

## Öznitelik Seçme ve Makine Öğrenmesi Yöntemleriyle Eğitim Performansının Tahmin Edilmesi

Fatih ÇİFÇİ<sup>1</sup>, Cihan KALELİ<sup>2</sup>, Serkan GÜNAL<sup>3</sup>

*Geliş Tarihi: 07.06.2018*

*Kabul Tarihi: 11.07.2018*

*Araştırma Makalesi*

### Öz

Günümüzde hayatın her sektöründe işlenen veri miktarının artması, veri madenciliğın giderek daha popüler hale gelmesine yol açmış ve yüksek miktarda verinin artan bir karmaşıklıkta işlenmesi ihtiyacı doğmuştur. Finanstan, sağlığa, savunmadan eğitime onlarca sektörün sorunlarını çözmek adına gün geçtikçe farklı yöntemler geliştirilmekte, sosyal, ekonomik, bilimsel birçok problemin çözümü adına veri madenciliği yöntemlerine başvurulmaktadır. Eğitilen ve eğiten sayısının gün geçtikçe arttığı eğitim sektöründe ise, sistemin başarısının geliştirilebilmesi için, gerek eğitilen gerekse eğitimcilerinin performanslarının takip edilmesi ve kıymetlendirilmesi ihtiyacı, eğitimsel veri madenciliği kavramını doğurmuştur. Bu alanda yapılan çalışmalar genel olarak, öğrenci performansı konularına yoğunlaştığından, eğitmen performansı konusunda daha çok çalışmaya ihtiyaç duyulmaktadır. Eğitimsel veri madenciliği alanında öznitelik seçme ile birleştirilmiş makine öğrenmesi kullanan çalışmaların genel olarak öğrenci performansı üzerine yoğunlaştığı, ancak az sayıdaki çalışmanın eğitmen performansı üzerinde durduğu görülmüştür. Bu çalışmamızda, eğitmen performansının eğitimsel veri madenciliği yöntemleriyle nasıl tespit edilebileceği üzerinde durulmuştur. Çalışma kapsamında Gazi Üniversitesi öğrencilerinin eğitmenleri hakkında doldurdukları bir Likert Ölçekli Anket veri seti üzerinde çalışılmış, çeşitli öznitelik indirgeme algoritmaları ve farklı makine öğrenme yöntemleriyle veri seti kıymetlendirilmiş ve eğitmenlerin performansları tahmin edilmiştir. Elde edilen sonuçlara göre genetik algoritma ile öznitelik seçmenin, kullanılan veri seti için diğer yöntemlere kıyasla en iyi sonucu verdiğini göstermiş ve 33 tane öznitelik yerine 19 öznitelik kullanılabileceği ortaya çıkarılmıştır. Genetik algoritma ile birlikte makine öğrenmesi yöntemi olarak derin öğrenme kullanımı ile birlikte %97,70 bir tahmin doğruluk performansına ulaşılmış ve bu değerin tüm özniteliklerin kullanılması ile elde edilebilecek değerden yüksek olduğu görülmüştür. Bu çalışmayı diğerlerinden farklı kılan özelliği ise, indirgenmiş öznitelik sayısı ve makine öğrenmesini birleştirmesinin yanında, eğitmen performanslarının sıralanması işlemini de somut olarak yapmasıdır.

*Anahtar kelimeler:* Eğitimsel veri madenciliği, eğitmen performansı, makine öğrenmesi, öznitelik seçme, performans kıymetlendirme

<sup>1</sup> Anadolu Üniversitesi, e-mail: fatihcifci@anadolu.edu.tr

<sup>2</sup> Anadolu Üniversitesi, e-mail: ckaleli@anadolu.edu.tr

<sup>3</sup> Anadolu Üniversitesi, e-mail: serkangunal@anadolu.edu.tr

## Predicting Instructor Performance by Feature Selection and Machine Learning Methods

---

---

*Submitted by 07.06.2018*

*Accepted by 11.07.2018*

*Research Paper*

### Abstract

Today, increasing amount of data in all sector of life, make data mining more popular, and high amount of data in increasing complexity demanded to acquit. Different methods developed day by day, for solving problems at many sectors like finance, health, defense, and education, applied to data mining for many social, economic, and scientific issues. In the education area, where both number of instructors and students always increase, for enhancing system performance, it is needed to observe and evaluate the performance of students and instructors and such situation causes to reveal a new concept Educational Data Mining. Research in this area generally focuses on student performance. Thus, there is a need for research in instructor performance. Research using machine learning combined with attribute selection in the field of educational data mining have focused on student performance in general, but few studies have focused on instructor performance. In this paper, it was discussed how the performance of the instructor can be determined by educational data mining methods. A Likert type questionnaire dataset on opinions of the Gazi University's student regarding their instructor's teaching performance is used in this research and different feature reduction, and machine learning algorithms are used for evaluating the data set and performances of instructors. According to the obtained results, it has been revealed that the feature selection with genetic algorithm gives the best result for the used data set compared to the other methods and 19 attributes can be used instead of 33 attributes. Utilizing genetic algorithm and deep learning as a machine learning method has achieved a predictive accuracy performance of 97.70 %, which is higher than the value that can be achieved by using all the attributes. This study differs from the others in that it combines the reduced number of attributes and machine learning, as well as the ordering of instructor performances in concrete terms.

