



## Önerilen Yapay Sinir Ağı Algoritması ile Ortaokul Öğrencilerin Akademik Performansının Tahmini

Sevda AGHALAROVA<sup>1</sup>, Sinem BOZKURT KESER<sup>1\*</sup>

<sup>1</sup> Eskişehir Osmangazi Üniversitesi, Mühendislik-Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, Eskişehir

### Özet

Eğitsel veri madenciliği, eğitim sürecine ilişkin elde edilen büyük veri üzerinde farklı kaynakları kullanarak şimdiki zamana ve gelecek zamana ilişkin tahmin yapmamızı sağlayacak kural ve ilişkileri araştırır. Eğitsel veri madenciliği ile veri madenciliği alanındaki teknik ve algoritmaların kullanılmasıyla öğrenci veya öğretmenlerin akademik performansları tahmin edilebilir. Bu çalışmada, ortaokul öğrencilerinin akademik performansını tahmin etmek amacıyla yeni bir yapay sinir ağı algoritması önerilmektedir. Önerilen algoritma, öncelikli olarak dengesiz sınıf dağılımı problemini çözmek için aşırı örnekleme tekniklerinden Sentetik Azınlık Örneklem Arttırma Yöntemi algoritmasını önleme aşamasında uygulamaktadır. Daha sonra, öznitelik seçim ve veri normalizasyonu işlemleri gerçekleştirilmektedir. Çalışmada kullanılan rastgele arama algoritması ile yapay sinir ağı modelinin hiper-parametreleri optimize edilmektedir. Öğrencilerin Matematik ve Portekizce derslerindeki başarıları 2-seviyeli ve 5-seviyeli sınıflandırma için önerilen algoritma ile tahmin edilmektedir. Deney sonuçlarında, Matematik dersi için %97.0 ve %92.3 doğruluk değerleri sırasıyla 2-seviyeli ve 5-seviyeli sınıflandırma için elde edilmektedir. Portekizce dersi için ise bu değerler sırasıyla %97.6 ve %87.9 olarak hesaplanmaktadır.

### Makale Bilgisi

Başvuru:  
30/12/2020  
Kabul:  
19/08/2021

**Anahtar kelimeler**—Eğitsel Veri Madenciliği, Yapay Sinir Ağları, Rastgele Arama

### Prediction of secondary school students' academic performance with proposed artificial neural networks algorithm

### Abstract

Educational data mining explores the rules and relationships that will enable us to make predictions about the present and the future by using different sources on the big data obtained about the educational process. With educational data mining, students' or instructors' academic performance is predicted by using various techniques and algorithms in data mining. In this study, a new artificial neural network algorithm is proposed to predict the academic performance of secondary school students. The proposed algorithm primarily applies the Synthetic Minority Sampling Method algorithm, one of the oversampling techniques, in the preprocessing stage to solve the problem of unbalanced class distributions. Then, feature selection and data normalization processes are performed. The hyper-parameters of the artificial neural network model are optimized by using the random search algorithm used in the study. Students' achievements in Mathematics and Portuguese lessons are predicted for 2-level and 5-level classification. In the experimental results, the 97.0% and 92.3% accuracy values for the Mathematics course are obtained for 2-level and 5-level classification, respectively by using the proposed algorithm. For the Portuguese course, these values are calculated as 97.6% and 87.9%, respectively.

**Keywords:** Educational Data Mining, Artificial Neural Networks, Random Search

\* e-posta: [sbozkurt@ogu.edu.tr](mailto:sbozkurt@ogu.edu.tr)

## 1 Giriş

Teknolojideki hızlı gelişmeler ile birlikte toplumlar çağdaşlaşmakta ve refah seviyesi artmaktadır. Bu durumun en önemli nedenlerinden biri beşeri sermayeye yapılan yatırımın artmasıdır. Beşeri sermaye ve kalkınma arasındaki ilişkinin kavranması ile birlikte eğitim alanında yapılan yatırımlarda global düzeyde artış gözlenmiştir [1].

Eğitim alanında doğru yatırımların yapılabilmesi için öncelikli olarak öğrencilerin mevcut başarıları değerlendirilmeli daha sonra bu başarılarının geliştirilmesi için izlenecek yöntem ve tekniklere uzman kişiler ile karar verilmelidir [2]. Eğitimde başarının değerlendirilmesi, başarıya etki eden faktörlerin tanımlanması ve bu faktörlerin doğru teknikler ile analiz edilmesi ile mümkündür. Literatürde, eğitsel veri madenciliği (EVM) altında tanımlanan teknikler ile öğrencilerin performansı etkili bir şekilde izlenebilmektedir [3]. EVM, öğrencilere gerekli bilginin zamanında ulaştırılması, öğretim sürecinin iyileştirilmesi, akıllı eğitim programının geliştirilmesi, kişisel eğitim programlarının oluşturulması, eğitim sürecinin izlenilmesi gibi avantajlar sunmaktadır. EVM ile birlikte eğitimler özel ilgiye ihtiyaç duyan öğrencileri belirleyebilmekte ve bu öğrencilerin eğitim performanslarını iyileştirebilmek için uygun önlemleri zamanında alabilmektedir [4].

