketlenmesinin tamamında fikir birliğine varılmıştır. Sonuç olarak, 1938 cümlelik bir veri seti ile öğrencilerin bilgi işlem kimliğe ilişkin görüşleri analiz edilmiştir. Bilgi işlemsel kimlik ile ilgili pozitif ve negatif etiketlenmiş cümle örnekleri Tablo 4.12’de verilmiştir.

Tablo 4.12: Bilgi işlemsel kimlik ile ilgili pozitif ve negatif alıntı örnekleri

	Etiket	Örnek Cümleler
Katılım	P	<p>“Çünkü programlama yaparken kafamızda kurduğumuz bir senaryoyu (algoritmayı) hayata geçirmeye çalışıyoruz, ilk yaptığımızda çoğu zaman işe yarayacağını bile bilmiyoruz ama buna rağmen, Aklimızdan geçenleri gerçekleştirebildiğimizde, doyum duygusu çok yeterli oluyor.”</p> <p>“Programlama benim için zevkli çünkü bir problem olduğunda çözümüne giden adımlar kod bloklarına dönüşüyor. Bu yüzden ilgi çekici”</p> <p>“Bunu ilgi çekici buluyorum çünkü sınırsız hayal gücüne sahip insanların yapabileceklerinin sınırı yok.”</p> <p>“Programların içinde ne tür kodlar olduğunu merak ediyordum.</p>
	N	<p>“Programlama oldukça sıkıcı, Mblock'ta karakter yaratmanın ilginç tarafını görmüyorum.”</p>
	P	<p>“Çalışmak için doğru yazılım alanını belirlemeyi, uygun bir işte çalışmayı ve her geçen gün kendimi geliştirmeyi ve gelebileceğim en iyi noktaya gelmeyi hayal ediyorum.”</p> <p>“Şirket kuracağım. Yapay zekâ ve kuantum bilgisayar teknolojilerine odaklanacağım.”</p>
İmgeleme	N	<p>“Programlama ile ilgili bir kariyer hedefim veya hayalim yok”</p> <p>“Programlamada ilerlemeyi planlamıyorum.”</p>
	P	<p>“Akranlarımla bir ekip olarak çalışmak, birden fazla bakış açısı görmeme, üfkümü genişletmeme ve yeni şeyler öğrenmeme olanak tanıyor. Aynı zamanda takım olarak çalışırken programlamayı daha iyi öğrendiğime inaniyorum”</p>
Bağlılık	N	<p>Akranlarla çalışmanın çok faydalı bir ekip çalışması olduğunu düşünmüyorum çünkü aynı yaş grubundan, aynı ortamda bulunan, aynı eğitimi alan insanların ortak bir projede birbirlerine çok şey katabileceklerini düşünmüyorum. ”</p> <p>“Olumlu yanları olduğunu düşünmüyorum, takım olarak yaptığım şeylerde hata payı yüksek çünkü iki kişide de var. Tek başıma yaptığımda daha iyi olduğunu düşünüyorum çünkü hata payı olan tek kişi benim.”</p>

P: Pozitif; N: Negatif

Bilgi işlemsel kimlikle ilgili pozitif ve negatif cümle sayıları Şekil 4.21’de verilmiştir.



Şekil 4.21: Bilgi işlemsel kimlik ile ilgili pozitif ve negatif cümlelerin frekansları

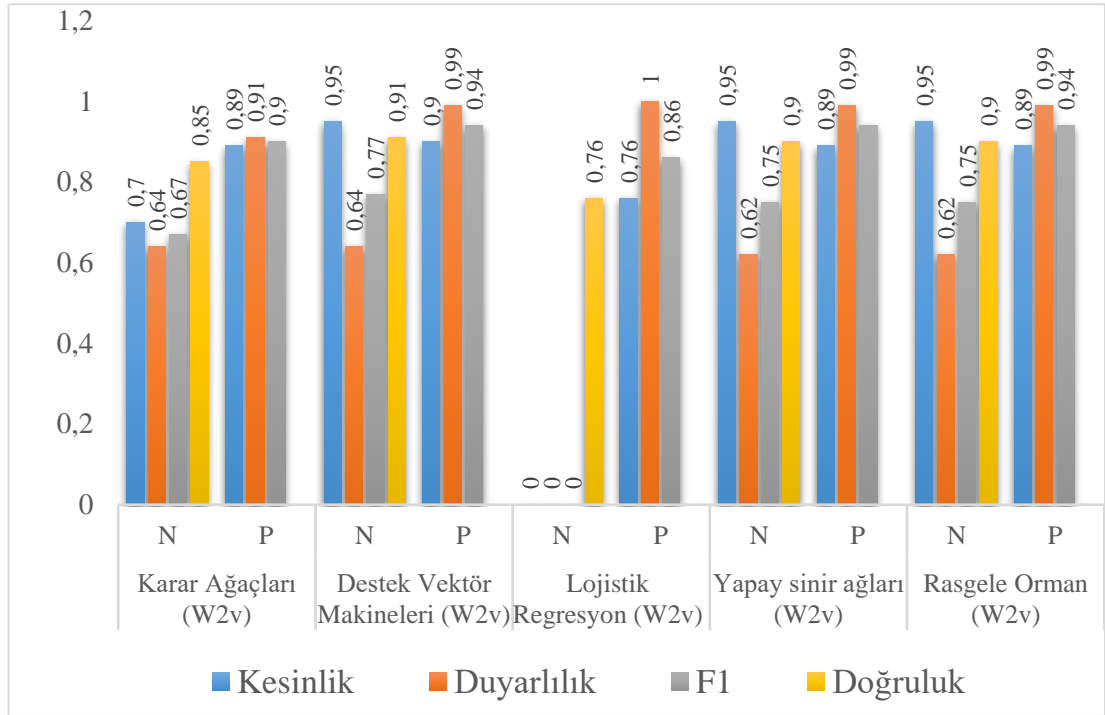
Şekil 4.21 incelendiğinde, pozitif cümlelerin frekanslarının, negatif cümlelerden daha fazla olduğu görülmektedir. Bilgi işlemsel kimliğin tahmin edilmesinde kullanılan makine öğrenmesi algoritmalarının sonuçları, Tablo 4.13’de verilmiştir.

Tablo 4.13: Bilgi işlemsel kimliğin tahminlenmesinde kullanılan makine öğrenme algoritmaları sonuçları


		Kesinlik	Duyarlılık	F1	Doğruluk
Karar Ağaçları (W2V)	Negatif (0)	0,70	0,64	0,67	0,85
	Pozitif (1)	0,89	0,91	0,90	
Karar Ağaçları (TF-IDF)	Negatif (0)	0,61	0,91	0,73	0,84
	Pozitif (1)	0,97	0,82	0,88	
DVM (W2V)	Negatif (0)	0,95	0,64	0,77	0,91
	Pozitif (1)	0,90	0,99	0,94	
DVM (TF-IDF)	Negatif (0)	0,89	0,74	0,81	0,91
	Pozitif (1)	0,92	0,97	0,94	
LR (W2V)	Negatif (0)	0,00	0,00	0,00	0,76
	Pozitif (1)	0,76	1,00	0,86	
LR (TF-IDF)	Negatif (0)	0,97	0,74	0,84	0,93
	Pozitif (1)	0,92	0,99	0,96	
YSA (W2V)	Negatif (0)	0,95	0,62	0,75	0,90
	Pozitif (1)	0,89	0,99	0,94	
YSA (TF-IDF)	Negatif (0)	0,85	0,86	0,86	0,93
	Pozitif (1)	0,96	0,95	0,95	

		Kesinlik	Duyarlılık	F1	Doğruluk
Rasgele Orman (W2V)	Negatif (0)	0,95	0,62	0,75	0,90
	Pozitif (1)	0,89	0,99	0,94	
Rasgele Orman (TF-IDF)	Negatif (0)	0,89	0,74	0,81	0,91
	Pozitif (1)	0,92	0,97	0,94	

Tablo 4.10 incelendiğinde, elde edilen doğruluk değerlerinin 0,76 ve 0,91 arasında değiştiği görülmektedir. Şekil 4.22’de Word2Vec kelime temsil yöntemi ile elde edilen makine öğrenme algoritmalarının sonuçlarının karşılaştırılması yapılmıştır. Şekil 4.23’de ise TF-IDF kelime temsil yönteminin kullanıldığı sonuçlara yer verilmiştir.



Şekil 4.22: Word2Vec kelime temsil yönteminin kullanıldığı makine öğrenmesi algoritmalarının bulguları (Bilgi işlemsel kimlik)



Şekil 4.23: TF-IDF kelime temsil yönteminin kullanıldığı makine öğrenmesi algoritmalarının bulguları (Bilgi işlemsel kimlik)

Bilgi işlemsel kimliğin makine öğrenmesi ile tahminlenmesinde, doğruluk değerinin en yüksek, TF-IDF kelime temsil yöntemi ile yapay sinir ağları ve lojistik regresyon algoritmasından elde edildiği saptanmıştır (%93). Bilgi işlemsel kimliğin tahminlenmesinde ayrıca, BERTurk transformer tabanlı dil modeli kullanılmıştır. BERTurk ile veri setinin eğitilmesi üç aşamada gerçekleştirilmiştir. BERTurk ile elde edilen kesinlik, duyarlılık, F1 ve doğruluk değerleri Tablo 4.14’de verilmiştir.

Tablo 4.14: Bilgi İşlemsel Kimliğin Tahmin Edilmesinde BERTurk Bulguları

	Kesinlik	Duyarlılık	F1	Doğruluk
Negatif	0.94	0.84	0.89	
Pozitif	0.96	0.99	0.97	0.96

AdamW ($\beta_1 = 0.9$; $\beta_2 = 0.999$, $\epsilon = 1e-8$) Öğrenme oranı: $3e-5$

Doğruluk değerleri birinci, ikinci ve üçüncü aşama için 0,94 olarak bulunmuştur. Sonuç olarak, BERTurk modeli ile %96’lık bir doğruluk değeri elde edilmiştir.

