

Öğrencilerin Derse Devam ve Ara Sınav Notlarını Dikkate Alarak Ders Başarısını Tahminlemek

Prediction of Student Success Considering Attendancy and Midterm Grades

Murat Karakaya¹, Atila Bostan¹, Erhan Gökçay²

¹Bilgisayar Mühendisliği Bölümü, Atılım Üniversitesi, Ankara, Türkiye

²Yazılım Mühendisliği Bölümü, Atılım Üniversitesi, Ankara, Türkiye
{murat.karakaya, atila.bostan, erhan.gokcay}@atilim.edu.tr

Özetçe—Bu çalışmada öğrencilerin bir dersten geçip ya da kalacaklarını, o dersin final sınavına girmeden önce tahmin edebilmek için bir araştırma yapılmıştır. Bu kapsamda, geçmiş dönemlerde verilen bir derste, öğrencilerin derse devam durumları ile iki ara sınav notları ve başarı harfleri derlenmiştir. Daha sonra bu bilgiler ile öğrencinin dersi geçmesi arasındaki ilişki Yapay Sinir Ağları kullanılarak modellenmiştir. Bu model kullanılarak yapılan tahminlemede farklı özelliklerin tahminleme başarısı üzerindeki etkisi gözlemlenmiştir.

Anahtar Kelimeler — öğrenci başarısı; tahminleme; Yapay Sinir Ağları.

Abstract— In this study, we conducted a research to predict if a students would pass or fail from a course before taking the final exam. In this context, we compiled two midterm grades, letters of success, and attendancy statistics in a lecture given in the past. Then, the relationship between the student's success with this information is modeled using Artificial Neural Networks. Using this model, the impact of the different features on the estimation performance was observed.

Keywords — student success; prediction; Artificial Neural Networks.

I. GİRİŞ

Öğrencilerin derslerde başarılı olmalarını etkileyen bir çok faktör vardır. Bu faktörlerin çıkış noktası öğrenme durumunu oluşturan; öğrenen, öğrenme, öğrenilen, öğretene ve öğrenme öğelerinden ve bunların etkileşimidir [1]. Bu öğelerin her biri karmaşık ilişkiler ve mekanizmalar içermektedir. Dolayısıyla, öğrencinin başarılı olması için bu öğelerin planlı ve uyumlu bir şekilde bir araya getirilmesi gerekmektedir. Ancak bu faktörlerin bir çoğu subjektif olan değerlere ait olmaktadır. Örneğin;

öğretmenin ve öğrencinin derse karşı olan motivasyonu ve hazırlığı, alıştırma ve tekrar yoğunluğu, uygun öğrenme metaryelleri ile ortamı, vb.

Diğer bir noktada, genel olarak öğrencinin derste başarılarının ölçümünün dönem sonunda ders içinde yaptığı tüm faaliyetlerinin (sınavlar, sözlüler, projeler, ödevler, v.d.) toptan değerlendirilmesi ile elde edilmesidir. Dönem sonu yapılan bu değerlendirmede öğrencinin dersten başarıyla geçip geçmediği, geçti ise ne kadar bir bilgi kazanımı ile geçtiğini gösterir başarı harfi ya da notu belirlenir. Ancak bu değerlendirme dönem sonunda yapıldığından dolayı, başarısız veya daha az başarılı olan öğrencilerin başarılarını yükseltmek için öğrenci ve öğretmen tarafından alınabilecek tedbirler için çok geç kalınmaktadır. Dersten kalan öğrenciler genelde aynı derse tekrar almakta, az başarı ile geçen öğrenciler ise sonraki derslerde bu eksiklik ile yüzleşmek zorunda kalabilmektedirler.

Bu çalışmamızın amacı; öğrencilerin dönem içinde yürüttükleri ölçülebilir aktivitelerini ve bunların sonuçlarını dikkate alan ve öğrencinin dönem sonunda kalıp geçtiğini tahmin edebilecek bir metod geliştirmektir. Böylelikle, hem öğretmen hem de öğrenciler muhtemel başarı ya da başarısızlık durumları için belirli güven aralıklarında önceden haberdar olabileceklerdir. Öğretmenler, başarısız olabilecek öğrencileri önceden tespit edebilirse, bu öğrenciler üzerine yoğunlaşarak onları destekleyerek başarı seviyelerini artırabilir. Öğrenciler de başarısız olma ihtimalini önceden görebilirlerse derse ayırdıkları zamanı ve enerjilerini daha artırabilirler.