EVM, çeşitli disiplinlerin (eğitim, bilgisayar bilimleri, istatistik) birleşimi olarak değerlendirilebilir. EVM eğitim ortamlarından gelen verileri analiz etmek, öğrencileri ve öğrendikleri ortamları daha iyi anlamak için veri madenciliği teknik ve algoritmaları geliştirir. Geliştirilen teknik ve algoritmalar ile keşfedilen bilgi yalnızca eğitim tasarımcıları ve öğretmenler tarafından değil, aynı zamanda öğrenciler tarafından da kullanılabilir. Böylece eğitimciler, öğretim için daha nesnel geri bildirim alabilir, ders içeriğinin yapısını ve öğrenme sürecindeki etkinliğini değerlendirebilirler. Bu değerlendirme sayesinde, öğrenciler rehberlik ve izlemedeki gereksinimlerine göre gruplara ayrılabilir ve öğretimde en sık yapılan hatalar saptanabilir, daha etkili etkinlikler bulunarak derslere uyarlanması sağlanabilir. Derslerin kişiye özgü tasarlanması için saha yeniden yapılandırılabilir, içerik öğrencinin gelişimine göre yeniden düzenlenebilir ve planlanabilir [5]. EVM, eğitim sürecine ilişkin elde edilen büyük verinin farklı kaynakların kullanımı ile şuna ve geleceğe dair tahmin

yapmamızı sağlayacak kural ve ilişkilerin araştırılmasıdır. Bu amaçla, veri madenciliği algoritma ve tekniklerinin bir veya birkaçı kullanılarak büyük veri içerisindeki örüntülerin, benzerliklerin ve korelasyonların tespit edilmesi ve anlamlandırılması sağlanabilir [6].

Bu çalışmada, ortaokul öğrencilerinin akademik performansını tahmin etmek amacıyla yeni bir yapay sinir ağı algoritması önerilmektedir. Önerilen algoritma, öncelikli olarak dengesiz sınıf dağılımı problemini çözmek için aşırı örnekleme tekniklerinden Sentetik Azınlık Örneklem Arttırma Yöntemi (SMOTE, Synthetic Minority Sampling Method) algoritmasını önileme aşamasında uygulamaktadır. Daha sonra, öznelik seçim ve veri normalizasyonu işlemleri yapılarak çalışılan öğrenci veri seti, önerilen algoritmanın kullanımına hazır hale getirilmektedir. Çalışmada kullanılan rastgele arama algoritması ile yapay sinir ağı modelinin hiper-parametreleri optimize edilerek problemin çözümünde kullanılacak algoritma için en uygun hiper-parametre seti belirlenmektedir. Öğrencilerin, Matematik ve Portekizce derslerindeki başarıları 2-seviyeli ve 5-seviyeli sınıflandırma tekniği ile önerilen algoritma kullanılarak tahmin edilmektedir. Deney sonuçlarında, önerilen algoritma ile Matematik dersi için %97.0 ve %92.3 doğruluk değerleri sırasıyla 2-seviyeli ve 5-seviyeli sınıflandırma için elde edilmektedir. Portekizce dersi için ise bu değerler sırasıyla %97.6 ve %87.9 olarak hesaplanmaktadır.

Çalışmanın takip eden bölümünde, EVM alanında literatürde yapılan çalışmalar anlatılmaktadır. Daha sonra, önerilen yöntem ve deney sonuçları verilmektedir. Çalışma, sonuçlar ve gelecek çalışmalar ile sonlandırılmaktadır.

## 2 Literatür araştırması

EVM alanında uzun yıllardır çalışmalar yapılmaktadır. Satyanarayana ve Nuckowski, birden çok sınıflandırma algoritmasının (karar ağaçları, naive bayes ve rasgele orman) kullanıldığı topluluk modeli ile öğrenci verileri üzerinde tahmin doğruluğunu iyileştirmektedirler. Ayrıca, kural tabanlı tekniklerin bir kombinasyonunu kullanarak öğrenci sonuçlarını etkileyen ilişkilendirme kurallarını da belirlemektedirler [7]. Chaudhury vd. dengesiz sınıf dağılımına sahip öğrenci performansı veri kümesi üzerinde veri