4.5 Programlamada Yetkilendirme İle İlgili Görüşlerin Tahmin Edilmesi

Öğrencilerin programlamada yetkilendirme ilgili açık uçlu sorulara verdikleri yanıtların etikelendirilmesinde iki kodlayıcı arasında uyum sağlamayan ifadeler birlikte tekrar okunup, cümlelerin etiketlenmesinin tamamında fikir birliğine varılmıştır. Sonuç olarak, 1938 cümlelik bir veri seti ile öğrencilerin programlamada yetkilendirme ile ilgili görüşleri analiz edilmiştir. Programlamada yetkilendirme ile ilgili pozitif ve negatif etiketlenmiş cümle örnekleri Tablo 4.15’de verilmiştir.


Tablo 4.15: Programlamada yetkilendirme ile ilgili pozitif ve negatif alıntı örnekleri

	Etiket	Örnek Cümleler
Anlamlılık	P	<i>"Programlama becerilerimde ilerleme kaydetmek, gelecekte iyi bir iş bulmamı sağlayacak."</i> <i>"Kodlamayı öğrenmek, günlük hayatta karşılaştığım sorunları çözmeme yardımcı oluyor."</i>
	N	<i>"Gelecekte programlama öğrenmenin benim için faydalı ve önemli olacağını düşünmüyorum."</i> <i>"Kodlamadan daha önemli dersler var, bence gereksiz."</i>
Etki	P	<i>"Yazılım alanında insan hayatını kolaylaştırma konusunda çok ileri bir seviyeye gidebileceğimizi düşünüyorum. En azından dünya ile ilgili sorunların çözümünde yeterli bir fark yaratılabilir."</i> <i>"İnsanları tüketmeye değil üretmeye yönlendirecek, zamanı verimli kullanmalarını sağlayacak bir dijital platform kurabilirim."</i> <i>"Engelli insanlara yardımcı olacak teknolojiler geliştirmeyi hayal ediyorum."</i> <i>"Çocuklara gerçek hayatı öğreten oyunlar yapmak istiyorum."</i> <i>"Hayatı kolaylaştıracak birçok projede yer almak isterim."</i>
	N	<i>"Programlama ile dünyada bir fark yaratmaya hiç niyetim yok."</i> <i>"Programlama ile uğraşmayı gerekli bulmuyorum. Daha doğrusu getirisi daha yüksek işlerle daha çok ilgileniyorum."</i>
Öz	P	<i>"Düşünme tarzım ve oyun geliştirme konusunda kendime güveniyorum."</i>

Etiket	Örnek Cümleler
	<p><i>“Mevcut seviyemde gelecekteki kariyerim için gerekli teknik altyapıya sahibim. Daha çok çalışarak daha ileri yetkinliklere sahip olacak kadar kendimi yeterli görüyorum.”</i></p> <p><i>“Artık herhangi bir karmaşık problemi daha hızlı çözebiliyorum, problem çözme konusunda yetkin olduğumu düşünüyorum.”</i></p>
N	<p><i>“Programlama yaparken sabır konusunda kendimi yeterli görmüyorum, çok strese giriyorum”</i></p> <p><i>“Her yönden yetersizim. Kendimi yolun başında bile görmüyorum.”</i></p>

P: Pozitif; N: Negatif

Programlamada yetkilendirme ile ilgili pozitif ve negatif cümle sayıları Şekil 4.24’da verilmiştir.




Şekil 4.24: Programlamada yetkilendirme ile ilgili pozitif ve negatif cümlelerin frekansları

Şekil 4.24 incelendiğinde, pozitif cümlelerin frekanslarının, negatif cümlelerden daha fazla olduğu görülmektedir. Yeniden düzenlenen veri setinde programlamada yetkilendirmenin pozitif ve negatif olarak tahmin edilmesinde kullanılan makine öğrenmesi algoritmalarının sonuçları, Tablo 4.16’da verilmiştir.


Tablo 4.16: Programlamada yetkilendirmenin tahminlenmesinde kullanılan makine öğrenme algoritmaları sonuçları

		Kesinlik	Duyarlılık	F1	Doğruluk
Karar Ağaçları (W2V)	Negatif (0)	0,79	0,80	0,79	0,84
	Pozitif (1)	0,88	0,87	0,87	
Karar Ağaçları (TF-IDF)	Negatif (0)	0,93	0,84	0,88	0,91
	Pozitif (1)	0,91	0,96	0,93	
DVM (W2V)	Negatif (0)	0,83	0,70	0,76	0,84
	Pozitif (1)	0,84	0,91	0,87	
DVM (TF-IDF)	Negatif (0)	0,95	0,88	0,92	0,94
	Pozitif (1)	0,93	0,97	0,95	
LR (W2V)	Negatif (0)	0,78	0,45	0,57	0,74
	Pozitif (1)	0,74	0,92	0,82	
LR (TF-IDF)	Negatif (0)	0,94	0,88	0,91	0,93
	Pozitif (1)	0,93	0,97	0,95	
YSA (W2V)	Negatif (0)	0,90	0,78	0,84	0,88
	Pozitif (1)	0,88	0,95	0,91	
YSA (TF-IDF)	Negatif (0)	0,92	0,89	0,90	0,93
	Pozitif (1)	0,93	0,95	0,94	
Rasgele Orman (W2V)	Negatif (0)	0,90	0,78	0,84	0,88
	Pozitif (1)	0,88	0,95	0,91	
Rasgele Orman (TF-IDF)	Negatif (0)	0,95	0,88	0,92	0,94
	Pozitif (1)	0,93	0,97	0,95	

Tablo 4.16 incelendiğinde, elde edilen doğruluk değerlerinin 0,74 ve 0,94 arasında değiştiği görülmektedir. Şekil 4.25’de Word2Vec kelime temsil yöntemi ile elde edilen makine öğrenme algoritmalarının sonuçlarının karşılaştırılması yapılmıştır. Şekil 4.26’da ise TF-IDF kelime temsil yönteminin kullanıldığı sonuçlara yer verilmiştir.



Şekil 4.25: Word2Vec kelime temsil yönteminin kullanıldığı makine öğrenmesi algoritmalarının bulguları (Duygular- genel)



Şekil 4.26: TF-IDF kelime temsil yönteminin kullanıldığı makine öğrenmesi algoritmalarının bulguları (Duygular- genel)

TF-IDF kelime temsil yöntemi ile elde edilen değerlerin daha yüksek olduğu görülmektedir. Duyguların makine öğrenmesi ile tahminlenmesinde, doğruluk değerinin en yüksek, TF-IDF kelime temsil yöntemi ile destek vektör makineleri ve rasgele orman algoritmasından elde edildiği saptanmıştır (%94).

Duyguların genel olarak tahminlenmesinde ayrıca, BERTurk transformer tabanlı dil modeli kullanılmıştır. BERTurk ile veri setinin eğitilmesi üç aşamada gerçekleştirilmiştir. BERTurk ile elde edilen kesinlik, duyarlılık, F1 ve doğruluk değerleri Tablo 4.11’de verilmiştir.

Tablo 4.17: Programlamada Yetkilendirmenin Tahmin Edilmesinde BERTurk Bulguları

	Kesinlik	Duyarlılık	F1	Doğruluk
Negatif	0.90	0.91	0.90	
Pozitif	0.98	0.98	0.98	0.96

AdamW ($\beta_1 = 0.9$; $\beta_2 = 0.999$, $\epsilon = 1e-8$) Öğrenme oranı: $3e-5$

Doğruluk değerleri birinci aşama için 0,94, ikinci aşama için 0,98 ve üçüncü aşama için 0,96 olarak bulunmuştur. Sonuç olarak, BERTurk modeli ile %96'lık bir doğruluk değeri elde edilmiştir.

Bölüm 5

Bulgular ve Tartışma

Bu çalışmada, programlama eğitimi alan öğrencilerin duyguları, bilgi işlemsel kimlikleri ve programlamada yetkilendirilmelerine ilişkin görüşleri, metin madenciliği algoritmaları kullanılarak tahmin edilerek yüksek performanslı bir sınıflandırma şemasının üretilmesi amaçlanmıştır. Bu kapsamda, öğrencilerin keyif, umut, kaygı ve sıkılma duyguları pozitif ve negatif etiketlenmiş ifadelerinden yola çıkılarak makine öğrenmesi algoritmaları ve BERT kullanılarak tahminlenmiştir. Araştırmanın sonuçları, keyif duygusuna yönelik tahminleme sürecinde, en yüksek doğruluk değerini destek vektör makineleri ve rasgele orman algoritmasının elde ettiğini göstermiştir (%94). BERTurk ile elde edilen doğruluk değeri %96 olarak bulunmuştur. Umut duygusuna yönelik tahminleme sürecinde, yapay sinir ağları ve lojistik regresyon algoritması en yüksek doğruluk değerlerini üretmiştir (%87). Umut için BERTurk ile elde edilen doğruluk değeri %92 olarak bulunmuştur. Kaygı duygusunda en yüksek doğruluk değerini, lojistik regresyon algoritması (%86); sıkılma duygusuna yönelik tahminleme sürecinde, destek vektör makineleri, rasgele orman ve lojistik regresyon algoritması (%89) üretmiştir. BERTurk ile elde edilen doğruluk değerleri; kaygı için %97, sıkılma için %96'dır. Araştırmanın sonuçları, duyguları genel olarak tahminleme sürecinde, destek vektör makineleri ve rasgele orman algoritmalarının %94 doğruluk değeri ürettiğini göstermiştir. BERTurk ile %96'lık bir tahminleme performansına ulaşılmıştır.

