



Kitlesel Çevrimiçi Ders Platformlarında Yapılan Yorumların Metin Madenciliği Kullanılarak Duygu Analizinin Yapılması

Sentiment Analysis of Comments Made on Massive Online Course Platforms using Text Mining

Ramazan Daşgın^{1*}, Kemal Adem²

¹Aksaray Üniversitesi, Sosyal Bilimler Enstitüsü, Yönetim Bilişim Sistemleri Anabilim Dalı, 68100, Aksaray, TÜRKİYE

²Sivas Bilim ve Teknoloji Üniversitesi, Bilgisayar Mühendisliği, 58000, Sivas, TÜRKİYE

Başyuru/Received: 16/03/2023

Kabul / Accepted: 01/06/2023

Çevrimiçi Basım / Published Online: 30/06/2023

Son Versiyon/Final Version: 30/06/2023

Öz

Çağımızda kolay ulaşılabilen, az maliyetli, zaman mekan kısıtı olmayan şeyler daha çok ilgi görmektedir. Son zamanlarda insanların sahip olduğu olanaklar ve teknolojinin gelişimi de düşünüldüğünde insanların ilgisinde yaşanan bu değişiklik eğitime de yansımıştır. İnsanlar artık istedikleri zaman, istedikleri yerden, kendi seçebilecekleri içeriklere ulaşmak istemektedirler. Bu istekler sonunda Kitleli Açık Çevrimiçi Ders (KAÇD) platformları ortaya çıkmaya başlamıştır. Bu platformlar üzerinde ücretli veya ücretsiz birçok konuda kurslar yer almaktadır. Birçok kişi bu kurslara kayıt olmadan önce, kurslara yapılan yorumlara ve kursa verilen puana göre değerlendirme yapılarak kayıt olmaktadır. Ancak tüm yorumları okuyarak bir kurs hakkında karar vermek kolay olmamaktadır. Bu çalışmada kullanıcıların yorumları okumasına gerek kalmadan kursları olumlu olumsuz olarak değerlendirmesi amacıyla KAÇD platformlarından birisi olan Udemy sitesinde bulunan kurslara yapılan yorumlar kullanılmıştır. Bu yorumlar üzerinden klasik makine öğrenmesi ve derin öğrenme kullanarak kurslar hakkında olumlu olumsuz değerlendirmeleri yapılmıştır. Klasik makine öğrenmelerinden BayesNet, J48, OneR ve DVM algoritmaları ile en başarılı sonuç %91.576 doğruluk sağlayan BayesNet algoritmasından elde edilmiştir. Veri setine Random, GloVe ve Word2Vec kelime gömmeleri uygulandıktan sonra, derin öğrenme modellerinden GRU ve CNN-LSTM hibrit mimarileri uygulanmış ve en başarılı sonuç GloVe Kelime gömmesi kullanıldıktan sonra %95.67 doğruluk oranıyla GRU mimarisinden elde edilmiştir.

Anahtar Kelimeler

“KAÇD, Udemy, Metin Madenciliği, Duygu Analizi, Word2Vec, Glove, GRU”

Abstract

In our age, things that are easily accessible, less costly, and have no time and space restrictions attract more attention. Considering the possibilities that people have recently and the development of technology, this change in people's interest has also been reflected in education. People now want to access content that they can choose from wherever they want, whenever they want. As a result of these requests, Massive Open Online Course (MOOC) platforms began to emerge. There are many paid or free courses on these platforms. Before enrolling in these courses, many people register based on the comments made and the score given to the course. However, it is not easy to decide about a course by reading all the reviews. In this study, comments made on Turkish courses on Udemy, one of the MOOC platforms, were used to evaluate the courses positively and negatively without the need for users to read the comments. On these comments, positive and negative evaluations were made about the courses using classical machine learning and deep learning. With BayesNet, J48, OneR, and SVM algorithms from classical machine learning, the most successful result was obtained from the BayesNet algorithm with an accuracy of 91.576%. After applying Random, GloVe, and Word2Vec word embeddings to the dataset, hybrid architectures of GRU and CNN-LSTM from deep learning models were applied and the most successful result was obtained from GRU architecture with an accuracy of 95.67% after using GloVe word embedding.

Key Words

“MOOC, Udemy, Text Mining, Sentiment Analysis, Word2Vec, Glove, GRU”

1. Giriş

Son yıllarda yazılım teknolojilerindeki gelişmeler ve bu gelişmelere bağılı olarak internete olan erişimin kolaylaşması gibi sebeplerle eğitimin verilme şeklinin de değiştiği görülmektedir. Teknolojideki gelişmelerle beraber bilgisayar ve internete erişim konusunda yaşanan sıkıntıların günden güne azalmasıyla öğretimin mekanı ve zamanlaması konusunda teknolojin esneklik katması kaliteli bir eğitime erişebileceğimizin göstergesidir (Chan, Rajamohan, Gan ve Samsudin, 2021).

2008 yılında popüler olmaya başlayan ve dünya çapında yayılmaya devam eden Kitleli Açık Çevrimiçi Dersler (KAÇD'ler), farklı alanlarda öğrenmeyi destekleyen, bilgilerin farklı yollarla ölçeklenebildiği, ücretsiz çevrimiçi kurslar olarak tanımlanmak ile birlikte birçok farklı tanımları da mevcuttur (İşgör Şimşek, 2015). Her ne kadar başlangıç olarak MIT, Harvard, Stanford gibi dünyaca ünlü üniversitelerin derslerini herkese açık ve ücretsiz sunduğu çevrimiçi bir ortam olarak ortaya çıksa da son zamanlarda farklılaşmaya başlamıştır (Demirci, 2014).

Kayıtlı kişi sayısının gün geçtikçe arttığı, dünyaca ünlü kurumların ücretsiz açık kurslarının yer aldığı Coursera, Edx, MiriadaX, FutureLearn ile beraber birde herkesin kurs yayınlayabildiği ve birçok alanda kurslar barındıran Udemy, Udacity, KhanAcademy gibi daha pek çok KAÇD platformu bulunmaktadır (Onan, 2020). Tüm bu sistemlerde ihtiyacı olan kişiler istedikleri alanda ve ulaşmak istedikleri amaçları doğrultusunda kurslara erişim sağlayarak ücretli-ücretsiz kayıtlarını olarak derslere erişim sağlamaktadırlar.