*Keywords:* Educational data mining, instructor performance, machine learning, feature selection, performance evaluation

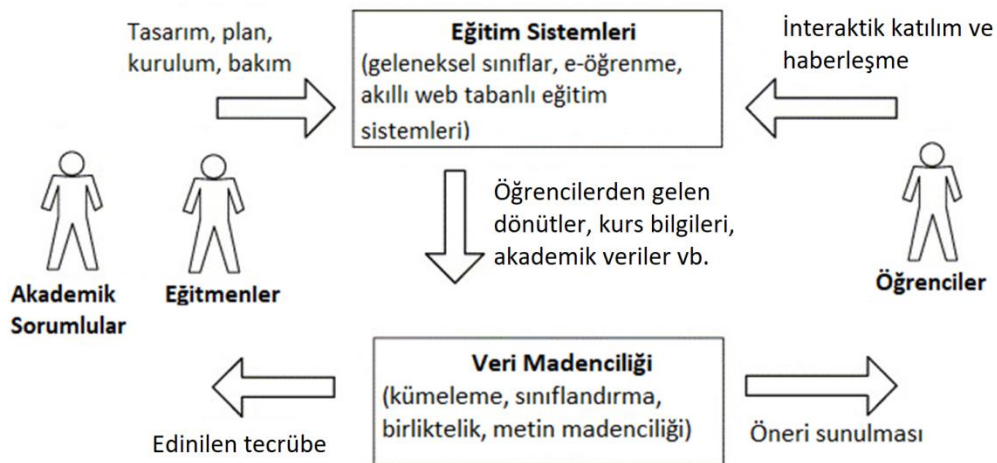
## Giriş

Eğitim, her toplumda olmazsa olmaz, kaybedilemeyecek ve ihmal edilemeyecek en temel olgu ve kurallardan biri olarak görülmüş, yazının icadından günümüze dek yaşanan binlere yıllık süreçte milyonlarca format değişikliğine uğramış, bütün bu süreçlere rağmen milletleri yaşatan temel dinamik olma özelliğini ise hiç kaybetmemiştir. Tüm dünyada eğitim sistemlerinin giderek büyümesi, eğitim kalitesinin toplumu her yönden etkilemesi ve nitelikli toplum yetiştirmenin ancak nitelikli eğitimle mümkün olabileceği gerçeği, başta öğrenci ve öğretmen olmak üzere sistemin tüm bileşenleri tarafından kabul edilmektedir. Nitelikli eğitime duyulan ihtiyaç çok eski dönemlerde fark edilmesine karşın, nüfus artışı, artan karmaşıklık, sürekli değişen sosyo-psikolojik şartlar eğitim sistemin iyileştirilmesini gün geçtikçe daha zor hale getirmiş ve artık günümüze gelindiğinde ise, tüm alanlarda olduğu gibi bu alanda da iyileşme sağlanabilmesi adına teknolojik yeniliklerden faydalanılmıştır. Eğitim sistemlerini iyileştirmede yaşanan sorunların çözümü adına son 50 yıldır kullanılan basit anket ve örneklemeler ise, günümüzde artık etkin bir kıymetlendirmeden uzak kalmıştır. Eğitim eko sisteminin yüksek hızda büyümesi, yüksek hız ve tutarlılıkta çözüm ihtiyacı doğurmuş ve bu durum özellikle yükseköğretimdeki eğitim yöneticileri için önemli bir problem haline gelmiştir (Anwar, Naseer, & Ali, 2014).

Son zamanlarda büyük önem kazanmaya başlayan veri madenciliği, büyük verileri işleyerek anlamlandırmada büyük başarı elde ederek; başta finans, sağlık, haberleşme ve eğitim olmak üzere birçok sektörde büyük problemleri çözmekte etkin tahminlerde bulunmaktadır (Mendes, de Voznika, Freitas, & Nievola, 2001). Veri madenciliği uygulamalarının eğitim alanında uygulanmasına yönelik son dönemde yapılan çalışmalar, bu alandaki geniş boşluğu doldurma adına büyük katkı sağlamış, Eğitim Veri Madenciliği (EVM) kavramının doğmasına yol açmıştır. Bu çalışmalar ile eğitim sistemlerinin etki, kalite

ve verimliliğini arttırmak hedeflenmiştir (Peña-Ayala, 2014). EVM üzerine yapılan araştırmalar genel olarak öğrencilerin başarıları üzerine odaklanmış, eğitim sistemi başarısını tespitte tek kaynağın öğrenciler olduğu vurgulanmıştır. Bu tespitler yapılırken de öğrencilerden alınan dönütlerin yeterince objektif olamayacağı kabul edilmiş, ancak eğitimle ilgili büyük miktarda ve çeşitteki verilerin yeterli miktarda ancak öğrencilerden alınabildiği belirtilmiştir (Delavari, Phone-Amnuaisuk, & Beikzadeh, 2008; Coburn, 1984; Hobson, & Talbot, 2001; Radmacher, & Martin, 2001). Bu nedenle eğitim sisteminin başarısı ile öğrencilerin başarısı arasında doğrusal bir ilişki kurularak, eğitim sistemi başarısı, öğrenci başarısı üzerinden değerlendirilmiştir (Andonie, 2010).

Eğitim sistemleri ekosistemi, içinde eğitim ortamı, eğitim materyalleri, eğitmenler, eğitim yöneticileri, eğitim kıymetlendirme sistemleri olmak üzere onlarca bileşeni içeren ve karmaşıklığı giderek artan sistemlerdir. Şekil 1’de görülen, eğitim sisteminin içindeki genel bileşenleri arasındaki etkileşim yoğunluğu, EVM alanındaki artan ihtiyacı gözler önüne sermektedir. EVM alanında bugüne dek yapılan çalışmalar da bu ihtiyacın belirli oranda giderilmesi ve sistemin iyileştirilmesini hedeflemiştir.



Şekil 1. Eğitim sistemi bileşenlerinin etkileşimi (Romero & Ventura, 2007)