Destek vektör makineleri, özellik uzayındaki sınıflar arasındaki ayrımı en üst düzeye çıkararak en uygun hiperdüzlemleri bulma yetenekleri nedeniyle popülerlik kazanmıştır. DVM, yüksek boyutlu uzaylarda etkili ve stabil olma özellikleriyle ön plana çıkmaktadır [100]. Öte yandan rasgele orman algoritması, genel tahmin doğruluğunu

artırmak ve yüksek boyutlu verileri etkili bir şekilde işlemek için birden fazla karar ağacını birleştirerek topluluk öğrenmesinden yararlanır. Bu model tutarlı olması ve aşırı uyumun eğiliminin düşük olması ile bilinmektedir [51]. Yapay Sinir Ağları (YSA), karmaşık ilişkileri modelleme ve birbirine bağlı nöron katmanları aracılığıyla karmaşık kalıpları çıkarma gücü ile bilinmektedir. Değişkenler arasındaki karmaşık ilişkilerle başa çıkma ve gürültülü verilere karşı iyi genelleme yapma yeteneğine sahiptir [100]. Metin verilerindeki hem doğrusal hem de doğrusal olmayan ilişkileri yakalayarak metin sınıflandırma görevleri için çok uygun hale getirmektedirler. Lojistik regresyon, özellik uzayında sınıfların dağılımı hakkında varsayımlara gerek olmadan, sınıflandırma görevleri için kullanılan olasılıksal bir regresyon analizidir [51].

Bu sonuçlar, öğrencilerin bu yapılara ilişkin bakış açılarını analiz ve tahmin etmede bu algoritmaların potansiyel etkinliğini göstermektedir. Ancak, diğer algoritmaların da nispeten yüksek doğruluk oranları gösterdiğine dikkat etmek önemlidir. Bu bulgular, öğrencilerin bakış açılarını tahmin etmek için birden fazla algoritmanın kullanılabileceğini ve algoritma seçiminin belirli gereksinimlere ve tercihlere bağlı olabileceğini göstermektedir. Bu bağlamda, duyguların etkinleştirici / devre dışı bırakıcı ya da pozitif veya negatif olması gibi özelliklerinin de rol oynayabileceği düşünülebilir. Bunun yanında, veri setinin oluşturulmasında farklı eğitim düzeylerinden gelen öğrencilerin kullandıkları programlama dili ile ilgili farklılıklar sonuçlar üzerinde etkili olabilir. Ayrıca, duyguların her biri için yapılan analizler ve genel olarak duyguların sınıflandırılmasında BERTurk'ün, makine öğrenmesi algoritmalarının tamamından daha yüksek doğruluk değerlerini ortaya çıkardığı görülmüştür. BERT nöral bir dil modelidir ve ön işleme görevleri olmadan tahmin performansı yüksek değerlerin elde edilebilmesi olanaklı kılmaktadır [116]

Bu çalışma, metin madenciliği algoritmalarının öğrencilerin bilgi işlemsel kimlik ve programlamada yetkilendirme ile ilgili tahmin etme performansını değerlendirmiştir. Lojistik regresyon ve yapay sinir ağları ile birlikte TF-IDF temsili bilgi işlemsel kimlik için en yüksek doğruluk oranını elde etmiştir (%93). Programlamada yetkilendirme için en yüksek doğruluk oranları destek vektör makineleri ve rasgele orman algoritmasından elde edilmiştir (%94). BERTurk ile elde edilen doğruluk değerleri;

bilgi işlemsel kimlik için %96, programlamada yetkilendirme için %96 olarak bulunmuştur.

Elde edilen bulgulardaki farklılaşmada etkili olan bir diğer faktör, Word2vec (W2v) ve Terim Frekansı-Ters Belge Frekansı (TF-IDF) gibi kelime temsil yöntemlerinin seçimidir. W2v, kelimeleri yoğun vektörler olarak temsil ederek anlamsal ilişkileri yakalarken, TF-IDF veri kümesindeki sıklığına ve dağılımına göre her kelimenin önemini hesaplamaktadır. Bu farklı gösterimler, metin verilerinden anlamlı bilgiler çıkarma yeteneklerini etkileyerek algoritmaların performansını etkileyebilir. Veri kümesinin kendisinin özellikleri de bir rol oynayabilir. Sınıf dağılımı dengesizliği, gürültülü veya belirsiz ifadeler veya öğrenciler tarafından kullanılan dilin karmaşıklığındaki farklılıklar gibi faktörler, algoritmaların performansını etkileyebilir. Örneğin, dengesiz sınıf dağılımları, azınlık sınıfında yanlış tahminlere veya daha düşük performansa yol açabilir. Benzer şekilde, gürültülü veya muğlak ifadelerin varlığı belirli algoritmalar için hassasiyet, geri çağırma, F1 puanı ve doğruluğunu etkileyen zorlukları ortaya çıkarabilir. Ayrıca, bireysel deneyimlerden, geçmişlerden ve motivasyonlardan etkilenen bilgi işlemsel kimliğin ve programlama yetkilendirmesinin çok boyutlu doğası, tahmin görevine karmaşıklık katabilir. Farklı algoritmalar, bu faktörleri farklı şekilde yakalayabilir ve ağırlıklandırabilir. Bunun da algoritmaların performanslarında farklılıklara yol açtığı düşünülebilir.

Bölüm 6

Sonuçlar

Bu çalışmada, programlama eğitimi alan öğrencilerin duyguları, bilgi işlemsel kimlik ve programlamada yetkilendirilmeleri konusundaki görüşleri ve bu bakış açılarını tahmin etmede çeşitli metin madenciliği algoritmalarının performansı hakkında bulgulara ulaşılmıştır. Programlama eğitimi alan ve yaşları 12-20 arasında değişen 646 öğrencinin açık uçlu yanıtları elde edilerek; ulusal alanyazında programlama eğitime yönelik bir veri seti elde edilmiştir. Bu görüşler analiz edilerek, öğrencilerin duyguları, bilgi işlemsel kimlik ve programlama yetkilendirme ile ilgili eğilimleri hakkında daha derin bir anlayış kazanılmasına çalışılmıştır. Elde edilen bulgular, öğrencilerin programlama etkinliklerine yönelik çoğunlukla olumlu duyguları olduğunu; programlama etkinliklerine motive olduklarını ve ilgilendiklerini göstermektedir. Bilgi işlemsel kimlik ile katılım, hayal gücü ve bağlılık bileşenleri arasındaki pozitif ilişkiler, öğrencilerin programlamaya devam eden katılımını ve bağlılığını desteklemek için bu boyutların potansiyelini vurgulamaktadır. Programlamada yetkilendirme açısından, olumlu yorumlar programlamanın faydalarını, programlama becerileriyle fark ve etki yaratma arzusunu ve programlama görevlerinde algılanan öz yeterliliği vurgulamıştır. Bu bulgular, yetkilendirilmiş öğrencilerin programlama görevlerini anlamlı buldukları, yeteneklerine inandıkları ve çabalarını etkili olarak algıladıkları fikriyle uyumludur. Öğrencilerin programlamanın gerçek dünya sorunlarını çözme, yaşamları iyileştirme ve olumlu toplumsal değişime katkıda bulunma potansiyelini fark ettiğini görmek cesaret vericidir. Programlama yetkilendirmesinin bu yönleri, programlama çabalarında öğrencilerin motivasyonunu, güvenini ve amaç duygusunu geliştirmek için gereklidir.

Umut verici bulgulara rağmen, duygu analizi ile ilgili bazı güçlükleri raporlamak gerekmektedir. Resmi olmayan yazım tarzı, dil bilgisi hataları, ironi ve belirsiz ifadeler ve kelimenin anlamının bağlama göre değişmesi bu güçlükler arasında sıralanabilir. Bunun yanı sıra elde edilen bulguların yorumlanmasında duygunun değişken doğasına da dikkat etmek gerekmektedir. Duygular, bağlama, cinsiyete ve yaşa göre farklılıklar gösterebilmektedir. Mevcut çalışmada, cinsiyet ve yaş gibi değişkenlere göre bir sınıflandırma yapılamamıştır. Gelecekteki çalışmalar, cinsiyet, yaş ya da okul düzeyine göre bu farklılıkları inceleyebilir. Duygu ile ilgili araştırmalarda karşılaşılan bir diğer güçlük ise, duygunun ölçülmesi ile ilgilidir. Duyguların, öz bildirim dayalı ölçme araçlarının yanı sıra fizyolojik ve yüz ifadeleri gibi birden fazla kanal aracılığıyla ölçülmesi önerilmektedir. Gelecekteki çalışmalar, duygu konusunda farklı veri tiplerini de dahil ederek, elde edilen veri setinin zenginleştirilmesine odaklanabilir. Ayrıca, kullanılan programlama dili ve ortamına göre duygu ve görüşlerin farklılaşması gelecekteki çalışmalarda incelenebilir.

Bilgi işlemsel kimlik ve programlamada yetkilendirme ile ilgili dikkate alınması gereken birkaç sınırlama vardır. İlk olarak, veri seti ağırlıklı olarak öğrencilerin deneyimlerini ve bakış açılarını tam olarak yakalayamayan olumlu yorumlardan oluşmaktaydı. Gelecekteki araştırmalar, olumsuz yorumlar veya zıt bakış açıları dahil olmak üzere daha dengeli bir veri kümesini dahil ederek bu sınırlamayı ele alabilir. Ek olarak, veri seti, önyargıya tabi olabilecek veya sosyal istenirlikten etkilenebilecek öğrencilerin öz bildirim yanıtlarından elde edilmiştir. Metin madenciliği yaklaşımını, görüşmeler veya gözlemler gibi niteliksel yöntemlerle birleştirmek, öğrencilerin bilgi işlemsel kimliği ve programlama yetkinliği hakkında daha kapsamlı bir anlayış sağlayabilir. Ayrıca, bulguların genellenebilirliği bu çalışmanın özel bağlamı ve örnekleme ile sınırlı olduğu göz önünde bulundurulmalıdır.