Çeşitli kurslar veren siteler üzerinden herhangi bir kurs almadan önce hangi kursun istenildiği gibi bir içeriğe sahip olduğu, hangisinin anlatımının, kapsamının kişinin hedefine uygun olduğunu kursu alan kişinin araştırması gerekir. Çünkü uygun olmayan kursu seçmek, zaman ve güven kaybına sebep olabilir, potansiyel ve yeteneklere zarar verebilir. Genellikle kurs hakkında yapılan derecelendirmeler, yorumlar kurs hakkında en iyi fikir aracıdır. Ancak tüm yorumları okuyarak kurs hakkında bir karara varmak zaman alıcı iş olmasına karşın son zamanlarda yaygınlaşan metin madenciliği ve derin öğrenme gibi yeni teknolojilerin sonucunda bu işlem kolaylaşmıştır. Önceki çalışmalar incelendiğinde, bu konuda çok fazla çalışma yapılmadığı özellikle Udemy platformuyla ilgili bu alanda hiç çalışmanın olmadığı görülmüştür. Bu sebeple bir kurs hakkında tüm öğrenci yorumlarını derecelendirmeler de dahil, gözden geçirip o kurs hakkında olumlu- olumsuz gibi bir yargıya hızlı bir şekilde ulaşmamızı sağlayacak bir sistem önermesi ve bu sistemin daha önceden Udemy üzerinden bir örneğinin bulunmaması açılarından çalışmamız önemlidir. Çalışmada klasik makine öğrenmelerinden BayesNet, J48 ve OneR algoritmaları, derin öğrenme modellerinden, Random, GloVe ve Word2Vec kelime gömmeleri kullanıldıktan sonra, GRU ve CNN-LSTM Hibrit Modelleri kullanılarak Udemy üzerindeki kurs yorumlarının olumlu-olumsuz sınıflandırması gerçekleştirilmiştir.

1.1 İlgili Çalışmalar

KAÇD platformlarındaki yorumların olumlu-olumsuz sınıflandırılmasıyla ilgili yeterli çalışma yer almamaktadır. Fakülte öğretim performansının değerlendirilmesinde öğrencilerin geri bildirimlerini kullanarak bakış açısına göre duygu analizinde derin öğrenme yaklaşımı kullanan ilk girişim olan çalışmalarında Sindhu vd. (2019), var olan metinden otomatik yön çıkarmak ve bunların karşılığı olan yönlendirmeyi bulan bir sistem önermişlerdir. Bu sistemde çift katmanlı LSTM modeliyle, denetimli bakış açısı temelli fikir madenciliği kullanılmıştır. Sukkur IBA Üniversitesi'nin son beş yıldaki öğrenci yorumlarını elle etiketleyip veri seti olarak kullandıkları çalışmada olumlu, olumsuz, nötr gibi yönelimler belirlenmiştir. Sistemde gömme katmanının sayesinde görünüm çıkarmada %91, duygu polaritesini algılamada %93 gibi yüksek doğruluk değeri elde etmişlerdir (Sindhu vd., 2019). Chakravartky, Kameswari, Mydeen ve Seenivasan (2020), Coursera'daki makine öğrenmesi dersinden alınan yorumları veri seti olarak kullandıkları ve bu verilere fikir madenciliği uyguladıkları çalışmalarında, doğal dil işleme yöntemiyle görüş çıkarma, yapılandırılmamış metni işleme, kutup sınıflandırması adımlarını kullanmışlardır. Fikir madenciliği sonucunda elde edilen performans, KNN, Lojistik Regresyon gibi makine öğrenimi algoritmalarını kullanarak değerlendirmişlerdir. KNN algoritması ile özgülük ve duyarlılık konularında daha iyi sonuçlar elde edilirken, Lojistik Regresyon ile %94 gibi KNN'den daha fazla bir doğruluk değeri elde edildiği görülmektedir (Chakravartky vd., 2020). Chan vd. (2021), Coursera platformunu kullanarak yaptıkları çalışmalarında, kurs arayan kişilerin, istedikleri kurslarla ilgili fikir edinmeleri konusunda yardımcı olmak amacıyla yaptıkları çalışmalarında, metin temizleme, lemmatizasyon, metin madenciliği, duygu analizi ve görselleştirmeyi kapsayan bir metin analizini boru hattı önermişlerdir. Diğer önemli amacın birçok kursu bir şekilde karşılaştırarak kursa giriş yapılmasının kolaylaştırılmasını sağlamak olan çalışmada, N-gram analizi ve kelime bulutu çalışmalarının kurslar hakkında olumlu olumsuz fikirler edinilmesi ve kurslar arası karşılaştırma yapılabilmesi açısından başarılı olduğu, ancak olumsuz yorumların tespitinde eksik kaldığı görülmüştür. N-gram analizi sonucu doğrulukta 52/60, kullanılabilirlikte 55/60 puan aldıkları gözlemlenirken, model olumlu duyguları ayırt etmede %97'lik, olumsuz duyguları ayırt etmeden %46'lık bir ayırt etme oranı yakalamıştır (Chan vd., 2021). Coursera platformundan öğrencilerden gelen geri bildirimlerin analizi öğretmen ve öğrenme çıktılarının incelenmesi nedenleriyle fikir madenciliği kullanarak makine öğrenmesi modellerinin değerlendirilmesi amacıyla Edalati, İmran, Kastrati ve Deudpota (2021), derin öğrenme yöntemleri ile birlikte makine öğrenmesi algoritmalarından Rastgele Orman, Destek Vektör Makinesi ve Karar Ağacı algoritmalarını kullanmışlardır. Sonuçta Rastgele Orman algoritması ile en boy oranı tanımlamada %98.01, duyarlılık sınıflandırma görevlerinde %99.43 F1 skoru elde ederek başarılı sonuçlar elde etmişlerdir (Edalati vd., 2021). Dina, Yunardi, Firdaus ve Airlangga (2021), çevrimiçi platformda kullanıcıların yaptıkları incelemeler ve KAÇD içeriğiyle ilgili gelecekte olabilecek tasarım eğilimlerini belirlemek amaçlı yaptıkları çalışmalarında verileri Coursera'dan elde etmişlerdir. Araştırmada amaçlarına ulaşmak için metin madenciliği kullandıktan sonra kullanıcı tercihlerinin belirlenmesi için özellik-duygu çiftleri (anahtar kelime çiftleri) çıkarılmıştır. Duygu analizi konusunda Destek Vektör Makinesinin kullanıldığı ve doğruluk, kesinlik, hatırlama ve F1 skoru değerlerinin %80'in üzerinde elde edildiği bu çalışmada, olumlu ve olumsuz özellik-duygu çiftlerinde kullanıcı tercihlerinin Coursera'da başarılı bir şekilde tanımlandığı anlaşılmaktadır (Dina

ve ark., 2021). Kullanıcı deneyimlerinin değerdendirilmesi konusunda geleneksel yöntemlere ek olarak, Beyin Bilgisayar Arayüzü teknolojisi olan elektroensefalografi (EEG) yöntemi kullanmayı amaçladığı çalışmasında Şahin (2022), Udey platformunun kullanıcı deneyimi (KD) değerdendirmesi için 13 katılımcılı bir kullanıcı çalışması değerdendirmesi yapmıştır. Katılımcılar platformla etkileşime girmeden önce ve girdikten sonra KD değerdendirmesinde kullanılmak üzere veriler Etki Grid Anketi, KD anketinin kısa versiyonu (UEQ-S), Pozitif Etki ve Negatif Etki ölçeği (PANAS), Web Sitesi Analizi ve ölçüm envanteri (WAMMI) ile elde edilmiştir. Daha sonrasında EEG kullanımı için gerekli veriler ise Emotiv Epc cihazı ile toplanmış ve Udey platformunun kullanıcı deneyiminin olumlu olduğunu gösteren sonuçlar alınmıştır. Elde edilen tüm veriler sonuçta Geleneksel ve EEG yöntemlerindeki olarak karşılaştırıldığında birbirini destekler nitelikte olduğu görülmüştür (Şahin, 2022).