1995-2005 yılları arasındaki veri madenciliğinin eğitim alanındaki uygulamalarına yönelik bir inceleme Romero ve Ventura (2007) tarafından yapılmış, geleneksel eğitim sistemlerine veri madenciliği uygulanmasından, özel web tabanlı kurslara kadar birçok konu incelenmiş, bunların ortak noktasının ise veri ön işleme işlemleri sonrasında veri madenciliği tekniklerinin uygulanması olduğu vurgulanmıştır. Minaei-Bidgoli ve Punch (2003) öğrencilerin yılsonu notlarını tahmin edebilmek için ilk kez genetik algoritma (GA) tabanlı sınıflandırma yapmışlardır ve GA ile birleşik sınıflandırma yöntemleri kullanmanın doğruluğu arttırdığını tespit etmişlerdir. Öğrencilerin akademik yıl içindeki performanslarını üç kademeli olarak derecelendirerek önceden tahmin etmeyi amaçlayan Superby ve ark.(206) tarafından yapılan çalışmada, Karar Ağacı (KA) ve Yapay Sinir Ağları (YSA), Diskriminat Analizi (DA) olmak üzere çeşitli veri madenciliği yöntemleri kullanılarak sınıflandırma yapılmış, bunlar arasından KA yöntemi ile en başarılı şekilde öğrencilerin dereceleri tahmin edilmiştir. Cortez ve Silva (2008) tarafından yapılan çalışmada Portekiz'in Alentejo bölgesindeki ortaokul öğrencilerinin matematik ve Portekizcilerinin neden zayıf oldukları konusu araştırılmış, kullanılan dört veri seti için KA ve YSA'nın her ikisinin de % 72'lik bir tahmin değeri yakaladığı belirtilmiştir. Bu çalışmaların yanı sıra araştırmacılar çeşitli veri madenciliği yöntemleri ile öğrencilerin yılsonu başarı notlarını tahmin etmeye çalışmışlardır (Koutina, & Kermanidis, 2011; Natek, & Zwilling, 2014; Sorour, & Goda, & Mine, 2015) YSA kullanılarak bazı özniteliklere göre öğrencilerin hangi dersi kaç kez tekrar ettiği tahmin edilmeye çalışıldığı Oyedotun ve ark. (2015) tarafından yapılan çalışmada, öğrenme ortamı, öğrenci-öğretmen arasındaki ilişkiler tahmin edilmeye çalışılmış, bunun için de Radial Tabanlı Fonksiyon Ağları (RTFA) kullanılmıştır.

Literatürde, öğretmen performansına yönelik çalışmalarda bulunmaktadır. Ağaoğlu (2016) çalışmasında KA algoritmaları, DVM, YSA ve Diskriminant analizi olmak üzere dört farklı sınıflandırma tekniği kullanarak Marmara Üniversitesi öğrencilerinin öğretmenlerinin

eđitim performanslarını 26 adet öznitelik üzerinden deęerlendirdikleri bir veri seti kullanmıştır. Anılan makine öęrenmesi yöntemlerinin sınıflandırma performansları kıyaslanmış, en başarılı sonucu doğruluk, hassasiyet ve özgünlük bakımından C5.0 KA algoritmasının verdiği vurgulanmıştır. Bu çalışmada ayrıca öęrenci verileri üzerinden eđitmen başarısını tahmin etmenin “öęrencilerin derse olan ilgisine” baęlı olduęu çıkarımı yapılmış, elde edilen veriler ile daha gelişmiş veri madencilięi bileşenlerinin oluşturulabileceęi bildirilmiştir. Ahmed ve ark.(2016) tarafından yapılan çalışmada, J48 KA, Çok Katmanlı Algılayıcı (ÇKA), Naive Bayes, ve Ardışık Minimal Optimizasyon (AMO) veri sınıflandırıcılar kullanılarak öęrenci başarısına etki eden faktörler ve eđitmen başarısı tahmini yapılmıştır. Sanjay ve Keshav (2017) tarafından yapılan çalışmada, eđitmen performansını tahmin etmek için, Naive Bayes sınıflandırma, C4.5 KA ve YSA kullanılmıştır. 10 öznitelikten oluşan bir anket veri setinin kullanıldığı çalışmada, kullanılan üç algoritma içinde en iyi Tahmin Doğruluęu Performansı (TDP)'nin C4.5 KA algoritmasının verdiği ifade edilmiştir.

### **Araştırma Problemi**

EVM alanında öznitelik seçme ile birleştirilmiş makine öęrenmesi kullanan çalışmaların genel olarak öęrenci performansı üzerine yoğunlaştığı, ancak az sayıdaki çalışmanın eđitmen performansı üzerinde durduęu görülmüştür. Bu çalışmamızda, eđitmen performansının EVM yöntemleriyle nasıl tespit edilebileceęi üzerinde durulmuştur. İyi bir eđitiminin her seviyeden öęrenciyi belirli ölçeklerde mutlaka başarıya ulaştırabileceęi gerçeęi eđitim uzmanları tarafından genel kabul görmekte ve birçok öęrenci tarafından, öęretilen dersten çok eđitmenin başarıyı etkilediğini bildirmesi (Marsh & Roche, 1997), eđitim sistemlerinde eđitmenlerin ne denli büyük bir öneme sahip olduğunu göstermektedir. Çalışmamızda, UC (University of California) Irvine Machine Learning Repository'de yer

alan, daha önce Gazi Üniversitesi'nde uygulanmış, öğrencilerin öğretmenlerinin eğitime performanslarını 33 öznitelik üzerinden değerlendirdiği Likert ölçekli bir veri seti kullanılmıştır. Bu veri seti üzerinde öznitelik indirilmesi ve çeşitli makine öğrenmesi algoritmaları kullanılarak öğretmen performans tahmini yapılmış ve 33 öznitelik yerine 19 öznitelik kullanılarak % 97,70 tahmin doğruluğu elde edilmiştir.

## Yöntem

### Araştırma Modeli

Daha önce ifade edildiği üzere, bu çalışmada öznitelik seçme ve makine öğrenme yöntemleriyle veri seti kıymetlendirilmiş ve öğretmenlerin performansları tahmin edilmiştir. Öznitelik seçme (ÖS), temel olarak mevcut veri seti ile ulaşılmak istenen tahmin performansına en yakın değere daha az öznitelik kullanarak ulaşmayı hedefleyen bir işlemler dizisidir. Daha az öznitelik kullanarak daha iyi sonuçlar elde etmek, sonuçların kıymetlendirmesinde işlem maliyetini büyük oranda aşağı çekmekte, sürecin daha hızlı ve başarılı yürütülmesini sağlamaktadır. Çalışmada bilgi kazancı (BK), geri yönlü eliminasyon (GYE) ve genetik algoritma (GA) olmak üzere üç farklı öznitelik seçme yöntemi kullanılmıştır. Makine öğrenmesi yöntemleri olarak ise k-en yakın komşuluk (K-EYK), karar ağacı, naive Bayes ve derin öğrenme temelli sınıflandırıcılardan faydalanılmıştır.