önışleme sürecinin sınıflandırma algoritmaları üzerindeki etkisini analiz etmektedirler. Bu doğrultuda, destek vektör makineleri, karar ağaçları ve naive bayes sınıflandırma algoritmaları için alt örnekleme ve aşırı örnekleme teknikleri uygulanarak dengesiz sınıf dağılımı problemi çözülmektedir. Deney sonuçlarında, aşırı örnekleme sınıfına ait SMOTE algoritması ile daha yüksek doğruluk değerlerine ulaşılmaktadır [8]. Salal vd. öğrenci performansı veri kümesi üzerinde Weka açık kaynak kodlu yazılımı kullanarak çeşitli sınıflandırma algoritmalarının başarısını analiz etmektedirler. Deneylerde, veri ön işleme aşamasında bazı özniteliklerin öğrenci performansını daha çok etkilediği ve bu aşamadan sonra sınıflandırma algoritmalarının doğruluk performansının arttığını gözlemlemektedirler [9]. Hamoud öğrencilerin performansını tahmin etmek amacıyla karar ağacı tabanlı sınıflandırma algoritmalarını kullanmaktadır [10]. Pojon doğrusal regresyon, karar ağacı ve naive bayes algoritmalarını kullanarak iki farklı öğrenci veri kümesi üzerinde öğrenci performanslarını tahmin etmektedir. Deney sonuçlarında, sınıflandırma algoritmalarının doğruluk değerlerinin her iki veri seti için de öznitelik seçme işleminden sonra arttığı gözlemlenmektedir [11]. Başer vd. öğrenci başarı veri kümesi üzerinde öğrencinin performans düzeyinin tahmin edilebilmesi için yinelemeli sınıflandırıcı, *OneR*, *LogitBoost* ile yapay sinir ağları yöntemlerini uygulamakta ve *OneR* yöntemi ile diğer yöntemlere kıyasla daha iyi performans değerleri elde etmektedirler [12]. Ünal çalışmasında karar ağacı, rastgele orman ve naive bayes üzerinde öznitelik seçim yöntemini uygulayarak sınıflandırma algoritmalarının öğrenci veri seti için performansını değerlendirmektedir. Deneylerde, en iyi doğruluk değerlerine rasgele orman algoritması ile ulaşılmaktadır [13]. Athani vd. öğrenci performans veri kümesi üzerinde naive bayes sınıflandırma algoritması ile öğrencilerin derslerdeki başarısını tahmin etmektedir [14]. Ma ve Zhou, öğrenci veri kümesi üzerinde 10-kat çapraz doğrulama ile karar ağaçları ve destek vektör makinesi algoritmalarını analiz etmişlerdir. Algoritmaların performanslarını iyileştirmek için ızgara arama algoritması ile hiperparametre optimizasyonu gerçekleştirmişlerdir [15]. Troussas vd. yaptıkları çalışmada, öğrenci veri seti üzerinde ikili sınıflandırma, beş seviyeli sınıflandırma ve regresyon olmak üzere üç farklı yaklaşım uygulanmaktadır. Bu yaklaşımlarda, k-

ortalamalar, en yakın komşu, destek vektör makineleri ve naive bayes algoritmaları karşılaştırma için kullanılmaktadır [16]. Singh vd. öğrencilerin bir yüksek öğretim programına devam etme isteklerini tahmin etmek için destek vektör makinesi, çok katmanlı algılayıcı ve rasgele orman algoritmasını kullanmıştır. Deney sonuçlarında rasgele orman algoritmasının diğer algoritmalar ile kıyaslandığında daha başarılı olduğu sonucuna varmışlardır [17]. Nidhi vd. naive bayes, karar ağaçları, rastgele orman, *JRip* ve *ZeroR* gibi sınıflandırma algoritmalarını öğrenci performansını tahmin etmek için kullanmışlardır. Öğrencilerin okudukları okulların ve çalışma saatlerinin final notu üzerinde oldukça etkisi olduğunu gözlemlemişlerdir [18]. Srivastava vd. k-en yakın komşu ve karar ağaçları algoritmalarını kullanarak öğrenci performansını tahmin etmek için en uygun modeli belirlemeye çalışmışlardır. Deney sonuçlarında, karar ağacı algoritması ile daha iyi performans değerleri elde etmişlerdir [19]. Zaffar vd. üç farklı öğrenci performans veri kümesi üzerinde hızlı korelasyon tabanlı filtreleme yönteminin destek vektör makinesi sınıflandırma algoritması üzerindeki etkisini analiz etmiştir. Deney sonuçlarında, öznitelik seçim işleminin öğrenci akademik performansı tahmin modelini iyileştirdiği sonucuna varılmaktadır [20]. Gök, öğrencilerin yaşam koşullarının ve sosyal çevrelerinin Türkçe, Matematik dersleri ve dönem sonu genel başarı ortalamalarına olan etkilerini incelemiştir. Bu doğrultuda, öğrenci ders puanı (0-100) regresyon yöntemleri ile ders notu ise Milli Eğitim Bakanlığı tarafından kullanılan 5'li not ölçeği temel alınarak sınıflandırma yöntemleri ile tahmin edilmiştir. Deneylerde, ders puanı tahmininde rastgele orman regresyon yönteminin, ders notu tahmininde ise korelasyon tabanlı öznitelik alt kümesi yönteminin birlikte uygulandığı lojistik sınıflandırma algoritmasının iyi sonuçlar sergilediği tespit edilmiştir [21].


