

Derin Öğrenme Yöntemleri ile Lisans Öğrencilerinin Akademik Performanslarına Dayalı
Mezuniyet Tahmini

Rumeysa Çınar

YÜKSEK LİSANS TEZİ

Bilgisayar Mühendisliği Anabilim Dalı

Aralık 2019

Graduation Predicting Based on Academic Performance of Undergraduate Students with
Deep Learning Methods

Rumeysa ınar

MASTER OF SCIENCE THESIS

Department of Computer Engineering

December 2019

Derin Öğrenme Yöntemleri ile Lisans Öğrencilerinin Akademik Performanslarına Dayalı
Mezuniyet Tahmini

Rumeysa Çınar

Eskişehir Osmangazi Üniversitesi
Fen Bilimleri Enstitüsü
Lisansüstü Yönetmeliği Uyarınca
Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Donanımı Bilim Dalında
YÜKSEK LİSANS TEZİ
Olarak Hazırlanmıştır

Danışman: Dr. Öğr. Üyesi Uğur Gürel

Aralık 2019

ONAY

Bilgisayar Mühendisliđi Anabilim Dalı Yüksek Lisans öđrencisi Rumeysa Çınar'ın YÜKSEK LİSANS tezi olarak hazırladığı “Derin Öğrenme Yöntemleri ile Lisans Öğrencilerinin Akademik Performanslarına Dayalı Mezuniyet Tahmini” başlıklı bu çalışma, jürimizce lisansüstü yönetmeliđin ilgili maddeleri uyarınca deđerlendirilerek oybirliđi ile kabul edilmiştir.

Danışman: Dr. Öğr. Üyesi Uđur Gürel

İkinci Danışman: -

Yüksek Lisans Tez Savunma Jürisi:

Üye: Dr. Öğr. Üyesi Uđur Gürel

Üye: Dr. Öğr. Üyesi Nihat Adar

Üye: Dr. Öğr. Üyesi Muammer Akçay

Fen Bilimleri Enstitüsü Yönetim Kurulu'nun tarih ve
..... sayılı kararıyla onaylanmıştır.

Prof. Dr. Hürriyet ERŞAHAN

Enstitü Müdürü

ETİK BEYAN

Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü tez yazım kılavuzuna göre, Dr. Öğr. Üyesi Uğur Gürel danışmanlığında hazırlamış olduğum “Derin Öğrenme Yöntemleri ile Lisans Öğrencilerinin Akademik Performanslarına Dayalı Mezuniyet Tahmini” başlıklı YÜKSEK LİSANS tezimin özgün bir çalışma olduğunu; tez çalışmamın tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı; tezimde verdiğim bilgileri, verileri akademik ve bilimsel etik ilke ve kurallara uygun olarak elde ettiğimi; tez çalışmamda yararlandığım eserlerin tümüne atıf yaptığımı ve kaynak gösterdiğimi ve bilgi, belge ve sonuçları bilimsel etik ilke ve kurallara göre sunduğumu beyan ederim. 30/12/2019

Rumeysa Çınar

ÖZET

Risk altındaki öğrencilerin normal eğitim süresinde mezun olma veya olmama durumlarının erken tahmini, yükseköğretim kurumları için önemlidir. Mezuniyet tahmini öğrencilerin nihai akademik başarısı ile ilgili faktörleri keşfettikten sonra danışmanların gerekli desteği sağlamalarına yardımcı olur. Bu tez çalışmasında, akademik faktörlerin öğrencilerin nihai performanslarındaki etkilerini analiz etmek amacıyla zaman serisi modelleri tabanlı derin öğrenme entegrasyonu hakkında bilgiler verilmektedir. Bu amaçla, bilgisayar mühendisliği programından 200 öğrencinin ders kayıtları üzerinde tekrarlayan sinir ağı (RNN), uzun kısa süreli bellek (LSTM) ve geçitli tekrarlayan birim (GRU) ağı modelleri uygulanmıştır. Daha sonra sigmoid ve/veya doğrusal aktivasyon fonksiyonundan geçirilerek eğitim sürecinin birinci, ikinci, üçüncü, dördüncü, beşinci, altıncı dönemleri için ayrı ayrı modeller kaydedilmiştir. Dönem bazında bir tahmin yöntemi olarak, normal eğitim süresinde mezun olma veya olmama durumu birçok faktör tarafından yönlendirildiği için farklı özellikler dikkate alınmıştır. Öğrencilerin normal eğitim süresinde mezun olma veya olmama durumunu etkin bir şekilde tahmin etmek adına, kullandığımız ağlar için en uygun girdi parametreleri belirlenmiştir. Bu girdi parametreleri, öğrencilerin genel not ortalaması, İngilizce puanı, cinsiyeti, tercih sırası, devamsızlık oranı ve her dönem için o zamana kadar alınan zorunlu ders notlarıdır. Beş kat çapraz doğrulama işleminin ardından, RNN, GRU ve LSTM için ortalama (altı dönem ortalaması) genel doğruluk oranlarının sırasıyla %81,07, %85,65 ve %84,41 olduğu görülmüştür. Ayrıca, altıncı yarıyıldaki öğrenciler için önerilen LSTM modeli, risk altındaki öğrencileri keşfederken %87,12 gerçek negatif oranına ulaşırken, GRU modelinde öğrencilerin başarısını tahmin etme yönünden hesaplanan en yüksek gerçek pozitif oranı %88,71'dir. Önerilen LSTM modeli ise, belirli bir test seti için %95 doğruluk oranıyla son akademik başarıyı tahmin edebilmektedir. Erken bir uyarı sistemi olarak, önerilen yöntemlerin, herhangi bir dönemde öğrencinin başarısız olma riskini azaltmayı sağlayan tatminkâr tahminler sağladığı görülmüştür. Bu sistemin, bir öğrenci bilgi sistemine entegre edildikten sonra öğrencilerin performansını artırabileceğini öngörüyoruz.

Anahtar Kelimeler: Tahmin, Eğitimsel Veri Madenciliği, Akademik Performans, RNN, LSTM, GRU.

SUMMARY

Early prediction of the status of graduation or non-graduation of students at risk during normal education is important for higher education institutions. Graduation prediction helps advisors to provide the right support after discovering factors relating to students' final academic success. In this thesis, information about deep learning integration based on time series models is given in order to analyze the effects of academic factors on students' final performances. For this purpose, recurrent neural network (RNN), long short-term memory (LSTM) and gated recurrent unit (GRU) network models have applied on the course records of 200 students from the computer engineering program. Then, sigmoid and / or linear activation function has applied, and separate models have recorded for the first, second, third, fourth, fifth and sixth periods of the training process. As a semester-wise prediction methodology, as the status of graduation or non-graduation during normal education is driven by multiple factors, different have been considered. To effectively predict students' graduation or non-graduation during normal education, the most appropriate hyper parameters were determined for the networks we use. These hyper parameters are the students' weighted grade point average, English score, gender, university order of attendance, absenteeism rate, and compulsory course grades have taken for each semester. These hyper parameters are the students' grade point average, English grade, gender, preference order, non-attend rate, and compulsory course grades have taken until that time for each semester. Following five-fold cross-validation, the overall (six-term average) accuracy rates for RNN, GRU, and LSTM were found to be 81.07%, 85.65%, and 84.41%, respectively. Also, for students in the sixth semester, the proposed LSTM model achieves a specificity (true negative rate) of 87,12% when discovering students at risk, whereas the highest recall accounted for is 88,71%, as determined by the GRU model in terms of predicting students' success. In addition, the proposed LSTM model can predict final academic success with a 95% accuracy rate for the specific test set. As an early alert system, the proposed methods provide satisfactory predictions that are useful in diminishing the risk of student failure during any semester. We anticipate that this system may improve students' performance once it has been integrated into a student information system.

Keywords: Prediction, Educational Data Mining, Academic Performance, RNN, LSTM, GRU.

TEŐEKKÜR

Tez alıŐmalarım sűresince, deęerli fikirleri ile beni yűnlendiren tez danıŐmanım Sn. Dr. Őęr. Ŭyesi Uęur Gűrel'e kıymetli tecrűbelerinden faydalandıęım Sn. Dr. Őęr. Ŭyesi Nihat ADAR ve Sn. Dr. Őęr. Ŭyesi Őahin IŐIK'a, manevi desteklerini esirgemeyen ok deęerli anneme ve babama, her zaman varlıęıyla beni motive eden sevgili eŐime teŐekkűr ederim.

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	vi
SUMMARY	vii
TEŞEKKÜR	viii
İÇİNDEKİLER	ix
ŞEKİLLER DİZİNİ	xi
ÇİZELGELER DİZİNİ	xii
SİMGELER VE KISALTMALAR DİZİNİ	xiii
1. GİRİŞ VE AMAÇ	1
2. LİTERATÜR ARAŞTIRMASI	4
3. YÖNTEM VE ARAÇLAR	9
3.1. Makine Öğrenmesi	9
3.1.1. Denetimli öğrenme	9
3.1.2. Denetimsiz öğrenme	10
3.2. Yapay Sinir Ağları	10
3.3. Yapay Nöronlar	10
3.4. Derin Öğrenme	12
3.5. Aktivasyon Fonksiyonu	13
3.5.1. Doğrusal fonksiyon	14
3.5.2. Sigmoid fonksiyon	14
3.6. Tahmin Oluşturmada Kullanılan Araçlar	15
3.6.1. Tekrarlayan sinir ağları (recurrent neural network)	16
3.6.2. Uzun kısa süreli bellek (long short term memory)	19
3.6.3. Geçitli tekrarlayan birimler (gated recurrent unit)	20
4. DENEYSEL ÇALIŞMALAR	22
4.1. Veri Toplama ve Ön Hazırlık Aşaması	26
4.2. Performans Değerlendirmesi	31
5. BULGULAR VE TARTIŞMA	38

İÇİNDEKİLER (devam)

	<u>Sayfa</u>
6. SONUÇ VE ÖNERİLER	41
KAYNAKLAR DİZİNİ.....	42
EK AÇIKLAMA-A: ESOGÜ Fen ve Müh. Bilimleri Bilimsel Araştırma ve Yayın Etiği Kurulu Belgesi	46

ŞEKİLLER DİZİNİ

<u>Sekil</u>	<u>Sayfa</u>
3.1. Yapay sinir ağının yapısı	11
3.2. Doğrusal fonksiyon	14
3.3. Sigmoid fonksiyon	15
3.4. Tekrarlayan sinir ağı	16
3.5. Tekrarlayan sinir ağının açılmış hali	17
3.6. RNN modeli	17
3.7. LSTM modeli	19
3.8. GRU modeli	21
4.1. Önerilen çerçevenin genel görseli	23
4.2. Matlab'da Ön İşleme Adımları	29
4.3. ROC eğri analizi açısından performans değerlendirmesi.....	35
4.4. Kullanılan ağların çalışma süresi karşılaştırması.....	36

ÇİZELGELER DİZİNİ

<u>Çizelge</u>	<u>Sayfa</u>
4.1. Her dönem için kullanılan özellikler.....	28
4.2. Not kodu dönüşümü.....	30
4.3. Derin öğrenme tabanlı model için, dönem başına çapraz geçerlilik doğruluğu (%)....	32
4.4. Ağların normal eğitim süresinde genel mezuniyet tahmini performansı	33
5.1. Bazı önemli yöntemlerle performans karşılaştırması.....	38

SİMGELER VE KISALTMALAR DİZİNİ

<u>Kısaltmalar</u>	<u>Açıklama</u>
RNN	Recurrent Neural Network (Tekrarlayan Sinir Ağı)
LSTM	Long Short-Term Memory (Uzun Kısa Süreli Bellek)
GRU	Gated Recurrent Units (Geçitli Tekrarlayan Birim)
VM	Veri Madenciliği
NBC	Naïve Bayes Classifier (Naïve Bayes Sınıflandırıcısı)
SMOTE	Synthetic Minority Over-sampling Technique (Sentetik Azınlık Aşırı-Örnekleme Tekniği)
NB	Naïve Bayes
DTC	Decision Tree Classifier (Karar Ağacı Sınıflandırıcısı)
ID3	Iterative Dichotomiser
YSA	Yapay Sinir Ağları
DT	Decision Tree (Karar Ağacı)
FGA	Fuzzy Genetic Logic (Bulanık Genetik Algoritma)
SMO	Sequential Minimal Optimization (Ardaşık Minimal Optimizasyon)
BLSTM	Bidirectional Long Short-Term Memory (İki yönlü Uzun Kısa Süreli Bellek)
ND-A	Nanodegree-A
ND-B	Nanodegree-B
VLE	Virtual Learning Environment (Sanal Öğrenme Ortamı)
AI	Artificial Intelligence (Yapay Zeka)

SİMGELER VE KISALTMALAR DİZİNİ (devam)

<u>Kısaltmalar</u>	<u>Açıklama</u>
WEKA	Waikato Environment for Knowledge Analysis (Waikato Bilgi Analizi Ortamı)
YÖK	Yüksek Öğretim Kurumu
YKS	Yükseköğretim Kurumları Sınavı
RAM	Random Access Memory (Rasgele Erişimli Bellek)
GNO	Genel Not Ortalaması
GPU	Graphics Processing Unit (Grafik İşlem Birimi)
ROC	Receiver Operating Characteristics (Alıcı Çalışma Özellikleri)
AUC	The Area Under The Curve (Eğri Altında Kalan Alan)
TPR	True Positive Rate (Gerçek Pozitif Oranı)
TNR	True Negative Rate (Gerçek Negatif Oranı)
TP	True Positive (Gerçek Pozitif)
FP	False Positive (Yanlış Pozitif)
TN	True Negative (Gerçek Negatif)
FN	False Negative (Yanlış Negatif)

1. GİRİŞ VE AMAÇ

Akademik başarıyı tahmin eden sistemler, yükseköğretim kurumlarında daha iyi bir eğitim sağlanmasına katkıda bulunabilir. Akademik tahmin sistemleri, öğrencilerin mezuniyet durumlarını tahmin ederek, akademik başarısızlığa sebep olabilecek, akademik başarıyı artırabilecek durumlar hakkında fikir edinmemizi sağlayabilir. Bu sistemler öğrenci için erken bir uyarı sistemi oluştururken eğitmen için ise öğrencisinin durumunu önceden ve geniş bir açıdan görmesine olanak sağlar. Kısaca akademik başarı tahmini, öğrencilere ve eğitmenlere, öğrencinin mezuniyet durumu hakkında, öğrenci mezun olmadan bilgi veren bir tahmin sistemidir diyebiliriz.

Veri Madenciliği (VM), kısaca mevcut verilerden, önceden bilinmeyen, kullanışlı bilginin çıkarılması işlemidir (Şengür ve Tekin, 2013). Öğrenmeyi geliştirmek için eğitim sistemlerine söz konusu bilgi çıkarma işlemlerini uygulamak, eğitim sistemlerinden faydalı veriler elde etmeyi, eğitim sistemini geliştirmeyi sağlayabilir. Veri madenciliği teknikleri uygulamak, eğitmenin öğretme ortamını geliştirirken vereceği kararlara pedagojik bir destek de sağlayabilir (Şengür ve Tekin, 2013).

Eğitimsel veri madenciliğinde güncel yönelim, öğrencilerin performansını analiz etmenin yanı sıra yeni stratejiler belirlemek ve eğitim planlamasını geliştirmek adına öğrencilerin ham verilerinden anlamlı bilgiler çıkarmak için eğitim kurumlarına yapay zeka araçlarını entegre etmek yönündedir (Özdemir, 2018).

Bu arada, eğitimsel veri madenciliği verileri beklentileri karşılamak için öğrenme kalitesini, mesleki kabulü ve eğitim politikalarının güncellenmesini geliştirebilir. Veri madenciliği teknikleri kullanılarak bilgileri filtrelemenin büyük avantajları vardır. Bunlardan biri öğrencilerin sınıftaki motivasyonunu keşfetmektir. Bir diğeri, öğrencilerin öğrenme performansına göre öğrencilere ders önerisi yapılabilir. Ayrıca, öğrencilerin faaliyet profilini çıkarmak, risk altındaki öğrencilerin erken tanımlanması için yararlı olur. Bununla birlikte performans düşme sebeplerinin üstesinden gelmek öğrencilerin ihtiyaçlarını karşılamada daha hayati öneme sahiptir.