Bu çalışmada, kurslara yapılan yorumları olumlu olumsuz sınıflandırması yapmak için daha önce literatürde üzerinde çalışma yapılmamış olan Udey sitesinde bulunan kurs yorumlarının klasik makine öğrenmesi alanında BayesNet, J48, OneR ve DVM algoritmalarıyla, Random, GloVe ve Word2Vec kelime gömmelerinden sonra, derin öğrenme modellerinden, CNN, GRU ve LSTM mimarilerini kullanarak olumlu- olumsuz şeklinde sınıflandırması gerçekleştirilmiştir. Çalışılan algoritma ve modellerin sonuçları karşılaştırıldığında performansların kabul edilebilir düzeyde iyi olduğu gözlemlenmiştir. Makalenin geri kalanında, İkinci bölümde çalışmada kullanılan Udey kurs yorumları veri kümesi ve kullanılan yöntemler verilmiştir. Üçüncü bölümde, deneysel değerdendirme sonuçları ve tartışma verilmiştir. Son bölümde, sonuçlar ve gelecekte yapılacak çalışma sunulmuştur.

2. Meteryal ve Metod

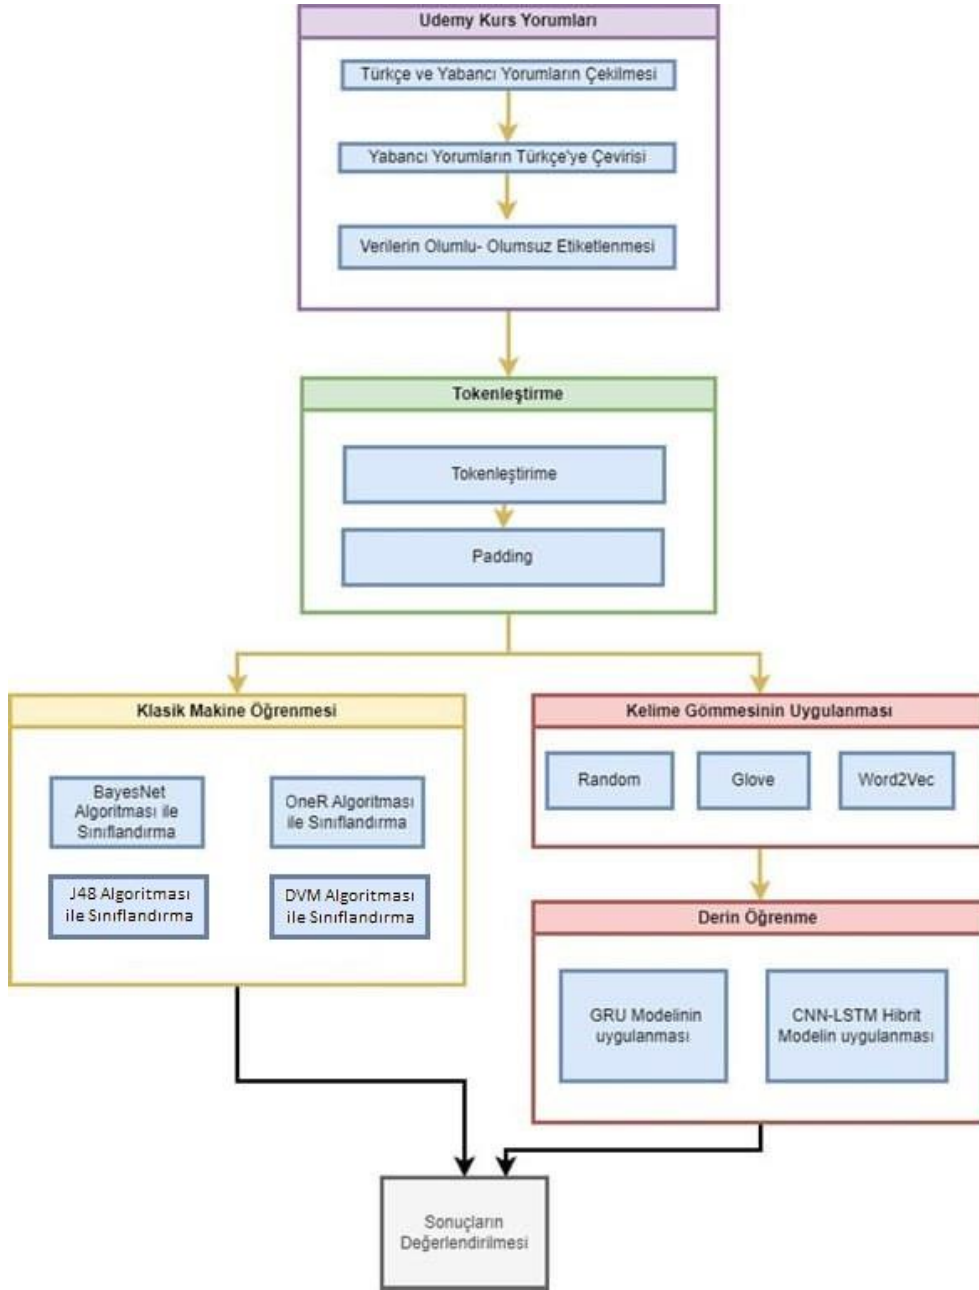
2.1. Udey kurs yorumları veri kümesi ve Veri Ön İşleme Aşaması

Bu çalışmada Udey sitesinde yer alan kurslara yapılan yorumlar kullanılmıştır. Verilerin Udey üzerinden alınması Udey API kullanılarak yapılmıştır. Udey’de yer alan kurslara verilen puanlara göre yorumlar olumlu olumsuz şeklinde sınıflandırılmıştır. Çalışmamızda kurslara yapılan yorumlardan elde edilen verilerde, 1 ve 3 puan arası olumsuz, 4 ile 5 puan arası yorumlar ise olumlu kabul edilmiştir. Verilerden anlamsız olabilecek 1 ile 3 harf arası olan kelimeler çıkarılmıştır. Anlamsız kelimelerin çıkarılması, yabancı dilde yazılmış yorumların ayıklanması gibi düzeltmelerden sonra 100000 olumlu ve 100000 olumsuz olmak üzere 200000 yorumdan oluşan veri seti elde edilmiştir. Veri setimizde yer alan olumlu ve olumsuz örnekler Tablo gösterilmiştir.

Tablo 1. Olumlu-Olumsuz Veri Örneği

Olumlu (1)	Olumsuz (0)
şuanlık konular sıkmadan izleyebiliyorum güzel bi anlatım var	şöyle böyle.Şimdiye kadar öğretilen şey çok basit.çok temel
şuana kadar satın aldığım en iyi eğitim oldu bu. tavsiye ederim	Eğitmenin talimatları bu modülde güncel veya uygulanabilir değildir

Düzenlenen verilerin kelime gömmelerinin işleyebileceği hale getirilmesi için tokenleştirme işlemi uygulanmıştır. Tokenleştirme işleminden sonra elde edilen verilerle klasik makine öğrenmeleri uygulanmıştır. Yine aynı tokenleştirme sonucuyla öncelikle kelime gömmelerinden Random, GloVe ve Word2Vec yöntemleri uygulanıp, her birinden sonra ayrı ayrı GRU ve CNN-LSTM hibrit derin öğrenme modelleri uygulanmıştır. Kullanılan çalışma aşamaları Şekil 1’de görülen adımlardan oluşmaktadır.