Öğrencilerin dönem sonunda söz konusu dersten geçip geçemeyeceklerini tahminlemek için önerdiğimiz model Yapay Sinir Ağları (YSA) tarafından gerçekleştirilmektedir. Modelin girdileri olarak; ders yoklamaları (öğrenci devam durumu) ile ara sınavlardan alınan notlar kullanılmıştır. Subjektif olabilecek diğer faktörlerin ölçüm zorluğundan

ve güvenilirliklerin düşüklüğünden dolayı modele eklenmemişlerdir. Örnek durum olarak Atılım Üniversitesi Bilgisayar Mühendisliği Bölümünde açılan COMPE 231 - Sayısal Devreler ve Sistemler dersine ait veriler kullanılmıştır.

Öğrenci başarısının tahminlemesi için literatürde çalışmalar mevcuttur. Örneğin, Kovacic Yeni Zelanda Açık Politeknik üniversitesinde öğrencilerin okulu bırakıp bırakmalarını kararını etkileyen sosyo-demografik değişkenler (yaş, cinsiyet, etnik köken, eğitim, çalışma durumu ve sakatlık) ve çalışma ortamı (ders programı ve ders blok) olmak üzere iki ana faktörün etkisini araştırmıştır [3]. Başka bir çalışmada, Geiser ve Santelices dört yıllık üniversite hayatının sonuçlarına göre öğrenci başarısını belirlemede lisede gösterilen başarı ile üniversiteye girişlerde yapılan standart testlerde elde edilen puanlar arasındaki ilişkiyi incelemişlerdir [4]. Eğitimde kullanılan dilin, öğrenci tarafından ne kadar bilindiğinin ders başarısı üzerindeki etkisini inceleyen Graham, belli bir düzeyin altında yetersiz dil bilgisine sahip bulunan öğrencilerin derslerde de başarısız olabileceğini göstermiştir [15]. Pritchard ve Wilson tarafından yapılan diğer bir çalışmada subjektif özellikler başarı tahminlemesinde kullanılmıştır [14]. Kullanılan faktörler arasında; duygusal ve sosyal faktörlerin (örneğin, stres, alkol tüketiminin frekansı) not ortalaması üzerinde, duygusal faktörlerin (örneğin, benlik saygısı, yorgunluk) ise dersi bırakma kararı üzerinde etkili olduğu görülmüştür.

Yukarıda özetlenen çalışmalardan farklı olarak, bu çalışmada, öğrencinin derse devam durumunu ve ara sınavlardan aldığı notlardan yola çıkarak söz konusu dersten geçip geçemeyeceğini tahmin etmeye çalıştık. Maklenin geri kalanında; toplanan veri hakkında açıklayıcı bilgiyi bir sonraki bölümde verdik. Üçüncü bölümde özetle Yapay Sinir Ağlarını (YSA) tanıtır bir sonraki bölümde elde edilen tahminlemenin sonuçlarını tartıştık. En son bölüm olarak da sonuçları paylaştık.

II. TOPLANAN VERİNİN TANIMI

Bu çalışmamızda Atılım Üniversitesi Bilgisayar Mühendisliği Bölümünde verilen COMPE 231 - Sayısal Devreler ve Sistemler dersi esnasında toplanan veriler kullanılmıştır. Bu veriler, 2011-12 Güz döneminde açılan 2 şube ile 2012-13 Güz döneminde açılan tek şubede ders alan toplam 99 öğrencinin; ara sınav notları, devam durumları ve dönem sonu aldıkları başarı harflerinden oluşmaktadır. COMPE 231 dersinde kullanılan değerlendirme faaliyetleri Tablo 1'de sunulmuştur [7]. Öğrencilerin Tablo 1'de yapılan faaliyetlerden aldıkları notlar Katkı Payları dikkate alınarak dönem sonu notu hesaplanmaktadır. Hesaplanan bu sayısal nottan başarı harflerine dönüşüm notların normal dağılım gösterdiği varsayımı ile yapılmaktadır. Atılım Üniversitesinde harf notu olarak AA, BA, BB, CB, CC, DC, DD, FD ve FF olmak üzere dokuz dilimli harf not ölçeği kullanılmaktadır. Her harf notu diliminin genişliği (aynı

Çalışmalar	Değerlendirme Sistemi	
	Sayı	Katkı Payı
Laboratuvar	2	%20
Uygulama	3	%10
Ara Sınavlar	2	%40
Final	1	%30
Toplam	8	%100

Tablo 1 Compe 231 dersinin değerlendirme sistemi [8]