### 3 Yöntem

EVM ile eğitim ortamlarından elde edilen verinin yararlı bilgiye dönüştürülmesi sağlanmaktadır [5]. EVM, öğrencilerin akademik performansının tahmininde sıklıkla kullanılmaktadır. Bu amaçla, sınıflandırma, kümeleme ve ilişkilendirme analizi teknikleri uygulanmaktadır [3]. Bu çalışmada, önerilen yapay sinir ağı algoritması ile ortaokul

öğrencilerin Matematik ve Portekizce derslerindeki performansları, 2-seviyeli ve 5-seviyeli sınıflandırma tekniği ile tahmin edilmektedir. Sınıflandırma başarısını iyileştirmek üzere, ilk olarak dengesiz sınıf dağılımı problemi çözülmektedir. Veri ön işleme sürecinden sonra yapay sinir ağı algoritmasının hiper-parametreleri optimize edilmektedir. Çalışmanın alt bölümlerinde yapay sinir ağları, hiperparametre optimizasyonu ve önerilen yöntem anlatılmaktadır.

### 3.1 Yapay sinir ağları

Yapay sinir ağları biyolojik sinir ağlarından esinlenerek oluşturulmuş, insan beyninin fonksiyonel özelliklerine benzer şekilde, makine öğrenmesi ve gerçek örnekler kullanarak olayları öğrenebilen ve öğrenme, sınıflandırma, optimizasyon ve tahmin gibi konularda başarıyla uygulanabilen bir yöntemdir [22]. Karmaşık görevleri öğrenmek için insan beynini simüle etmeye çalışır. İnsan beynindeki büyük nöron ağına benzer şekilde birbirine bağlı düğümler grubu olarak modellenmektedir. Doğrusal olmayan, çok boyutlu, gürültülü ve eksik veri olduğunda sıklıkla kullanılan bir yöntemdir. Yapay sinir ağlarının yapay sinir hücreleri proses elemanları olarak bilinir ve 5 temel elemanı vardır [23]. Bunlar girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıkışlardır. Şekil 1'de yapay sinir ağı modeli gösterilmiştir.



Şekil 1 Yapay Sinir Ağı

Şekil 1 ile verilen yapay sinir ağı bir giriş katmanı, bir ara katman ve bir çıkış katmanından oluşmaktadır. Giriş katmanı olarak adlandırılan ilk katmana bilgiler verilir, bu katmanda hiç bir işlem yapılmaz [24]. Giriş katmanına gönderilen her bir bilgi farklı ağırlık değerleriyle çarpılarak toplanır. Bu işlemde elde edilen değer bias katsayısı ile toplanır. Daha sonra, bu toplam değeri sırasıyla aktivasyon fonksiyonuna ve ara katmana iletilir. Girdi ve çıktılar arasındaki ilişki doğrusal değil ise

model oluşturmak için birden fazla ara katman kullanılabilir. Ara katmanlar giriş katmanından gelen bilgileri işleyerek, yani ağırlık değerlerini kullanarak çıktıya dönüştürmek üzere kullanılır [24]. Çıktı katmanına iletilen değer, ağa verilen girdi değeri için üretilen çıkış değeridir.

### 3.2 Hiper-parametre optimizasyonu

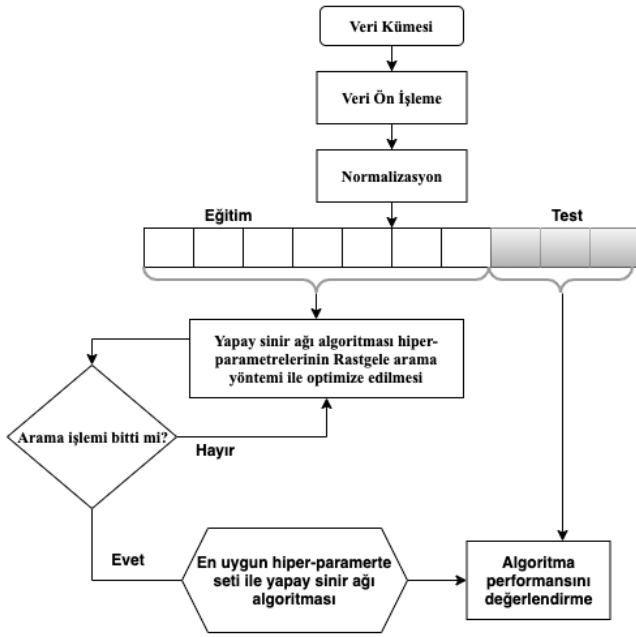
Eğitim sürecinden önce belirlenen parametreler, hiper-parametreler olarak bilinir [25]. Her hangi bir yöntemi veri kümesine uygulamadan önce, uygun bir hiper-parametre kümesi seçmek gerekir [26]. Hiper-parametrelerin eğitilen modelin performansı üzerinde önemli bir etkisi vardır. Farklı hiper-parametre setleri belirlenerek, farklı modeller oluşturulabilir [25]. Aşağıda yapay sinir ağı algoritmasına özgü bazı hiper-parametreler verilmektedir.