Şekil 1. Çalışma Akış Diyagramı

Bu çalışmada, klasik makine öğrenmesi yöntemlerinden BayesNet, J48, OneR ve DVM ile, derin öğrenme modellerinden GRU ve CNN-LSTM Hibrit modelleriyle Udemy kurs yorumlarının olumlu-olumsuz sınıflandırması gerçekleştirilerek performansları karşılaştırılmıştır.

2.2. BayesNet

Tahmin değişkenleri veya özellikleri aracılığıyla tanımlanmış olan örnek verilere etiket veya bir kategori atamayı amaçlayan BayesNet, denetimli sınıflandırma algoritmaları arasında yer almaktadır (Gürtürk, 2022). Çok terimli olan verilerin analizi sırasında istatistiksel sınıflandırma tekniğini kullanarak, buna göre olasılıkları hesaplar (Altınsoy, 2019). BayesNet algoritması ağın yapısını öğrendikten sonra olasılık tablolarını öğrenme mantığıyla çalışmaktadır. Ağ yapısının iyi olduğunu belirlediğinde koşula bağlı olan bu olasılık tablosunu her değişkene özel tahmin etmektedir (Belen, 2018). Birbirinden bağımsız olan durumların aynı zamanda oluşması ve iki durumun da ayrı ayrı oluşması durumlarına göre sonucun hesaplandığı bu algoritmanın formülü Eşitlik 1'de yer almaktadır (Eraldemir, 2014).

$$P(A|B) = \frac{(P(A)P(B|A))}{P(B)} \quad (1)$$

Eşitlik 1’de yer alan formülde yer alan ifadeler (Altınsoy, 2019):

$P(A/B)$: B durumu gerçekleştiğinde A durumunun gerçekleşme olasılığını, $P(A)$: A durumunun gerçekleşme olasılığını, $P(B/A)$: A durumu gerçekleştiğinde B durumunun gerçekleşme olasılığını, $P(B)$: B durumunun gerçekleşme olasılığını temsil etmektedir.


2.3. OneR

Hata temelli kural çıkarımına dayalı bu algoritma Holte (1993) tarafından önerilmiştir (Başer vd., 2020). Veride bulunan yordayıcı değişkenlerin her birine ait kurallar ürettikten sonra hatanın en az olduğu kuralı “bir kural” seçen basit bir yapıya sahip algoritmadır (Özden, 2018). Basit yapısına rağmen bu yöntem ile, birçok veri seti üzerinde başarılı sonuçlar elde edilmiştir (Kaynar vd., 2018). Her değişkenin tek olarak kullanıldığında oluşabilecek hata değerini hesaplayıp değişkenleri sıralama amacıyla, veri setinde bulunan her değer için bir model oluşturmaktadır. Bu modeller sonunda elde edilen toplam hatalar küçükten büyüğe doğru sıralanarak, eşik değeri altında kalan modeli oluşturan değişken belirlenir ve veri setinden çıkarılır (Kaynar vd. 2018). Tahminlerin ayrı ayrı sınıflandırma üzerindeki etkisi sonunda ortaya çıkmış olan toplam hatanın küçük çıkması, tahminin ne kuvvetli olduğunu göstermektedir (Tavacı, 2011).

2.4. J48

Weka veri madenciliği programında bulunan J48, C4.5 karar ağacı algoritması ve entropi değerlerini daha verimli hale getirmek amacıyla Ross Quinlan (1993) tarafından geliştirilmiş istatistiksel bir sınıflandırma algoritmasıdır (Gürtürk, 2022). J48’de anlaşılmasının kolaylığı ve karmaşık olmaması açısından karar verici olarak karar ağaçları tercih edilir. Ağaç karmaşıklığı işlemlerin doğruluğunda etkili olduğundan önemlidir (Akgül, 2019).

Karar ağaçları, kök, düğüm, dal ve yaprakтан oluşan bir yapıya sahiptir (Özdemir, 2020). Bu yapıda bulunan düğüm sayısı, yaprak sayısı, ağacın derinliği, ağacın oluşturulmasındaki özellikler ağacın karmaşıklığını belirler. J48 algoritmasındaki amaç da bu karar ağacının boyutunun küçük tutulabilmesidir (Akgül, 2019). J48 algoritmasının ağaç yapısı Şekil 2’de yer almaktadır.



Şekil 2. J48 Algoritması Ağaç Modeli (Çoban, 2011)

2.5. Destek Vektör Makinesi (DVM)

Vapnik (1995), örüntü tanıma ve sınıflandırma problemlerini çözmek için DVM yöntemini geliştirmiştir (Cortes ve Vapnik, 1995). DVM, istatistiksel öğrenme teorisine dayalıdır ve temel olarak iki veri sınıfını mümkün olan en iyi şekilde ayırt etmek için kullanılır. Bu amaçla karar sınırları veya hiperdüzlemler belirlenir. Doğrusal olmayan bir veri kümesinde, DVM'ler doğrusal bir hiper düzlem çizemez. Bu nedenle, polinomsal, Gauss gibi çekirdek fonksiyonları kullanılır. Çekirdek fonksiyonları, doğrusal olmayan veriler üzerinde doğruluk değerlerini büyük ölçüde artırır.

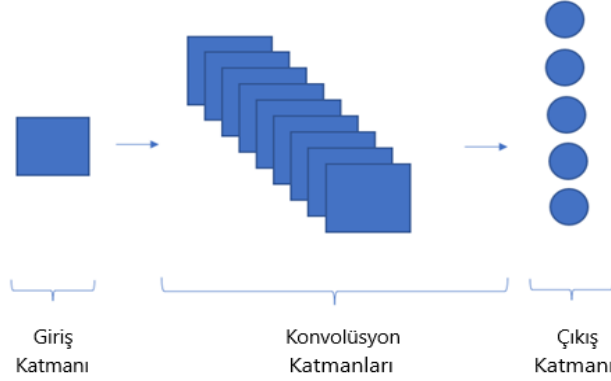
2.6. CNN (Convolution Neural Network- Evrimsel Sinir Ağları)

Derin öğrenme yöntemlerinin en yaygın olarak kullanılanlarından birisi olan CNN, 1989 yılında LeCun tarafından tanımlanmıştır (Seyidbayli, 2022). Ancak evrimsel sinir ağlarının donanımsal ihtiyaçlarının yüksek olmasından dolayı başlarda gelişimi yavaşlamıştır. Donanımsal kapasitelerin gelişmesiyle 2010’lu yıllarda, CNN’lerin yeterli süre içinde çalışabilecek seviyelere gelmiş ve kullanımı hızla yayılmaya başlamıştır (Yaşar, 2022).