Veri Seti	Veri Seti Özellikleri			
	Verildiği Yıl ve Dönem	Öğrenci sayısı	Dersi Geçen Öğrenci (Sayı)	Dersi Geçen Öğrenci (%)
Şube 1	2011-12 Güz Section 1	38	33	%87
Şube 2	2011-12 Güz Section 2	25	18	%72
Şube 3	2012-13 Güz	36	31	%86
Tüm Şubeler	-	99	82	%83

Tablo 2. Kullanılan veri setlerinin özellikleri

Veri Seti	Öğrencilerin Derse Devam Durumları			
	Ortalama	Minimum	Maximum	Varyans
Şube 1	27,90	4	39	90,97
Şube 2	20,72	0	38	130,63
Şube 3	27,36	4	38	80,24
Tüm Şubeler	25,88	0	39	104,16

Tablo 3. Kullanılan veri setlerinin özellikleri

harfi alan en düşük ve en yüksek not aralığı) öğrenci not dağılım standart sapmasının 5/9'u olarak hesaplanmaktadır. Başarı harflerinden FF veya FD alan öğrenci dersten kalarak başarısız olmaktadır. Diğer başarı harfini alan öğrenciler ise dersi geçmiş sayılmaktadırlar.

Tablo 2 ve 3'de kullanılan veri seti hakkında detaylı bilgi sunulmuştur. Tablo 2'de seçilmiş 3 kısma ait verilere göre derse kayıtlı öğrenci sayısı, dersi geçen öğrenci sayısı ile bunların oranları verilmiştir. Kullanılan bu üç veri seti ayrıca birleştirilerek sanki tüm öğrenciler aynı dönem dersi almış gibi düşünülerek tek bir veri seti oluşturulmuştur. Tablo 2'de dikkat çeken bir husus Şube 2'deki başarı durumunun diğer iki şubeye göre daha düşük olduğudur. Dolayısıyla, Şube 2 veri setinde kalan öğrencilere ait daha çok örnek değerler bulunmaktadır.

Tablo 3'de ise veri setlerindeki öğrencilerin devam durumlarına ait özet istatistiksel bilgi sunulmuştur. Ortalama

devam sayıları dikkate alındığında Şube 2'deki öğrencilerinin devamının diğer şubelerde gözlemlenen değerlere göre daha düşük olduğu görülmektedir. Bu şubedeki 6 öğrencinin devam sayılarının 10'un altında olduğu veri yakından incelendiğinde görülmüştür. 10 ve daha az derse devam eden öğrenci sayısı diğer veri setlerinde çok daha azdır (Şube 1 ve Şube 3'de ikişer kişi). Şube 2'ye ait varyansın yüksek olması da devamsızlık yapan bu grubun devamlı derse gelen öğrencilerden büyük sapma yaşadıklarını göstermektedir.

III. YAPAY SİNİR AĞLARI

Yapay Zeka yöntemleri özellikle doğrusal olmayan problemlerin çözümünde kullanılmaktadır. Bu tür problemlerin matematiksel olarak modellenmesi veya çözümlenmesi büyük verilerde etkin ve verimli olamamaktadır. Bu nedenle Yapay Zeka yöntemleri doğrusal olmayan problemlerde sıkça kullanılmaktadır.

Sınıflandırma (classification) problemi şu anki Yapay Zeka metodlarının en sık kullanıldığı alanlardan biridir [5]. Sınıflandırma problemleri; bir nesnenin, bu nesneye ilişkin gözlenen niteliklerine göre daha önceden tanımlanmış bir dizi zümreye veya sınıfa ayrılması gerektiğinde oluşur. İş, bilim, sanayi ve tıpta pek çok sorun sınıflandırma problemleri olarak ele alınabilir. Örnek olarak; iflas tahmini, kredi puanlama, tıbbi tanı, kalite kontrol, el yazısından karakter tanıma ve konuşma tanıma verilebilir [8][9][10][12].

Sınıflandırmada kullanılan diskriminant analizi gibi geleneksel istatistiksel sınıflandırma prosedürleri Bayes karar teorisi üzerine inşa edilmiştir [6]. İstatistiksel modellerin en önemli sınırlamalarından biri, bu modellerin başarıyla uygulanabilir olması için önce kullanıcıların veri özellikleri ve model yetenekleri hakkında oldukça detaylı bir bilgiye sahip olmaları gerekmektedir. Ancak karmaşık sistemlerde bu her zaman mümkün değildir.