Kaynaklar

- [1] Nouri, J. L. Manilla, Z. L. and Norén, E. “Development of computational thinking, digital competence and 21st century skills when learning programming in K-9”, *Education Inquiry*, vol. 11, no. 1, 2020, doi: 10.1080/20004508.2019.1627844.
- [2] Angeli, C. and Valanides, N. “Developing young children’s computational thinking with educational robotics: An interaction effect between gender and scaffolding strategy,” *Comput Human Behav*, vol. 105, 2020, doi: 10.1016/j.chb.2019.03.018.
- [3] Kazakoff, E.R., Sullivan, A. and Bers, M. U. “The Effect of a Classroom-Based Intensive Robotics and Programming Workshop on Sequencing Ability in Early Childhood,” *Early Child Educ J*, vol. 41, no. 4, 2013, doi: 10.1007/s10643-012-0554-5.
- [4] Papadakis, S., Kalogiannakis, M. and Zaranis, N. “Developing fundamental programming concepts and computational thinking with ScratchJr in preschool education: A case study,” *International Journal of Mobile Learning and Organisation*, vol. 10, no. 3, 2016, doi: 10.1504/IJMLO.2016.077867.
- [5] Atman Uslu, N., Mumcu, F. and Eğin, F. “Görsel programlama etkinliklerinin ortaokul öğrencilerinin bilgi-işlemsel düşünme becerilerine etkisi,” *Ege Journal of Educational Technologies*, vol. 2, no. 1, 2018.
- [6] Oluk, A. Ö. Korkmaz, Ö. and Oluk, H. A. “Scratch’ın 5. sınıf öğrencilerinin algoritma geliştirme ve bilgi-işlemsel düşünme becerilerine etkisi,” *Turkish Journal of Computer and Mathematics Education (TURCOMAT)*, vol. 9, no. 1, 2018.

- [7] Saritepeci, M. “Developing Computational Thinking Skills of High School Students: Design-Based Learning Activities and Programming Tasks,” *Asia-Pacific Education Researcher*, vol. 29, no. 1, 2020, doi: 10.1007/s40299-019-00480-2.
- [8] Mouza, C. Yang, H., Pan, Y. C., Yilmaz, S., Pollock, L. “Resetting educational technology coursework for pre-service teachers: A computational thinking approach to the development of technological pedagogical content knowledge (TPACK),” *Australasian Journal of Educational Technology*, vol. 33, no. 3, 2017, doi: 10.14742/ajet.3521.
- [9] Romero, M., Lepage, A., and Lille, B. “Computational thinking development through creative programming in higher education,” *International Journal of Educational Technology in Higher Education*, vol. 14, no. 1, 2017, doi: 10.1186/s41239-017-0080-z.
- [10] Fagerlund, J., Vesisenaho, M., and Häkkinen, P. “Fourth grade students’ computational thinking in pair programming with Scratch: A holistic case analysis,” *Int J Child Comput Interact*, vol. 33, 2022, doi: 10.1016/j.ijcci.2022.100511.
- [11] Ou Yang, F. C., Lai, H. M., and Wang, Y. W. “Effect of augmented reality-based virtual educational robotics on programming students’ enjoyment of learning, computational thinking skills, and academic achievement,” *Comput Educ*, vol. 195, 2023, doi: 10.1016/j.compedu.2022.104721.
- [12] Bers, M. U., Govind, M. and Relkin, E. “Coding as Another Language: Computational Thinking, Robotics and Literacy in First and Second Grade,” *Computational Thinking in PreK-5: Empirical Evidence for Integration and Future Directions*, 2022.
- [13] Hsu, T. C., Chang, C., Wu, L. K., Looi, C. K. “Effects of a Pair Programming Educational Robot-Based Approach on Students’ Interdisciplinary Learning of Computational Thinking and Language

- Learning,” *Front Psychol*, vol. 13, 2022, doi: 10.3389/fpsyg.2022.888215.
- [14] Karaahmetoğlu, K., Korkmaz, Ö. “The effect of project-based arduino educational robot applications on students’ computational thinking skills and their perception of basic stem skill levels,” *Participatory Educational Research*, vol. 6, no. 2, 2019, doi: 10.17275/per.19.8.6.2.
- [15] Da Cruz Alves, N., Gresse Von Wangenheim, C., and Hauck, J. C. R. “Approaches to assess computational thinking competences based on code analysis in K-12 education: A systematic mapping study,” *Informatics in Education*, vol. 18, no. 1, 2019, doi: 10.15388/infedu.2019.02.
- [16] Román-González, M., Moreno-León, J., and Robles, G. “Combining Assessment Tools for a Comprehensive Evaluation of Computational Thinking Interventions,” in *Computational Thinking Education*, 2019. doi: 10.1007/978-981-13-6528-7_6.
- [17] Brennan, K. and Resnick, M. “New frameworks for studying and assessing the development of computational thinking,” *Annual American Educational Research Association meeting, Vancouver, BC, Canada*, 2012.
- [18] Kong, S.-C. “A framework of curriculum design for computational thinking development in K-12 education,” *Journal of Computers in Education*, vol. 3, no. 4, 2016, doi: 10.1007/s40692-016-0076-z.
- [19] Angeli, C. *et al.*, “A K-6 computational thinking curriculum framework: Implications for teacher knowledge,” *Educational Technology and Society*, vol. 19, no. 3, 2016.
- [20] Ioannidou, A., Bennett, V., Repenning, A., Koh, K. H., and Basawapatna, A. “Computational Thinking Patterns,” *Online Submission*, vol. 2, 2011.

- [21] Tikva, C., and Tambouris, E. “Mapping computational thinking through programming in K-12 education: A conceptual model based on a systematic literature Review,” *Comput Educ*, vol. 162, 2021, doi: 10.1016/j.compedu.2020.104083.
- [22] Ferreira-Mello, R., André, M., Pinheiro, A., Costa, E., and Romero, C. “Text mining in education,” *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, vol. 9, no. 6. 2019. doi: 10.1002/widm.1332.
- [23] Umar, M., Ahmad, N. B., and Zainal, A. “Sentiment Analysis of Student’s Opinion on Programming Assessment: Evaluation of Naïve Bayes over Support Vector Machines,” *International Journal of Innovative Computing*, vol. 10, no. 2, 2020, doi: 10.11113/ijic.v10n2.278.
- [24] Kumar, L., and Bhatia, P. K. “Text Mining: Concepts, Process, and Applications,” *Journal of Global Research in Computer Science*, vol. 4, no. 3, 2013.
- [25] Hearst, M. *What is text mining*. . US Berkeley, 2003.
- [26] Demir, F. “The effect of different usage of the educational programming language in programming education on the programming anxiety and achievement,” *Educ Inf Technol (Dordr)*, vol. 27, no. 3, 2022, doi: 10.1007/s10639-021-10750-6.
- [27] Lindberg, R. S. N., Laine, T. H., and Haaranen, L. “Gamifying programming education in K-12: A review of programming curricula in seven countries and programming games,” *British Journal of Educational Technology*, 2018, doi: 10.1111/bjet.12685.
- [28] Angeli, C. and Giannakos, M. “Computational thinking education: Issues and challenges,” *Computers in Human Behavior*, vol. 105. 2020. doi: 10.1016/j.chb.2019.106185.

- [29] Wing, J. M. “Computational thinking,” *Commun ACM*, vol. 49, no. 3, pp. 33–35, 2006.
- [30] Shute, V. J., Sun, C., and Asbell-Clarke, J. “Demystifying computational thinking,” *Educational Research Review*, vol. 22, 2017. doi: 10.1016/j.edurev.2017.09.003.
- [31] Cetin, I., and Dubinsky, E. “Reflective abstraction in computational thinking,” *Journal of Mathematical Behavior*, vol. 47, 2017, doi: 10.1016/j.jmathb.2017.06.004.
- [32] Cabanac, M. “What is emotion?,” *Behavioural Processes*, vol. 60, no. 2, 2002, doi: 10.1016/S0376-6357(02)00078-5.
- [33] Mulligan, K., and Scherer, K. R. “Toward a working definition of emotion,” *Emotion Review*, vol. 4, no. 4, 2012. doi: 10.1177/1754073912445818.
- [34] Shott, S. “A Social Interactional Theory of Emotions. Theodore D. Kemper,” *American Journal of Sociology*, vol. 86, no. 4, 1981, doi: 10.1086/227338.
- [35] Barbour, R. F. “Attachment and Loss. Vol. 1. Attachment. By John Bowlby. London: The Hogarth Press and Institute of Psycho-Analysis. 1969. Pp. 428. Price 63s.,” *The British Journal of Psychiatry*, vol. 116, no. 530, pp. 102–103, 1970.
- [36] Eliot, J. A. R., and Hirumi, A. “Emotion theory in education research practice: an interdisciplinary critical literature review,” *Educational Technology Research and Development*, vol. 67, no. 5, 2019, doi: 10.1007/s11423-018-09642-3.
- [37] Tracy, J. L. and Randles, D. “Four models of basic emotions: A review of Ekman and Cordaro, Izard, Levenson, and Panksepp and Watt,” *Emotion Review*, vol. 3, no. 4, 2011. doi: 10.1177/1754073911410747.