Bu çalışmada bilgisayar mühendisliği programından 200 öğrencinin ders kayıtları üzerinde deneyler yaparak, öğrencilerinin normal eğitim süresinde mezuniyet olup olamama durumlarını, mezuniyet öncesi tahmin etmek amaçlanmıştır. Böylece alınabilecek önlemler için erken hareket edilebilir.

Sözü geçen 200 öğrenci, Eskişehir Osmangazi Üniversitesi Mühendislik Mimarlık Fakültesi Bilgisayar Mühendisliği öğrencilerinden 2009-2013 yılları arasında üniversiteye giriş yapmış öğrencilerdir. Anlamlı sonuçlar almak için, verilerinde eksiklik olan öğrenciler çıkarılarak veri bu 200 sayısına indirgenmiştir.

2009-2013 yılları arası verilerin alınma nedeni ise 2009 yılı öncesi verilerde eksiklikler ve bazı derslerin değişmiş veya farklı olması iken 2013 yılı sonrası veriler için ise 2014 yılında üniversiteye giriş yapan öğrencilerin genellikle hazırlık ve dört yıllık lisans eğitimiyle birlikte 2019 da mezun olması gerektiği durumudur. Çalışmaya 2019 yılında başladığından ve deney sonuçlarımızdaki tahmin durumumuzu, mezun öğrencilerin durumlarıyla karşılaştırdığımızdan 2013 sonrası veri bizim için henüz test edilebilir değildir. Bu 200 öğrenciden dört yıllık eğitim sürecinde mezun olmayı başarabilen öğrenci sayısı 126 iken, mezun olamayan öğrenci sayısı 74'tür. Bilgisayar mühendisliği öğrencilerine bağlı kalmamızın sebebi ise farklı bölümleri dahil ettiğimizde, farklı derslerin parametrelerini ortak parametre olarak kullanamayacak oluşumuzdur.

Her ders dönemi öğrencinin son durumuna etki eden faktörler arttığından, her dönem için ayrı ayrı deneyler yapılması planlanmıştır. Böylece her dönem sonunda başarılı ve başarısız olan ders notları kullanılarak, öğrencilerin normal eğitim süresinde mezun olup olmadıkları tahmin edilmiştir. Sonuçta bir dönem ders almış biri ile altı dönem ders almış birinin normal eğitim süresinde mezun olup olamama durumunu tahmin etmenin, farklı sonuçlar oluşturması beklenir.

Ele alınan dönem sayısı altıdır. Hazırlık notu temel parametre olarak alındığından ve hazırlıkta teknik dersler görülmediğinden hazırlık dönemleri dahil değildir. Son sınıf ise daha çok bitirme tezi ağırlıklı ve seçmeli ders yoğunluklu dönemler olduğu için dahil edilmemiştir. Kısaca birinci, ikinci ve üçüncü sınıfın dönemleri baz alınarak altı farklı dönem için deneyler yapılmıştır.

Genel not ortalaması (GNO), hazırlık İngilizce puanı, cinsiyet ve tercih sırası altı dönem için temel parametrelerdir. Birinci dönem için temel parametreler dışındaki diğer parametreler matematik 1, fizik 1, kimya, programlamaya giriş, programlamaya giriş laboratuvar, ileri okuma ve yazma (İngilizce) ders notları olarak belirlenmiştir. İkinci dönem için temel parametreler, birinci dönemin ders notu parametreleri ve ikinci dönemin kendi ders notu parametreleri olarak belirlenmiştir. Bu şekilde her dönem için parametre sayısı birbirine katlanarak artmaktadır.

Her dönem için sırasıyla 11, 17, 24, 30, 35 ve 39 adet parametre belirlenmiştir. Parametrelerin tüm öğrenciler için ortak olması gerektiğinden ders notu parametreleri belirlenirken zorunlu ders statüsünde olan dersler kullanılmıştır. Güncel derin öğrenme modellerinden Tekrarlayan Sinir Ağı (RNN), Uzun Kısa Süreli Bellek (LSTM) ve Geçitli Tekrarlayan Birim (GRU) sinir ağı modelleri kullanılmıştır. Bu modeller zaman serisine dayalı, uzun süreli bağımlılıkları ezberleyebilen derin öğrenme araçlarındandır.

2. LİTERATÜR ARAŞTIRMASI

Literatüre baktığımızda bir üniversitedeki belirli bölümlerde akademik başarısızlık nedenlerini ele almak için, veri madenciliği kavramına dayanan birçok modelleme tekniği geliştirildiği görülür.

Marbouti vd. (2016) çalışmalarında, risk altındaki öğrencileri tanımlamak için gerçekleştirilen tahmin stratejilerinde, belirli bir dersle ilgili standartlara dayalı not verme süreci kullanılmıştır. Tahmin modelleri, dönem boyunca kaydedilen dönem içi performans verilerine dayandırılmıştır. Modellerinde, belirli bir dönemde kaydedilen performans puanları, bir tahmin sistemi oluşturmak için kabul edilmiştir. Özellik seçimi kavramı, veri miktarını azaltmak, aynı zamanda modeli genelleştirmek ve doğruluğu artırmak amacıyla gerçekleştirilmiştir. Yedi farklı model üzerinde deneyler yaptıktan sonra, Naïve Bayes Sınıflandırıcısının (NBC) ve üç modelden oluşan bir topluluk modelinin (NBC, Destek Vektör Makinesi ve K-En Yakın Komşu) diğer modellerden daha iyi tahminler verdiği görülmüştür. Veri seti 780 eğitim ve 1413 test örneğidir. En iyi doğruluk oranı, topluluk modeline göre risk altındaki öğrencileri belirlemede %92, öğrencilerin başarısını doğrulamak için tahmin doğruluğu ise %85 olduğu görülmüştür.

Başka bir çalışmada, Marquez-Vera vd. (2011) tarafından, öğrencilerin nihai performansı hakkında tahminler üretmek için bazı veri madenciliği teknikleri uygulanmıştır. Sistem, Meksika'daki Zacatecas Özerk Üniversitesi'nden 670 ortaokul öğrencisinin simülasyonlarını yaparak 10 farklı sınıflandırma algoritmasının performans değerlendirmesine dayandırılmıştır. Değerlendirilen veriler dengesiz bir formda olduğu için, işlenmiş sınıfın en yakın komşularından yola çıkarak sentetik özellikler üretmek için denetimli bir özellik seçim yöntemi olan Sentetik Azınlık Aşırı-Örnekleme Tekniği (SMOTE) algoritması kullanılarak, verilerin bir özellik seçim metodolojisi ile yeniden dengelenmesi için çaba sarf edilmiştir. Sonuçlar, sırasıyla dengeleme ve maliyete duyarlı durumlarda deneyler yapılması durumunda ADTree sınıflandırması ile %97,7, SimpleCart sınıflandırması ile %97,2 doğruluk oranında başarılı sağlamıştır.

Farklı bir bakış açısıyla Guarín vd. (2015) tarafından, Naïve Bayes (NB) ve Karar Ağacı Sınıflandırıcısından (DTC) geri dönen iki modeli, başlangıçtaki akademik bilgiler (örneğin lise türü, giriş türü), demografik ve sosyo-ekonomik bilgiler (kabul yaşı, cinsiyet, memleket) ve akademik potansiyel (kabul puanı/puanları) ile ilgili geçmiş akademik kayıtlara dayanarak öğrencilerin akademik statü kaybını değerlendirmek için kabul edilmiştir. Modelin sağlamlığı, 1532 ikinci sınıf öğrencisinde, NB tarafından bulunan %85 doğruluk skoruyla doğrulanmıştır.

Ayrıca, Altujjar vd. (2016) lisans programında kız öğrencilerin akademik performansını etkileyen kilit derslerin yanı sıra öğrencilerin performansını araştırmıştır. Sistemin performansı, 75 eğitim örneği iken geri kalanlar test amaçlı olmak üzere 100 öğrencinin geçmiş kayıtlarına dayanarak değerlendirilmiştir. Iterative Dichotomiser'e (ID3) dayanan bir model, birinci, ikinci ve üçüncü derece öğrenciler için sırasıyla %68, %80 ve %76 doğruluk puanı sağlamıştır.

Öğrencilerin davranış özellikleri ile akademik başarı arasında doğrudan bir bağlantı olup olmadığını araştırmak için Amrieh vd. (2016), Yapay Sinir Ağı (YSA), NB ve Karar Ağacı (DT) gibi farklı bağımsız sınıflandırıcıların yanı sıra, çoğunluk oylama stratejisinin ötesinde çalışan bir topluluk kuralına dayanan bir tahmin sistemi oluşturmuştur. 500 öğrenci üzerindeki simülasyonlar sonucunda, topluluk modelinin 500 öğrenci için %75,60'lık bir doğruluk oranı sağlamasına karşın DT modelinin 25 test örneği için neredeyse %80 başarı elde ederek diğerlerinden daha iyi performans gösterdiği görülmüştür. Ele alınan özelliklerin, demografik, sosyo-ekonomik ve akademik geçmişle olduğu kadar davranış özellikleriyle de ilgili olduğu tespit edilmiştir.

Lisans ve yüksek lisans öğrencilerinin performanslarına ilişkin erken bir tahmin çerçevesi olarak Hamsa vd. (2016), ilk akademik bilgilerin yanı sıra geçmiş akademik özellikleri de göz önünde bulundurularak bağımsız iki model önermiştir. Bu iki model dışında, 120 lisans ve 30 yüksek lisans öğrencisinin risk tespiti için %80 anlamlı bir doğruluğa ulaşan DT ve Bulanık Genetik Algoritma (FGA) uygulaması kullanılmıştır.

Baars vd.'nin (2017) çalışmasında, lojistik regresyon (gerileme) analizi yönteminin etkisi, 1819 tıp öğrencisi hakkında tahminlerde bulunmak için değerlendirilmiştir. Sistemin

performansı %84,50 gerçek pozitif oranı ve %66,67 gerçek negatif oranı olarak kaydedilmiştir.

Yine, Pitts vd. (2017), 612 öğrencinin son başarısını tahmin etmek için OLS regresyon modelinin potansiyel kabiliyetini araştırmıştır. Araştırma sonuçları, her ne kadar öğrenci başarı tahmini ile ilgili tüm alanlara ve tüm sorulara cevap vermese de genel eğitim kursları alt kümesinde, öğrencilerin belirli bir not ortalamasını almalarının gerektiği herhangi bir kurum tarafından göz önünde bulundurulması kuvvetle muhtemel olarak düşünülen bir çalışma haline geldiği görülmüştür.

Bir başka çalışmada, Helal vd. (2018) öğrencilerin performans düzeyini tahmin etmek için akademik özelliklerin katkılarını analiz etmiştir. İki kara kutu (NB ve Ardışık Minimal Optimizer (SMO) yöntemleri) ve iki beyaz kutu (J48 ve JRip) sınıflandırma yöntemiyle, lisans öğrencilerinin performans gelişimini hangi faktörlerin etkileyeceğini belirleyen bir tahmin sistemi kurulmuştur. Analizler sonucunda, öğrenci alt popülasyonlarının örnekleri kullanılarak eğitilen modellerin, tüm veri örneklerini kullanarak oluşturulan modellerden daha iyi performans gösterdiği gözlemlenmiştir. Yapılan deneyler, hiçbir yöntemin her açıdan üstün performans sağlamadığını göstermiştir. Tüm bunlarla birlikte kural tabanlı ve ağaç tabanlı yöntemlerin daha yüksek oranda yorumlanabilir modeller oluşturacağı düşünülmüştür.

Yukarıda belirtilen yöntemler, geleneksel yöntemler olarak adlandırılır. Bu stratejilerin bir zayıflığı, kullanılan sınırlı sayıda veri nedeniyle, kullanılan modelleme yöntemlerinin genelleştirilememesidir.

Derin bir öğrenme yaklaşımı kullanan bir çalışma olarak ise Kim vd. (2018) tarafından, iki yönlü uzun kısa süreli hafızaya (BLSTM) dayanan GritNet adında derin öğrenme temelli bir algoritma kullanılarak öğrenci performansını tahmin etme problemi ele alınmıştır. Çalışmalar sırasında mezuniyet tahmin etme için Udacity öğrenci verileri kullanılmıştır. Öğrencilerin belirli bir periyottaki öğrenme aktivitesi bilgisi GridNet algoritmasına ham bir girdi olarak verilmiştir. Oluşturulan GridNet modelinde, geçmiş öğrenci etkinliklerinin analiz edip gelecekteki bir olayı tahmin etmek amaçlanmıştır. Udacity'nin iki farklı programı olan Nanodegree-A (ND-A) ve Nanodegree-B (ND-B)

öğrenci veri tabanı üzerinde karşılaştırılmıştır. Bunun nedeni, bu iki programın birçok yönden birbirinden ayrı bilgilere sahip olmasıdır. ND-A için 07.03.2017 ve 30.09.2017 tarihleri arası 1853 öğrenci; ND-B için 20.06.2016 ve 30.09.2017 tarihleri arası 8301 öğrenci kullanılmıştır. Yapılan deneyde her iki yön başına 128 hücre boyutuna sahip bir BLSTM kullanılmıştır. BLSTM çıktısına %10 ila %20 arası bir düşme uygulanıp toplu iş büyüklüğüne 32 değeri verildiğinde her iki veri kümesinin de iyi çalıştığı gözlemlenmiştir. Deneyler yapılırken, lisans ve lisansüstü sayı oranları birbirine yakın olan kategorilerle beş katmanlı bir çapraz doğrulama kullanılmıştır. Deney sonuçlarında GritNet yönteminin etkilerini kanıtlamak için gerçek pozitif oranının, yanlış pozitif orana çizildiği bir Alıcı Çalışma Özellikleri (ROC) grafiği elde edilmiştir. Bu bilgilere göre GritNet yönteminin diğer temel yöntemlere göre, ND-A’da bir haftalık süreçte yaklaşık %5,3, ND-B’de üç haftalık süreçte yaklaşık %7,7 daha fazla doğrulukla çalıştığı görülmüştür.

Bir başka derin öğrenme yaklaşımı olarak, Waheed vd. (2020) tarafından, sanal öğrenme verileri kullanılarak, öğrencilerin öğrenme süreçleriyle ilgili risklerini önceden tahmin edebilmek için derin öğrenme temelli bir yapay sinir ağı kullanılmıştır. Yapılan çalışmada, kurumlara pedagojik destek vermek ve eğitimin sürdürülebilir olmasında bir karar destek sistemi rolü edinmek amaçlanmıştır. Araştırmada, OULA platformundan alınan, 9 aylık bir kurs sürecinde 32593 öğrencinin verileri kullanılmıştır. Sanal öğrenme ortamındaki demografik öğrenci bilgileri ve derslerin her bir öğrencinin üç aylık periyotlardaki tıklama verileri benimsenerek iki katlı bir analiz yapılmıştır. Ortaya çıkarılan, derin öğrenme temelli yapay sinir ağı modeliyle, öğrencinin bir kurstan erken ayrılma durumunun hesaplanması, öğrencilerin çeşitli başarı ölçütlerine göre performans kıyaslamaları, dersten çekilebilecek öğrencilerin analizi vs. gibi konulara alt yapı oluşturulmuştur. Deneylerde, öğrencilerin demografik bilgileri ve sanal öğrenme ortamından elde edilen verilerin dört farklı araştırma kategorisinde, destek vektör makinesi, lojistik regresyon ve derin öğrenme tabanlı yapay sinir ağı yöntemleriyle çapraz doğrulanması yapılmıştır. Deneylerde en iyi doğruluk oranı sonuçları derin öğrenme tabanlı yapay sinir ağı modelinden elde edilmiştir.