- Öğrenme oranı
- Gizli Katmanlar
- Aktivasyon Fonksiyonları
- Optimizasyon Yöntemleri

Hiper-parametre optimizasyonu için kullanılan yöntemlere ızgara araması ve rastgele aramayı örnek olarak gösterebiliriz. ızgara araması, başlangıçta tanımlanan hiper-parametre değerleri ızgarasından, en uygun hiper-parametre kümesi üzerinde kapsamlı bir arama işlemi gerçekleştirir. [27]. Rastgele arama algoritması ise uygun hiper-parametre kümesini bulmak için ızgara içerisinde rastgele gezinir [28]. Rastgele araması, ızgara arama algoritmasına göre daha düşük hesaplama süresine sahiptir. Bergstra, çalışmasında farklı veri kümeleri üzerinde farklı sınıflandırma algoritmalarının hiper-parametre optimizasyonu için rastgele arama algoritmasının, ızgara arama algoritmasına göre daha iyi sonuçlar verdiğini göstermektedir [29]. Bu çalışmada önerilen yöntemin hiper-parametreleri rastgele arama algoritması kullanılarak optimize edilmektedir.

### 3.3 Önerilen yöntem

Bu çalışmada yeni bir yapay sinir ağı algoritması önerilmektedir. Yöntem veri ön işleme, hiper-parametrelerin optimize edilmesi ve modelin değerlendirilmesi aşamalarından oluşmaktadır. Önerilen yöntemin akış diyagramı Şekil 2 ile verilmektedir.



Şekil 2 Önerilen yöntemin akış diyagramı


İlk aşamada, çalışmada kullanılan öğrenci veri kümesi için ön işleme işlemi yapılmaktadır. Veri ön işleme aşamasında, veri kümesi içerisinde yer alan kategorik değerler sayısal değerlere dönüştürülmektedir. Literatürdeki çalışmalar incelendiğinde yapay sinir ağı algoritmasının normalize edilmiş değerler ile daha iyi çalıştığı sonucuna varılmaktadır [30]. Bu doğrultuda, veriler  $[0, 1]$  aralığına normalize edilmektedir. Kullanılan veri setinin dengesiz sınıf dağılımı problemine sahip olduğu görülmektedir. Bu problemi çözmek için SMOTE algoritması ve ağırlık atama işlemi kullanılmaktadır. SMOTE yönteminde sayıca daha az örnek içeren sınıfta bulunan en yakın komşular arasında rasgele interpolasyon yöntemi ile sentetik veriler oluşturulmaktadır. Böylece, az sayıda örneklem içeren sınıf için veri sayısı artırılır. Bu yöntemde aynı örnek yeniden oluşturulmadığı için aşırı örnekleme yönteminde sık karşılaşılan asırı uyum problemi bir dereceye kadar önlenmektedir [8]. Ağırlık atama işlemi ise dengesiz veri kümesindeki sınıfları tahmin edip, onu dengeli olarak değiştirir. Bu işlem '*scikit-learn*' kütüphanesinin '*compute class weight*' fonksiyonu kullanılarak gerçekleştirilmektedir. Yapılan deneylerde SMOTE yönteminin daha iyi sonuçlar verdiği gözlemlenmektedir. Sonraki aşamada, Keras kütüphanesi kullanılarak %70 eğitim, %30 test olarak ayrılan veri seti üzerinde yapay sinir ağı

algoritması ile iki-seviyeli ve beş-seviyeli sınıflandırma işlemi gerçekleştirilmektedir. İlk olarak veri kümesindeki tüm öznitelikler kullanılarak sınıflandırma işlemi gerçekleştirilmektedir. Daha sonra öznitelik seçme işlemi uygulanmaktadır. Öznitelik seçme işlemi için filtreleme ve özyinelemeli özellik çıkarma (ÖÖÇ) yöntemleri kullanılmaktadır. Filtreleme yöntemi istatistiksel ölçülere dayalı fonksiyonlar kullanarak öznitelik seçme işlemi yapmaktadır [31]. ÖÖÇ yönteminde ise tüm özellikler derecelendirilir ve en düşük skora sahip öznitelik, öznitelikler kümesinden çıkarılır [31]. Eğitim aşamasında, rastgele arama algoritması ile yapay sinir ağı algoritmasının hiper-parametreleri optimize edilmektedir. Test aşamasında ise rastgele arama yöntemi ile bulunan en uygun hiper-parametre seti ile algoritmanın başarısı hem öznitelik seçim işlemi olmadan hem de öznitelik seçim işlemi için sınıflandırma işlemi için değerlendirilmektedir.