- [38] Sander, D., Grandjean, D., and Scherer, K. R. "A systems approach to appraisal mechanisms in emotion," *Neural Networks*, vol. 18, no. 4, 2005, doi: 10.1016/j.neunet.2005.03.001.
- [39] Pekrun, R. and Stephens, E. J. "Achievement Emotions: A Control-Value Approach," *Soc Personal Psychol Compass*, vol. 4, no. 4, 2010, doi: 10.1111/j.1751-9004.2010.00259.x.
- [40] Pekrun, R. "The control-value theory of achievement emotions: Assumptions, corollaries, and implications for educational research and practice," *Educ Psychol Rev*, vol. 18, no. 4, 2006, doi: 10.1007/s10648-006-9029-9.
- [41] Pekrun, R., Goetz, T., Titz, W., and Perry, R. P. "Academic emotions in students' self-regulated learning and achievement: A program of qualitative and quantitative research," *Educational Psychologist*, vol. 37, no. 2. 2002. doi: 10.1207/S15326985EP3702_4.
- [42] Kong, S. C. and Lai, M. "Computational identity and programming empowerment of students in computational thinking development," *British Journal of Educational Technology*, vol. 53, no. 3, 2022, doi: 10.1111/bjet.13175.
- [43] Brousseau, E., and Sherman, M. "Position: The Role of Blocks Programming in Forming Computational Identity," in *Proceedings - 2019 IEEE Blocks and Beyond Workshop, B and B 2019*, 2019. doi: 10.1109/BB48857.2019.8941219.
- [44] Kong, S. C. and Wang, Y. Q. "Formation of computational identity through computational thinking perspectives development in programming learning: A mediation analysis among primary school students," *Comput Human Behav*, vol. 106, 2020, doi: 10.1016/j.chb.2019.106230.
- [45] Capobianco, B. M., French, B. F. and Diefes-Dux, H. A. "Engineering identity development among pre-adolescent learners," *Journal of*

- Engineering Education*, vol. 101, no. 4, 2012, doi: 10.1002/j.2168-9830.2012.tb01125.x.
- [46] Sfard, A. and Prusak, A. “Telling Identities: In Search of an Analytic Tool for Investigating Learning as a Culturally Shaped Activity,” *Educational Researcher*, vol. 34, no. 4, 2005, doi: 10.3102/0013189X034004014.
- [47] Tissenbaum, M., Sheldon, J., and Abelson, H. “Viewpoint from computational thinking to computational action,” *Communications of the ACM*, vol. 62, no. 3. 2019. doi: 10.1145/3265747.
- [48] Page, N., and Czuba, C. E. “Empowerment: What is it?,” *Journal of Extension*, vol. 37, no. 5. 1999.
- [49] Houser, M. L., and Frymier, A. B. “The role of student characteristics and teacher behaviors in students’ learner empowerment,” *Commun Educ*, vol. 58, no. 1, 2009, doi: 10.1080/03634520802237383.
- [50] Kong, S. C., Chiu, M. M., and Lai, M. “A study of primary school students’ interest, collaboration attitude, and programming empowerment in computational thinking education,” *Comput Educ*, vol. 127, 2018, doi: 10.1016/j.compedu.2018.08.026.
- [51] Wankhade, M., Rao, A. C. S., and Kulkarni, C. “A survey on sentiment analysis methods, applications, and challenges,” *Artif Intell Rev*, vol. 55, no. 7, 2022, doi: 10.1007/s10462-022-10144-1.
- [52] Grimalt-Álvaro, C., and Usart, M. “Sentiment analysis for formative assessment in higher education: a systematic literature review,” *J Comput High Educ*, pp. 1–36, 2023.
- [53] Sangeetha, K., and Prabha, D. “Sentiment analysis of student feedback using multi-head attention fusion model of word and context embedding for LSTM,” *J Ambient Intell Humaniz Comput*, vol. 12, pp. 4117–4126, 2021.

- [54] Onan, A. "Mining opinions from instructor evaluation reviews: A deep learning approach," *Computer Applications in Engineering Education*, vol. 28, no. 1, 2020, doi: 10.1002/cae.22179.
- [55] Lai, R. P. Y. "Teachers' Ontological Perspectives of Computational Thinking and Assessment: A Text Mining Approach," *Journal of Educational Computing Research*, vol. 60, no. 3, 2022, doi: 10.1177/07356331211043547.
- [56] Bringula, R., Ulfa, S. A. I. D. A., Miranda, J. P. P., and Atienza, F. A. L. "Text mining analysis on students' expectations and anxieties towards data analytics course," *Cogent Eng*, vol. 9, no. 1, 2022, doi: 10.1080/23311916.2022.2127469.
- [57] Onan, A. "Sentiment analysis on massive open online course evaluations: A text mining and deep learning approach," *Computer Applications in Engineering Education*, vol. 29, no. 3, 2021, doi: 10.1002/cae.22253.
- [58] Zhou, J., and Ye, J. M. "Sentiment analysis in education research: a review of journal publications," *Interactive Learning Environments*. 2020. doi: 10.1080/10494820.2020.1826985.
- [59] Atman Uslu, N. "How do computational thinking self-efficacy and performance differ according to secondary school students' profiles? The role of computational identity, academic resilience, and gender," *Educ Inf Technol (Dordr)*, 2022, doi: 10.1007/s10639-022-11425-6.
- [60] Kumar, S., Kar, A. K., and Ilavarasan, P. V. "Applications of text mining in services management: A systematic literature review," *International Journal of Information Management Data Insights*, vol. 1, no. 1. 2021. doi: 10.1016/j.jjime.2021.100008.
- [61] Dang, S., and Ahmad, P. H. "Text Mining: Techniques and its Application," *IJETI International Journal of Engineering & Technology Innovations*, vol. 1, no. 4, 2014.

- [62] Abbe, A., Grouin, C., Zweigenbaum, P., and Falissard, B. "Text mining applications in psychiatry: A systematic literature review," *Int J Methods Psychiatr Res*, vol. 25, no. 2, 2016, doi: 10.1002/mpr.1481.
- [63] Gupta, A., Dengre, V., Kheruwala, H. A., and Shah, M. "Comprehensive review of text-mining applications in finance," *Financial Innovation*, vol. 6, no. 1. 2020. doi: 10.1186/s40854-020-00205-1.
- [64] Gupta, V., and Lehal, G. S. "A Survey of Text Mining Techniques and Applications - Volume 1, No. 1, August 2009 - JETWI," *Journal of Emerging Technologies in Web Intelligence*, vol. 1, no. 1, 2009.
- [65] Khadjeh Nassirtoussi, A., Aghabozorgi, S., Ying Wah, T., and Ngo, D. C. L. "Text mining for market prediction: A systematic review," *Expert Systems with Applications*, vol. 41, no. 16. 2014. doi: 10.1016/j.eswa.2014.06.009.
- [66] Hickman, L., Thapa, S., Tay, L., Cao, M., and Srinivasan, P. "Text Preprocessing for Text Mining in Organizational Research: Review and Recommendations," *Organ Res Methods*, vol. 25, no. 1, 2022, doi: 10.1177/1094428120971683.
- [67] Kannan, S. *et al.*, "Preprocessing techniques for text mining," *International Journal of Computer Science & Communication Networks*, vol. 5, no. 1, pp. 7–16, 2014.
- [68] Gharatkar, S., Ingle, A., Naik, T., and Save, A. "Review preprocessing using data cleaning and stemming technique," in *Proceedings of 2017 International Conference on Innovations in Information, Embedded and Communication Systems, ICIIECS 2017*, 2018. doi: 10.1109/ICIIECS.2017.8276011.
- [69] Kowsari, K., Meimandi, K. J., Heidarysafa, M., Mendu, S., Barnes, L. and Brown, D. "Text classification algorithms: A survey," *Information (Switzerland)*, vol. 10, no. 4. 2019. doi: 10.3390/info10040150.

- [70] Balakrishnan V., and Ethel, L.-Y. “Stemming and Lemmatization: A Comparison of Retrieval Performances,” *Lecture Notes on Software Engineering*, vol. 2, no. 3, 2014, doi: 10.7763/Inse.2014.v2.134.
- [71] Khyani, D., Siddhartha B.S, Niveditha, N.M, and Divya, B.M, “An Interpretation of Lemmatization and Stemming in Natural Language Processing,” *Journal of University of Shanghai for Science and Technology*, vol. 22, no. 10, 2020.
- [72] Kadhim, A. I. “An Evaluation of Preprocessing Techniques for Text Classification,” *International Journal of Computer Science and Information Security*, vol. 16, no. 6, 2018.
- [73] Singh J., and Gupta, V. “A systematic review of text stemming techniques,” *Artif Intell Rev*, vol. 48, no. 2, 2017, doi: 10.1007/s10462-016-9498-2.
- [74] Hotho, A., Nürnberger, A., and Paaß, G. “A Brief Survey of Text Mining,” *Journal for Language Technology and Computational Linguistics*, vol. 20, no. 1, 2005, doi: 10.21248/jlcl.20.2005.68.
- [75] Asudani, D. S., Nagwani, N. K., and Singh, P. “Impact of word embedding models on text analytics in deep learning environment: a review,” *Artif Intell Rev*, 2023, doi: 10.1007/s10462-023-10419-1.
- [76] Zhang, Y., Jin, R., and Zhou, Z. H. “Understanding bag-of-words model: A statistical framework,” *International Journal of Machine Learning and Cybernetics*, vol. 1, no. 1–4, 2010, doi: 10.1007/s13042-010-0001-0.
- [77] Kern M. L. *et al.*, “Gaining insights from social media language: Methodologies and challenges,” *Psychol Methods*, vol. 21, no. 4, 2016, doi: 10.1037/met0000091.
- [78] Christian, H., Agus, M. P., and Suhartono, D. “Single Document Automatic Text Summarization using Term Frequency-Inverse Document Frequency (TF-IDF),” *ComTech: Computer, Mathematics*

- and Engineering Applications*, vol. 7, no. 4, 2016, doi: 10.21512/comtech.v7i4.3746.
- [79] Naseem, U., Razzak, I., Khan, S. K., and Prasad, M. “A Comprehensive Survey on Word Representation Models: From Classical to State-of-the-Art Word Representation Language Models,” *ACM Transactions on Asian and Low-Resource Language Information Processing*, vol. 20, no. 5, 2021, doi: 10.1145/3434237.
- [80] Safie, W. N. H. W., Sjarif, N. N. A., Azmi, N. F. M., Yuhaniz, S. S., Yusof, R. C. M., and Yaacob, S. “SMS spam classification using Vector Space Model and Artificial Neural Network,” *International Journal of Advances in Soft Computing and its Applications*, vol. 10, no. 3, 2018.
- [81] Huang, E. H., Socher, R., Manning, C. D., and Ng, A. Y. “Improving word representations via global context and multiplexed prototypes,” in *50th Annual Meeting of the Association for Computational Linguistics, ACL 2012 - Proceedings of the Conference*, 2012.
- [82] Wang, Y., Liu, Z., and Sun, M. “Incorporating linguistic knowledge for learning distributed word representations,” *PLoS One*, vol. 10, no. 4, 2015, doi: 10.1371/journal.pone.0118437.
- [83] Jiang, Z., Li, L., and Huang, D. “An Unsupervised Graph Based Continuous Word Representation Method for Biomedical Text Mining,” *IEEE/ACM Trans Comput Biol Bioinform*, vol. 13, no. 4, 2016, doi: 10.1109/TCBB.2015.2478467.
- [84] Sarzynska-Wawer, J. *et al.*, “Detecting formal thought disorder by deep contextualized word representations,” *Psychiatry Res*, vol. 304, 2021, doi: 10.1016/j.psychres.2021.114135.
- [85] Niraula, N. B., Gautam, D., Banjade, R., Maharjan, N., and Rus, V. “Combining word representations for measuring word relatedness and similarity,” in *Proceedings of the 28th International Florida Artificial Intelligence Research Society Conference, FLAIRS 2015*, 2015.