BK, entropinin tersi olarak ifade edilebilen ve 0 ile bir arasında değerler alabilen bir çıkarımdır. BK, işlenen veri setindeki her bir niteliğin, yapılan her bir sınıflandırmaya yatkınlığının incelendiği bir ölçüdür. Bir öznitelik, yapılan tüm sınıflandırmalar içinde ne kadar çok sınıftan, ne kadar çeşitli değer alıyorsa; BK 1 değerine o kadar yakın bir değer alır. Eğer, bir öznitelik örneklemden tüm sınıflara ait farklı değerler taşıyorsa BK=1 ve Entropi=0

olur. Başka bir deyişle, bir öznelik, sınıflardan genel olarak ne kadar uzaksa, BK o kadar düşük olur.

GYE işleminde amaç, sonuç olarak performansa yüksek oranda etki eden öznelikler kümesi elde etmektir. Bunun için öncelikle maksimum mutlak azalma parametresi (MMAP) belirlenir. Bu değer iterasyonlarda karşılaştırma işlemleri için kullanılacak eşik değeridir. GYE işlemine örnek veri setinin tamamı ile başlanır ve her turda öznelikler azaltılarak devam edilir. Her öznelik kaldırma işleminde yerel kıymetlendirme öğeleri ile performans değerlendirmesi yapılır ve elde edilen değer MMAP değeri ile kıyaslanır. GYE'nin amacı performansa etkisi büyük (atıldığında büyük performans azalmasına yol açacak) verileri korumak olduğundan, iterasyona (istenmeyen öznelikleri atmaya) devam etmek için, elde edilen performans değerinin MMAP değerinden küçük olması ve elendiğinde performans artışına neden olan bir niteliğin tespiti durumlarının oluşması gerekir. MMAP değerine eşit ya da büyük bir durum tespit edildiğinde iterasyon durdurulur.

GA'nın temel amacı, herhangi bir problemin çözümünde, o problem için uygulanabilecek tüm çözümlerin arasından en iyi çözümü seçmektir. GA bunu yaparken gen biliminde olduğu gibi kaliteli nesiller üretmeyi hedefler. Popülasyondan (işleme alınan veri kümesinden) üretilecek her yeni nesilde kötü çözümlerin gitgide yok olması, iyi çözümlerin ise daha iyi çözümler elde etmek üzere yeni nesillerin oluşturulmasında kullanılması beklenir.

K-EYK algoritması, önceden sınıflandırma yapılmış bir veri kümesinde, yeni bir elemanı sınıflandırmada kullanılır. Algoritmanın temelinde, sınıflandırılmak istenen öğenin, en yakın mesafede olduğu  $k$  adet komşusunun tespiti vardır. Bu  $k$  adet en yakın komşunun çoğunluğu hangi sınıfa mensup ise, işleme alınan eleman da o sınıfa dâhil edilir (Han, Pei, & Kamber, 2011).

Karar ağaçları, verilerin bir ağaç yapısı şeklinde sürekli olarak kümelenildiği ve bölündüğü, tümevarım mantığıyla hareket eden bir makine öğrenmesi yöntemidir. Karar



ağaçları, ayırık parametrelerden oluşur ve gürültüye dayanıklı bir yapıya sahiptir. Karar ağaçları ana bileşenler olarak karar düğümleri ve yapraklardan oluşmaktadır. Karar düğümleri, veriler kümelenirken hangi yöne gideceklerini tayin ederken, yapraklar son noktadaki sonucu, bir başka deyişle ögenin dâhil edileceği sınıfı gösterir (Theodoridis & Koutroumbas, 2008).

Naive Bayes algoritması, olasılık temelli bir algoritmadır. Bayes teoremine göre istatistiksel tahmin yapar. Algoritmanın amacı sınıf üyelik olasılığını tahmin etmektir. Diğer sınıflandırma işlemlerinde olduğu gibi Bayes teoremi tabanlı olarak yapılan sınıflandırmada da örneklem uzayının bir kısmı öncelikle eğitim amaçlı kullanılarak öğrenme yapılır, örneklem uzayının kalan kısmı ile öğrenilen veriler üzerinden tahmin yapılır. Bir ögenin hangi öznelikleri kendisinde topladığı ve böylece hangi sınıfa atandığı algoritma tarafından öğrenildiğinden, test kümesi içinde sıralı birtakım özellikleri verilen öğelerin hangi sınıfa ait olduğu tahmin edilebilir (Han, Pei, & Kamber, 2011).

Derin öğrenme, son dönemde makine öğrenmesi ve yapay zekâ kavramları içerisinde popülerliği artan bir yöntemdir. Günümüzde derin öğrenme, görüntü sınıflandırma, kişilerin seslerinin analizi, video işleme, doğal dil öğrenme, canlı trafik akışı analizi gibi birçok alanda kullanılmakta ve özellikle büyük teknoloji firmaları ve üniversite araştırma grupları tarafından ciddi yatırımlarla desteklenmektedir. Derin öğrenmenin klasik makine öğrenmesi yöntemlerinden en büyük farkı, önceden hazırlanmış herhangi bir matematiksel modele dayalı öznelik çıkarımına ihtiyaç duymamasıdır. Öznelik çıkarıcı, derin öğrenme tarafından otomatik olarak uygun şekilde öğrenildiğinden, sistem ağ katmanlarına ve tahmin işlemlerine odaklanmaktadır (Karahana & Akgül, 2016).

## Verilerin Hazırlanması

Bu çalışmada, önemli bir veri madenciliği yazılımı olan Rapidminer yazılımı kullanılmıştır. Veri seti olarak Kaliforniya Üniversitesi Makine Öğrenmesi Veri Havuzunda (University of California, Irvine, USA) bulunan “Türkiye Öğrenci Kıymetlendirme Veri Seti (Turkey Student Evaluation Data Set)” isimli açık kaynak bir veri seti (Dosya: turkiye-student-evaluation\_generic.csv) kullanılmıştır (Gunduz & Fokoue, 2013). Veri seti, 2013 yılında Gazi Üniversitesi’nde yapılmış ve 2850 öğrencinin, kendilerine toplam 13 ders veren 3 adet eğitmeni değerlendirdiği bir çalışma sonuçlarını içermektedir. Veri setinde toplam 33 adet niteliğin 5 adedi derslerin isimlerini, derslerin zorluklarını, derslerin öğrenci tarafından alınma sayılarını ve öğretmenlerin isimlerini sembolize etmekte diğer 28 öznelikte ise öğrenciler eğitmenlerine dair sorulmuş çeşitli soruları cevaplamaktadır. 33 adet niteliğin açıklamaları aşağıda belirtilmiştir:

**Instr:** Eğitmeni ifade eder; {1,2,3} değerlerinden birini alır.

**Class:** Alınan dersin ismini ifade eder, {1-13} aralığındaki değerlerden birini alır.

**Repeat:** Öğrenci tarafından ilgili dersin kaç kez alındığını ifade eder; {1,2,3} değerlerinden birini alır.

**Attendance:** Öğrencinin derse katılım seviyesi; {0, 1, 2, 3, 4} değerlerinden birini alır.

**Difficulty:** Öğrencinin yorumuna göre dersin zorluk seviyesi; {1,2,3,4,5} değerlerinden birini alır.

Q1: Dönem başında bildirilen ders içeriği ve öğretim metodu ve kıymetlendirme sistemi

Q2: Dönem başında kursun amaç ve kazanımları açıkça bildirilmiştir.