## 4 Bulgular

### 4.1 Veri kümesi

Bu çalışmada kullanılan veri kümesi 2005-2006 öğretim yılı boyunca Portekizde, iki okuldan, Matematik ve Portekizce olmak üzere iki ders üzerinden, okul raporları ve anketler kullanılarak hazırlanmaktadır [28]. Veri kümesi öğrenci başarısına etki edebilecek farklı özniteliklerden oluşmaktadır. Portekizce dersine ait veri kümesinde 649 örnek, Matematik dersine ait veri kümesinde ise 395 örnek yer almaktadır. Eksik veri yoktur. Öznitelikler sayısal, ikili ve kategorik değerler içermektedir. Veri kümesindeki veriler giriş ve çıkış verileri olarak iki yere ayrılır. Çıkış değişkeni olan G3 (final notu) 0 ile 20 arasında değerler almaktadır. Final notu değişkeni iki-seviyeli sınıflandırma için  $G3 \geq 10$  ise geçti,  $G3 < 10$  ise kaldı olarak düzenlenmektedir. Beş-seviyeli sınıflandırma için ise 16-20 arasında değer alan notlar I, 14-15 notları II, 12-13 notları III, 10-11 notları IV ve 9-0 notları ise V olarak düzenlenmektedir. Şekil 3'de veri kümesinin final notlarını temsil eden değişkene göre hem portekizce, hem de matematik dersleri üzere sınıf bazında ağırlık oranları gösterilmektedir. Şekil 3'ten de görülebileceği gibi her iki ders için de sınıf bazında ağırlık oranlarında büyük fark görülmektedir.



Şekil 3 (a)Matematik ve (b) Portekizce derslerine ait veri kümesi üzerinde iki-seviyeli ve beş-seviyeli sınıflandırma için sınıf dağılımları

Tablo 1’de veri kümesini oluşturan değişkenler, değişkenlerle ilgili açıklamalar ve her bir değişkenin aldığı değerler gösterilmektedir. Tablo 1’de görüldüğü üzere veriler öğrencilerin notları, demografik özellikleri, sosyal çevresi ve okulu ile ilgili özelliklerden oluşmaktadır.

Tablo 1. Veri kümesi ile ilgili değişkenler

Değişkenler	Açıklama	Değerler
sex	Öğrencinin Cinsiyeti	İkili: kadın veya erkek
age	Öğrencinin yaşı	Sayısal: 15-22
school	Öğrencinin okuduğu okul	İkili: Gabriel Pereira ve Mousinho da Silveira
address	Öğrencinin ev adresi	İkili: kentsel veya kırsal
Pstatus	Ebeveyninin birlikte yaşama durumu	İkili: birlikte veya ayrı
Medu	Annenin eğitimi	Sayısal: 0-4
Mjob	Annenin işi	Nominal: öğretmen, sağlıkla ilgili, kamu hizmetleri, evde, diğer
Fedu	Babanın eğitimi	Sayısal 0-4
Fjob	Babanın işi	Nominal: öğretmen, sağlıkla ilgili, kamu hizmetleri, evde, diğer
guardian	Öğrencinin velisi	Nominal: anne, baba, diğer
famsize	Ailedeki kişi sayısı	İkili: ≤ 3 veya > 3
famrel	Ailedeki ilişki kalitesi	Sayısal: 1-5 çok kötüden mükemmele
reason	Bu okulu seçme sebebi	Nominal: eve yakın, okul itibarı, kurs tercihi, diğer
traveltime	Evden okula kadar olan süre	Sayısal: 1: < 15 dk., 2: 15 ile 30 dk., 3: 30 dk- 1 saat, 4: > 1 saat
studytime	Haftalık çalışma zamanı	Sayısal: 1 : < 2 saat, 2: 2 - 5 saat, 3: 5- 10

failures	Geçmiş sınıflardaki başarısızlık sayısı	saat 4: > 10 saat Sayısal: n eğer $1 \leq n < 3$ , değilse 4
schoolsup	Okulun desteklediği ekstra eğitim	İkili : evet veya hayır
famsup	Ailenin eğitim desteği	İkili : evet veya hayır
activities	Okul dışı etkinlikler	İkili : evet veya hayır
paidclass	Ekstra ücretli dersler	İkili : evet veya hayır
internet	Evde internet erişimi	İkili : evet veya hayır
nursery	Anaokuluna gidip gitmemesi	İkili : evet veya hayır
higher	Yüksek öğrenim görmek isteyip istememesi	İkili : evet veya hayır
romantic	Romantik ilişkisinin olup olmaması	İkili : evet veya hayır
freetime	Okuldan sonra boş zamanı	Sayısal:1-çok düşük,5-çok yüksek
goout	Arkadaşları ile dışarı çıkması	Sayısal:1-çok düşük,5-çok yüksek
Walc	Haftasonu alkol tüketimi	Sayısal:1-çok düşük,5-çok yüksek
Dalc	Haftaiçi alkol tüketimi	Sayısal:1-çok düşük,5-çok yüksek
health	Sağlık durumu	Sayısal:1-çok kötü,5-çok iyi
absences	Okul devamsızlık sayısı	Sayısal: 0-93
G1	Birinci dönem notu	Sayısal: 0-20
G2	İkinci dönem notu	Sayısal: 0-20
G3	Final notu	Sayısal: 0-20