Derin bir öğrenme yaklaşımı kullanmanın erken bir alarm sistemi olarak akademik başarıya sağlam ve uygun çözüm sunacağı düşünülmektedir. Sinir ağı temelli tahmin çerçeveleri, sadece değerli ve doğru tahminler üretmekle kalmaz, aynı zamanda iyi genelleme yeteneği de sağlar (Bozüyük vd., 2005). Bu, lisans öğrencilerinin nihai performansını, özellikle de normal eğitim süresinde mezun olma veya olmama durumlarını tahmin etmek için güçlü sinir ağı yaklaşımlarını kullanmamıza olanak tanır.

Tezin geri kalanı şu şekilde düzenlenmiştir: Bölüm 3'te, sistemde kullanılan yöntem ve araçlar anlatılmaktadır. Bölüm 4'te, yapılan deneyler, bölüm 5'te ise kullandığımız yöntemin faydaları ve diğer çalışmalardan farkları üzerinde durulmuştur. Son olarak bölüm 6'da sonuç ve önerilere yer verilmiştir.

3. YÖNTEM VE ARAÇLAR

Tez kapsamında kullanılan derin öğrenmeye dayalı akademik durum tahmini sistemi, RNN, LSTM ve GRU gibi popüler mimarilere dayanmaktadır. RNN, LSTM, GRU tekrarlayan yapay sinir ağlarındandır. Tekrarlayan yapay sinir ağları denetimli bir öğrenme türüdür. Denetimli öğrenme ise makine öğrenmesinin alt kollarından biridir. Bu bölümde, makine öğrenmesi, denetimli öğrenme, denetimsiz öğrenme, yapay sinir ağları, yapay nöronlar, derin öğrenme, aktivasyon fonksiyonları, RNN, GRU, LSTM modelleri gibi konular açıklanmıştır.

3.1. Makine Öğrenmesi

Makine Öğrenmesi, bir makinenin büyük veri setlerini kullanmayı öğrenmesidir ve bilgisayarların kendi başlarına öğrenmelerini sağlar. Makine öğrenmesi matematiksel ve istatistiksel yöntemler kullanır. Bu tür öğrenme, büyük veri setlerini kolayca işleyebilen modern bilgisayarların işlem gücünden yararlanır. Yapay zekaya göre daha yeni bir kavramdır ve yapay zekanın alt koludur. Makine öğrenmesinin temel amacı doğru tahminler yapmaktır (Akay, 2018).

İstenilen bilgileri elde edip, tahmin yapmak için makine öğrenme algoritmaları kullanılır. Bu algoritmalar genellikle verilerin öğrenme yöntemlerine göre denetimli öğrenme ve denetimsiz öğrenme olarak iki gruba ayrılır (Fırat ve Güngör, 2004).

3.1.1. Denetimli öğrenme

Girdinin ne olduğunu ve çıktının ne olacağını söylediğimiz öğrenme biçimidir. Yani öğreticinin her bir girdi için beklenen doğru çıktıyı hedef olarak ilgili ağa vermesidir (Saraç, 2012). Çeşitli algoritmalar, girdileri istenen çıktılara eşleyen bir fonksiyon üretir (Kotsiantis vd., 2007). Örnek çıktı ile ağ çıktısı karşılaştırılır, ağın hatası bulunur. Çıktı, istenen sonuca en yakın olana kadar hesaplamalar tekrar ayarlanır ve işlem hatanın minimize olması için tekrar eder (Keleşoğlu, 2009).

Denetimli öğrenmede veri setinin büyük bölümü eğitim veri seti olarak belirlenir ve bu eğitim veri setinde öğrenme gerçekleşir. Daha sonra geriye kalan veri seti, test veri seti olarak belirlenir ve test veri setiyle eğitim veri seti denetlenir (Akay, 2018).

3.1.2. Denetimsiz öğrenme

Belirli bir yapısı olmayan veri setlerini kullanan makine öğrenimidir. Ağa sadece giriş veri grubu verilir, ağ bu veri grubuna uyumlu çıkış değeri üretmek için kendisini düzenler (Keleşoğlu, 2009). Denetlenmemiş öğrenmeyi kullanarak bir yapay zekayı eğiterseniz, yapay zekaya verilerin mantıksal sınıflandırmasını yapma izin verirsiniz. Denetimsiz öğrenmenin bir örneği, bir e-ticaret web sitesi için tahmin yapan yapay zeka örnek verilebilir. Çünkü burada etiketli bir girdi ve çıktı veri seti kullanılarak öğrenilmez. Bunun yerine girdi verileri kullanarak kendi sınıflandırmasını oluşturur. Hangi tür kullanıcıların daha fazla farklı ürün alabileceklerini söyler (Şimşek, 2019).

3.2. Yapay Sinir Ağları

Sinir ağları canlı kompleks organizmalardaki biyolojik sinir ağlarından ilham alan denetimli bir makine öğrenmesi yöntemidir. Bu ağlar matematiksel yapılandırılmış model sınıfı olarak görülmektedir. Yapay Sinir Ağları (YSA), gerçek sinir sisteminin çalışma prensiplerini basit şekilde taklit etmeye çalışmaktadır (Ersoy ve Karal 2012).

YSA, zaman serileri tahmini, görüntü işleme, sınıflandırma, regresyon analizi, veri işleme, örüntü tanıma, karar verme, sahtekarlık tespiti, astronomi, süreç kontrol, bilişsel tanıma gibi alanlardaki sorunları çözmek için yaygın olarak kullanılmaktadır (LeCun vd., 2015).


3.3. Yapay Nöronlar

İnsan beyinde yaklaşık 1 milyar nöron bulunmaktadır (Cherry, 2019). Henüz insan beyni kadar kapsamlı olmasa da yapay sinir ağının temel elemanı da biyolojik nöronlarla bazı benzerlikler gösteren bu sanatsal nöronlardır. Biyolojik bir nöron diğer nöronlardan gelen sinyalleri dendritleriyle toplar; daha sonra bu sinyaller toplanır ve çıktı bir hücre tarafından üretilir.

Benzer şekilde, yapay nöron durumunda, ayrı ayrı ağırlıklı girdiler, sanatsal nöronların vücuduna iletilir. Vücut, ağırlıklı girişleri ve tahminleri toplar. Ardından toplama, tanımlanan transfer fonksiyonuna göre işlenir. Temel bilişim nöron modelinin ilk resmi tanımı, McCulloch ve Pitts (1943) tarafından tanımlanmış ve formüle edilmiştir. Bu açıklamalarda, çıkış fonksiyonu bir basamak fonksiyonudur. Bu, belirli bir eşik değerinin karşılandığı zaman, çıktı bir değer alır; diğer durumda çıktı sonucu değeri sıfırdır.

Nöronlar üç farklı katmana ayrılır:

- 1) Giriş Katmanı
- 2) Gizli Katmanlar
- 3) Çıkış Katmanı



Şekil 3.1. Yapay Sinir Ağının Yapısı

Giriş katmanı giriş verilerini alır. Gizli katmanlar girdilerimizde matematiksel hesaplamalar yapar. YSA oluşturmadaki zorluklardan biri, her bir katman için nöronların sayısının yanı sıra gizli katmanların sayısına da karar vermektir. Derin Öğrenmedeki “Derin”, birden fazla gizli katmana sahip olmayı ifade eder. Çıkış katmanı, çıktı verilerini döndürür. Bahsedilen sürecin gösterimi Şekil 3.1’de mevcuttur.

Nöronlar arasındaki her bağlantı bir ağırlık ile ilişkilidir. Bu ağırlık, girdi değerinin önemini belirler. Her nöron bir aktivasyon fonksiyonuna sahiptir. Aktivasyon fonksiyonunun amaçlarından biri nöronun elde edilen çıktıları “standartlaştırmak” tır. Bir veri kümesi sinir ağının tüm katmanlarından geçtikten sonra, çıktı katmanından sonuç olarak döner. Yapay sinir ağını eğitmek için büyük bir veri setine ve yüksek hesaplama gücüne ihtiyaç vardır.

3.4. Derin Öğrenme

Derin öğrenme bir makine öğrenme yöntemidir ve insanı taklit eden bir öğrenme biçimidir. Makine öğrenmesinden temel farkı; makine öğrenmesinde manuel işlemler gerçekleştirilirken, derin öğrenmede tüm sistemin otomatize edilmesi hedeflenmektedir. Makine öğrenmesinden bir diğer farkı aynı anda birden çok katmanda işlem yapabilmesidir. Derin öğrenme, verilen bir veri kümesi ile çıktıları tahmin edecek yapay zekayı eğitmemize olanak sağlar. Yapay zekayı eğitmek için hem denetimli hem de denetimsiz öğrenme kullanılabilir (Şeker vd., 2017).

Derin öğrenmede hedef, alternatif senaryolar karşısında bilgisayar modeli çözüm üretebilmesi adına, bir yazılımı adım adım kurgulamak yerine bu kurguyu bilgisayar modelinin yapabilmesi için zemin hazırlamaktır. Çünkü yazılımı yazan kişinin üretebileceği senaryo kısıtlıdır. Oysa derin öğrenmeye tabi tutulan makineler çok fazla çözüm sunabilirler.

Bilgisayarın tanıyacağı nesne türleri eğitim seti halinde bilgisayara yüklenmelidir. Tanıtılmak istenen her bir nesne, ilk olarak “etiketli veri” şeklinde sisteme yüklenmelidir. İnsan vücudundaki derin sinir ağları gibi derin öğrenme algoritmaları da sebep sonuç ilişkilerini kurabilir hale gelir. Yararsız kodlar elenir, yararlı kodlar giderek daha sık ve verimli kullanılır. Derin öğrenmenin katman sayısı arttıkça, bilgisayar daha fazla beslenmekte ve daha fazla doğruluk oranları elde edilmektedir (Ayvaz, 2019).

Derin öğrenme, çoklu soyutlama seviyelerine sahip verilerin gösterimini öğrenmek için çoklu işleme katmanlarından oluşan hesaplama modellerine izin verir. Bu yöntemler konuşma tanıma, karakter tanıma, doğal dil işleme, görsel nesne tanıma, nesne algılama ve genomik gibi birçok alanda, teknolojiye önemli ölçüde katkı sağlamıştır (Anonim3, 2017).

Derin öğrenme, bir makinenin, her katmandaki gösterimi önceki katmandaki gösterimden hesaplamak için kullanılan dahili parametrelerini nasıl değiştirmesi gerektiğini göstermek için geri yayılma algoritmasını kullanarak karmaşık veri kümelerinde karmaşık yapıyı keşfeder (Schmidhuber, 2015). Derin evrimsel ağlar, görüntü, video, konuşma ve ses işlemede, tekrarlayan ağlar ise metin ve konuşma gibi ardışık veriler üzerinde etkilidir (LeCun vd., 2015).

3.5. Aktivasyon Fonksiyonu

Bir nöron biriminin aktivasyon seviyesini bir çıkış sinyaline dönüştürmek için kullanılan fonksiyona aktivasyon fonksiyonu denir (Karlık ve Olgac, 2011).


Yapay sinir ağları öğrenme sürecinde, girişleri alır, değerlendirir, aktivasyon fonksiyonundan geçirerek oluşan tepkiyi çıkışa iletir. Aktivasyon fonksiyonunun temel amaçlarından biri nöronlardan elde edilen çıktıları “standartlaştırmak” tır. Yani çıktı olarak “1”, “0” yanıtları üreterek, çıkış genliğini sınırlamak amaçlanır. Bu çıkış, eldeki tecrübeyle verilen çıkışla karşılaştırılarak hata bulunur. Bu hata azaltılarak gerçek çıkış bulunmaya çalışılır (Keleşoğlu vd., 2005). Aktivasyon fonksiyonlarından en çok tercih edilen fonksiyonlar; sigmoid, tanh, konik bölüm ve radyal taban fonksiyonlarıdır (Karlık ve Olgac, 2011).

Çalışmamızda sigmoid fonksiyonu ve doğrusal fonksiyon kullandık. Her dönem, her modelde (RNN, LSTM, GRU) kullanacağımız aktivasyon fonksiyonu olarak bu iki fonksiyondan birini veya her ikisini birden kullandık. Bu fonksiyon/fonksiyon kombinasyonlarını deneme yanılma yöntemiyle en iyi sonucu veren olarak belirledik. Aşağıda sadece kullanılan aktivasyon fonksiyonları açıklanmıştır.

3.5.1. Doğrusal fonksiyon

Doğrusal bir problemi çözmek için kullanılır. Genellikle katmanlı yapay sinir ağlarının çıkış katmanında kullanılır. Hücrenin net girdisini doğrudan hücre çıkışı olarak verir. Doğrusal aktivasyon fonksiyonunun matematiksel gösterimi denklem (3.1)'de de gösterildiği gibi $y=x$ şeklinde ifade edilir (Şanlı, 2008). Şekil 3.2'de fonksiyon gösterimi mevcuttur.

$$y = x \quad (3.1)$$




Şekil 3.2. Doğrusal Fonksiyon

3.5.2. Sigmoid fonksiyon

RNN modüllerinde kullanılan en yaygın aktivasyon fonksiyonlarından biridir (Amidi ve Amidi, 2019). Sigmoid tipi aktivasyon fonksiyonunun denklemi, denklem (3.2)'de gösterilmiştir. Sigmoid tipi aktivasyon fonksiyonunun şekli, Şekil 3.3'te de görülebileceği gibi S harfine benzemektedir. 0 ile 1 arasında değerler alır. Bir durumun olma/olmama ihtimalini bulmada 0 ile 1 arasında değerler aldığı için kullanılabilir (Sharma, 2017).

$$y = \frac{1}{1+e^{-x}} \quad (3.2)$$



Şekil 3.3. Sigmoid Fonksiyon

3.6. Tahmin Oluşturmada Kullanılan Araçlar

Bu tezin amacı, öğrencilerin normal eğitim süresinde mezun olup olamayacağını öngörebilmek ve öğrencilerin mezun olma veya olamama performansını etkileyen gizli faktörleri analiz etmek için bir tahmin sistemi oluşturmaktır.


Öğrencilerin bilgi gizliliğini ihlal etmeksizin, her dönem için ders notları, derse katılım, genel not ortalaması ve lisans düzeyine göre mezun olma ve olamama sonuçları olarak verilen bağımlı nitelikler gibi bağımsız özellikler arasındaki ilişkiyi değerlendirmek için kullanıcı dostu bir çerçeve geliştirilmiştir. Kişisel verileri korumak için, öğrencilerin, adı, soyadı, öğrenci numarası gibi özel bilgileri veri setinde bulunmamaktadır. Yukarıda tarif edilen, anonim veri setinde bulunan parametreler, sayısal değerlere dönüştürüldükten sonra her dönem için RNN, LSTM, GRU sinir ağı modellerimizle eğitilmiştir.

Önerilen sistem, çok katmanlı bir sinir ağı kavramının ötesinde çalışan sağlam bir derin öğrenme aracı olan geleneksel RNN modelinin geliştirilmiş sürümlerine dayanmaktadır (Hochreiter ve Schmidhuber, 1997; Rumelhart ve McClelland, 1986). Bir öğrenciyle ilgili ham zaman serisi verileri göz önüne alındığında, zaman serisi modelleri, geçmiş bilgiyi modellemek ve ortak özellikleri olan öğrenciler adına tahminlerde bulunmak için kullanılabilir (Hochreiter ve Schmidhuber, 1997; Cho vd., 2014). Bu noktadan yola çıkarak, zaman serisi modellerinden olan RNN, LSTM ve GRU modellerini kullanarak, öğrencilerin normal eğitim süresinde mezun olup olamayacağını tahmin eden bir sistemi oluşturduk.

3.6.1. Tekrarlayan sinir ağları (recurrent neural network)


Tekrarlayan yapay sinir ağı, tekrarlayan bir topolojiye sahip sinir ağıdır. Bu topolojide bilginin akış yönü konusunda herhangi bir kısıtlama yoktur. Bilgi geriye doğru ve aynı seviyede nöronlar arasında olabilir. Geriye doğru akış yeteneği, tekrarlayan ağların, giriş dizilerini incelemek için dahili hafızalarını kullanmalarını sağlar.