Q3: Kurs, kendisine atanan kredi düzeyine karşılık verebilecek niteliktedir.

Q4: Kurs, ders programında belirtildiği şekilde işlendi.

Q5: Sınıf içi tartışmalar, verilen ödevler, yapılan uygulama ve çalışmalar yeterli düzeydeydi.

Q6: Kullanılan tüm dokümanlar güncel ve yeterliydi.

Q7: Ders için yeterli sınıf, laboratuvar ve tartışma alanı hazırlanmıştı.

Q8: Quiz, ödev, proje ve örnekler eğitime katkısı sağladı.

Q9: Derslere katılmaktan çok zevk aldım ve hevesliydim.

Q10: Dönem başındaki beklentilerim, dönem sonunda karşılandı.

Q11: Kurs kişisel gelişimim için faydalı oldu.

Q12: Kurs, hayata yeni bir perspektifte bakmamı sağladı.

Q13: Öğretmenin bilgisi yeterli ve günceldi.

Q14: Öğretmen sınıfa hazır geldi.

Q15: Öğretmen, anlatılan ders planına uydu.

Q16: Öğretmen, dersini adanmış ve anlaşılır bir şekilde sundu.

Q17: Öğretmen, derslere zamanında geldi.

Q18: Öğretmenin konuşması akıcı ve düzgündü.

Q19: Öğretmen, ders saatlerini efektif kullandı.

Q20: Öğretmen, dersi öğrencilere sevdirmeye konusunda istekliydi.

Q21: Öğretmen, öğrencilere karşı pozitif bir yaklaşım sergiliyordu.

Q22: Öğretmen, öğrencilerin yorumlarına karşı açık ve saygılıydı.

Q23: Öğretmen, öğrencileri derse katılma konusunda cesaretlendirirdi.

Q24: Öğretmen, öğrencilere derslerine katkı sağlayacak ödev/projeler verdi.

Q25: Öğretmen, öğrencilerin kurs ile ilgili sorularını her ortamda cevapladı.

Q26: Öğretmenin kursu kıymetlendirme adına yaptığı tüm sınavlar, kursun amacına yönelikti.

Q27: Öğretmen, sınavların çözümlerini öğrencilerle paylaştı ve tartıştı.

Q28: Öğretmen, bütün öğrencilere eşit ve tarafsız davrandı.

Q1-Q28 aralığındaki tüm öznel ifadeler Likert tipinde olup {1,2,3,4,5} değerlerinden birini almaktadır.


## **Verilerin Analizi**

Çalışmada kullanılan veri setinde her satır, bir öğrencinin aldığı bir dersle ilgili, eğitmeni hakkında yaptığı değerlendirmeleri ifade etmektedir. Ancak bu özneliklerin sonucunda öğrencinin o dersten öğretmene verdiği bir puan olmadığı için, öğrencinin kanaati somut olarak ifade edilmemiştir. Bu durumu çözmek adına öğrencinin öğretmeni hakkında çeşitli özellikler üzerinden puan verdiği Q1-Q28 arası özneliklerin toplanarak ortalamalarının alındığı “SCORE” adlı 34 numaralı öznelik oluşturulmuştur. Ayrıca veri setindeki tüm öğretmenleri ders bazlı genel şekilde kategorize edebilmek için ise başarı durumunu sözel olarak ifade edecek “SUCCESS” niteliği oluşturulmuştur. SUCCESS niteliğinin değerinin hesaplanması için, 4’ten küçük değerler KÖTÜ, 4’e eşit değerler İYİ, 4’ten büyük değerler ise MÜKEMMEL olarak belirlenmiştir.

## **Bulgular**


### **En İyi Öznelik Seçme Metodunun Tespit Edilmesi**

Bilgi Kazancı algoritması tarafından sıralanan öznelikler Şekil 2 de görülmektedir. Ağırlık değeri 0,45 ten büyük olan değere sahip 28 adet öznelik seçilmiş ve indirgenmiş veri seti, çıktı olarak tahmin kıymetlendirme kısmına gönderilmiştir. Burada sınır olarak tespit edilen 0,45 değeri, yaptığımız gözlem sonrası 5 niteliğin ağırlık değerinin diğerlerinden çok düşük olduğu görsel olarak tespit edilerek belirlenmiştir.




Şekil 2. Bilgi kazancı yöntemiyle ağırlıklandırılmış veri seti öznitelikleri

Geri Yönlü Eliminasyon ile öznitelik seçme yapılırken, Rapid miner “Backward Elimination” modülü kullanılmış, *maksimum eliminasyon sayısı=10*, *spekülatif tur sayısı=0*, *duruş davranışı=azalma* olacak şekilde belirlenmiş ve sonuçta ağırlıkları 1 değerine eşit olan ve 26 adet öznitelikten oluşan, Şekil 3’de gösterilen indirgenmiş veri seti elde edilmiştir.



Şekil 3. Geri yönlü eliminasyon yöntemi ile seçilen öznitelikler

Genetik Algoritma ile öznitelik seçimi yapmak için *Optimize Selection(Evolutionary)* modülü kullanılmış, *minimum öznitelik sayısı=1*, *popülasyon boyutu=5*, *jenerasyonların maksimum sayısı=30* olarak belirlenmiş, 0.25 değerli turnuva yöntemi kullanılmış,  $p$  ilk=0,5,  $p$  mutasyon=-1,0,  $p$  çaprazlama=0,5, çaprazlama tipi: tekdüze olarak belirlenmiş ve ağırlıklar normalize edilmiştir. Seçilen öznitelikler Şekil 4'de gösterilmiştir.