- [86] Pavlinek, M., and Podgorelec, V. "Text classification method based on self-training and LDA topic models," *Expert Syst Appl*, vol. 80, 2017, doi: 10.1016/j.eswa.2017.03.020.
- [87] Rong, X. "word2vec parameter learning explained," *arXiv preprint arXiv:1411.2738*, 2014.
- [88] Mikolov, T., Chen, K., Corrado, G. and Dean, J. "Efficient estimation of word representations in vector space," *arXiv preprint arXiv:1301.3781*, 2013.
- [89] Barrientos, G. M., Alaiz-Rodríguez, R., González-Castro V., and Parnell, A. C. "Machine learning techniques for the detection of inappropriate erotic content in text," *International Journal of Computational Intelligence Systems*, vol. 13, no. 1, 2020, doi: 10.2991/ijcis.d.200519.003.
- [90] Yu, L. C., Wang, J., Robert Lai K., and Zhang, X. "Refining Word Embeddings Using Intensity Scores for Sentiment Analysis," *IEEE/ACM Trans Audio Speech Lang Process*, vol. 26, no. 3, 2018, doi: 10.1109/TASLP.2017.2788182.
- [91] Zaidi, S. F. A., Awan, F. M., Lee, M., Woo, H., and Lee, C. G. "Applying Convolutional Neural Networks with Different Word Representation Techniques to Recommend Bug Fixers," *IEEE Access*, vol. 8, 2020, doi: 10.1109/ACCESS.2020.3040065.
- [92] Phang, J., Févry, T., and Bowman, S. R. "Sentence encoders on stilts: Supplementary training on intermediate labeled-data tasks," *arXiv preprint arXiv:1811.01088*, 2018.
- [93] Getzen, E., Ruan, Y., Ungar, L., and Long, Q. "Mining for Health: A Comparison of Word Embedding Methods for Analysis of EHRs Data," *medRxiv*, 2022.

- [94] Wang, S., Zhou, W., and Jiang, C. “A survey of word embeddings based on deep learning,” *Computing*, vol. 102, no. 3, 2020, doi: 10.1007/s00607-019-00768-7.
- [95] Dhyani, B. “Transfer Learning in Natural Language Processing: A Survey,” *Mathematical Statistician and Engineering Applications*, vol. 70, no. 1, pp. 303–311, 2021.
- [96] Jiao Q., and Zhang, S. “A Brief Survey of Word Embedding and Its Recent Development,” in *IAEAC 2021 - IEEE 5th Advanced Information Technology, Electronic and Automation Control Conference*, 2021. doi: 10.1109/IAEAC50856.2021.9390956.
- [97] Liu, B. “*Sentiment analysis: Mining opinions, sentiments, and emotions.*” 2015. doi: 10.1017/CBO9781139084789.
- [98] Akaichi, J., Dhouioui, Z., and Pérez, M. J. L.-H. “Text mining facebook status updates for sentiment classification,” in *2013 17th International conference on system theory, control and computing (ICSTCC)*, IEEE, 2013, pp. 640–645.
- [99] Serrano-Guerrero, J., Olivas, J. A., Romero, F. P. and Herrera-Viedma, E. “Sentiment analysis: A review and comparative analysis of web services,” *Inf Sci (N Y)*, vol. 311, 2015, doi: 10.1016/j.ins.2015.03.040.
- [100] Birjali, M., Kasri, M., and Beni-Hssane, A. “A comprehensive survey on sentiment analysis: Approaches, challenges and trends,” *Knowl Based Syst*, vol. 226, 2021, doi: 10.1016/j.knosys.2021.107134.
- [101] Ligthart, A., Catal, C., and Tekinerdogan, B. “Systematic reviews in sentiment analysis: a tertiary study,” *Artif Intell Rev*, vol. 54, no. 7, 2021, doi: 10.1007/s10462-021-09973-3.
- [102] Sun, S., Luo, C., and Chen, J. “A review of natural language processing techniques for opinion mining systems,” *Information Fusion*, vol. 36, 2017, doi: 10.1016/j.inffus.2016.10.004.

- [103] Mehta, P. and Pandya, S. “A review on sentiment analysis methodologies, practices and applications,” *International Journal of Scientific and Technology Research*, vol. 9, no. 2. 2020.
- [104] Acheampong, F. A., Nunoo-Mensah, H., and Chen, W. “Transformer models for text-based emotion detection: a review of BERT-based approaches,” *Artif Intell Rev*, vol. 54, no. 8, 2021, doi: 10.1007/s10462-021-09958-2.
- [105] Onan, A., Korukoğlu, S., and Bulut, H. “Ensemble of keyword extraction methods and classifiers in text classification,” *Expert Syst Appl*, vol. 57, pp. 232–247, 2016.
- [106] Janikow, C. Z. “Fuzzy decision trees: Issues and methods,” *IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics*, vol. 28, no. 1, 1998, doi: 10.1109/3477.658573.
- [107] Kaparathi, S., and Bumblauskas, D. “Designing predictive maintenance systems using decision tree-based machine learning techniques,” *International Journal of Quality and Reliability Management*, vol. 37, no. 4, 2020, doi: 10.1108/IJQRM-04-2019-0131.
- [108] Ray, S. “A Quick Review of Machine Learning Algorithms,” in *Proceedings of the International Conference on Machine Learning, Big Data, Cloud and Parallel Computing: Trends, Perspectives and Prospects, COMITCon 2019*, 2019. doi: 10.1109/COMITCon.2019.8862451.
- [109] Bansal, M., Goyal, A., and Choudhary, A. “A comparative analysis of K-Nearest Neighbor, Genetic, Support Vector Machine, Decision Tree, and Long Short Term Memory algorithms in machine learning,” *Decision Analytics Journal*, vol. 3, 2022, doi: 10.1016/j.dajour.2022.100071.
- [110] Hercus, C., and Hudaib, A. R. “Delirium misdiagnosis risk in psychiatry: A machine learning-logistic regression predictive algorithm,” *BMC Health Serv Res*, vol. 20, no. 1, 2020, doi: 10.1186/s12913-020-5005-1.

- [111] Sarker, I. H. “Machine Learning: Algorithms, Real-World Applications and Research Directions,” *SN Computer Science*, vol. 2, no. 3. 2021. doi: 10.1007/s42979-021-00592-x.
- [112] Uddin, S., Khan, A., Hossain, M. E., and Moni, M. A. “Comparing different supervised machine learning algorithms for disease prediction,” *BMC Med Inform Decis Mak*, vol. 19, no. 1, 2019, doi: 10.1186/s12911-019-1004-8.
- [113] Singh, A., Thakur, N., and Sharma, A. “A review of supervised machine learning algorithms,” in *2016 3rd International Conference on Computing for Sustainable Global Development (INDIACom)*, Ieee, 2016, pp. 1310–1315.
- [114] Bikia, V., Rovas, G., Pagoulatou, S., and Stergiopoulos, N. “Determination of Aortic Characteristic Impedance and Total Arterial Compliance From Regional Pulse Wave Velocities Using Machine Learning: An in-silico Study,” *Front Bioeng Biotechnol*, vol. 9, 2021, doi: 10.3389/fbioe.2021.649866.
- [115] Zaib, M., Sheng, Q. Z., and Emma Zhang, W. “A short survey of pre-trained language models for conversational ai-a new age in nlp,” in *Proceedings of the Australasian computer science week multiconference*, 2020, pp. 1–4.
- [116] Schweter, S. “BERTurk-BERT models for Turkish, April 2020,” *URL <https://doi.org/10.5281/zenodo>*, vol. 3770924, 2020.
- [117] Bozuyula, M. “Advanced Turkish fake news prediction with bidirectional encoder representations from transformers,” *Konya Mühendislik Bilimleri Dergisi*, vol. 10, no. 3, pp. 750–761, 2022.

Ekler

Ek A

Tezden Üretilmiş Yayınlar

Makaleler

1. Atman Uslu, N., Onan, A. Investigating computational identity and empowerment of the students studying programming: A text mining study. 2023, *Necmettin Erbakan University Journal of Faculty of Education*,5(1), 29-45.

Özgeçmiş

Adı Soyadı: Nilüfer ATMAN USLU

Eğitim:

Doktora (2010-2014) Hacettepe Üniversitesi, Eğitim Bilimleri Enstitüsü, Bilgisayar ve Öğretim Teknolojileri Eğitimi

Yüksek Lisans (2006-2009) Ege Üniversitesi, Bilgisayar ve Öğretim Teknolojileri Eğitimi

Lisans (2001-2006) Ege Üniversitesi, Bilgisayar Ve Öğretim Teknolojileri Öğretmenliği Pr.