Sınıflandırma işleminde en sık kullanılan Yapay Zeka yaklaşımlarından bir Yapay Sinir Ağlarıdır. Yapay Sinir Ağları (YSA), insan beyninde nöron yapısı ve davranışları örnek olarak modellenmiş bilgisayar tabanlı bir algoritmadır [11]. YSA karmaşık örüntü (pattern) tanımak ve kategorize için kullanılabilir. Örüntü tanıma, deneyimlerden öğrenme yoluyla hata minimizasyonu süreciyle YSA parametrelerini ayarlayarak elde edilir. Sınıflandırma probleminde, verilen sınıflara ait örneklerin içersindeki örüntülerin keşfedilmesinden istifade edilmektedir. Böylece her bir sınıfa ait örüntülerin tespitinden sonra gelecek bir nesnenin hangi sınıfa ait olması gerektiği tahminleneceği zaman, daha önceden elde edilen örüntüler ile nesnenin sahip olduğu özellikler karşılaştırılmaktadır.

YSA'nın avantajı teorik altyapılarında yatmaktadır[5][13]. Öncelikle, YSA, belirgin özelliklere sahip olmayan verilere dahi uyarlamalı yöntemler uygulayarak modelini ayarlayabilir. Ayrıca, YSA'da bulunan evrensel fonksiyonlar, çözümün gerektirdiği

hassasiyete ve doğruluğa ulaşmak için kendilerinin parametre ağırlıklarını uyarlayabilirler. Üçüncü olarak, sinir ağları, doğrusal olmayan modeller olduklarından gerçek dünyadaki karmaşık ilişkileri modellemede başarılıdırlar.

Genel olarak, YSA modelinin yapısı temelde giriş, gizli ve çıkış tabakalarından oluşur. Üzerinde çalıştığımız problemde öğrenci başarısını tahmin etmekte iki önemli özellik (feature) belirlenmiştir. Bunlar: öğrencinin devam durumu ve ara sınavlardan aldığı notlardır. YSA modelini oluşturan giriş tabakasına bu seçilen özelliklerden oluşturulan üç kombinasyon girdi değerleri olarak verilmiştir. Bu üç kombinasyon:

- Tüm özellikler
- Sadece ara sınav notları
- Sadece devam durumu

Bu nedenle üç farklı YSA modeli kullanılmıştır. Çıkış katında ise iki adet sınıflandırma mevcuttur: Geçti ve Kaldı. Böylelikle YSA, kendisine verilen eğitim verisindeki (training data set) özellikleri ve dersi geçme durumlarını kullanarak gizli katmandaki nöronlarının fonksiyonlarını otomatik olarak ayarlamaktadır. Eğitim setindeki bilgileri kullanarak çıkıştaki sınıflandırmadaki hata miktarını minimize edebildiği noktada YSA'nın eğitim safhası bitmektedir. Daha sonra, modelin onaylanması için ayrılan veri seti ile sistem bir kez daha çalıştırılarak sınıflandırmadaki hata oranlarına göre gizli tabakadaki nöronların fonksiyonları düzenlenmektedir. Son safhada ise test için ayrılan veri ile sistemin başarımlı ölçülmektedir.

MATLAB hesaplama aracı kullanılarak oluşturulan Yapay Sinir Ağları (YSA) modeli için iki katmanlı ileri beslemeli (two-layer feedforward network) bir ağ kullanılmıştır. Gizli ve çıkış katmanında sigmoid transfer fonksiyonları kullanılmıştır. Gizli katmandaki nöron sayısı 10 adettir. Çıkış katmanında ise öğrencinin geçip kaldığına karar verecek şekilde 2 nöron kullanılmıştır.

Her bir veri setinin rastgele seçilen %70'lik kısmı ile YSA modeli eğitilmiştir. Geriye kalan verinin rastgele seçilen yarısı modelin onaylanması (validation) ve diğer yarısı da modelin sınanması (test) için kullanılmıştır.

IV. SINIFLANDIRMA SONUÇLARI VE ANALİZİ

Derlenen veri setleri ile MATLAB hesaplama aracı üzerinde oluşturulan YSA modelleri kullanılarak öğrencilerin dersi başarı ile geçip geçemeyecekleri tahminlenmeye çalışılmıştır. Tablo 4 elde edilen sonuçlar toplu olarak verilmektedir. Tablonun ilk sütununda kullanılan veri setinin adı verilmiştir. Tahminleme doğruluğu yüzde olarak seçilen 3 özelliğe göre tablonun diğer sütunlarında verilmiştir. Her bir veri seti için en

yüksek doğruluk ile tahminleme yapılmasını sağlayan özelliklerin sonuçları **koyu renk** ile işaretlenmiştir.