Şekil 4. Genetik algoritma ile seçilen öznitelikler

Öznitelik seçme işleminde görüldüğü üzere mevcut 33 öznitelik arasından sonuca etki eden en iyi 19 niteliği tespit etmesiyle Genetik Algoritma en iyi sonucu vermiş görünmektedir. Öznitelik seçme işleminde elde edilen sonucun doğruluğunu pekiştirmek ve her üç algoritmanın öznitelik seçme performansını kıyaslayabilmek için, tüm algoritmaların etiketli niteliği tahmin etmelerini kıymetlendirme adımlarında  $k$ -nn Yakın Komşuluk (K-EYK) algoritması ilişkiye dayalı *ayrık kıymetlendirme* seçilerek kullanılmıştır. *Ayrım değeri=0,5* (veri setinin yarısı eğitim, yarısı test) olarak belirlenmiştir. K-EYK algoritmasının değerleri tüm öznitelik seçme işlemleri için  $k=1$ , *ölçüm uzaklık birimi= Öklid Uzaklığı* olarak ayarlanmıştır.

Öznitelik seçme işleminin doğruluğa olan katkısı Tablo 1’de görülmektedir. Hiçbir öznitelik seçme yapılmadan, 33 öznitelik kullanılarak yapılan tahmin işlemi, ancak %90,10’luk bir TDP’e ulaşılmıştır. Filtreleme algoritmalarından olan BK yöntemi veri setinin öznitelik sayısını 28’e indirgerken, tahmin doğruluğunu %95,84’e çıkarmıştır. Öğrenme tabanlı çalışan GYE ise, BK’na göre durumu biraz daha iyileştirerek öznitelik sayısını 26’ya, doğruluk performansını da 96,98’e taşımıştır. Genetik Algoritma ise BK ve GYE metotlarına karşı öznitelik indirgeme açısından üstünlük sağlayarak, 19 öznitelik sayısı ile % 95,5’lik bir TDP elde etmiştir.

Tablo 1

*Öznitelik Seçme İşlemlerinin Kıyaslanması*

<b>Öznitelik Seçme Algoritması</b>	<b>Seçilen Nitelik Adedi</b>	<b>TDP (%)</b>
YOK	33	90,10
Bilgi Kazancı	28	95,84
Geri Yönlü Eliminasyon	26	96,98
Genetik Algoritma	19	95,5

**En İyi Makine Öğrenmesi Metodunun Tespit Edilmesi**

Çalışmanın ikinci aşaması olan, veri setindeki etiketli niteliğin çeşitli makine öğrenmesi yöntemleriyle tahmin edilmesi işlemlerinde ise dört farklı makine öğrenmesi yöntemi kullanılmıştır. Ön işlem olarak kullanılan Genetik Algoritma (GA) çıktılarının önceden öngörülelemeyeceği, önceki bölümlerde açıklanmıştır. Tablo 2’de görüldüğü üzere GA, her işlemde farklı sayıda öznitelik seçmiştir. Tabloya göre, K-EYK algoritması için 15 öznitelik seçilmiş ve sonuçta % 96,12 TDP elde edilmiştir. Naive Bayes %95,43 doğruluk oranı 18 öznitelik, Karar Ağacı %94,57 doğruluk oranı 19 öznitelik elde etmiştir. Derin

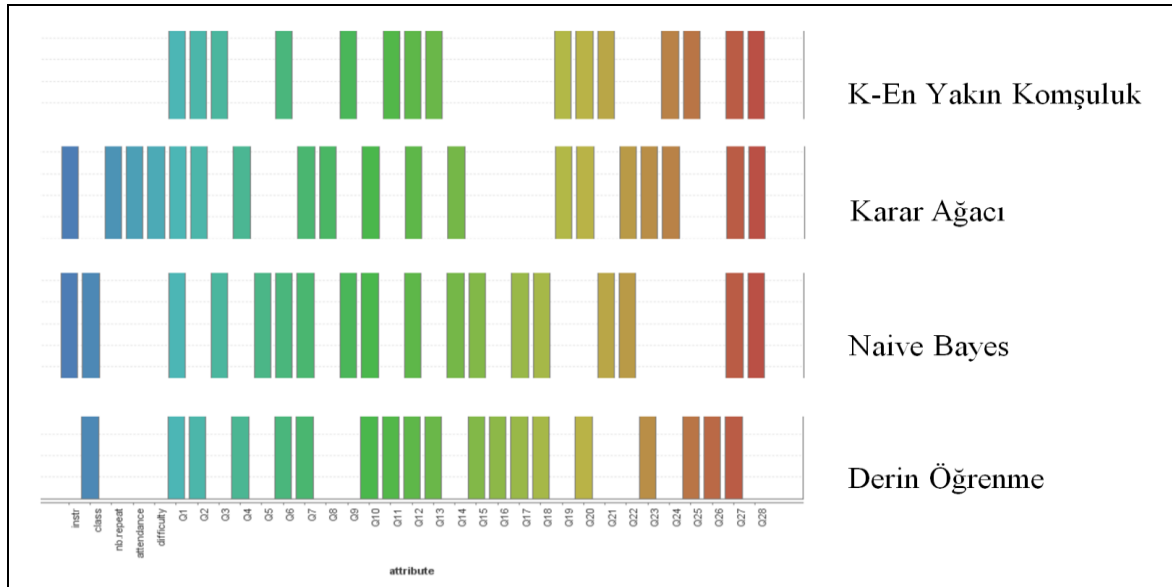
Öğrenme algoritması ise 19 öznitelik seçmesine rağmen %97,70 ile en yüksek doğruluk performansı oranını elde etmiştir. Toplam işlem zamanı açısından bakıldığında ise 3,6 saniye işlem zamanı ile naive Bayes algoritması diğer algoritmalara göre tüm işlemleri çok daha hızlı tamamlamıştır.