Tekrarlayan sinir ağının en genel topolojisi, her bir temel ağ bloğunun diğerlerine doğrudan her yöne doğrudan bağlandığı tam tekrarlayan bir ağıdır (LeCun vd., 2015). RNN sıralı verilerin modellenbildiği bir sinir ağı çeşididir. Başka bir deyişle sinir ağının gizli katmanında birbirini tekrar eden yapılar bulunmaktadır.




Şekil 3.4. Tekrarlayan Sinir Ağı (Burcu, 2019)

Şekil 3.4'te RNN mimarisinin tekrarlayan yapısı gösterilmektedir. Giriş parametreleri katmana gelir, bir çıkış parametresi üretir ve katman verisi diğer aşamaya taşınarak tekrarlayan öğrenme sağlanır. Şekil 3.5'te ise RNN mimarisinin açılmış hali gösterilmektedir. S harfi her bir katmanı ifade eder. Her katmanda giriş parametreleri ve bu parametrelere bağlı çıkış parametreleri bulunur. Her katman bir sonraki katmana bilgi aktarır. Katman sayısı öğrenmeyi tasarlayan kullanıcı tarafından belirlenir.



Şekil 3.5. Tekrarlayan Sinir Ağının Açılmış Hali (Burcu, 2019)

RNN modeli oldukça esneklik sunduğundan dolayı oldukça yorumlanabilir bir alandır. Bu durum RNN ile ilgili yapılacak bir çalışmada konunun daha fazla ayrıntılı hale getirilmesi gerektiğini gösterir.



Şekil 3.6. RNN Modeli

Şekil 3.6, RNN modelinin esas sürecini görselleştirmek için yönlendirilmiş bir döngü grafiğini göstermektedir. Şekil 3.6'nın sağ kısmı, RNN modelinin katlanmamış versiyonunu göstermektedir. İşlenecek n diziliş varsa, ağ n katmandan oluşur. Her RNN katmanı, S harfi ile temsil edilir.

Öğrencilerin özellikleri vektör gösterimleriyle kodladıktan sonra, aşağıdaki denklem (3.3) tarafından yönetilen doğrusal bir RNN mimarisinin durum geçişleri; (X_0, X_k, \dots, X_t) , bir zaman serisi verileri verildiğinde, ağı katmanlarına beslenir.

$$S_t = f(S_{t-1} \times W_{recursive} + X_t W_x) \quad (3.3)$$

S_t , t adımıdaki gizli durumdur. RNN modelinin “hafızası” olarak da bilinir. X_t , t adımıdaki zaman girişidir. Değeri bir skaler değer veya vektör olabilir. $W_{recursive}$ ve W_x , tüm RNN katmanları boyunca kullanılan ortak ağırlıklar olarak bilinir. Denklemde (3.3) belirtildiği gibi, gizli durum, S_t , giriş ağırlıklarından ve yinelemeli ağırlıklardan etkilenen önceki durum S_{t-1} ve giriş X_t 'ye bağlıdır.

RNN kavramında durumlar, ileriye doğru yayılmalarını (forward propagation) aktive ederek ve zamanla geriye doğru yayılmalarını (backward-propagation) güncelleyerek yinelemeli olarak kontrol edilir.

RNN modelinin ileri sürecini anlamak karmaşık olmamakla birlikte, geriye dönük sürecini, sinir ağı optimizasyonunun/iyileştirmesinin doğası gereği kaçınılmaz olarak karşılaşılan gradyan kayması ya da patlayan problemler nedeniyle anlamak biraz karmaşıktır. Eğimlerdeki (gradients) bu dengesiz dalgalanmaların üstesinden gelmek için, esnek geri yayılım (RMSprop) optimizasyonu gradyanları izlemek için uygulanabilir (Riedmiller, 1994).

Çalışmamızda her öğrencinin normal eğitim süresinde mezun olup olamama tahminine yönelik aynı işlemi tek tek yapmamız gerekliydi. Bu yüzden bir dizinin her elemanı için aynı görevi yerine getiren, kendini tekrarlayan RNN modelini kullandık. RNN modeli kullanmamızın bir başka nedeni, öğrencilerin geçmiş verilerini kullanarak çıktı üretebilecek olmamızdır. Çünkü RNN bir çıktı oluşturmak için önceki hesaplamalar hakkında bilgi toplar, hafızasında tutar ve kullanır. Ayrıca RNN modeli, her katmanda farklı parametreler kullanan geleneksel bir derin sinir ağından farklı olarak, aynı parametreleri kullanır. Bu durum, her adımda, sadece farklı girdilerle aynı görevi yerine getirmemizi sağlar. Böylece sistemin öğrenmesi gereken toplam parametre sayısı büyük ölçüde azalır.

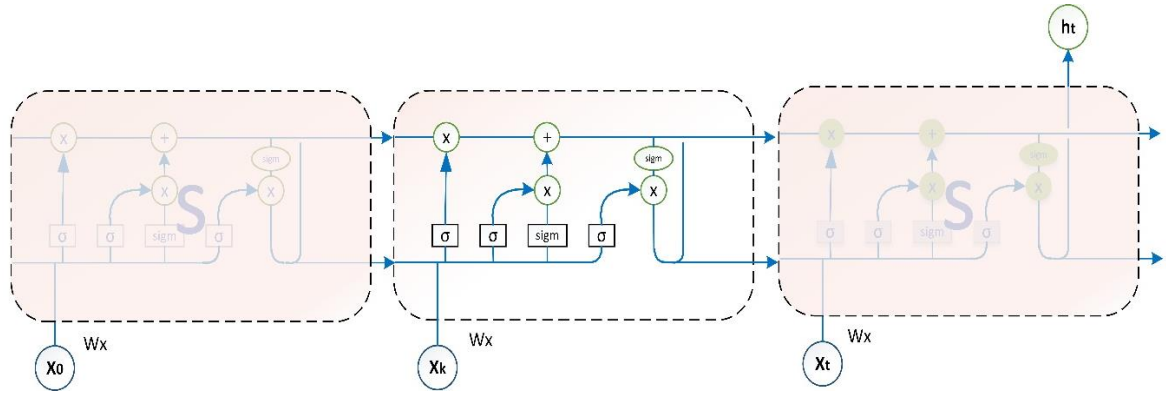
3.6.2. Uzun kısa süreli bellek (long short term memory)

Uzun Kısa Süreli Bellek, tekrarlayan yapay sinir ağlarının başka bir topolojisidir. Önemli olaylar arasındaki hem kısa hem de uzun gecikme süreleri ile zaman serilerini sınıflandırabilir ve tahmin edebilir. Uzun Kısa Süreli Bellek, bilgileri temel tekrarlayan yapay şebekelerden daha çok hatırlama yeteneğine sahiptir çünkü özel bir bellek hücresi vardır. LSTM modelleri varsayılan olarak bilgiyi uzun süre hatırlar durumdadırlar ve öğrenmek için uğraşmazlar. Uzun Kısa Süreli Belleğin giriş katmanının aktarım işlevi sigmoiddir.

LSTM üç tip kontrol kapısını içerir (Shewalkar, 2018):

- Giriş Kapısı: Bellek hücresine girişleri belirler.
- Unutma Kapısı: Saklanan hafıza değerinin ne kadarının bir sonraki zaman adımına aktarıldığını kontrol eder.
- Çıkış kapısı: Bellek hücresinin çıkışlarını düzenler.

Şekil 3.7’de LSTM modelinin zincir benzeri yapısını ve LSTM modelindeki belirli bir hafıza hücresini gösterir.



Şekil 3.7. LSTM Modeli

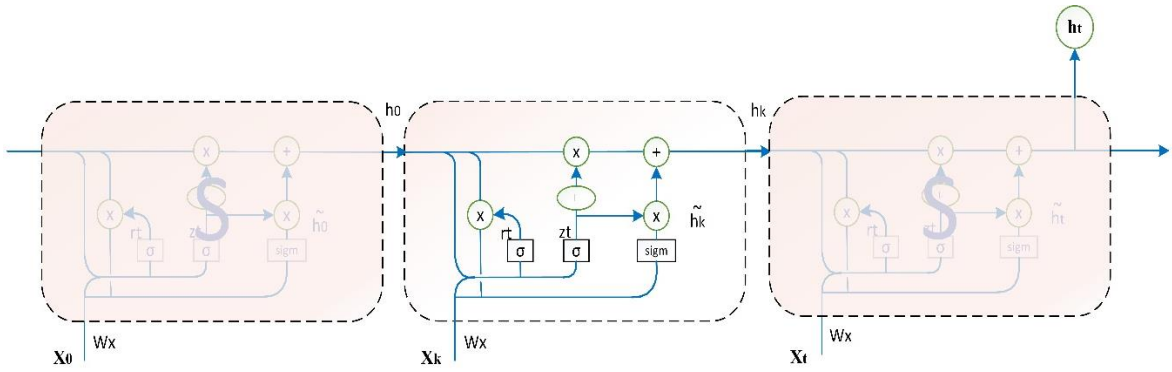
RNN eğimlerin (gradyanların) kaybolması gibi bazı sınırlamalara sahiptir. Kaybolan ve patlayan gradyanlara RNN modelinde sıklıkla rastlanır. Bunların olmasının nedeni, katman sayısına göre katlanarak azalan/artan olabilen çarpımsal gradyan nedeniyle uzun vadeli bağımlılıkları yakalamanın zor olmasıdır (Amidi ve Amidi, 2019). RNN zaman serileri, girişleri arasındaki uzun vadeli korelasyon ağın sonuna geldiğinde hatırlayamamaktadır. Bu zayıflığı gidermek için, LSTM mimarileri, RNN öğrenme mekanizmasını, bilgileri unutmaktan veya hatırlamaktan sorumlu olarak tanıtilen bir “hafıza bloğu” ile geliştirilmiştir. Bilgi taşımak için veri yolu gibi fonksiyonelliğe sahip hücre durumları vardır. Hücre durumları, sigmoid ve noktadan çarpma (pointwise multiplication) olarak bilinen iç kapılardan oluşur ve bilgileri hatırlamak veya unutmak için kullanılır, yani, sigmoid aktivasyonu sıfır çıktı verirse, çarpma işleminden sonra önceki bilgiler (S_{t-1} durumu) unutulacaktır. Sonunda, H_t çıkışı dahili bellek hücresinden tetiklenir. Bu işlem, S olarak gösterilen her bir hafıza hücresi için tekrarlanır.

LSTM modeli, RNN modelinin gelişmiş bir varyasyonudur. RNN modelinde ağır hafızası, önceki adımlarda neler olduğu hakkında bilgi toplar ancak çok fazla zaman aşamasından önceki bilgileri yakalayamaz. RNN modelinden farklı olarak, LSTM modeli, sebep sonuç ilişkisini uzun adımlarda da hafızasında tutmayı başarmaktadır. RNN’in bir varyasyonu olması ve uzun süreli geçmişe yönelik verileri RNN modelinden farklı olarak saklayabilmesi, LSTM modelini temel kullanma nedenimizdir.

3.6.3. Geçitli tekrarlayan birimler (gated recurrent unit)

Geçitli tekrarlayan birimler (GRU), tekrarlayan sinir ağlarında (RNN) bir geçiş mekanizmasıdır (Anonim2, 2019). Bir RNN çeşidi olan Uzun Kısa Süreli Belleğin (LSTM) biraz daha basitleştirilmiş bir varyasyonudur. Unutma ve giriş kapılarını tek bir “güncelleme kapısı” içinde birleştirir ve ilave bir “sıfırlama kapısı” vardır. GRU, yapı olarak LSTM modellerine benzese de değindiğimiz gibi daha basittir ve giderek daha popüler hale gelmektedir (Rana, 2016).

GRU ve LSTM modelleri arasında yakın bir ilişki bulunmaktadır. LSTM uzun vadeli bağımlılıkları olan sıra bazlı görevler üzerinde iyi çalıştığı saptanmış olmasıyla birlikte, GRU modellerinin iyi sonuç verdiği uygulamalara konuşma tanıma ve makine çevirisi birer örnektir (Chung vd., 2014). Ayrıca polifonik müzik modellemesi, konuşma sinyali modellemesi, el yazısı tanıma örnek verilebilir (Anonim2, 2019). GRU, daha az parametreye sahiptir ve LSTM modelindeki gibi bir çıkış kapısı içermez.



Şekil 3.8. GRU Modeli

GRU ağını bu kadar popüler yapan, standart LSTM ile karşılaştırıldığında sadeliği ve etkinliği gibi öne çıkan özellikleridir. Şekil 3.8'den görülebileceği gibi, GRU modeli, güncelleme ve sıfırlama kapıları olarak bilinen iki önemli denetleyici içerir.

Güncelleme geçidi, önceki birimden ne kadar bilginin çarpma işlemiyle hafıza hücresinden geçirilmesi gerektiğine karar verir. Öte yandan, sıfırlama geçidi önceki birimden gelen bilgilerle ilgili unutkanlık oranını izler. Güncelleme geçidi ve sıfırlama geçidinin, standart LSTM modelinin temelini oluşturan bilgileri hatırlamak veya unutmak gibi davrandığı söylenebilir. Yine, dahili bellek hücresinden ve öncekinden ne kadar bilginin geçirileceğini ayarladıktan sonra bir çıkış etkinleştirilecektir.

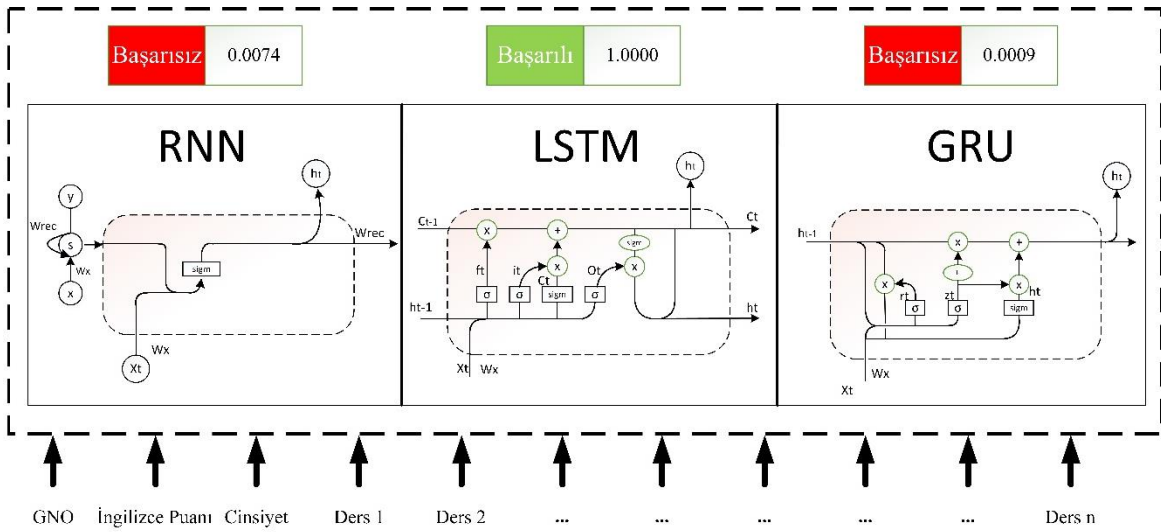
GRU modelini kullanma nedenimiz ise LSTM modelinden daha az karmaşık olan GRU modelinin performansını analiz etmektir. Her ne kadar benzer bir mimariye sahip olsalar ve uzun süreli bağımlılıklar için oldukça kilit rol oynasalar da LSTM ve GRU modelleri birbiriyle kıyaslanabilir özelliklere sahiptirler (Shewalkar, 2018).