## 4.2 Performans değerlendirilmesi

Veri madenciliği algoritmalarının değerlendirilmesi aşamasında karmaşıklık matrisi kullanılmaktadır. Hata matrisi olarak da adlandırılan karmaşıklık matrisi algoritmanın etkinliğini belirlemek, kullanılan yöntemleri karşılaştırmak ve algoritmanın performansı değerlendirmek için kullanılan temel araçlardan biridir [32]. Karmaşıklık matrisi kullanılarak doğruluk, kesinlik, hassasiyet gibi performans ölçütleri hesaplanır [33]. Tablo 2'de öğrencilerin akademik performansının 2-seviyeli sınıflandırma yöntemi ile tahmininde kullanılmak üzere 2x2'lik bir matris oluşturulmaktadır.

Tablo 2. Karmaşıklık matrisi

		Gerçek	
		Geçti	Kaldı
Tahmini	Geçti	Doğru Pozitif (DP)	Yanlış Pozitif (YP)
	Kaldı	Yanlış Negatif (YN)	Doğru Negatif (DN)

- Doğru Pozitif (DP): Öğrencinin dersten geçme durumunu ifade eder.
- Doğru Negatif (DN): Öğrencinin dersten kalma durumunu ifade eder.
- Yanlış Pozitif (YP): Dersten kalan öğrencinin yanlış bir şekilde geçti olarak belirlenmesidir.
- Yanlış Negatif (YN): Dersten geçen öğrencinin yanlış bir şekilde kaldı olarak belirlenmesidir.

Tablo 2 ile verilen karmaşıklık matrisindeki değerler kullanılarak sınıflandırma algoritmanın başarısını değerlendirmek üzere aşağıda verilen performans ölçütleri hesaplanmaktadır [34].

Doğruluk: Doğru olarak sınıflandırılan örneklem sayısının toplam örneklem sayısına oranını ifade eder.

$$\text{Doğruluk} = \frac{DP + DN}{DP + YP + DN + YN} \quad (1)$$

Hassasiyet: Sınıflandırma algoritmasının doğru tahmin ettiği pozitif örneklem sayısının pozitif olarak tahmin ettiği toplam örneklem sayısına oranıdır.

$$Hassasiyet = \frac{DP}{DP + YP} \quad (2)$$

Hatırlama: Sınıflandırma algoritmasının pozitif örneklemeleri doğru tahmin etme gücünü ifade eder. Yani, bir dersten geçen öğrencilerin doğru bir şekilde geçti olarak tahmin edilme olasılığıdır.

$$Hatırlama = \frac{DP}{DP + YN} \quad (3)$$

Özgüllük: Bir dersten kalan öğrencilerin doğru bir şekilde kaldı olarak tahmin edilme olasılığıdır.

$$\text{Özgüllük} = \frac{DN}{DN + YP} \quad (4)$$

F-ölçütü: Hassasiyet ve hatırlama ölçütlerinin geometrik ortalaması olup her iki ölçüt değerinin beraber ele alınmasını sağlar.

$$F - \text{ölçütü} = \frac{2 * Hassasiyet * Hatırlama}{Hassasiyet + Hatırlama} \quad (5)$$

### 4.3 Deneysel sonuçlar

Bu çalışmada ortaokul öğrencilerinin matematik ve portekizce olmak üzere iki ders üzerinden akademik performansları sınıflandırma yöntemleri ile tahmin edilmektedir. Sınıflandırma işlemi Python programlama dili kullanılarak gerçekleştirilmektedir. Deneyler MacOS işletim sisteminde, Python'un 3.7.9 sürümü kullanılarak, 8 GB RAM'e sahip (Dual-Core Intel Core i5, 1.8GHz) bilgisayarda gerçekleştirilmektedir. Sınıflandırma işlemi gerçekleştirilmeden önce veri kümesi üzerinde ön işleme işlemi yapılmaktadır. Veri kümesinde yer alan ve kategorik değerler içeren öznitelikler önce sayısal değerlere dönüştürülmektedir. Veri kümesindeki dengesiz sınıf dağılımı problemi SMOTE yöntemi kullanılarak çözülmektedir. Veri kümesi %70 eğitim ve %30 test verisi olarak iki yere ayrılmaktadır. Eğitim aşamasında, rastgele arama algoritması ile Tablo 3 ile verilen hiper-parametre değer aralıkları veri seti için en uygun yapay sinir ağı algoritması araştırılmaktadır. Bu değerler, literatürde örnek bir çalışma ele alınarak belirlenmektedir [35].