Tablo 2

*Makine Öğrenmesi Yöntemlerinin Performanslarının Kıyaslanması*

Makine Öğrenmesi Algoritması	Seçilen Nitelik Adedi	TDP ( %)	Toplam İşlem Zamanı (Milisaniye)
K-EYK	15	96,12	185640
Karar Ağacı	19	94,57	10703
Naive Bayes	18	95,43	3575
Derin Öğrenme	19	97,70	529774

GA, öznitelik seçme işleminde seçtiği tüm özniteliklere 1 ağırlık verirken, her makine öğrenmesi yöntemi için hem ortak hem de farklı olan ve Şekil 5’de gösterilen öznitelikleri seçebilmiştir.



Şekil 5. Dört farklı makine öğrenmesi yöntemi için GA tarafından seçilen öznitelikler



### **Tartışma, Sonuç ve Öneriler**

Bu çalışmaya başlanılmasında ki amaç, eğitim kıymetlendirme işleminin mümkün olduğunda doğru, hızlı ve etkin bir şekilde yapılması sağlayabilecek veriler elde etmek olmuştur. Mevcut eğitim sistemlerinin kıymetlendirilmesi yüksek sayıda katılımcıdan toplanan, yüksek sayıda niteliğin değerlendirilmesini esas almakta ve bu da işlem maliyeti, zaman, doğru öznitelik seçimi gibi birçok kısıtı beraberinde getirmektedir.

Bu çalışma kapsamında genetik algoritma ile öznitelik seçmenin, kullanılan veri seti için en iyi sonucu verdiğini göstermiş, kullanılan öznitelik sayısının ciddi oranda azaltması işlem maliyetini düşürdüğü gibi, hem anket hazırlayanlara, hem de anket dolduranlara –daha az veri ile daha iyi sonucu elde etme- olanağı sağlamıştır. Genetik Algoritma ile mevcut veri setindeki 33 öznitelik arasından yalnızca 19’unu seçerek işlem maliyeti büyük oranda indirilirken, kullanılan öznitelik seçme algoritmaları içinde 95,5’lik oran yakalaması da tahmin başarısının diğer iki algoritmaya oldukça yakın olduğu görülmüştür.

Makine öğrenmesi algoritmalarının performanslarının kıyaslanmasında ise %97,70 ile en iyi doğruluğu Derin Öğrenme vermesine karşılık, en hızlı algoritma olarak 3,6 saniye ile Naive Bayes algoritması ön plana çıkmaktadır. Derin öğrenme algoritması ise 530 saniye ile Naive Bayes algoritmasına göre oldukça yavaş kalmaktadır.

EVM alanında bugüne dek yapılan çalışmalarda eğitim sistemi kalitesinin kıymetlendirilmesi işlemi tek yönlü olmuştur. Örneğin, eğitmen performansını tespit için öğrencilere yapılan anketlerde, eğitmenleri hakkındaki görüşleri alınmış ve eğitmen performans kıymetlendirmesi yalnızca bu veriler üzerinde yapılmıştır. Ancak, bu verilerin yeterince objektif olamayacağı açıktır. Bu kıymetlendirme işlemlerindeki objektiflik performansını arttırmak için ise, her bir öğrencinin ilgili eğitmeninden aldığı ilgili dersin yıl sonu notlarının diğer anket veri setlerine entegre edilmesi veya, her bir öğrenciye ait “objektiflik katsayısı” benzeri bir çarpanının -öğrencinin geçmiş akademik kariyerinden

hareketle- tespit edilerek, bu katsayının ilgili öğrencinin eğitmeni hakkındaki kanaatiyle çarpılması etkili olacaktır. Birleştirilmiş yeni veri setlerinin hem satır bazlı, hem de tüm veri seti olarak yeniden değerlendirilmesiyle (verilere *objektiflik optimizasyonu* yapılmasıyla), öğrencilerin eğitmenleri hakkındaki görüşlerin ne kadar gerçekçi olduğu büyük ölçüde ortaya çıkmış olacaktır.

Çalışmada olduğu gibi, birçok eğitime ait verilerin bulunduğu veri setlerinde, eğitmen başarılarının sıralanması için ilave bir ölçüt olarak ağırlıklandırılmış eğitmen başarıları kullanılabilir. Bir başka deyişle öğretmenlerin tüm öğrencilerin kaçta kaçına ders vermiş olduğu hesaplanarak, bu değer eğitmenin ortalama başarı puanı ile çarpılması ile elde edilecek bu değer, eğitmen başarısına öğrenci sayısının da katkısı ele aldığı için, daha kaliteli bir kıymetlendirme elde edilmesini sağlayacaktır. Böylece daha kalabalık bir kitleye hitap etmesine rağmen başarı elde edebilen bir eğitmenin değeri takdir edilebilecektir.

Gelecekte bu ekseninde, EVM sistemindeki kaliteyi tespit adına şu çalışmalar da yapılabilir: örneğin lise son sınıf öğrencilerinin öğretmenleri hakkındaki görüşleri anket veri seti + öğrencilerin yılsonu notları birleştirilmiş bir veri seti ile aynı öğrencilere ait Üniversite giriş sınavı veri setleri karşılaştırılarak, bu iki veri setinin birbiriyle örtüşmesi temel alınarak bu okul ve öğretmenlerinin ulusal eğitimdeki genel başarı düzeyinin neresinde olduklarına (ulusal anlamda gerçekten başarılı olup olmadıklarına) dair bir kanaat elde edilebilir. Ayrıca, eğitim yöneticilerine dair EVM alanında literatürde yapılmış bir çalışma bulunmadığından, eğitim yöneticileri kıymetlendirme işlemi, bu yöneticilerin astı konumunda bulunan bireylerden ya da üstlerinden alınan değerlendirme anket veri setleri ile yapılabilir. Tüm eğitim ekosisteminin sağlıklı olabilmesi adına bu sistemin tepesinde bulunan yöneticilere de diğer bireylere yapıldığı gibi mutlaka performans analizi yapılmalıdır.