4. DENEYSSEL ÇALIŞMALAR

Bu tez çalışmasında, öğrencilerin normal eğitim süresinde mezun olup olamama durumlarını tahmin etmek amacıyla, zaman serisine dayalı derin öğrenme araçlarının potansiyel yetenekleri araştırılmıştır. Bu amaçla, öğrencilerin akademik performanslarını tahmin etmek için, tekrar eden yapıda olmaları, uzun vadeli bağımlılıkları ezberleyebilmeleri ve aynı parametreleri kullanarak farklı girdilerle görevlerini yerine getirmeleri gibi nedenlerle RNN, LSTM ve GRU tekrarlayan sinir ağı modelleri kullanılmıştır. Sinir ağı mimarilerinin yeteneğini eşzamanlı olarak ortaya koymak adına her dönem için modeller oluşturulmuştur. Bu modelleri oluşturmak için, veri setinden her dönem için yaş, tercih sırası, genel not ortalaması, İngilizce hazırlık notu, devamsızlık oranı bilgileri her dönem kullanılmakla birlikte her dönem o zamana kadar alınmış olan zorunlu ders notları döneme binaen veri seti olarak kullanılmıştır. Her dönem için oluşturulan bu veri setleri, beş katlamalı çapraz doğrulama işlemine tabi tutularak, her adımda 160 öğrenci eğitim, 40 öğrenci test verisi biçiminde ardışık olarak her adımda bir sonraki 40 değer test verisi olacak şekilde beş adımda deneyler yapılmıştır. Her adımda ilgili veri setine RNN, LSTM ve GRU modelleri uygulanarak, sigmoid ve/veya doğrusal aktivasyon fonksiyonundan geçirilerek modeller kaydedilmiştir. Burada aktivasyon fonksiyonu, deneme yanılma yoluyla her adımda en iyi sonucu veren fonksiyon veya fonksiyonlar kullanılmıştır. Sonuç olarak, her bir dönem için birer model olmak üzere, altı RNN modeli, altı LSTM modeli ve altı GRU modeli aynı anda öğrencilerin özellikleriyle ilgili eğitim parametreleri uygulanarak üretilmiştir.

Tez çalışmasında önerilen tahmin çerçevesi, Şekil 4.1'de gösterilmiştir. Her sinir ağı mimarisi eşzamanlı olarak öğrencilerin geçmiş özellikleri hakkında ham zaman serisi verilerini alır ve eğitim sürecinden sonra bir model oluşturur. Oluşturulan model, bir öğrencinin mezun olma veya olamama profili olan bağımlı parametreler ve hedef faktörler arasındaki ilişkileri içerir.

Öğrenci başarısını tahmin ederken model çıktısı 0 ile 1 arasında değişmektedir. 0, mezun olamama anlamına gelirken, 1 mezun olma anlamına gelir. 0.5 eşiğine dayanarak, her öğrencinin normal eğitim süresinde mezun olma veya olamama durumuna karar verilir. 0.5 eşliğinden büyük çıktılar üretildiğinde mezun olma tahmini oluşurken, küçük çıktılar üretildiğinde mezun olamama tahminleri oluşur. Yani 1'e yaklaştıkça %100 mezun olmaya yaklaşırken, 0'a yaklaştığında %100 mezun olamamaya yaklaşır. Şekil 4.1.'de kullanılan tekrarlayan sinir ağı modelinin yapısı bir arada gösterilmiştir. Şekilde girdiler daha önce bahsedilen önemli eğitim parametreleri iken, üretilen çıktı ise normal eğitim süresinde mezun olup olamama durumunu yansıtan değerdir. Kırmızı renkle ifade edilen örnek çıkış değerleri, 0,5 eşliğinden küçük değerler olduğundan mezun olamama durumunu temsil ederken, yeşil renkle ifade edilen çıkış değeri ise 0,5 eşliğinden büyük olduğundan mezun olma durumunu temsil eder. Mavi renkli ok sembolleri modellere uygulanan eğitim ve test deneylerini simgelemektedir.



Şekil 4.1. Önerilen çerçevenin genel görseli

Kullanılan veri seti, Eskişehir Osmangazi Üniversitesi (ESOGU), Bilgisayar Mühendisliği bölümünden 200 farklı lisans öğrencisini içermektedir. Veri setinde 74 öğrenci dört yılda mezun olamamış, geri kalanı mezun olmuştur.

Eđitim s¼recinde, uygun hiper parametreler dođruluk ve hesaplama s¼resi arasındaki denge g¼z ¼n¼nde bulundurularak belirlenmiřtir. Hiper parametre, problemde veri setine g¼re deđiřiklik g¼steren parametrelerdir (Çarkacı, 2018). Veri setimizde kullandıđımız toplu iř b¼y¼kl¼đ¼, ¼đrenme oranı, devir sayısı, segment sayısı optimizasyon algoritması, kayıp fonksiyonu hiper parametrelerimizdir. Hiper parametre deđerleri gerek literat¼rdeki alıřmalardan tec¼be edinerek gerekse deneme yanılma yoluyla en iyi dođruluk oranını almamızı sađlayan deđerler olarak belirlenmiřtir

¼zellikle, her mimari iin toplu iř b¼y¼kl¼đ¼ (batch size), ařırı uyumu (overfitting) veya yetersiz uyumu (underfitting) ¼nlemek iin 128 olarak belirlenmiřtir. Toplu iř b¼y¼kl¼đ¼ ađ ¼zerinden yayılacak ¼rnek sayısıdır. Veri setini eđitmekte bellek aısından problem yařandıđı durumlarda iře yarayabilecek bir öz¼md¼r. ¼nk¼ toplu iř b¼y¼kl¼đ¼ ađda daha az ¼rnek eđitmemize olanak sađladıđı iin daha az belleđe ihtiya duyulur. Ađ k¼¼k gruplar halinde iřletildiđi iin daha hızlı alıřır. Ařırı uyum, eđitim seti kullanılarak deđerlendirilen model iyi performans g¼sterdiđinde ortaya ıkar, fakat test veri seti kullanıldıđında iyi bir dođruluk elde edilmez (Mikulski, 2019). Yetersiz uyum ise modelin eđitim seti hatasının, beklenen hatadan ¼nemli ¼l¼de b¼y¼k olduđunda ortaya ıkan problemdir (Mikulski, 2019).

Ayrıca, RNN, LSTM ve GRU modellerinin kullanıldıđı g¼sterim modellenirken ¼đrenme oranı $1e-3$ ve devir sayısı (epochs) 4000 olarak belirlenmiřtir. Devir, yapay sinir ađları aısından, eđitim veri seti boyunca bir evrimi ifade eder. Genellikle, bir sinir ađını eđitmek birka devirden daha fazlasını gerektirir. Bařka bir deyiřle, bir sinir ađını farklı desenlerde birden fazla d¼nem iin eđitim verilerini beslersek, sisteme yeni bir test verisi verildiđinde sistemin daha iyi bir genellemesi yapılabilir.

Devir, genellikle iterasyon kavramıyla karıřtırılır. İterasyonlar, bir d¼nemin tamamlanması iin gereken, eđitim verilerinin b¼l¼mlenmiř paketlerinden geen toplu iřlem veya adım sayısıdır. Devir ise bir evrim s¼recini anlatır (Anonim1, 2019).

Teknik olarak, bellek hücrelerinin sayısı her dönem için özellik sayısı ile eşleştirilmiştir. Her bir sinir ağı mimarisi etkinleştildiğinde, optimizasyon algoritması ve kayıp fonksiyonu (loss function), RMSprop optimizasyonu ve ikili çapraz entropi kaybı fonksiyonu olarak belirlenmiştir. İkili çapraz entropi kaybını kullanmanın nedeni, iki sınıf olduğunda (0 veya 1) aykırı değerlere karşı mücadele açısından diğer kayıp fonksiyonlarından daha sağlam olmasıdır. Aykırı değerler, bir özellik hakkında bilgi eksikliği olarak tanımlanabilir. Mesela bu çalışma için öğrencilerin bilgisayar mühendisliği programını tercih sırası aykırı değere örnek verilebilir.

Deneylerin tümü, TensorFlow arka uçlu Keras kütüphanesine (Chollet, 2019) dayanan bir python çerçevede gerçekleştirilmiştir. Eğitim ve test simülasyonları sırasında 4 GB Rasgele Erişimli Belleğe (RAM) sahip tek bir Grafik İşlem Birimi (GPU) kullanıldı.

Keras, python dili ile yazılmış kullanıcı dostu bir kütüphanedir. Keras ile kolay ve hızlı prototip oluşturulabilir ve kullanıcı hataları üzerine net geri bildirimler sağlar. CPU ve GPU üzerinde sorunsuz çalışır. Evrişimli sinir ağlarını, tekrarlayan sinir ağlarını ve evrişimli sinir ağları ile derin sinir ağlarının kombinasyonlarını destekler. Keras üst düzey bir sinir ağı API'sidir. Tensorflow, Theano veya CNTK üzerinde çalışabilir. Bizim çalışmamızda tensorflow üzerinde çalışılmıştır (Chollet, 2019).

TensorFlow, açık kaynaklı bir yazılım kütüphanesidir. Makine öğrenmesinde son teknolojinin kullanılmasına olanak tanıyan kapsamlı araçtır. Makine öğrenmesi destekli uygulamaları kolayca oluşturup dağıtma işlevine sahiptir. Keras gibi sezgisel üst düzey API'leri kullanarak makine öğrenmesi modellerini kolayca oluşturmayı ve eğitmeyi sağlar. Veri akış grafikleri kullanarak sayısal hesaplama için kullanılır. Bir masaüstü, sunucu veya mobil cihazdaki bir veya daha fazla CPU'ya veya GPU'ya sadece bir API ile dağıtma olanağı sunar (Şeker vd., 2017).

4.1. Veri Toplama ve Ön Hazırlık Aşaması

Tahmin sistemi, 122 erkek ve 78 kadın olmak üzere 200 öğrenciden oluşturulmuştur. Kullanılan öğrencilerin tamamı 2009-2013 yılları arasında bilgisayar mühendisliği programından mezun olan veya olamayan öğrencilerden oluşturulmuştur. Bir öğrencinin mezun yani başarılı olarak nitelendirilebilmesi için normal eğitim süresi olan beş yılda okulunu tamamlaması gerekir. Buradaki beş yıl öğrencinin okula giriş yaptığı tarihten itibaren hesaplanır. Normal eğitim süresinin beş yıl olmasının sebebi ise Eskişehir Osmangazi Üniversitesi Bilgisayar Mühendisliği Bölümü'nde bir yıl hazırlık dört yıl alan eğitimi verilmesidir.

Özelliklerin belirlenmesinde, daha önce bu alanda yapılan çalışmalarda kullanılan parametreler referans olarak kabul edilmiştir. Temel doğruluk seti (ground truth set), dört yıllık normal eğitim süresi baz alındığında, 74 mezun olamamış ve 126 mezun olmuş öğrenciden oluşmaktadır. Ham değeri sayısal değerlere dönüştürmek için kapsamlı bir ön işleme aşaması gerçekleştirilmiştir.

Toplanan özellikler iki gruba ayrılmıştır:

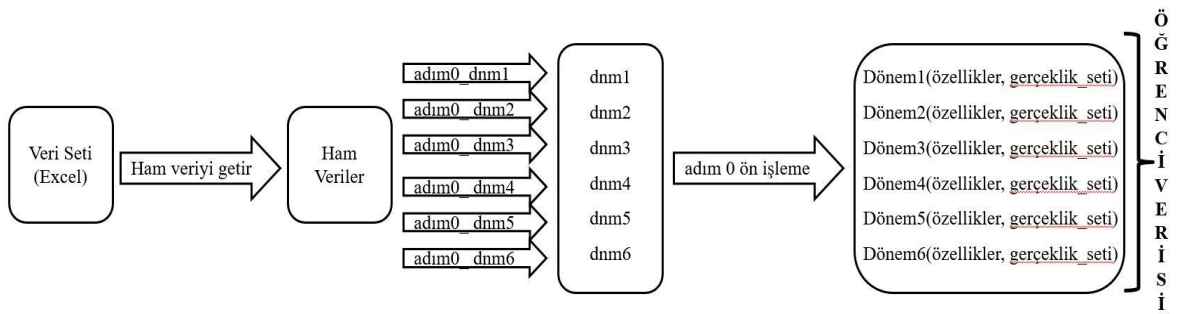
- Demografik ve Sosyo-ekonomik: Giriş sırasındaki yaş, cinsiyet ve memleket.
- Akademik: Ders notları, tercih sırası, İngilizce hazırlık notu ve devamsızlık oranı.
- Değerlendirilen özelliklerin tümü Çizelge 4.1'de verilmiştir. Ayrıca, her bir özellik teriminin açıklaması aşağıda verilmiştir.
- Memleket bilgileri, şehir koduyla kodlanmıştır. İki haneden oluşur.
- GNO, genel not ortalaması anlamına gelir ve aralığı 0 ile 4,00 arasındadır.
- İngilizce notu, yabancı dil bölümünden geçmek için elde edilen ortalama notu ifade eder. 0 ile 100 arasındadır.
- Cinsiyet özelliğini 0 ve 1 ile temsil etmek, derin öğrenme mimarileriyle çalışırken sıfır öğrenilen ağırlıkları ortadan kaldırırken anlamlı olmadığından, cinsiyet bilgileri erkekler ve kadınlar için sırasıyla 1 ve 2'ye dönüştürülür.

- Tercih Sırası, Yüksek Öğretim Kurumu (YÖK) tarafından yürütülen Yükseköğretim Kurumları Sınavı'ndan (YKS) bilgisayar mühendisliği programını seçme sırasındır.
- Devamsızlık oranı, DZ olan ders sayısı anlamına gelir.
- Özelliklerin geri kalanı bir derste öğrencilerin final notu koduna dayanmaktadır. Çizelge 4.2, not kodlarını sayısal gösterimleriyle birlikte göstermektedir. “AA” kodu 4.00 ile temsil ederken “FF” kodu 0.50 ile temsil edilir. Ayrıca, mezun olamama nedeni devamsızlık (DZ) ise, o zaman not 0,25 olarak işaretlenmiştir.