İş Deneyimi:

2016- devam ediyor Manisa Celal Bayar Üniversitesi Eğitim Fakültesi – Öğretim üyesi

Makaleler:

1. [SSCI] Yıldız Durak, H., & Atman Uslu, N. (2023). Group regulation guidance through agile learning strategies: Empowering co-regulation, transactive memory, group cohesion, atmosphere, and participation. *Educational Technology Research and Development*, <https://doi.org/10.1007/s11423-023-10237-w>
2. [SSCI] Yıldız Durak, H., & Atman Uslu, N. (2023). The role of flexible thinking and academic achievement emotions in predicting goal-setting, time management, and self-evaluation in online learning: A multi-group analysis. *Interactive Learning Environments*, <https://doi.org/10.1080/10494820.2023.2214180>

3. [SSCI] Atman Uslu, N., Yavuz, G. Ö., & Koçak Usluel, Y. (2022). A systematic review study on educational robotics and robots. *Interactive Learning Environments*, 1-25. <https://doi.org/10.1080/10494820.2021.2023890>
4. [SSCI] Atman Uslu, N., & Yıldız Durak, H. (2022). Understanding self-regulation, achievement emotions, and mindset of undergraduates in emergency remote teaching: a latent profile analysis. *Interactive Learning Environments*, 1-20. <https://doi.org/10.1080/10494820.2022.2129391>
5. [SSCI] Atman Uslu, N. (2022). How do computational thinking self-efficacy and performance differ according to secondary school students' profiles? The role of computational identity, academic resilience, and gender. *Education and Information Technologies. Education and Information Technologies*. <https://doi.org/10.1007/s10639-022-11425-6>
6. [SSCI] Yıldız Durak, H., & Atman Uslu, N. (2022). Investigating the effects of SOLO taxonomy with reflective practice on university students' meta-cognitive strategies, problem-solving, cognitive flexibility, spatial anxiety: an embedded mixed-method study on 3D game development. *Interactive Learning Environments*, 1-23. <https://doi.org/10.1080/10494820.2022.2067187>
7. [SSCI] Yıldız Durak, H., Atman Uslu, N., Canbazoğlu-Bilici, S., Güler, B. (2022). Examining the Predictors of TPACK for Integrated STEM: Science teaching self-efficacy, computational thinking, and design thinking. *Education and Information Technologies*.
8. [SSCI] Gökçearsan, Ş., Yildiz Durak, H., & Atman Uslu, N. (2022). Acceptance of educational use of the Internet of Things (IoT) in the context of individual innovativeness and ICT competency of pre-service teachers. *Interactive Learning Environments*, 1-15. <https://doi.org/10.1080/10494820.2022.2091612>
9. [SSCI] Saritepeci, M., Yildiz Durak, H., & Atman Uslu, N. (2022). A Latent Profile Analysis for the Study of Multiple Screen Addiction, Mobile Social Gaming Addiction, General Mattering, and Family Sense of Belonging in University Students. *International Journal of Mental Health and Addiction*, 1-22. <https://doi.org/10.1007/s11469-022-00816-y>

10. [SSCI] Vezne, R., Yildiz Durak, H., & Atman Uslu, N. (2022). Online learning in higher education: Examining the predictors of students' online engagement. *Education and Information Technologies*, 1-25. <https://doi.org/10.1007/s10639-022-11171-9>
11. [SSCI] Mumcu, F., Atman Uslu, N., & Yıldız, B. (2022). Teacher development in integrated STEM education: Design of lesson plans through the lens of computational thinking. *Education and Information Technologies*, 1-32. <https://doi.org/10.1007/s10639-022-11342-8>
12. [SSCI] Atman Uslu, N., & Durak, H. Y. (2022). Parental awareness and supervision to prevent cyberbullying: Scale adaptation and a review in terms of demographic variables. *Children and Youth Services Review*, 133, 106329.
13. [SSCI] Atman Uslu, N., & Durak, H. Y. (2022). The relationships between university students' information-seeking strategies, social-media specific epistemological beliefs, information literacy, and personality traits. *Library & Information Science Research*, 44(2), 101155.
14. [SSCI] Ustunluoglu, E., Mumcu, F., Atman Uslu, N., & Askar, P. (2022). A case study on the usage of lecture capture: perceptions of students, faculty members and administrators. *Journal of Computing in Higher Education*, 34(2), 343-370.
15. [SCI] Atman Uslu, N., Yildiz Durak, H., & AY, G. M. Comparing reflective and supportive scaffolding in 3D computer-aided design course: Engineering students' metacognitive strategies, spatial ability self-efficacy, and spatial anxiety. *Computer Applications in Engineering Education*, 30(5).
16. [SSCI] Vezne, R. Durak, H.Y., & Atman Uslu, N. (2022). Modeling of Variables Related to Parents' Awareness in Cyberbullying Prevention. *Current Psychology*. <https://doi.org/10.1007/s12144-022-03837-x>
17. [SSCI] Atman Uslu, N., & Usluel, Y. K. (2019). Predicting technology integration based on a conceptual framework for ICT use in education. *Technology, Pedagogy and Education*, 28(5), 517-531.
18. [SSCI] Atman Uslu, N., & Durak, H. Y. (2022). Predicting learner autonomy in collaborative learning: The role of group metacognition and motivational regulation strategies. *Learning and Motivation*, 78, 101804.

19. [SCI] Çiloğlugil, B., Balci, B., & Atman Uslu, N. (2020). Acquisition of teamwork competence in a hardware course: perceptions and co-regulation of computer engineering students. *The International journal of engineering education*, 36(1), 388-398.
20. [Scopus] Haşlamam, T., Atman Uslu, N., & Mumcu, F. (2022). Development and In-Depth Investigation of Pre-Service Teachers' Digital Competencies Based on DigCompEdu: A Case Study. *Quality and Quantity*.
21. [ERIC, ESCI] Tankiz, E., & Atman Uslu, N. (2022). Preparing Pre-Service Teachers for Computational Thinking Skills and its Teaching: A Convergent Mixed-Method Study. *Technology, Knowledge and Learning*, 1-23. <https://doi.org/10.1007/s10758-022-09593-y>.
22. [ERIC] Uslu, A., & Atman Uslu, N. (2021). Improving Primary School Students' Creative Writing and Social-Emotional Learning Skills through Collaborative Digital Storytelling. *Acta Educationis Generalis*, 11(2), 1-18.
23. [H.W. Wilson] Atman Uslu, N. (2022). Exploring Pre-service Teachers' Perception Regarding Factors in Technology Integration with Q Methodology. *Bartın University Journal of Faculty of Education*, 11(3), 543-558.
24. [ERIC] Mumcu, F., Atman Uslu, N., & Yildiz, B. (2022). Investigating Teachers' Expectations from a Professional Development Program for Integrated STEM Education. *Journal of Pedagogical Research*, 6(2), 44-60.
25. [ERIC] Mumcu, F., Atman Uslu, N., Özdiñç, F., & Yıldız, B. (2022). Exploring teacher development courses in the lens of integrated STEM education: A holistic multiple case study. *International Journal of Contemporary Educational Research*, 9(3), 476-491.
26. [TR DİZİN] Özbek, Z. T., & Atman Uslu, N. (2021). Technology integration into science education: Systematic review and mapping of postgraduate theses in Turkey. *Başkent University Journal of Education*, 8(2), 427-440.
27. [TR DİZİN] Bakır, E., Atman Uslu, N., & Usluel, Y. (2021). Başarımla İlgili Duygular Anketinin Öğretmen Adayları için Geçerleme Çalışması ve Kısa Formu. *Dokuz Eylül Üniversitesi Buca Eğitim Fakültesi Dergisi*, 52, 412-438.
28. [TR DİZİN] Öztüre, G., Fidan, A., Bakır, E., Atman Uslu, N., & Usluel, Y. (2021). Eğitsel Bağlamda Teknoloji Ve Duygu Çalışmaları Üzerine Bir

- Sistemik Haritalama Çalışması: Tanımlar, Kuramlar Ve Gelecekteki Yönelimler. *Eğitim Teknolojisi Kuram ve Uygulama*, 11(1), 20-47.
29. [TR DİZİN] Atman Uslu, N., Mumcu, F., & Üstünlüoğlu, E. (2020). Yükseköğretimde Ders Yakalama Sisteminin Kullanımının Öğrenci Açısından İncelenmesi. *Eğitim Teknolojisi Kuram ve Uygulama*, 10(2), 590-607.
30. [TR DİZİN] Atman Uslu, N., & Usluel, Y. K. (2018). Bilgi ve İletişim Teknolojilerinin Öğrenme-Öğretme Sürecine Entegrasyonunu Yordayabilecek Yapılara İlişkin Geçerlik ve Güvenirlik Çalışması. *Manisa Celal Bayar Üniversitesi Sosyal Bilimler Dergisi*, 16(1), 45-62.
31. [TR DİZİN] Avcı, Ü., Usluel, Y. K., Kurtoğlu, M., & Atman Uslu, N. (2013). Yeniliklerin benimsenmesi sürecinde rol oynayan değişkenlerin betimsel tarama yöntemiyle incelenmesi. *Pamukkale Üniversitesi Eğitim Fakültesi Dergisi*, 33, 53-71.
32. [TR DİZİN] Usluel, Y. K., & Atman Uslu, N. (2013). Teachers' Perceptions Regarding Usefulness of Technology as an Innovation. *İlköğretim Online*, 12(1).
33. Atman Uslu, N., & Yıldız Durak, H. (2022). Turkish Adaptation of a Scale to Measure Three Modes of Motivational Regulation Strategies: Self-, Co-, and Socially Shared Regulation of Motivation for Collaborative Activity. *Research on Education and Psychology*, 6(Special Issue), 1-11.
34. Güngör, H., & Atman Uslu, N. (2022). Öğretmenlerin Teknoloji ile Öğretime Yönelik Duygularının Ölçülmesi: Bir Geçerlik ve Güvenirlik Çalışması. *Öğretim Teknolojisi ve Hayat Boyu Öğrenme Dergisi*, 3(2), 115-128.
35. Yıldız Durak, H., & Atman Uslu, N. (2021). Turkish adaptation of the group metacognitive scale: Metacognition in online collaborative group activity. *Research on Education and Psychology*, 5(2), 288-301.
36. Atman Uslu, N. (2021). Öğretmen Adaylarının Teknoloji Entegrasyonuna İlişkin Metaforik Algıları. *Öğretim Teknolojisi ve Hayat Boyu Öğrenme Dergisi*, 2(2), 234-247.
37. Atman Uslu, N., Mumcu, F., Eğin, F. (2018). Görsel programlama etkinliklerinin ortaokul öğrencilerinin bilgi-işlemsel düşünme becerilerine etkisi. *Ege Eğitim Teknolojileri Dergisi*, 2(1), 19-31.