Tablo 4 incelendiğinde ilk dikkati çeken tüm veri setleri ile tüm seçilen özelliklerin YSA modelleri tarafından kullanılması sonucu elde edilen en düşük doğruluğun %72 ve en yüksek doğruluğun ise %97 civarında olduğudur. Diğer önemli gözlemler şöyle sıralanabilir:

- En düşük doğruluklu tahminlemeye genelde sadece Devam Durumu girdi olarak kullanıldığında ulaşılmıştır.
- En yüksek doğruluklu tahminlemeye ise genelde her üç özelliğin birlikte girdi olarak kullanıldığı modelde ulaşılmıştır.
- Sadece iki ara sınav notların girdi olarak kullanıldığı modelde genelde kabul edilebilir doğrulukta tahminleme yapılmıştır.

Veri Seti	Tahminleme Doğruluğu		
	Devam Durumu ve 2 Ara Sınav Notları	Sadece Devam Durumu	Sadece 2 Ara Sınav Notları
Şube 1	%92.1	%89.5	%97.4
Şube 2	%96.0	%72.0	%96.0
Şube 3	%94.4	%83.3	%75.0
Tümü	%86.9	%78.8	%81.8

Tablo 4 Kullanılan özelliklere göre elde edilen tahminlemenin doğruluğu

Tablo 4'te verilen sonuçların daha detaylı olarak değerlendirilmesi için Tablo5'te tahmin doğruluklarının geçme ve kalma tahminlerine göre sınıflandırılmış hali verilmiştir. Örneğin, Şube 1 veri seti için tüm özellikler kullanılarak tahminleme yapıldığında; geçecek olarak tahmin edilen tüm öğrencilerin gerçekte veri setinde geçen öğrenciler olduğu görüldüğünden doğruluk %100 olmuştur. Ancak, kalacak öğrenci olarak tahmin edilen öğrencilerin gerçekte sadece %40'nın dersi geçemediği veri setiyle yapılan karşılaştırmadan görülmüştür. Geri kalan %60 oranındaki öğrencilerin ise gerçekte dersi geçtikleri görülmüştür. Bu sonuçlara bakarak Şube 1 veri seti için 3 özelliğin kullanıldığı durumda geçtiğini tahmin ettiğimiz öğrencilerin hepsinin gerçekte de dersi geçtiğini ancak kalacağını tahmin ettiğimiz öğrencilerin önemli bir kısmında yanıldığımızı söyleyebiliriz.

Tablo 5'te özetlenen veriler incelendiğinde şu çıkarımlar yapılabilir:

- En düşük doğruluklu tahminlemeyi, genelde kalan öğrencilerin tespitinde sadece devam durumu özelliği kullanıldığı modelde görmekteyiz. Bunun sebebi, sadece derse katılımın az olmasının dersten kalmak için yeterli bir sebep olamaması gösterilebilir.

- Genelde geçen öğrencileri yüksek doğrulukla tespit edebilmekteyiz. Örneğin her üç özelliğin birlikte kullanıldığı ilk YSA modelinde tüm veri setlerinde bu doğruluk oranı ortalama %94 civarındadır.

- Genelde kalan öğrencileri daha düşük doğrulukla tahmin edebilmekteyiz. Bunun bir sebebi kalan öğrenci sayısının, geçen öğrenci sayısına göre göreceli olarak çok daha az olması olabilir. YSA kalan öğrenci sınıfına ait daha az sayıda öğrenci ile eğitildiğinden tahminleme doğruluğu da daha düşük olabilmektedir.

- Sadece 2 ara sınav notlarının kullanıldığı üçüncü YSA modelinde, kalan öğrenciler diğer modellere nispeten tüm veri seti dikkate alındığında daha yüksek bir doğrulukla tahmin edilmektedir.

- Tablo 1 ve 2'ye göre en fazla sayıda öğrenciye sahip, en çok ortalama ders devamının olduğu ve en çok ders geçme başarısının gözlemlendiği Şube 1 veri setinde geçen öğrencilerin doğru tahminlenmesi %100 oranındadır. Diğer taraftan kalan öğrencilerin tahminlenmesinde oldukça düşük başarı oranları görülmektedir. Bunun bir sebebi yukarıda açıklandığı üzere, kalan öğrenci sayısının azlığı olabilir.