Tek boyutlu olan zaman serilerinin ve iki boyutlu olan görsel verilerin işlenmesinde kullanılan bu yapay sinir ağı, son zamanlardaki donanımsal değişimlerin gerçekleşmesiyle üç boyutlu mimariler de gelişmeye başlamıştır (Tekinarıslan, 2022). Dil içerikli olan

sinyal ve diziler bir boyutlu, görüntü, ses gibi içerikler iki boyutlu, videolar, hacimli görüntüler üç boyutlu yapılarda kullanılır (LeCun ve ark., 2015).

Evrışim adındaki matematiksel işlemi kullanan CNN, birden fazla katman ve parametreden oluşmaktadır. Girdi verisinin içerisindeki ağırlıkları işlemekten önce öğrenebilir parametreler içeren filtreyi girdi üzerinde dolaştırma mantığıyla çalışır. Bu işlem sonunda modeldeki parametre sayısı azaldığından, girdi üzerinde yer alan komşu verilerin ilişkisi daha iyi yakalanmış olmaktadır (Özbilen, 2022). Bu aşlarda alınan giriş verileri katmanlar halinde işlenerek eğitim süreci gerçekleştirilir (Fındık, 2022). Yapısında yer katmanlar genel hatlarıyla Şekil 3'te görüldüğü gibi giriş katmanı, konvolüsyon (evrışimsel) katmanları ve çıkış katmanıdır.



Şekil 3. CNN Katman Yapısı (Keskin, 2022)

2.7. LSTM (Long Short-Term Memory- Uzun Kısa Süreli Bellek)

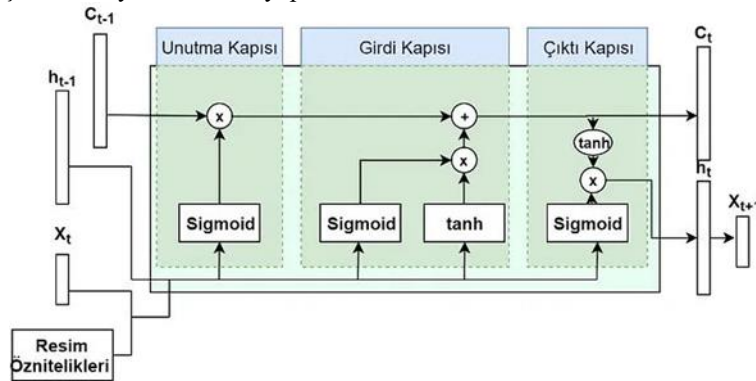
İnsan beyni, bir metin okuduğunda aradığı bilgiyi bulduktan sonra genelde metnin geri kalan kısmını unutmaması şeklinde çalışarak verileri işlemektedir. İnsan beyninin bu işleyişini taklit eden ve RNN'in gelişmiş versiyonu olan LSTM, Hochreiter ve Schmidhuber (1997) tarafından tasarlanmıştır (Eren, 2022). Bilgileri varsayılan olarak uzun süre saklayabilen LSTM, RNN'deki kaybolan gradyanlar problemini çözmek için kapı olarak adlandırılan, neyin hatırlanacağı neyin unutulacağına karar verilmesi için 3 yapı geliştirmiştir (Şekil 4). LSTM, bu kapılar aracılığıyla hazırlanan hücre yapılarına bilgilerin eklenmesi ya da kaldırılması işlevlerine sahiptir (Fındık, 2022).

Hücrelerin durumunu kontrol edip koruyan bu kapılar şu şekildedir (Keskin, 2022):

Unutma Kapısı: Bellekte var olan bilgilerin hangilerinin tutulup hangilerinin tutulmayacağını aktivasyon fonksiyonları kullanarak karar verir.

Girdi Kapısı: Verilerin ne olduğunu öğrenip, girdilerin hafıza hücrelerine akışını kontrol eder.

Çıktı Kapısı: Çıktıların ağı akışını belirleyerek tahmin yapar.

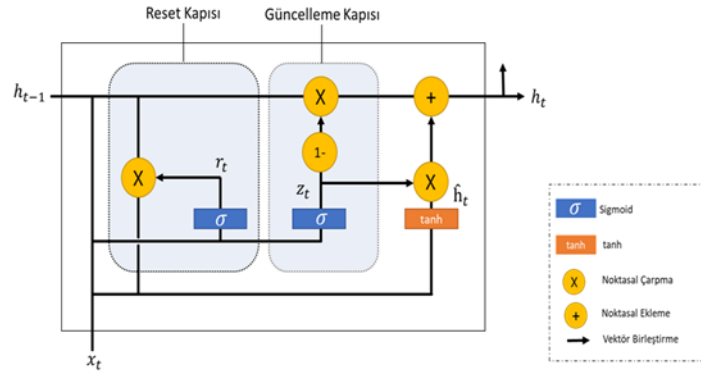


Şekil 4. LSTM Modeli Kapı Yapısı (Yıldız, 2020)

2.8. GRU (Gated Recurrent Unit- Kapılı Tekrarlayan Birim)

Tekrarlayan Sinir Ağları (RNN) mimarisinin bir çeşidi olan ve LSTM mimarisinin de birden fazla varyasyonundan en çok tercih edilen Kapılı Tekrarlayan Birim (GRU), Cho ve arkadaşları tarafından 2014 yılında ortaya konulmuştur. LSTM yapısı üzerindeki giriş ve unutma kapısını güncelleme kapısı olarak birleştirerek değişiklik yapmışlardır (Eren, 2022). GRU ve LSTM mimarileri birbirine benzediğinden başarılı sonuçlar üretebilmektedirler (Fındık, 2022).

GRU yapısının temelinde sıfırlama kapısı ve güncelleme kapısı yer almaktadır (Şekil 5). Model üzerinde var olan geçmiş bilgilerden ne kadarının unutulacağına karar vermede sıfırlama kapısı, modeldeki önceki zamanda var olan adımların hangilerinin ileriye dönük aktarılmasının belirlenmesinde güncelleme kapısı kullanılmaktadır (Ballı, 2022). GRU bu yapıyla LSTM'ye göre daha basit, hızlı eğitilebilen, daha verimli yürütülebilen bir model olmaktadır (Gencer, 2022).



Şekil 5. GRU Mimarisi (Canlı, 2022)

Bu çalışmada, kurs yorumlarının sınıflandırılmasının gerçekleştirilmesi için klasik makine öğrenmesi yöntemlerinden BayesNet, OneR, J48 ve DVM, derin öğrenme yöntemlerinden metin madenciliğinde sıklıkla kullanılan GRU ve CNN-LSTM hibrit modelleri kullanılmıştır. Kullanılan modeller için Tablo 4'te görülen değerler seçilerek deneysel değerlendirmeler yapılmıştır. Deneysel değerlendirmeler, klasik makine öğrenmesi için Weka programı, derin öğrenme modelleri için, Python dili ve Jupyter Lab, Spyder kod editörleri kullanılarak gerçekleştirilmiştir.