Çizelge 4.1. Her dönem için kullanılan özellikler

Dönem1	Dönem2	Dönem3	Dönem4	Dönem5	Dönem6
1 Genel not ortalaması	Genel not ortalaması	Genel not ortalaması	Genel not ortalaması	Genel not ortalaması	Genel not ortalaması
2 İngilizce puanı	İngilizce puanı	İngilizce puanı	İngilizce puanı	İngilizce puanı	İngilizce puanı
3 Cinsiyet	Cinsiyet	Cinsiyet	Cinsiyet	Cinsiyet	Cinsiyet
4 Tercih sırası	Tercih sırası	Tercih sırası	Tercih sırası	Tercih sırası	Tercih sırası
5 Calculus I	Calculus I	Calculus I	Calculus I	Calculus I	Calculus I
6 Physics I	Physics I	Physics I	Physics I	Physics I	Physics I
7 Chemistry	Chemistry	Chemistry	Chemistry	Chemistry	Chemistry
8 Int. to Prog.	Int. to Prog.	Int. to Prog.	Int. to Prog.	Int. to Prog.	Int. to Prog.
9 Int. to Prog. Lab.	Int. to Prog. Lab.	Int. to Prog. Lab.	Int. to Prog. Lab.	Int. to Prog. Lab.	Int. to Prog. Lab.
10 Adv. Read. & W.	Adv. Read. & W.	Adv. Read. & W.	Adv. Read. & W.	Adv. Read. & W.	Adv. Read. & W.
11 Devamsızlık durumu	Calculus II	Calculus II	Calculus II	Calculus II	Calculus II
12	Physics II	Physics II	Physics II	Physics II	Physics II
13	Engineering Graphics	Engineering Graphics	Engineering Graphics	Engineering Graphics	Engineering Graphics
14	Linear Algebra	Linear Algebra	Linear Algebra	Linear Algebra	Linear Algebra
15	Computer Prog.	Computer Prog.	Computer Prog.	Computer Prog.	Computer Prog.
16	Comp. Prog. Lab.	Comp. Prog. Lab.	Comp. Prog. Lab.	Comp. Prog. Lab.	Comp. Prog. Lab.
17	Devamsızlık durumu	Differential Eq.	Differential Eq.	Differential Eq.	Differential Eq.
18		Digital Sys. I	Digital Sys. I	Digital Sys. I	Digital Sys. I
19		Data Struc.	Data Struc.	Data Struc.	Data Struc.
20		Data Struc. Lab.	Data Struc. Lab.	Data Struc. Lab.	Data Struc. Lab.
21		Object Oriented Prog. I	Object Oriented Prog. I	Object Oriented Prog. I	Object Oriented Prog. I
22		Object Oriented Prog. I Lab.	Object Oriented Prog. I Lab.	Object Oriented Prog. I Lab.	Object Oriented Prog. I Lab.
23		Numerical Methods	Numerical Methods	Numerical Methods	Numerical Methods
24		Devamsızlık durumu	Digital Sys. II	Digital Sys. II	Digital Sys. II
25			Digital Sys. Lab	Digital Sys. Lab	Digital Sys. Lab
26			Object Oriented Prog. II	Object Oriented Prog. II	Object Oriented Prog. II
27			Object Oriented Prog. II Lab	Object Oriented Prog. II Lab	Object Oriented Prog. II Lab
28			Formal Lang. & Automation	Formal Lang. & Automation	Formal Lang. & Automation
29			Alg. & Complexity	Alg. & Complexity	Alg. & Complexity
30			Devamsızlık durumu	Int. to Operating Sys.	Int. to Operating Sys.
31				Int. to Operating Sys. Lab.	Int. to Operating Sys. Lab.
32				Database Man. Sys.	Database Man. Sys.
33				Database Man. Sys. Lab.	Database Man. Sys. Lab.
34				Project & Business Man.	Project & Business Man.
35				Devamsızlık durumu	Int. To Micro.
36					Int. To Micro. Lab.
37					Entrepreneurship
38					Design Processes
39					Devamsızlık durumu

Çizelge 4.1'de belirtildiği gibi, toplam özellik sayısı (GNO, İngilizce notu, cinsiyet, tercih sırası, devamsızlık oranı ve toplam zorunlu ders notları) birinci, ikinci, üçüncü, dördüncü, beşinci ve altıncı yarıyıllarda sırasıyla 11, 17, 24, 30, 35 ve 39'dur. Verilen dersler ilgili lisans öğrencileri için zorunludur. İlgili dönemdeki eğitim modelleri söz konusu olduğunda, modellerin tahmin kabiliyetini geliştirmek için geçmiş dönemlerin özellikleri de göz önünde bulundurulmuştur. Veri seti eğitilmeden önce bazı ön işlemlerden geçirilmiştir. Her bir ön işleme adımı Matlab uygulaması aracılığı ile gerçekleştirilmiştir. Bu ön işleme adımları Şekil 4.2.'de özetlenmiştir.



Şekil 4.2. Matlab'da Ön İşleme Adımları

Eskişehir Osmangazi Üniversitesi Bilgisayar Mühendisliği öğrencilerinin veri seti excel formatı şeklinde bulunmaktaydı. Şekil 4.2.'de 'Ham veriyi getir' olarak belirtilen işlem adımı ile excel formatında olan bu veri seti Matlab uygulamasında 'Ham Veriler' adında bir matlab veri dosyasına dönüştürüldü. Şekilde 'adım0_dnm1' olarak ifade edilen Matlab kodu ile kullanılmayacak veriler, veri setinden çıkartılmış, veri seti birinci dönem için sınırlandırılmış, veriler sayısallaştırılmış ve nihayetinde birinci döneme ait bir veri seti oluşturulmuştur.

Uzatma durumunu saptamak için, öğrencinin okulda bölüm derslerine başladığı tarih ile okuldan ilişişinin kesildiği tarih aralığı gün bazında hesaplanmış, hesaplanan gün, ay cinsine dönüştürülmüştür. Olağan bir mezuniyet sürecinde bir öğrencinin eylül ayında okula başladığı, dört yılın sonunda eylülde önce okuldan ayrılması gerektiği düşünülerek zaman eşiği 47 ay olarak belirlenmiştir. 47 aydan daha az bir eğitim sürecine sahip öğrencinin uzatma durumu 0 (sıfır), 47 aydan fazla bir eğitim sürecine sahip öğrencinin ise uzatma durumu 1 (bir) olarak veri setine eklenmiştir.

Cinsiyet durumu veri setinde K (Kadın) ve E (Erkek) şeklinde belirtildiği için kadın 1, erkek 2 olarak cinsiyet durumu sayısallaştırılmıştır. Cinsiyet durumu verisini sayısallaştırırken 0 (sıfır) kullanılmamasının nedeni sıfırın veri setinin öğrenmesine katkı sağlamaması, parametre ağırlığını sıfırlamasıdır. Memleket bilgisi ise ilgili şehrin plaka kodu olarak sayısallaştırılmıştır.

Kullanılan veri setinde ders notları harfli sistemde bulunmaktaydı, bu notlar dörtlük not sistemine dönüştürülmüştür (Çizelge 4.2). Yani öğrencinin ilgili dersten dönem sonunda aldığı harf notu sayısallaştırılmıştır. İlgili öğrenciye ait, ilgili dersin harf notunu veri setinden bulurken ‘dersi_bul’ adını verdiğimiz Matlab kodu, harf notu dönüşümleri için ise ‘not_kodu_dönüştür’ olarak isimlendirdiğimiz Matlab kodu kullanılmıştır. Eğer öğrenci, ilgili dersten devamsızlık yaparak kaldıysa, ders notu olarak ‘DZ’ yani ‘0,25’ olarak belirlediğimiz sayısal değer veri setine işlenmiştir.

Çizelge 4.2. Not kodu dönüşümü

AA	BA	BB	CB	CC	DC	DD	FF	DZ
4.00	3.50	3.00	2.50	2.00	1.50	1.00	0.50	0.25

Veri setinde boş değer olarak bulunan durumlar ise 0 (sıfır) olarak sayısallaştırılmıştır. Birinci dönem için belirlenen veri setindeki özellikler genel not ortalaması, İngilizce puanı, cinsiyet, tercih sırası, devamsızlık durumu, altı zorunlu dönem dersi, uzatma durumudur.

Benzer şekilde ‘adım0_dnm2’, ‘adım0_dnm3’, ‘adım0_dnm4’, ‘adım0_dnm5’, ‘adım0_dnm6’ olarak ifade edilen Matlab kodları ile sırası ile ikinci, üçüncü, dördüncü, beşinci altıncı dönemler için benzer işlemler yapılmıştır. Bahsi geçen matlab kodlarının ‘adım0_dnm1’ matlab kodundan farkı her dönem önceki dönemlerinde ders kodu parametrelerini dahil etmektir. Bu matlab kodlarının bir diğer işlevi ise her öğrencinin tüm parametrelerini tek bir dizi haline getirmesidir. Daha sonra her dönem için oluşturulan bu veri setleri ‘dnm1’, ‘dnm2’, ‘dnm3’, ‘dnm4’, ‘dnm5’ ve ‘dnm6’ olarak isimlendirilerek kaydedilmiştir.

Şekil 4.2.'de 'adım 0 ön işleme' olarak belirtilen matlab koduyla yine her dönem için ayrı ayrı olacak şekilde 'özellikler' ismini verdiğimiz özellikler veri seti ve 'gerçeklik_seti' adını verdiğimiz çıktı veri seti oluşturulmuştur. Çıktı veri setinde öğrencilerin uzatma durumu (0/1) yer alırken, özellikler veri setinde ise öğrencinin uzatma durumu hariç diğer parametreleri (giriş veri seti) yer almaktadır. Her dönem için giriş veri seti ve çıkış veri seti 'Dönem1', 'Dönem2', 'Dönem3', 'Dönem4', 'Dönem5' ve 'Dönem6' olarak kaydedilmiştir.

4.2. Performans Değerlendirmesi

Deneysel çalışma yoluyla, bir öğrencinin nihai performansının tahmin edilmesine olumlu katkıda bulunan özelliklere odaklanarak tahmin modellerinin entegrasyonunun yeteneği analiz edilmiştir. Bu amaçla yapılan deneylerde, öğrenciler için sırasıyla birinci, ikinci, üçüncü, dördüncü, beşinci ve altıncı dönemlerde performans değerlendirme yapılmıştır. Temel olarak, tüm örneklerdeki paylaşılan bilgileri yakalayan, alt popülasyonlarda makine öğrenme modelinin eğitilmesinin amaçlanmasından dolayı, bu işlevsel bir model, bir dönem boyunca kalma riski taşıyan öğrenciler için doğru tahminler verebilir.

Performans değerlendirmek için çok sayıda istatistiksel yöntem bulunmaktadır. K Katlamalı Çapraz Doğrulama (K Fold Cross Validation) en yaygınlarından biridir. K katmanlı çapraz doğrulama yönteminde veri aynı büyüklükteki k gruba ayrılır. K, katlama değeri anlamına gelmektedir. K tane grubun her biri ardılı olarak test grubu seçilir. Geriye kalan k-1 grup eğitim verisi olarak seçilir (Eskidere, 2012). Kapsamlı bir performans değerlendirme için, sonuçların güvenilirliğinin sağlanması için k katlamalı çapraz doğrulama yapılabilir (Tekeli ve Aşlıyan, 2016). Bizim deneylerimizde k beş olarak seçilmiş yani beş katlamalı çapraz doğrulama yapılmıştır. Veri seti 5 eşit parçaya bölünmüş, 4 tanesi eğitim, 1 tanesi test için kullanılmıştır. Bu şekilde her parçası test için ve kalan 4 parçası eğitim için kullanılarak 5 kere uygulama yapılmıştır. Sonuçların ortalaması sistemin başarımları olarak kabul edilmiştir. Özetle, 200 öğrenci verimiz 5 parçaya bölünmüş, her 40 veri, sırayla test verisi olacak şekilde 5 uygulama gerçekleştirilmiştir. Gerçekleştirilen her uygulamada 40 test verisinden geriye kalan 160 veri, eğitim verisi olarak kullanılmıştır.

Çizelge 4.3. Derin öğrenme tabanlı model için, dönem başına çapraz geçerlilik doğruluğu (%)

		Dönem1	Dönem2	Dönem3	Dönem4	Dönem5	Dönem6
LSTM	ÇD1	82.93	82.93	87.80	80.49	87.80	92.68
	ÇD2	82.50	85.00	85.00	87.50	95.00	92.50
	ÇD3	77.50	85.00	82.50	85.00	87.50	87.50
	ÇD4	82.50	75.00	80.00	82.50	75.00	80.00
	ÇD5	87.18	87.18	87.18	84.62	84.62	79.49
	Ortalama Değer	82.52	83.02	84.50	84.02	85.98	86.43
GRU	ÇD1	80.49	85.37	87.80	90.24	92.68	90.24
	ÇD2	87.50	85.00	92.50	90.00	92.50	92.50
	ÇD3	80.00	85.00	80.00	82.50	85.00	85.00
	ÇD4	82.50	75.00	80.00	87.50	85.00	82.50
	ÇD5	89.74	89.74	82.05	87.18	82.05	82.05
	Ortalama Değer	84.05	84.02	84.47	87.48	87.45	86.46
RNN	ÇD1	73.17	78.05	85.37	82.93	85.37	87.80
	ÇD2	80.00	85.00	87.50	90.00	90.00	90.00
	ÇD3	67.50	80.00	82.50	82.50	82.50	92.50
	ÇD4	72.50	70.00	77.50	75.00	75.00	77.50
	ÇD5	74.36	82.05	82.05	82.05	79.49	82.05
	Ortalama Değer	73.51	79.02	82.98	82.50	82.47	85.97

Her model için beş katlı çapraz doğrulama doğruluğu puanları Çizelge 4.3'te gösterilmiş ve RNN, LSTM ve GRU performansları, tahmin görevi için en iyi yaklaşımı ortaya koymak amacıyla karşılaştırılmıştır. Çapraz doğrulama (ÇD) sonuçlarının daha ileri analizleri, derin öğrenme temelli bir zaman serisi modelinin performansının değişen eğitim ve test veri setlerine göre değiştiğini göstermektedir. İlk bakışta, GRU tabanlı modelin herhangi bir dönemde öğrencilerin bireysel performans durumlarını tahmin etmede başarılı puanlar sağladığı görülebilir. Yine, sunulan sonuçlara göre, eğitim veri setinden oluşturulmuş LSTM modeli, model yerleştirme sırasında görünmeyen test örneklerini doğru şekilde sınıflandırabilir. Özellikle, ÇD2 için, LSTM %95 doğruluk oranında en yüksek tahmin performansını verir. Bununla birlikte, RNN modeli, her bir yarıyılı genel doğruluklara dayandırıldığında akademik faktörlerin anlamlı önerilerle eşleştirilmesinden yoksundur. Modelleri yerleştirirken uygun aktivasyon fonksiyonu ayarlanmıştır. Uygun aktivasyon fonksiyonu deneme yanılma yoluyla her adım için en iyi sonucu veren aktivasyon fonksiyonu veya fonksiyonları (doğrusal ve/veya sigmoid) olarak belirlenmiştir.

Çizelge 4.4. Ağların normal eğitim süresinde genel mezuniyet tahmini performansı

	RNN (%)	GRU (%)	LSTM (%)
Dönem1	73.51	84.05	82.52
Dönem2	79.02	84.02	83.02
Dönem3	82.98	84.47	84.50
Dönem4	82.50	87.48	84.02
Dönem5	82.47	87.45	85.98
Dönem6	85.97	86.46	86.43
Genel Ortalama	81.07	85.65	84.41

GRU, LSTM ve RNN modellerinden alınan normal eğitim süresinde öğrencilerin mezun olma veya olamama tahmin sonuçları ile gerçek veri seti mezun olma/olamama durumları karşılaştırılarak ağların genel tahmin performansı yarıyıl bazında hesaplanmıştır. Bu tahmin performansları Çizelge 4.4'te gösterilmiştir. Deneyler yaptıktan sonra, GRU tabanlı sistemin, RNN ve LSTM performanslarından daha yüksek olan tüm dönemler için yaklaşık %85,65 genel doğruluk skoru ile daha doğru tahminler üretebildiği gözlemlenmiştir. RNN ve LSTM modellerini karşılaştırırken, LSTM modelinin çıktıları temel doğruluk verilerine çok yakındır. Deneyler, RNN tabanlı modelin, genelleme kabiliyetinin neden olduğu zayıflığı nedeniyle öğrencinin başarısını önemsemediğini göstermektedir. En iyi tahmin doğruluğu, dördüncü, beşinci ve altıncı yarıyıldaki öğrenciler için sırasıyla %87,48, %87,45 ve %86,46 puanları ile GRU tarafından belirlenmiştir. Bu değerler, dördüncü dönem derslerinin nihai akademik başarıya önemli etkileri olduğunu göstermektedir.

Bunun aksine, birinci ve ikinci yarıyıldaki öğrencilerin tahmin doğruluğu beşinci ve altıncı yarıyıllara göre daha düşüktür. Bu durum, bir modelin, dikkate alınan faktörlere göre özellik boyutu arttığında öğrencilerin normal eğitim süresinde mezun olamama riskini daha iyi tahmin edebileceği beklentisini desteklemektedir. Bu nedenle, ayırt edici faktörler verildiğinde, geliştirilen modeller, öğrencilerin özelliklerini eşleştirebilir ve normal eğitim süresinde mezun olma/olamama performansı ile ilgili ikna edici bir olasılık puanı öngörebilir.

$$TPR = TP/(TP + FN) \quad (4.1)$$

$$TNR = TN/(TN + FP) \quad (4.2)$$

Ayrıca, zaman serisi tabanlı ağların performansını sırasıyla Denklem (4.1) ve Denklem (4.2) tarafından temsil edilen gerçek pozitif oranı (TPR) ve gerçek negatif oranı (TNR) ölçütleri temelinde analizleri yapılmıştır. Gerçek Pozitif (True Positive) (TP), mezun olmuş (başarılı) olarak doğru işaretlenmiş toplam mezun olmuş (başarılı) öğrenci sayısını belirtirken, Yanlış Pozitif (False Positive) (FP) mezun olamamış (başarısız) olarak yanlış belirtilmiş toplam mezun olmuş öğrenci sayısını belirtir. Benzer şekilde, Yanlış Negatif (False Negative) (FN), mezun olamamış (başarısız) olarak hatalı sayılan mezun olamamış (başarısız) öğrencilerin toplamını belirtirken, Gerçek Negatif (True Negative) (TN), gerçekten mezun olamamış (başarısız) olan öğrencilerin toplamını ifade eder. Gerçek pozitif oranı, öğrencinin geçtiği göz önüne alındığında, mezun olmuş/başarılı bir öğrencinin tahmin olasılığını ifade ederken, gerçek negatif oranı ise yanlışlıkla mezun olmuş (başarılı) olarak kategorize edilmiş olması koşuluyla başarısız olan bir öğrencinin tahmin olasılığını belirtir. Daha yüksek bir gerçek pozitif oranı, mezun olan öğrencilerin daha iyi bir şekilde ayırt edilmesini gerektirirken, daha yüksek bir gerçek negatif oranı, risk altındaki öğrencilerin daha iyi belirlenmesi anlamına gelir.