Veri Seti	Tahminleme Doğruluğu					
	Devam Durumu ve 2 Ara Sınav Notları		Sadece Devam Durumu		Sadece 2 Ara Sınav Notları	
	Geçen	Kalan	Geçen	Kalan	Geçen	Kalan
Şube 1	%100	%40	%100	%20	%100	%80
Şube 2	%94	%100	%89	%29	%94	%100
Şube 3	%94	%100	%90	%40	%74	%80
Tümü	%89	%77	%94	%6	%81	%88

Tablo 5 Kullanılan özelliklere göre geçen ve kalan öğrencileri tahminleme doğruluğu

V. SONUÇ

Öğrencilerin derse devam durumları ile iki ara sınavda aldıkları notu dikkate alarak oluşturduğumuz Yapay Sinir Ağı modelleriyle öğrencilerin dersten geçip geçemeyeceklerinin tahminlenmesi üzerine bir çalışma yaptık. Bu çalışmamızda sınırlı miktarda veri kullanılmasına rağmen genel olarak başarılı öğrencileri yüksek doğrulukla tahmin edebileceğimizi gördük. Ancak kalacak öğrencilerin tahmininde doğruluk oranının yükseltilebilmesi için daha çok veri gerektiğini düşünmekteyiz.

İleride yapılacak çalışmalar için, veri toplamasına devam etmekteyiz. Veri miktarının artırılması ve farklı dersler için de benzer verilerin toplanması ile daha detaylı YSA modelleri kurmasının mümkün olacağı ve böylece daha sağlıklı tahminler yapabilmeyi umuyoruz.

KAYNAKÇA

- [1] Seven, M. A., Engin, A. O. (2008). Öğrenmeyi etkileyen faktörler. *Atatürk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 12(2).
- [2] Dursun, Ş., & Yüksel, D. E. D. E. (2004). Öğrencilerin matematikte başarısını etkileyen faktörler matematik öğretmenlerinin görüşleri bakımından. *Gazi Üniversitesi Gazi Eğitim Fakültesi Dergisi*, 24(2).
- [3] Kovacic, Z. (2010). Early prediction of student success: Mining students' enrolment data. Informing Science and Information Technology Education Joint Conference, Cassino, Italy.
- [4] Geiser, S., & Santelices, M. V. (2007). Validity of High-School Grades in Predicting Student Success beyond the Freshman Year: High-School Record vs. Standardized Tests as Indicators of Four-Year College Outcomes. Research & Occasional Paper Series: CSHE. 6.07. Center for studies in higher education.
- [5] Zhang, G. P. (2000). Neural networks for classification: a survey. *IEEE Transactions on Systems, Man, and Cybernetics*, Part C (Applications and Reviews), 30(4), 451-462.
- [6] P. O. Duda and P. E. Hart, *Pattern Classification and Scene Analysis*. New York: Wiley, 1973.
- [7] Atılım Üniversitesi Web Sitesi, <http://compe.atilim.edu.tr/academicprogramcourses/view/id/606?lang=tr>, Temmuz, 2016
- [8] Atiya, A. F. (2001). Bankruptcy prediction for credit risk using neural networks: A survey and new results. *IEEE Transactions on neural networks*, 12(4), 929-935.
- [9] Fritzke, B. (1994). Growing cell structures—a self-organizing network for unsupervised and supervised learning. *Neural networks*, 7(9), 1441-1460.
- [10] Dutta, S., & Shekhar, S. (1988, July). Bond rating: a nonconservative application of neural networks. *In Neural Networks*, 1988., IEEE International Conference on (pp. 443-450). IEEE.
- [11] Bishop, C.M. *Neural Networks for Pattern Recognition*. Clarendon Press, Oxford, 1995.
- [12] Khan, J., Wei, J. S., Ringner, M., Saal, L. H., Ladanyi, M., Westermann, F., ... & Meltzer, P. S. (2001). *Classification and diagnostic prediction of cancers using gene expression profiling and artificial neural networks*. *Nature medicine*, 7(6), 673-679.
- [13] K. Hornik. *Approximation capabilities of multilayer feedforward networks*. *Neural Networks*, vol. 4, pp. 251-257, 1991.
- [14] Pritchard, M. E., & Wilson, G. S. (2003). Using emotional and social factors to predict student success. *Journal of college student development*, 44(1), 18-28.
- [15] Graham, J. G. (1987). English language proficiency and the prediction of academic success. *TESOL quarterly*, 505-521.