Tablo 2. Modellerin Eğitiminde Kullanılan Parametreler

Modeller	Parametreler	Değerler
Klasik Makine Öğrenmesi	Fold	10
	Embedding size	300
GRU	Learning rate	0.001
	Aktivasyon fonksiyonu	Sigmoid
CNN	Filtre boyutu	3, 4
	Drop out	0.1, 0.2
	Pool size	1, 2, 4

2.9. Değerlendirme Kriterleri

Çalışmada kullanılan veri kümesindeki veriler yapılan yorumların puan durumlarına göre olumlu ve olumsuz şeklinde iki farklı sınıf ile ifade edilmektedir. Çalışmada klasik makine öğrenmesi modellerinin eğitimi için fold değeri 10 alınarak deneysel değerlendirmeler gerçekleştirilmiştir. Derin öğrenme modellerinden GRU için embedding size 300, learning rate 0.001 ve aktivasyon fonksiyonu olarak sigmoid, CNN-LSTM hibrit modelinde CNN parametrelerinden filtre boyutu 3, 4, drop out değeri 0.1, 0.2 ve pool size 1, 2, 4 alınarak deneysel değerlendirmeler gerçekleştirilmiştir. Çalışmada klasik makine öğrenmelerinin performansları doğruluk ve f1-skor değeri kriterlerine, derin öğrenme modellerinin performansları doğruluk, kesinlik, duyarlılık, f1-skor kriterlerine göre karşılaştırılmıştır (Sırasıyla Eşitlik 2, 3, 4, 5) (Degadwala vd., 2021).

$$\text{Doğruluk} = \frac{\text{TN} + \text{TP}}{\text{TN} + \text{TP} + \text{FP} + \text{FN}} \quad (2)$$

$$\text{Kesinlik} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (3)$$

$$\text{Duyarlılık} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (4)$$

$$\text{F1 - skor} = 2 * \frac{\text{kesinlik} * \text{duyarlılık}}{\text{kesinlik} + \text{duyarlılık}} \quad (5)$$

Eşitliklerde yer alan *TP* gerçek pozitif, *TN* gerçek negatif, *FP* yanlış pozitif ve *FN* ise yanlış negatif değerlerini göstermektedir. Doğruluk değeri modelde doğru tahmin edilen örneklerin toplam veri kümesine oranı ile hesaplanmaktadır. Kesinlik değeri, Pozitif olarak tahminlenen değerlerin gerçekten kaç adedinin Pozitif olduğunu göstermektedir. Duyarlılık değeri, Pozitif olarak tahmin edilmesi gereken örneklerin ne kadarının Pozitif olarak tahmin edildiğini gösterir. F1 skor değeri de kesinlik ve duyarlılık değerlerinin harmonik ortalamasını göstermektedir.

3. Deneysel Sonuçlar ve Tartışma

Çalışmada klasik makine öğrenmesi algoritmaları ve derin öğrenme modelleri ile deneysel analizler gerçekleştirilmiştir. Bu bölümde, UdeMy kurs yorumları veri kümesi üzerinden yorum sınıflandırılması işlemini gerçekleştirebilmek için BayesNet, OneR, J48, DVM, GRU ve CNN-LSTM modelleri kullanılarak elde edilen deneysel sonuçlar sunulmuştur. Çalışmada kullanılan klasik makine öğrenmesinin deneysel sonuçları Tablo 3'te, derin öğrenme modellerinin deneysel sonuçları Tablo 4'te, Random, GloVe ve Word2Vec kelime gömmelerinden sonra uygulanan her bir derin öğrenme modeli sonunda ortaya çıkan sonuçlar ise Tablo 5, Tablo 6, Tablo 7'de yer almaktadır.

Tablo 3. Klasik Makine Öğrenmelerinin Karşılaştırılması

	Doğruluk	F Skoru
BayesNet	91.5960	0.916
OneR	85.1305	0.851
J48	82.9085	0.829
DVM	82.2850	0.822

Çalışmada, Tablo 3'te yer alan doğruluk oranlarına göre klasik makine öğrenmesi algoritmalarının değerlendirilmesi sonucu, en yüksek doğruluğun %91.596 oranla BayesNet ile, en düşük doğruluğun %82.2850 oranla DVM'e ait olduğu gözlemlenmiştir. Kullanılan OneR algoritması ile de %85.1305 oranla ortalama bir başarı elde edilmiştir. F- skorları açısından değerlendirildiğinde BayesNet için %91.6, OneR için %85.1, J48 için %82.9 ve DVM için ise %82.2 oranı elde edildiği görülmüştür.

Tablo 4. Derin Öğrenme Modellerinin Sonuçları

	Doğruluk	Duyarlılık	Kesinlik
GRU (GloVe)	0.9567	0.9582	0.9493
CNN-LSTM (Random)	0.9458	0.9580	0.9280
CNN-LSTM (GloVe)	0.9493	0.9464	0.9449
CNN-LSTM (Word2Vec)	0.9484	0.9454	0.9439

Tablo 4'te yer alan doğruluk oranlarına göre kullanılan modellerin değerlendirilmesi sonucu, en yüksek doğruluğun %95.67 oranla GloVe kelime gömmesi uygulandıktan sonra GRU modeliyle elde edilmişken, en düşük doğruluğun ise %94.58 oranla Random kelime gömmesi kullanıldıktan sonra CNN-LSTM hibrit modeline ait olduğu gözlemlenmiştir. Ayrıca diğer modellerinin doğruluk oranlarının ise birbirine çok yakın olduğu görülmektedir. GloVe kelime gömmesi yapıldıktan sonra GRU derin öğrenme modeliyle %95.82 duyarlılık, %94.93 kesinlik, Random kelime gömmesi yapıldıktan sonra CNN-LSTM derin öğrenme modeliyle %95.80 duyarlılık, %92.80 kesinlik, GloVe kelime gömmesi yapıldıktan sonra CNN-LSTM derin öğrenme modeliyle %94.64 duyarlılık, %94.49 kesinlik, Word2Vec kelime gömmesi yapıldıktan sonra CNN-LSTM derin öğrenme modeliyle %94.54 duyarlılık, %94.39 kesinlik oranları elde edildiği görülmüştür.

Tablo 5. GRU Modeli Sonuçları

Kelime Gömmesi	Doğruluk	Duyarlılık	Kesinlik
Random	0.9499	0.9468	0.9458
GloVe	0.9567	0.9582	0.9493
Word2Vec	0.9441	0.9406	0.9396

Tablo 5'teki doğruluk, duyarlılık ve kesinlik oranlarına göre kullanılan modelin değerlendirme sonuçlarına bakıldığında, en yüksek performansın %95.67 doğruluk, %95.82 duyarlılık ve %94.93 kesinlik oranlarıyla GloVe kelime gömmesinden sonra GRU modeli kullanılarak elde edildiği görülmektedir.

Tablo 6. Random Kelime Gömmesi Uygulaması Sonrası CNN-LSTM Hibrit Model Sonucu

CNN Parametreleri			Doğruluk	Duyarlılık	Kesinlik
Filtre Boyutu	Drop out	Havuz boyutu			
3	0.2	1	0.9458	0.9580	0.9280
3	0.2	4	0.9456	0.9408	0.9423
4	0.1	2	0.9238	0.9099	0.9254

Tablo 6'daki doğruluk, duyarlılık ve kesinlik oranlarına göre Random kelime gömmesi sonucunda uygulanan CNN-LSTM hibrit modelin değerlendirme sonuçlarına bakıldığında, en yüksek performansın CNN filtre boyutu 3, dropout değeri 0.2 ve pool size değeri 1 olarak ayarlandığı durumda elde edildiği görülmektedir. Bu durumda %94.58 doğruluk, %95.80 duyarlılık ve %92.80 kesinlik oranlarına ulaşılmıştır. En düşük performans ise filtre boyutu 4, dropout değeri 0.1 ve pool size değeri 2 olarak ayarlandığında elde edilmiştir, bu durumda %92.38 doğruluk, %90.99 duyarlılık ve %92.54 kesinlik oranlarına ulaşılmıştır.