Ardışık olarak, GRU, LSTM ve RNN modelleri için gerçek pozitif oranı/gerçek negatif oranı yüzde değerleri sırasıyla 88,71/85,51, 85,29/87,12 ve 87,50/86,03'tür. Gerçek pozitif oranı sonuçlarına bakıldığında, GRU modelinin tahmin yeteneğinin, öğrencilerin normal eğitim süresinde mezun olma performansını tahmin ederken, RNN ve LSTM modellerinden biraz daha yüksek olduğu görülmektedir. Ancak, gerçek negatif oranı ölçümü için, LSTM modelinin performansı risk altındaki öğrencileri tahmin etmek için daha iyi sonuç verdiği görülmektedir.

ROC analizi yaygın olarak sistemde anormal bir durumun olup olmadığının kararını vermekte kullanılır. ROC analizindeki iki eksen, bir sınıflandırıcının iki sınıf arasında ayırım yaparken yaptığı hataları (yanlış pozitifler) ve faydaları (gerçek pozitifler) arasındaki değişim durumunu temsil eder (Fawcett, 2006).

ROC grafikleri ise, sınıflandırıcıları düzenlemek ve performanslarını görselleştirmek için geliştirilmiştir. ROC grafikleri, son yıllarda makine öğrenmesi ve veri madenciliği çalışmalarında yaygın olarak kullanılmaktadır (Fawcett, 2006). ROC grafikleri genel olarak yararlı bir performans grafiklendirme yöntemidir. Ayrıca özellikle eğrilmiş sınıf dağılımı ve eşit olmayan sınıflandırma hatası maliyetleri olan alanları daha kullanışlı hale getiren özelliklere sahiptir. Bu özellikler, dengesiz sınıfların varlığında maliyete duyarlı öğrenme ve öğrenme alanlarına yönelik araştırmalar devam ettikçe, giderek daha çok önem kazanmıştır (Fawcett, 2006).

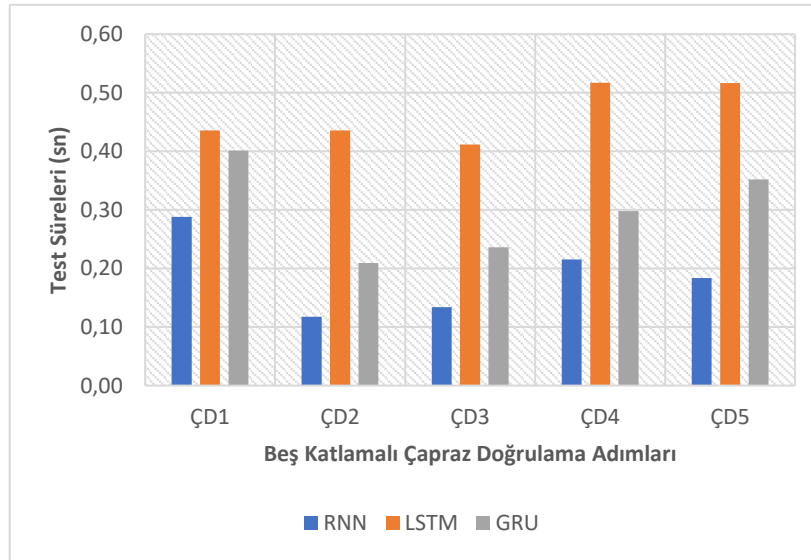
Tez çalışmamızda, her bir ağın tahmin doğruluğunun kapsamlı bir analizini sağlamak için Şekil 4.3'de ROC eğrisini görselleştiriyoruz. Şekilde Eğri Altındaki Alan (AUC) değerlerinin RNN, LSTM ve GRU için gösterimleri mevcuttur. TPR doğru pozitif değerleri, TNR doğru negatif değerleri göstermektedir.

LSTM modelinin AUC değerinin (%86,13), GRU (%84,44) ve RNN (%84,96) modellerinden daha yüksek olduğu görülmektedir. Bu nedenle, LSTM modelinin, normal eğitim süresinde mezun olma durumu bakımından öğrencinin nihai performansını tahmin etme adına çevrimiçi bir sisteme entegre etmek için diğer modellerden daha mantıklı olduğu düşünülebilir.



Şekil 4.3. ROC eğri analizi açısından performans değerlendirmesi

Ayrıca, öğrencilerin normal eğitim süresinde mezun olamama durumunu tahmin etmeye, birden fazla faktörün etki ettiği endişesine dayanarak, ağların tahmin performansı, memleket, cinsiyet ve tercih sırası gibi özelliklerin yokluğu ve varlığına göre test edilmiştir. Bu amaçla, 6. yarıyıldaki öğrenciler için GRU ağında eş zamansız deneyler yapılmıştır. GRU modelinin altıncı dönem için orijinal tahmin performansı %86,46 olarak bulmuştuk. Cinsiyet ve tercih sırası özellikleri tek tek hariç tutulduğunda, GRU modelinin doğruluğu sırasıyla %87,96 ve %85,01'e ulaşmıştır. Sonuçlar, cinsiyet özelliğinin nihai performans üzerindeki etkisinin nispeten düşük olduğunu göstermektedir. Öğrencilerin başarısının cinsiyetleri ile sınırlı olmadığı görülmüştür. Ancak, tercih sırası önemli bir faktördür, çünkü öğrencilerin bilgisayar mühendisliği programına olan ilgisini göstermektedir. Bu durum, tahmin performansının, tercih sırasının yokluğunda arttığını göstermektedir. İlginç bir şekilde, memleket bilgilerini dahil etmek, %87,98 olarak kaydedilen tahmin performansını önemli ölçüde artırdığı görülmüştür. Ayrıca, akademik faktörler arasında, dördüncü ve beşinci yarıyıl derslerinin, öğrencilerin nihai başarı tahminini artıran faktörler olduğu gözlemlenmiştir. Alınan yüksek tahmin puanlarının nedenlerinden biri, bir modelin genelleme yeteneğinin geliştirilmesinde büyük etkiye sahip olan artırılan devir sayısı (epoch) ve toplu iş büyüklüğü (batch size) faktörleridir.



Şekil 4.4. Kullanılan ağların çalışma süresi karşılaştırması

Ayrıca, RNN, LSTM ve GRU ağlarının tahminleri üretme durumunda çalışma süreleri değerlendirilmiştir. Bu amaçla, altıncı dönemdeki öğrenciler için her bir modelin test süresi (saniye olarak) Şekil 4.4'te gösterilmektedir. Şekilde bulunan ÇD1, ÇD2, ÇD3, ÇD4 ve ÇD5 değerleri beş katlamalı çapraz doğrulamanın, her bir katlama adımını simgelemektedir. Şekil 4.4'ün sonuçlarından, RNN modelinin LSTM ve GRU modellerinden daha hızlı olduğu görülmüştür. 200 kayıt için toplam çalışma süreleri, RNN, LSTM ve GRU ağları için sırasıyla 0,94(s), 2,32(s) ve 1,50(s) olarak kaydedilmiştir. RNN modeli en hızlı olanı iken, LSTM ve GRU modellerinden daha düşük doğruluk skorları üretmiştir. Bunun nedeni RNN modeli teoride bilgiyi uzun süre kullanabilir gözüke de pratik olarak birkaç adım kadar geriye bakabilmesidir (Britz, 2015). Böylece RNN daha az vakit kaybeder, sonuca daha hızlı ulaşır. Ağın bir hafızası vardır fakat çok aşama olduğundan birkaç adım önceki bilgileri yakalayamaz (Britz, 2015). Bu yüzden diğer iki modelden daha düşük skor ürettiği düşünülmektedir.

5. BULGULAR VE TARTIŞMA

Bu bölümde, öğrencilerin normal eğitim süresinde mezun olma/olamama durumunu tahmin etmek için derin öğrenme temelli zaman serisi yaklaşımlarını kullanmanın faydaları analiz edilmiştir. Daha adil bir karşılaştırma için, öğrencilerin nihai performans tahminiyle ilgili özelliklerinin potansiyel yeteneğini geliştirmeye yönelik çaba harcayan benzer çalışmalar literatürde karşılaştırılmıştır. Her yöntem için, kullanılan özelliklerin sayısı, veri boyutu ve sınıflandırıcı türü Çizelge 5.1'de verilmiştir.

Çizelge 5.1. Diğer önemli yöntemlerle performans karşılaştırması

Tahmin Görev	Öznitelik Sayısı	Sınıflandırıcı	Öğrenci Sayısı	Doğruluk (%)	Referans
Öğrencinin mezun olma/olamama tahmini	39	RNN	200	81.07	Önerilen Yöntem
Öğrencinin mezun olma/olamama tahmini	39	GRU	200	85.65	Önerilen Yöntem
Öğrencinin mezun olma/olamama tahmini	39	LSTM	200	84.41	Önerilen Yöntem
Akademik durum kaybı	17	NB	1532	85.00	(Guarín vd., 2015)
Öğrencinin mezun olma/olamama tahmini	16	DT	500	75.60	(Amrieh vd., 2016)
Öğrencinin mezun olma/olamama tahmini	5	Ensemble Of Classifiers	2,193	92.60	(Marbouti vd., 2016)
Öğrencinin mezun olma/olamama tahmini	5	Logistic Regression	1819	79.50	(Baars vd., 2017)
Öğrencinin mezun olma/olamama tahmini	27	Jrip	4,010	76.66	(Helal vd., 2018)

Guarín vd.nin (2015) çalışmasında, öğrencilerin ilk dört yarıyıl boyunca belirli bir kayıt için akademik kayıplarını tahmin etmek amaçlanmıştır. Veri madenciliği modelleri, Waikato Bilgi Analizi Ortamı (Waikato Environment for Knowledge Analysis) (WEKA) (Hall vd., 2009) adıyla iyi bilinen bir paket program üzerinde, eğitim ve test deneyleri yapılarak öğrencilerin geçmiş akademik özelliklerinden oluşturulmuştur. 1532 veri kayıtlarına bakıldığında, sistem performansı başlangıçtaki verilerle ve görünmeyen test kayıtlarındaki gibi akademik niteliklerle değerlendirirken %85 doğruluk oranı elde edilmiştir. Ayrıca, lise türü, erişim türü ve öğrencinin programı seçtiği tercih sırası da dahil olmak üzere yalnızca ilk bilgileri göz önünde bulundurarak tahmin performansının %57 olduğunu vurgulanmıştır. Elde edilen sonuçlar, başlangıçtaki verilerin risk altındaki öğrencileri tahminle etme açısından anlamlı olmadığını göstermiştir.

Başka bir çalışmada, Amrieh vd. (2016) tarafından öğrencinin başarısızlık durumunu tahmin etmek için bir fikir birliği karar mekanizması uygulanmıştır. Sistem oy çoğunluğu kavramına dayanmaktadır, yani ANN, DT ve NB sınıflandırıcılarının çıktıları bir oylama aşamasına iletilmiştir. Bununla birlikte, sistemin öğrencinin akademik başarısı ile geçmiş özellikleri arasındaki gizli bilgi ilişkisini ortaya çıkarmak için etkili olmadığı vurgulanmıştır.

Farklı bir amaçla, kursa özgü tahmin, bir çalışmada risk altındaki öğrencileri belirlemek için araştırılmıştır (Marbouti vd., 2016). Bu amaçla, bir dönemdeki ilk beş haftanın, ev ödevleri, kısa sınavlar (quiz) ve vize notları gibi verilerinin tahmin edici bir model oluşturduğu kabul edilmiştir. Bir özellik seçim süreci kullanılarak, 44 özellikten 14'ü seçilmiştir ve sistemin performansı, 1266 başarılı ve 147 başarısız öğrenciden oluşan belirli bir test veri seti için %92,10 doğruluk oranına ulaşmıştır.

Dahası, Baars vd.nin (2017) araştırması, tıp lisans eğitiminin ilk yılında öğrencilerin profilini kullanarak öğrencilerin başarısızlığının erken tespiti için bir model geliştirmeyi amaçlamıştır. 0, 4, 6, 8, 10 ve 12 ay olarak verilen ardışık altı dönem için, tahmin sisteminin gerçek pozitif oranı yaklaşık %84,5, gerçek negatif oranı yaklaşık %66,7 olarak bulunmuştur. Ek olarak, TP, FP, TN ve FN oranlarından, yaş, cinsiyet, kabul öncesi özellikler, üniversite öncesi eğitim not ortalaması ve hazırlık eğitimi sertifikası özellikleri kullanılarak 834 test örneği için sistemin doğruluğu %79,50 olarak belirtilmiştir. Elde edilen

performans, lojistik regresyon analizlerine dayalı tahmin sistemindeki gelişmelerin akademik veriler gibi ek faktörlerle sağlanabileceğini göstermiştir.

Ayrıca Helal vd. (2018) tarafından, beyaz kutu sınıflandırıcıları (J48 ve JRip), kara kutu yöntemleriyle (NB ve SMO) birlikte WEKA ortamında, öğrencilerin LMS aktivite verilerine (Forum Görünümü, Sınav Görünümü, Ders Görünümü vb.) ve kayıt özelliklerine (cinsiyet, yaş, lise durumu vb.) dayanarak performanslarını tahmin etmek için değerlendirilmiştir. Bu çalışmanın temel katkısı, öğrencilerin derslerle ilgili endişeleri ile derslere ve ilgili final performanslarına olan ilgileri arasındaki bağlantıyı ortaya çıkarması olarak değerlendirilmiştir. Bu sistemin doğruluğu göreceli olarak düşük olsa da akademik verinin öğrenci başarısızlığının en etkili göstergesi olduğu sonucuna varılmıştır.

Çizelge 5.1'de gösterildiği gibi, önerilen yöntemlerin yorumlanabilir ve genelleştirilebilir oluşu, öğrencilerin özellikle son yarıyıl için yaptığımız deneyleri göz önüne alındığında, normal eğitim süresinde mezun olacağını veya olamayacağını tahmin etme söz konusu olduğunda oldukça yüksektir. Önerilen zaman serisi modelini kullanmanın avantajları aşağıdaki gibi özetlenebilir:

- Tamamen otomatik ve parametreden bağımsız bir tahmin sistemidir.
- Karmaşık değildir.
- Çevrimiçi bir uyarı sistemi olarak basit entegrasyon taşınabilirliğine sahiptir.