ULUSLARARASI KİTAP BÖLÜMLERİ

1. Atman Uslu, N., Mumcu, F. (2021). Hayat Boyu Öğrenmede Açık ve Uzaktan Eğitim. Dijital Çağda Hayat Boyu Öğrenme, (Ed. Mustafa SARITEPECİ, Hatice YILDIZ DURAK), Pegem Yayınevi, Ankara
2. Atman Uslu, N., Mumcu, F. (2020). Bilişim Teknolojileri Öğretmenlerinin Programlama Eğitimine İlişkin Algıladıkları Yeterlikleri ve Mesleki Gelişim Beklentileri Üzerine Bir İnceleme. Eğitim Teknolojileri Okumaları 2020 (Ed.: Hatice Ferhan Odabaşı, Buket Akkoyunlu, Aytekin İşman) Pegem Yayınevi, Ankara.
3. Mumcu, F., Atman Uslu, N. (2019). Bilgisayar Bilimi Eğitiminde Proje Tabanlı Öğrenmeye Yönelik Ders Tasarımları. Eğitim Teknolojileri Okumaları 2019. (Ed.: Aytekin İşman, Hatice Ferhan Odabaşı, Buket Akkoyunlu) Pegem Akademi, Ankara
4. Atman Uslu, N. (2018). Öğrenme - Öğretme Süreçlerine BİT'in Entegrasyonunda Öğretmen İnançları. Eğitim Teknolojileri Okumaları 2018 (Ed.:Buket Akkoyunlu, Aytekin İşman, Hatice Ferhan Odabaşı) Pegem Afademi, Ankara
5. Atman Uslu, N., Selçuk, G.(2017). Eğitimde Robotik Programlama Öğretiminin Potansiyeli: Sistemik Bir Tarama Çalışması. Sosyo Ekonomik Stratjiler III: Eğitim Bilimleri (Ed.: Akif Köse, Gülenaz Selçuk, Erkan Atalmış), JOPEC Publication, Londra
6. Atman Uslu, N. (2017).A Professional Development Model Designed for ICT Integration. Various Aspects of ICT Integration in Education (Ed.:Yasemin USLUEL), Gazi Kitabevi, Ankara.

ULUSLARARASI BİLDİRİLER

1. Bakır, E. Atman Uslu, N., Öztüre, G., Fidan, A., & Usluel, Y. K. (2021). Should Emotions Be Taken Into Consideration Within Online Learning Environments? A Systematic Review Study. Annual Meeting of the American Educational Research Association (AERA) (2021), Doi: 10.3102/1690243
2. Mumcu, F., & Atman Uslu, N. (2018). Course designs of teachers with project-based learning in teaching computer science. Association for Educational Communications and Technology (AECT) 2018 International Convention. Chicago-USA

3. Mumcu, F., & Atman Uslu, N. (2018). Social media addiction of high school students relating to problematic mobile phone usage and academic procrastination. Association for Educational Communications and Technology (AECT) 2018 International Convention. Chicago-USA
4. Atman Uslu, N., & Usluel, Y. K. (2016). A Proposal for Designing Strategies and Content in a professional development program on ICT integration. 10th International Technology, Education and Development Conference, 778-784., Doi: 10.21125/inted.2016.1184 . Valencia-SPAIN
5. Şimşek, Ö., Atman, N., İnceoğlu, M. M., Arıkan, Y. D. (2010). Diagnosis of learning styles based on active reflective dimension of felder and silverman s learning style model in a learning management system. International Conference on Computational Science and Applications (ICCSA-2010), 2, 544-555. Fukuoka-JAPAN
6. Atman Uslu, N., İnceoğlu, M. M., Aslan, B. G. (2009). Learning styles diagnosis based on learner behaviors in web based learning. International Conference on Computational Science and Applications (ICCSA-2009), 2, 900-909. Suwon-SOUTH KOREA.

ULUSAL BİLDİRİLER

1. Yıldız- Durak, H., Atman Uslu, N. (2021). Grup Üstbiliş Ölçeğinin Türkçeye Uyarlaması: Güvenirlik ve Geçerlik Çalışması. III. Uluslararası Eğitim Araştırmaları ve Öğretmen Eğitimi Kongresi, 184-186. Uşak- TÜRKİYE
2. Atman Uslu, N., Yıldız-Durak, H. (2021). İşbirlikli Etkinliklerde Öz, İşbirlikli ve Sosyal Olarak Paylaşılan Motivasyonun Düzenlenmesinin Ölçülmesi: Bir Ölçek Uyarlama Çalışması. III. Uluslararası Eğitim Araştırmaları ve Öğretmen Eğitimi Kongresi, 181-183. Uşak- TÜRKİYE
3. Atman Uslu, N. (2021). Acil Uzaktan Öğretim Sürecinde Öğretim Elemanları ve Öğretmen Adaylarının Algılarının İncelenmesi: Bir Durum Çalışması. 8. Uluslararası Öğretim Teknolojileri ve Öğretmen Eğitimi Sempozyumu. Trabzon- TÜRKİYE
4. Mumcu, F., Atman Uslu, N., Yıldız, B., Özdiç, F. (2020). Disiplinlerarası yenilikçi derslerin tasarlanması için öğretmenler nasıl desteklenmeli? 3 yıllık öğretmen eğitimi projelerinin karşılaştırılmalı olarak incelenmesi. 2.

- Uluslararası Fen, Matematik, Girişimcilik ve Teknoloji Eğitimi Kongresi (FMGT 2020), 5-6. Online - TÜRKİYE
5. Mumcu, F., Atman Uslu, N., Yıldız, B. (2019). Öğretmenlerin Disiplinlerarası Mesleki Gelişim Çalışmalarından Beklentilerinin İnfomal Öğrenme Açısından İncelenmesi. I. Uluslararası İnfomal Öğrenme Kongresi, 140-141. Nevşehir- TÜRKİYE
 6. Balcı, B., Çiloğlugil, B., Atman Uslu, N. (2019). Enhancing Computer Engineering Student's Learning: Pedagogical Implications for Logic Design Course. 2nd International Instructional Engineering Education Conference, 20-20. İzmir-TÜRKİYE
 7. Atman Uslu, N., Mumcu, F., Üstünlüoğlu, E. (2018). Bir Üniversitede Derslerin Görüntülü ve Sesli Kayıt Altına Alınmasına İlişkin Öğrenci Görüşleri. 6th International Instructional Technologies Teacher Education Symposium. Edirne- TÜRKİYE
 8. Mumcu, F., Atman Uslu, N., Üstünlüoğlu, E. (2018). Derslerin Görüntülü ve Sesli Kayıt Altına Alınmasının Kabulü: Modeller ve Belirleyici Faktörler. 6th International Instructional Technologies Teacher Education Symposium. Edirne - TÜRKİYE
 9. Mumcu, F., Atman Uslu, N., Geriş, A. (2018). Öğretmen Adaylarının Bilgi ve İletişim Teknolojileri Yeterlikleri Ölçeğinin Türkçeye Uyarlama Çalışması. 8. Uluslararası Eğitimde Araştırmalar Kongresi, 72-72. Manisa- TÜRKİYE
 10. Atman Uslu, N., Mumcu, F., Geriş, A. (2018). Bilgi ve İletişim Teknolojileri (BİT) Motivasyonu Envanterinin Türkçeye Uyarlama Çalışması. 8. Uluslararası Eğitimde Araştırmalar Kongresi, 75-75. Manisa- TÜRKİYE
 11. Atman Uslu, N., Selçuk, G. (2017). Eğitimde Robotik programlama Eğitiminin Potansiyeli: Sistemik Bir Tarama Çalışması. II. Uluslararası Stratejik Araştırmalar Kongresi. Antalya- TÜRKİYE
 12. Atman Uslu, N., Selçuk, G. (2017). Öğrenmede Esnek Düşünme Ölçeğini Türkçeye Uyarlama Çalışması.. 1. Uluslararası Sınırsız Eğitim ve Araştırma Sempozyumu, 20-20. Alanya- TÜRKİYE
 13. Usluel, Y. K., Atman Uslu, N. (2016). Öğretmen Adaylarının Yetiştirilmesi Sürecinde Öğretim Üyeleri Perspektifinden BİT Entegrasyonu. Akademik Bilişim. Aydın - TÜRKİYE

14. Atman Uslu, N., Usluel, Y. K. (2015). BİT entegrasyon sürecinde var olan durumun öğretmen perspektifinden değerlendirilmesi Engeller becerileri ve destek. 9th International Computer & Instructional Technologies Symposium (ICITS), 100-106. Afyon- TÜRKİYE
15. Usluel, Y. K., Atman Uslu, N. (2015). Öğretmenlerin BİT kullanımlarının sınıflandırılması üzerine bir çerçeve. Öğretmen Yetiştirme Siyaseti ve Sorunlar Sempozyumu (2015), 186-192.
16. Usluel, Y. K., Ergün, E. Bilgiç, H. G., Atman Uslu, N. (2011). Öğrenme öğretme süreçlerine BİT entegrasyonu ve mesleki gelişim: FATİH projesi örneği. 11th International Educational Technology Conference, 2, 1852-1857. İstanbul- TÜRKİYE
17. Atman, N., Inceoğlu, M. M., Öğretmen, T., Aslan, B. G. (2009). Felder ve Soloman Öğrenme Biçemi Ölçeği Etkin Yansıtıcı ve Görsel Sözel Boyutlarının Geçerlik Güvenirlik Çalışması. The First International Congress of Educational Research. Çanakkale- TÜRKİYE