Tablo 7. Glove Kelime Gömmesi Uygulaması Sonrası CNN-LSTM Hibrit Model Sonucu

CNN Parametreleri			Doğruluk	Duyarlılık	Kesinlik
Filtre Boyutu	Drop out	Havuz boyutu			
3	0.2	1	0.9493	0.9464	0.9449
3	0.2	4	0.9464	0.9289	0.9548
4	0.1	2	0.9216	0.9001	0.9296

Tablo 7'deki doğruluk, duyarlılık ve kesinlik oranlarına göre GloVe kelime gömmesi sonucunda uygulanan CNN-LSTM hibrit modelin değerlendirme sonuçlarına bakıldığında, en yüksek performansın CNN filtre boyutu 3, dropout değeri 0.2 ve pool size değeri 1 olarak ayarlandığı durumda elde edildiği görülmektedir. Bu durumda %94.93 doğruluk, %94.64 duyarlılık ve %94.49 kesinlik oranlarına ulaşılmıştır. En düşük performans ise filtre boyutu 4, dropout değeri 0.1 ve pool size değeri 2 olarak ayarlandığında elde edilmiştir, bu durumda %92.16 doğruluk, %90.01 duyarlılık ve %92.96 kesinlik oranlarına ulaşılmıştır. Ayrıca, CNN filtre boyutu 3, dropout değeri 0.2 ve pool size değeri 4 olarak ayarlandığında %94.64 doğruluk, %92.89 duyarlılık ve %95.48 kesinlik oranlarına ulaşılmıştır.

Tablo 8. Word2Vec Kelime Gömmesi Uygulaması Sonrası CNN-LSTM Hibrit Model Sonucu

CNN Parametreleri			Doğruluk	Duyarlılık	Kesinlik
Filtre Boyutu	Drop out	Havuz boyutu			
3	0.2	1	0.9484	0.9454	0.9439
3	0.2	4	0.8774	0.8264	0.9023
4	0.1	2	0.9416	0.9466	0.9293

Tablo 8'de yer alan Word2Vec kelime gömmesi sonunda uygulanan CNN-LSTM hibrit modelinde filtre boyutu 3, drop out değeri 0.2 ve havuz boyutu 1 olan CNN parametrelerinde %94.84 ile en yüksek doğruluk değerine ulaşılmıştır. Yapılan tüm deneylerde en iyi başarı oranını klasik makine öğrenmesi algoritmalarından BayesNet, derin öğrenme modellerinden GloVe kelime gömmesi sonunda GRU ile edildiği görülmektedir. Kullanılan modeller arasında ikinci en iyi başarı oranı klasik makine öğrenmesi algoritmalarından OneR ile %85.1305 doğruluk, %85.1 f skor oranları, derin öğrenme modellerinden GloVe kelime gömmesi sonunda CNN-LSTM hibrit modeli ile %94.93 doğruluk, %94.64 duyarlılık ve %94.49 kesinlik oranları elde edilmiştir.

4. Sonuç ve Tartışma

Coursera, FutureLearn, Khan Academy, Udemy gibi zamanla gelişmesine devam eden KAÇD'ler mevcuttur. Bu sistemlerde kurslar, bazıları az bir ücretle, bazıları ücretsiz bir şekilde yer almaktadır. Kullanıcılar kurslara kaydolarken, birçok çevrimiçi işlerimizde olduğu gibi, kursla ilgili yorumlara bakmaktadırlar. Kurslarla ilgili yorumlara bakarak değerlendirmenin gerçekleştirilmesi bazen çok zor olmaktadır. Klasik makine öğrenmesi ve derin öğrenme yöntemleri kullanılarak bu değerlendirmeler kolaylıkla gerçekleştirilmektedir. Ancak bu konuda az çalışma bulunup, Udemy ile yapılan bir çalışmanın olmadığı görülmektedir. Çalışmada kullanıcıların Udemy sitesindeki kurs yorumlarını okumasına gerek kalmadan kursla ilgili olumlu-olumsuz olmak üzere bir yargıya varmaları amacıyla makine öğrenmesi ve derin öğrenme yöntemleri kullanılarak yorumlar sınıflandırılmıştır. Deneysel değerlendirmeler sonucu en başarılı sonucun klasik makine öğrenmesi algoritmalarından BayesNet ile %91.596 doğruluk oranı, derin öğrenme modellerinden GloVe kullanıldıktan sonra GRU ile %95.67 doğruluk oranıyla gerçekleştiği görülmüştür. Gelecekte

yapılacak çalışmalarda, farklı kelime gömme yöntemleri, makine öğrenmesi ve derin öğrenme algoritmaları kullanılarak sınıflandırma doğruluğunun artırılması hedeflenmektedir.