6. SONUÇ VE ÖNERİLER

Bu çalışmada, herhangi bir döneme dair özellikler kullanılarak bilgisayar mühendisliği öğrencilerinin normal eğitim süresinde mezun olup olamayacağını tahmin etmek için RNN, LSTM ve GRU sinir ağlarının tahmin kabiliyeti araştırılmıştır. Bu amaçla, derin öğrenmeye dayalı zaman serisi modelleri geliştirilmiştir ve modeller bilgisayar mühendisliği programındaki 200 öğrencinin ders kayıtlarına uygulanmıştır. Sonuçlarda, GRU modelinin performansının LSTM ve RNN modellerinden biraz daha yüksek olduğu görülmüştür. Dönemsel değerlendirme açısından, derin öğrenmeye dayalı eğitimsel veri madenciliği kullanarak öğrencilerin akademik performansını etkileyebilecek özelliklerin potansiyelini incelenmiştir. Bilgisayar mühendisliği programından alınan öğrenciler için elde edilen tahmin puanları, altıncı yarıyıldaki derslerin, öğrenci başarısızlığını tahmin etmede erken bir gösterge olarak yararlı olabileceği görülmüştür. Deneysel değerlendirme yoluyla, niteliklerin artmasının modellerin genelleme başarısını olumlu yönde etkilediğini gözlemlenmiştir. Ayrıca, memleket bilgileri, cinsiyet ve tercih sırası özellikleri gibi bazı faktörleri hariç tutmanın veya dahil etmenin etkisi de araştırılmıştır. Altıncı dönemde GRU modelinin doğruluğu, cinsiyet ve tercih sırası özellikleri tek tek hariç tutulduğunda sırasıyla %87,96 ve %85,01'e ulaşmıştır. Memleket bilgilerini dahil edildiğinde ise altıncı dönemdeki GRU modelinin doğruluğunu %87,98'e ulaşmıştır.

Yapılan deneyler, derin öğrenme temelli zaman serisi modellerinin, önceden tanımlanmış faktörlere dayanarak öğrencilerin nihai performansı hakkında tahminlerde bulunmada önemli bir potansiyele sahip olduğunu göstermiştir. Özellikle, geliştirilmiş uyarı sistemi, bir kez bir öğrenci bilgi sistemine entegre edildiğinde erken bir tahmin yapısı olarak hizmet edebilir. Bu çalışmanın sonuçlarına dayanarak, öğrenciler, bu tahmin sonuçlarının kendilerine gösterilmesinin ardından herhangi bir dönemde başarısız olma riskinin farkında olacaklardır. Ayrıca, akademik danışmanlar öğrencilere gerekli desteği sağlayabilir ve başarısızlık riskini en aza indirebilir. Gelecekteki çalışmalarla ilgili olarak, sistem öğrenci bilgi sistemine entegre edilebilir ve kullanılan modellerin tahmin performansını iyileştirmek için veri seti artırılabilir.

KAYNAKLAR DİZİNİ

- Akay, E. Ç., 2018, Ekonometride Yeni Bir Ufuk: Büyük Veri ve Makine Öğrenmesi, Sosyal Bilimler Araştırma Dergisi, 7(2), 41-53.
- Altujjar, Y., Altamimi W., Al-Turaiki I., Al-Razgan M.J.P.C.S., 2016, Predicting Critical Courses Affecting Students Performance: A Case Study, 82, 65-71.
- Amidi, A., Amidi, S., Recurrent Neural Networks Cheatsheet, <https://stanford.edu/~shervine/teaching/cs-230/cheatsheet-recurrent-neural-networks>, erişim tarihi: 11.12.2019.
- Amrieh E.A., Hamtini T., Aljarah, I.J.I.J.o.D.T., 2016, Application, Mining Educational Data to Predict Student's Academic Performance Using Ensemble Methods, 9, 119-136.
- Anonim1, Epoch, <https://deepai.org/machine-learning-glossary-and-terms/epoch>, erişim tarihi: 12.12.2019.
- Anonim2, Gated Recurrent Unit, <https://deepai.org/machine-learning-glossary-and-terms/gated-recurrent-unit>, erişim tarihi: 10.12.2019.
- Anonim3, 2017, Derin Öğrenme, <http://www.iot.gen.tr/forums/topic/derin-ogrenme/>, erişim tarihi: 10.12.2019.
- Ayvaz, T., Deep Learning (Derin Öğrenme) Nedir?, <https://www.mediatick.com.tr/blog/deep-learning-derin-ogrenme-nedir>, erişim tarihi: 10.12.2019.
- Baars, G.J., Stijnen, T., Splinter, T.A.J.H.P.E., 2017, A Model to Predict Student Failure in The First Year of The Undergraduate Medical Curriculum, 3, 5-14.
- Bozüyük, T., Yağcı, C., Gökçe, İ., Akar, G., 2005, Yapay Zeka Teknolojilerinin Endüstrideki Uygulamaları.
- Britz, D., 2015, Recurrent Neural Networks Tutorial, Part 1–Introduction to Rnns, <http://www.wildml.com/2015/09/recurrent-neural-networks-tutorial-part-1-introduction-to-rnns>, erişim tarihi: 09.12.2019
- Burcu, C., 2019, LSTM Ağları ile Türkçe Kök Bulma, Bilişim Teknolojileri Dergisi, 12(3), 183-193.
- Cherry, K., 2019, How Many Neurons Are in The Brain?, <https://www.verywellmind.com/how-many-neurons-are-in-the-brain-2794889>, erişim tarihi: 10.12.2019.

KAYNAKLAR DİZİNİ (devam)

- Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., Bengio, Y.J.a.p.a., 2014, Learning Phrase Representations Using RNN Encoder-Decoder for Statistical Machine Translation.
- Chollet, F., 2019, Keras. <https://github.com/fchollet/keras>, erişim tarihi: 12.12.2019.
- Chung, J., Gulcehre, C., Cho, K., Bengio, Y., 2014, Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling, arXiv preprint arXiv, 1412.3555.
- Çarkacı, N., 2018, Derin Öğrenme Uygulamalarında En Sık Kullanılan Hiper-Parametreler, <https://medium.com/deep-learning-turkiye/derin-ogrenme-uygulamalarinda-en-sik-kullanilan-hiper-parametreler-ece8e9125c4>, erişim tarihi: 12.12.2019.
- Ersoy, E., Karal, Ö., 2012, Yapay Sinir Ağları ve İnsan Beyni, İnsan ve Toplum Bilimleri Araştırmaları Dergisi, 1(2), 188-205.
- Eskidere, Ö., 2012, A Comparison Of Feature Selection Methods For Diagnosis Of Parkinson's Disease From Vocal Measurements, Sigma, 30, 402-414.
- Fawcett, T., 2006, An Introduction to ROC Analysis, Pattern Recognition Letters, 27(8), 861-874.
- Fırat, M., Güngör M., 2004, Askı Madde Konsantrasyonu ve Miktarının Yapay Sinir Ağları ile Belirlenmesi, Teknik Dergi, 15(73).
- Guarín, C.E.L., Guzmán, E.L., González, F.A.J.I.R.I.d.t.d.A., 2015, A Model to Predict Low Academic Performance at A Specific Enrollment Using Data Mining, 10, 119-125.
- Hall, M., Frank, E., Holmes, G., Pfahringer, B., Reutemann, P., Witten, I.H.J.A.S.e.n., 2009, The WEKA Data Mining Software: An Update, 11, 10-18.
- Hamsa, H., Indiradevi, S., Kizhakkethottam, J.J.J.P.T., 2016, Student Academic Performance Prediction Model Using Decision Tree and Fuzzy Genetic Algorithm, 25, 326-332.
- Helal, S. Li, J., Liu, L., Ebrahimie, E., Dawson, S., Murray, D.J., 2018, Long, Predicting Academic Performance by Considering Student Heterogeneity, 161, 134-146.
- Hochreiter, S., Schmidhuber, J.J.N.c., 1997, Long Short-Term Memory, 9, 1735-1780.
- Karlık, B., Olgac, A. V., 2011, Performance Analysis of Various Activation Functions in Generalized MLP Architectures of Neural Networks, International Journal of Artificial Intelligence and Expert Systems, 1(4), 111-122.

KAYNAKLAR DİZİNİ (devam)

- Keleşoğlu, Ö., Ekinci, C. E., Fırat, A., 2005, The Using of Artificial Neural Networks in Insulation Computations, *Sigma*, 3, 58-66.
- Keleşoğlu, Ö., 2009, Yapay Sinir Ağları ile Kısa Konsolların Donatı Tayini, *Engineering Sciences*, 4(3), 404-413.
- Kim, B. H., Vizitei, E., Ganapathi, V., 2018, GritNet: Student Performance Prediction With Deep Learning, arXiv preprint arXiv, 1804.07405.
- Kotsiantis, S. B., Zaharakis, I., Pintelas, P., 2007, Supervised Machine Learning: A Review of Classification Techniques, *Emerging Artificial Intelligence Applications in Computer Engineering*, 160, 3-24.
- LeCun, Y., Bengio, Y., Hinton, G., 2015, Deep Learning, *Nature*, 521(7553), 436-444.
- Marbouti, F., Diefes-Dux, H.A., Madhavan, K.J.C., 2016, Education, Models for Early Prediction of At-Risk Students in A Course Using Standards-Based Grading, 103, 1-15.
- Marquez-Vera, C., Romero, C., Ventura, S., 2011, Predicting School Failure Using Data Mining, in: EDM, ERIC, 271-276.
- McCulloch, W. S., Pitts, W., 1943, A Logical Calculus of The Ideas Immanent in Nervous Activity, *The Bulletin of Mathematical Biophysics*, 5(4), 115-133.
- Mikulski, B., 2019, How To Deal With Underfitting And Overfitting In Deep Learning, <https://www.mikulskibartosz.name/how-to-deal-with-underfitting-and-overfitting-in-deep-learning/>, erişim tarihi: 24.12.2019.
- Özdemir, A., Saylam, R., Bilen, B. B., 2018, Eğitim Sisteminde Veri Madenciliği Uygulamaları ve Farkındalık Üzerine Bir Durum Çalışması, *Atatürk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 22(Özel Sayı 2), 2159-2172.
- Pitts, J.D., Johnson, J.D.J.J.o.H., Leisure, T. Education, Predicting Student Success in An Undergraduate Sport Management Program From Performance in General Education Courses, 21, 55-60.
- Rana, R., 2016, Gated Recurrent Unit (GRU) for Emotion Classification From Noisy Speech, arXiv preprint arXiv, 1612.07778.
- Riedmiller, M., 1994, Rprop-Description and Implementation Details: Technical Report, Inst. f. Logik, Komplexität u. Deduktionssysteme.
- Rumelhart, D.E., McClelland, J.L., 1986, Parallel Distributed Processing: Explorations in The Microstructure of Cognition. Volume 1. Foundations.

KAYNAKLAR DİZİNİ (devam)

- Saraç, E., 2012, Yapay Sinir Ağları Metodu ile Gayrimenkul Değerleme, İstanbul Kültür Üniversitesi/Fen Bilimleri Enstitüsü/İnşaat Mühendisliği
- Sharma, S., 2017, Activation Functions In Neural Networks, <https://towardsdatascience.com/activation-functions-neural-networks-1cbd9f8d91d6>, erişim tarihi: 28.12.2019.
- Shewalkar, A. N., 2018, Comparison of RNN, LSTM and GRU on Speech Recognition Data.
- Schmidhuber, J., 2015, Deep Learning in Neural Networks: An Overview, Neural Networks, 61, 85-117.
- Şanlı, M. T. O., 2008, Yapay Sinir Ağları ile Kredibilite Tespiti, Fen Bilimleri Enstitüsü.
- Şeker, A., Diri, B., Balık, H. H., 2017, Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme, Gazi Mühendislik Bilimleri Dergisi (GMBD), 3(3), 47-64.
- Şengür, D., Tekin A., 2013, Öğrencilerin Mezuniyet Notlarının Veri Madenciliği Metotları ile Tahmini, Bilişim Teknolojileri Dergisi, 6(3), 7-16.
- Şimşek, N. Y., Derin Öğrenme (Deep Learning) Nedir ve Nasıl Çalışır?, <https://medium.com/@nyilmazsimsek/derin-%C3%B6%C4%9Frenme-deep-learning-nedir-ve-nas%C4%B1l-%C3%A7al%C4%B1%C5%9F%C4%B1r-2d7f5850782>, erişim tarihi: 10.12.2019.
- Tekeli, K., Aşlıyan, R., 2016, Çok Katmanlı Algılayıcı, K-NN ve C4. 5 Metotlarıyla İstenmeyen E-postaların Tespiti, Aydın: XVIII. Akademik Bilişim Konferansı.
- Waheed, H., Hassan, SU., Aljohani, NR., Hardman, J., Alelyani, S., Nawaz, R., 2020, Predicting Academic Performance of Students From VLE Big Data Using Deep Learning Models, Computers in Human Behavior, 104, 106189.



T.C.
ESKİŞEHİR OSMANGAZİ ÜNİVERSİTESİ
Fen ve Mühendislik Bilimleri Bilimsel Araştırma ve Yayın Etiği Kurul
HİZMETE ÖZEL



Sayı : 53893652-299-E.48341
Konu : 2019.07.01.Karar.

22/04/2019

Sayın Dr.Öğr.Üyesi Uğur GÜREL

Sorumlu Araştırmacısı olduğunuz "*Derin Öğrenme Yöntemleri İle Bilgisayar Mühendisliği Lisans Öğrencilerinin Akademik Performanslarına Dayalı Mezuniyet Tahmini*" başlıklı çalışma hakkında alınan karar ilişikte gönderilmektedir.

Bilgilerinizi ve gereğini saygı ile rica ederim.

Prof. Dr. Neşe ÖZTÜRK
Kurul Başkanı

BU BELGE ELEKTRONİK
İMZA İLE GÖNDERİLMİDİR.

22/04/2019

Sibel AK
Bilgisayar İşletmeni

Sibel AK

HİZMETE ÖZEL

Bu evrak 5070 sayılı Elektronik İmza Kanunu'na göre elektronik olarak imzalanmıştır. Evrak doğrulama adresi:
<https://ebysnetm.ogu.edu.tr/Home/Dogrulama/b82130fc-a04e-44b7-9818-0e4ed8f10666>

Adres	: Meselik Kampüsü PK:26480 Odunpazarı	Ayrıntılı Bilgi	: Münevver Sibel AK - Bilgisayar İşletmeni
Telefon	: 0222 2393750-5074	Faks	:
E-Posta	: sibelak@ogu.edu.tr	Elektronik Ağ	: http://www.ogu.edu.tr
		KEP Adresi	: esk.osmangaziunirek@hs01.kep.tr

T.C.
ESKİŞEHİR OSMANGAZİ ÜNİVERSİTESİ
FEN VE MÜHENDİSLİK BİLİMLERİ
BİLİMSEL ARAŞTIRMA VE YAYIN ETİĞİ KURULU
ESKİŞEHİR

Toplantı Tarihi : 19.04.2019

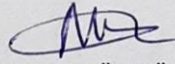
Toplantı No : 2019-07

GÜNDEM :

1. Başvuru Sahibi : Dr.Öğretim Üyesi Uğur GÜREL. **Konu :** “Derin Öğrenme Yöntemleri İle Bilgisayar Mühendisliği Lisans Öğrencilerinin Akademik Performanslarına Dayalı Mezuniyet Tahmini” konulu anket ve içeriğinin, Fen ve Mühendislik Bilimleri Bilimsel Araştırma ve Yayın Etiği Kurulu’na etik açıdan uygunluğunun görüşülmesi.

KARAR :

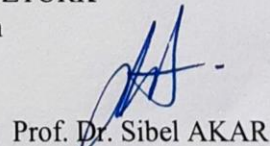
1. Dr.Öğretim Üyesi Uğur GÜREL’in “Derin Öğrenme Yöntemleri İle Bilgisayar Mühendisliği Lisans Öğrencilerinin Akademik Performanslarına Dayalı Mezuniyet Tahmini” konulu anket ve içeriğinin, veri toplama araçlarını uygulamak için gerekli yerlerden yasal izinleri almak şartıyla Fen ve Mühendislik Bilimleri Bilimsel Araştırma ve Yayın Etiği Kurulu’na uygun olduğuna, oy birliğiyle karar verildi.



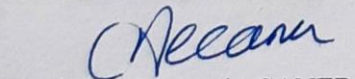
Prof.Dr.Neşe ÖZTÜRK
Başkan




Prof. Dr. Rafet ASLANTAŞ
Başkan Yardımcısı




Prof. Dr. Sibel AKAR
Raportör



Prof. Dr. Necmettin CANER
Üye



Prof. Dr. Bülent SAKA
Üye



Prof. Dr. Gökhan ÇINAR
Üye

Prof. Dr. Volkan KARABACAK
Üye (Görevli)