### Kaynakça

- Agaoglu, M. (2016). Predicting instructor performance using data mining techniques in higher education. *IEEE Access*, 4, 2379-2387.
- Ahmed, A. M., Rizaner, A., & Ulusoy, A. H. (2016). Using data mining to predict instructor performance. *Procedia Computer Science*, 102, 137-142.
- Andonie, R. (2010). Extreme data mining: Inference from small datasets. *International Journal of Computers Communications & Control*, 5(3), 280-291.
- Anwar, M., Naseer, A., & Ali, I. (2014). Identifying hidden patterns in students' feedback through cluster analysis. *International Journal of Computer Theory and Engineering*, 7, 16-20.
- Coburn, L. (1984). Student evaluation of teacher performance. *Education Resources Information Center Publications*.
- Cortez, P., & Silva, A. M. G. (2008). Using data mining to predict secondary school student performance. *The European Multidisciplinary Society for Modelling and Simulation Technology*.
- Delavari, N., Phon-Amnuaisuk, S., & Beikzadeh, M. R. (2008). Data mining application in higher learning institutions. *Informatics in Education*, 7(1), 31-54.
- Gunduz, G., & Fokoue, E. (2013). UCI machine learning repository [<http://mllearn.ics.uci.edu/MLRepository.html>]. Irvine, CA: University of California, School of Information and Computer Science.
- Han, J., Pei, J., & Kamber, M. (2011). *Data mining: Concepts and techniques*. Morgan Kaufmann.
- Hobson, S. M., & Talbot, D. M. (2001). Understanding student evaluations: What all faculty should know. *College teaching*, 49(1), 26-31.

- Karahan, Ş., & Akgül, Y. S. (2016). Eye detection by using deep learning. *24th International Conference on Signal Processing and Communication Application (SIU)*, 2145-2148, Izmir, Turkey.
- Koutina, M., & Kermanidis, K. L. (2011). Predicting postgraduate students' performance using machine learning techniques. *Advances in Information and Communication Technology*, 364, 159-168.
- Marsh, H. W., & Roche, L. A. (1997). Making students' evaluations of teaching effectiveness effective: The critical issues of validity, bias, and utility. *American Psychologist*, 52(11), 1187.
- Mendes, R. R. F., de Voznika, F. B., Freitas, A. A., & Nievola, J. C. (2001) Discovering fuzzy classification rules with genetic programming and co-evolution. *Lecture Notes in Computer Science - Principles of Data Mining and Knowledge Discovery*, 2168, 314-325.
- Minaei-Bidgoli, B., & Punch, W. F. (2003). Using genetic algorithms for data mining optimization in an educational web-based system. *Lecture Notes in Computer Science*, 2724, 2252-2263.
- Natek, S., & Zwillig, M. (2014). Student data mining solution—knowledge management system related to higher education institutions. *Expert Systems with Applications*, 41(14), 6400-6407.
- Oyedotun, O. K., Tackie, S. N., Olaniyi, E. O., & Khashman, A. (2015). Data mining of students' performance: Turkish students as a case study. *International Journal of Intelligent Systems and Applications*, 7(9), 20-27.
- Peña-Ayala, A. (2014). Educational data mining: A survey and a data mining-based analysis of recent works. *Expert Systems with Applications*, 41(4), 1432-1462.

- Radmacher, S. A., & Martin, D. J. (2001). Identifying significant predictors of student evaluations of faculty through hierarchical regression analysis. *The Journal of Psychology, 135*(3), 259-268.
- Romero, C., & Ventura, S. (2007). Educational data mining: A survey from 1995 to 2005. *Expert Systems with Applications, 33*(1), 135-146.
- Sanjay, S. S., & Keshav, B. B. (2017). Teacher's performance analyzer. *The International Journal on Emerging Trends in Technology, 4*(1), 178- 180.
- Sorour, S. E., Goda, K., & Mine, T. (2015). Estimation of student performance by considering consecutive lessons. *4th International Congress on Advanced Applied Informatics (IIAI-AAI)*, 121-126, Okayama, Japan.
- Superby, J. F., Vandamme, J. P., & Meskens, N. (2006). Determination of factors influencing the achievement of the first-year university students using data mining methods. *8th International Conference on Intelligent Tutoring Systems, Educational Data Mining Workshop*, 234-240, Jhongli, Taiwan.
- Theodoridis, S., & Koutroumbas, K. (2008). *Pattern recognition*. Academic Press.

### **Extended Abstract**

Education is seen as one of the essential facts and rules that cannot be ignored in any society. The format of the education has been changed many times in the process that has been going from day to day. In spite of all these processes, it has never lost its fundamental dynamic which makes the nations live. Education systems are growing all over the world. The quality of education affects society in every way. It is clear that raising qualified societies is only possible with adequate education. Even though the need for qualified education is not recognized much in the past, population growth, increasing complexity, continually changing socio-psychological conditions have made it harder for the education system to be improved day by day. When it comes to daily use, technological innovations have been utilized to ensure that improvements are made in this area as well as in all areas. The simple

questionnaires and samples used in the last 50 years in the name of solving the problems experienced in improving the education systems have remained far away from effective evaluation today. The growth of the training echo system at high speed has created a need for solutions at high speed and consistency, and this has become a particularly significant problem for higher education administrators. Today, increasing amount of data in all sector of life, make data mining more popular, and a high amount of data in increasing complexity demanded to acquit. Different methods developed day by day, for solving problems in many sectors like finance, health, defense, and education, applied to data mining for many social, economic, and scientific issues. In the education area, where both number of instructors and students always increase, for enhancing system performance, it is needed to observe and evaluate the performance of students and instructors, and such situation causes to reveal a new concept Educational Data Mining. Research in this area generally focuses on student performance. Thus, there is a need for research in instructor performance. Research using machine learning combined with attribute selection in the field of educational data mining has focused on student performance in general, but few studies have focused on instructor performance. In this paper, it was discussed how the performance of the instructor can be determined by educational data mining methods. A Likert type questionnaire dataset on opinions of the Gazi University's student regarding their instructor's teaching performance is used in this research and different feature reduction, and machine learning algorithms are used for evaluating the data set and performances of instructors. According to the obtained results, it has been revealed that the feature selection with genetic algorithm gives the best result for the used dataset compared to the other methods and 19 attributes can be used instead of 33 attributes. Utilizing genetic algorithm and deep learning as a machine learning method has achieved a predictive accuracy performance of 97.70 %, which is higher than the value that can be achieved by using all the attributes. This study differs from the others in that it combines the reduced number of attributes and machine learning, as well as the ordering of instructor performances in concrete terms.