Kaynaklar

- Altınsoy, F. (2019). Uzaktan Eğitim Öğrencilerinin Başarılarının Yapay Zeka Teknikleri İle Tahmini. (Yüksek Lisans Tezi), Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı, Isparta.
- Başer, S. H., Hökekleli, O. & Adem, K. (2020). Ortaöğretimde Öğrenim Gören Öğrenci Performanslarının Veri Madenciliği Yöntemleri ile Tahmin Edilmesi. *Bilgisayar Bilimleri ve Teknolojileri Dergisi*, 1 (1), 22-27.
- Belen, N. (2018). Acil Tıp Kliniğine Göğüs Ağrısı Şikayeti ile Başvuran Hastalarda Otuz Günlük Kardiyak İlişkili Olayların Tanımlanmasında Klinik Karar Destek Sistemi (Clinical Decision Support System) Geliştirilmesi. (Uzmanlık Tezi), Sağlık Bilimleri Üniversitesi İzmir Bozyaka Eğitim ve Araştırma Hastanesi Acil Tıp Kliniği, İzmir
- Canlı, H. (2022). IoT Tabanlı Akıllı Şehirlerde Derin Öğrenme ve Mobil Tabanlı Akıllı Park Sistemi Yaklaşımı. (Doktora Tezi), Düzce Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı, Düzce.
- Chakravarthy, V.J. Kameswari, M. Devan Mydeen, H. & Seenivasan, M. (2021). Opinion mining from student text review for choosing better online courses. *IOP Conference Series: Materials Science and Engineering*, 1070, 1-13
- Chan, H. Y., Rajamohan, R., Gan, K.H. & Samsudin, N. (2021, Eylül)Text Analytics on Course Reviews from Coursera Platform. 2021 IEEE International Conference on Artificial Intelligence in Engineering and Technology (IICAIET), Kota Kinabalu, Malaysia.
- Cortes C, Vapnik V. 1995. Support-vector networks. *Machine Learning* 20: 273-297. <https://doi.org/10.1007/BF00994018>
- Çoban, T. (2011). Makine Öğrenme Algoritmaları ile Web Sitelerinin Tıklamalarının Analizi. (Yüksek Lisans Tezi), Beykent Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı, İstanbul
- Degadwala, S., Vyas, D., Chakraborty, U., Dider, A. R., & Biswas, H. (2021). Yolo-v4 Deep Learning Model for Medical Face Mask Detection. 2021 International Conference on Artificial Intelligence and Smart Systems (ICAIS), 209-213.
- Demirci, N. (2014). What is Massive Open Online Courses (MOOCs) and What is promising us for learning?: A Review-evaluative Article about MOOCs. *Necatibey Eğitim Fakültesi Elektronik Fen ve Matematik Eğitimi Dergisi*, 8(1), 231-256.
- Dina, N., Yunardi, R., & Firdaus, A. (2021). Utilizing text mining and feature-sentiment-pairs to support data-driven design automation massive open online course. *International Journal of Emerging Technologies in Learning (iJET)*, 16(1), 134-151.
- Edalati, M., Imran, A.S., Kastrati, Z., Daudpota, S.M. (2022). The Potential of Machine Learning Algorithms for Sentiment Classification of Students' Feedback on MOOC. In: Arai, K. (eds) *Intelligent Systems and Applications. IntelliSys 2021. Lecture Notes in Networks and Systems*, vol 296. Springer, Cham.
- Eraldemir, S. G. (2014). EEG verileri kullanılarak metinsel okuma ve matematiksel işlemlerin analizi. (Yüksek Lisans Tezi), Mustafa Kemal Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Ana Bilim Dalı, Hatay.
- Eren, M. Ç. (2022). Yinelemeli Sınır Ağları İle Sermaye Piyasası Yön Tahmini Üzerine Bir Çalışma. (Yüksek Lisans), İstanbul Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Endüstri Mühendisliği Anabilim Dalı, İstanbul.
- Fındık, M. M. (2022). Derin Öğrenme Tabanlı Hibrit Tahminleme Modeli Kullanarak Rüzgar Hızı Tahminlemesi. (Yüksek Lisans Tezi), Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı, Tokat.
- Gencer, M. (2022). Yapısal Olmayan Metinler İçin Adlandırılmış Varlık Tanıma Algoritmaları ve Uygulamaları. (Yüksek Lisans Tezi), Dokuz Eylül Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Bilimleri Anabilim Dalı, İzmir.
- Gürtürk, U. (2022). Türkiye'nin Siber Güvenlik Politikalarının Yazılım Mühendisliği Açısından Değerlendirilmesi ve Kritik Altyapıların Siber Saldırlardan Korunmasına Yönelik Olay Yönetim Sistemi Tasarım. (Yüksek Lisans Tezi), İstanbul Üniversitesi-Cerrahpaşa Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı, İstanbul.
- Hochreiter, S. & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, vol. 9, no. 8, pp. 1735-1780, 15 Nov. 1997, doi: 10.1162/neco.1997.9.8.1735.
- Holte, R.C. (1993) Very simple classification rules perform well on most commonly used data sets. *Machine Learning*, 11(1), 63-90.
- İşgör Şimşek, E. 2015, Mobil Ortamlarda Kitleli Açık Çevrimiçi Derslerin (Kaçd) Kullanılabilirliğinin Değerlendirilmesi. (Yüksek Lisans Tezi), Mimar Sinan Güzel Sanatlar Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Kaynar, O. Arslan, H. Görmez, Y. & Işık, Y. E. (2018). Makine Öğrenmesi ve Öznitelik Seçim Yöntemleriyle Saldırı Tespiti. *Bilişim Teknolojileri Dergisi*, 11 (2), 175-185. DOI: 10.17671/gazibtd.368583

- Keskin, C. (2022). Graf Tabanlı Yaklaşım ile Uzun Vadeli Trafik Akış Hızı Tahmini. (Yüksek Lisans Tezi), Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı, İstanbul.
- Lecun, Y., Bengio, Y., Hinton, G. (2015). Deep learning. *Nature*, 521(7553): 436–444.
- Onan, A. (2020). Sentiment analysis on massive open online course evaluations: A text mining and deep learning approach. *Special Issue Article 29(3)*, 572-589.
- Özbilen, M. L. (2022). Hisse Senedi Fiyat Tahmininde Otokodlayıcı ve Graf Evrişimli Ağının Uygulanması. (Yüksek Lisans Tezi), İstanbul Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı, İstanbul.
- Özdemir, E. (2020). Basketbol Maç Sonuçlarının Makine Öğrenmesi Yöntemleri ile Tahmin Edilmesi. (Yüksek Lisans Tezi), Muğla Sıtkı Koçman Üniversitesi Fen Bilimleri Enstitüsü Bilişim Sistemleri Mühendisliği Anabilim Dalı, Muğla.
- Özden, C. (2018). The Effects Of Preprocessing Methods On Prediction Of Traffic Accident Severity. (Yüksek Lisans Tezi), Çukurova University Institute Of Natural And Applied Sciences Department Of Computer Engineering, Adana.
- Quinlan, J. R. (2014). *C4. 5: programs for machine learning*. Elsevier.
- Seyidbayli, C. (2022). Transfer Öğrenmesi Tabanlı Hibrit Evrişimsel Sinir Ağı Modelleri Kullanılarak Meme Kanseri Teşhisi. Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Mekatronik Mühendisliği Anabilim Dalı, İstanbul.
- Sindhu, I., Daudpota, S. M., Badar, K., Bakhtyar, M., Baber, J., & Nurunnabi, M. (2019). Aspect-based opinion mining on student's feedback for faculty teaching performance evaluation. *IEEE Access*, 7, 108729-108741.
- Şahin, E. B., & Durdu, P. O. (2021). Bilişsel gezinti ile kitlesel açık çevrimiçi ders (kaçd) web sitelerinin kullanılabilirliğinin değerlendirilmesi. *Bilişim teknolojileri dergisi*, 14(4), 377-389.
- Tavacı, H. (2011). GSM şebekelerinde sahtekarlık yönetimi için veri madenciliği yöntemlerinin uygulanması. (Yüksek Lisans Tezi), Bahçeşehir Üniversitesi Fen Bilimleri Enstitüsü Bilgi Teknolojileri Ana Bilim Dalı, İstanbul.
- Tekinarslan, R. (2022). Çevrimiçi Öğrenme Ortamlarında Öğrenme Analitiği Verileri ve Makine Öğrenmesi Kullanarak Akademik Başarının Değerlendirilmesi. (Yüksek Lisans Tezi), Başkent Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı, Ankara.
- Yaşar, H. (2022). Covid-19 Hastalığının Derin Öğrenme Yöntemleri Kullanılarak Tespiti. (Doktora Tezi), Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı, Konya.
- Yıldız, E. (2020). LSTM ve Metin Sınıflandırması. 14.01.2023 tarihinde <https://medium.com/@iamemreyildiz/lstm-ve-metin-siniflandirmasi-c1a48eb53e01> adresinden erişilmiştir.