Tablo 3'de modelin 3 katmandan oluştuğunu görmekteyiz. Oluşturulan ağ 1 giriş, 1 gizli ve 1 çıkış katmanından oluşmaktadır. Nöron sayısına bakıldığında 64 birim giriş için, 64 birim gizli katman için, ikili ve beş seviyeli sınıflandırmada için sırasıyla 1 birim ve 5 birim çıkış katmanı için kullanılmaktadır.

Tablo 3. Yapay sinir ağı için hiper-parametre seti

Katman sayısı	3
Nöron sayısı	64, 64, 1(5)
Ağırlık başlatma fonksiyonu	Uniform
Aktivasyon fonksiyonu	Relu
Çıkış katmanı için aktivasyon fonksiyonu	(sigmoid,softmax)
Kayıp fonksiyonu	Binary_crossentropy
2'li Kayıp fonksiyonu	sparse_categorical_crossentropy
5'li Optimizasyon yöntemi	Rmsprop
Devir sayısı	100
Grup sayısı	8
Öğrenme oranı	0.01

Testlerde ağırlık başlatma fonksiyonu olarak *uniform* kullanılmıştır. Ağırlık başlatma yöntemleri kullanılarak , ağırlıkların başlangıç değerleri belirlenir ve bu yöntemler yapay sinir ağının eğitimini hızlandırmak için en etkili yaklaşımlardan biri olarak kabul görülmektedir [36]. Aktivasyon fonksiyonu, girdi verilerinin ağırlık değerlerini ayarlayarak nöronun aktif olup olmama durumuna karar verir [35]. Modelde *relu* aktivasyon fonksiyonu kullanılmıştır. Çıkış katmanında iki-seviyeli sınıflandırma için *sigmoid* beş-seviyeli sınıflandırma için *softmax* aktivasyon fonksiyonu kullanılmaktadır. Kayıp fonksiyonu olarak iki-seviyeli sınıflandırma için *binary\_crossentropy*, beş-seviyeli sınıflandırma için *sparse\_categorical\_crossentropy* kullanılmıştır. Kayıp fonksiyonu, modelin hata oranını ölçen fonksiyondur. Optimizasyon fonksiyonu, gerçek değer ile tahmin edilen değer arasındaki farkı en aza indirmek için kullanılmaktadır [35]. Bu çalışmada, optimizasyon fonksiyonu olarak *rmsprop* kullanılmaktadır. Bütün bu parametreler ayarlandıktan sonra veri 16 gruba (*batch size=16*) bölünerek deneyler 100 kez (*epochs=100*) tekrarlanmaktadır. Modelin değerlendirilmesi aşamasında ise doğruluk, kesinlik, f-ölçüsü ve duyarlılık performans ölçütleri olarak kullanılmaktadır.



İki-seviyeli ve beş-seviyeli sınıflandırma işlemi ilk olarak veri kümesi üzerinde tüm öznitelikler kullanılarak gerçekleştirilmektedir. Şekil 4'de Matematik (a) ve Portekizce (b) dersleri için oluşturulmuş veri kümesi için iki-seviyeli ve beş-seviyeli sınıflandırma yapıldıktan sonra oluşan karmaşıklık matrisi gösterilmektedir. Bu karmaşıklık matrisi veri kümesi üzerinde hiç bir öznitelik çıkarma işlemi gerçekleştirilmeden, Tablo 3'de verilen hiper-parametreler kullanılarak elde edilmiştir. Kullanılan veri setinin dengesiz sınıf dağılımı problemi SMOTE algoritması ve ağırlık atama işlemi kullanılarak çözülmektedir.

	Geçti	Kaldı
Geçti	58	8
Kaldı	2	51

	I	II	III	IV	V
I	11	1	0	0	0
II	5	11	3	0	0
III	0	1	10	3	0
IV	0	0	5	15	4
V	0	0	0	7	43

(a) Matematik


	Geçti	Kaldı
Geçti	40	15
Kaldı	2	129

	I	II	III	IV	V
I	18	7	0	0	0
II	5	10	15	1	0
III	1	9	39	6	0
IV	0	1	9	34	10
V	0	0	1	5	24

(b) Portekizce

Şekil 4. Matematik ve portekizce dersleri için ikili ve beş seviyeli sınıflandırmanın karmaşıklık matrisi

Şekil 4'de sırasıyla Matematik ve Portekizce dersleri için oluşturulan veri setleri için iki-seviyeli



(a) Matematik

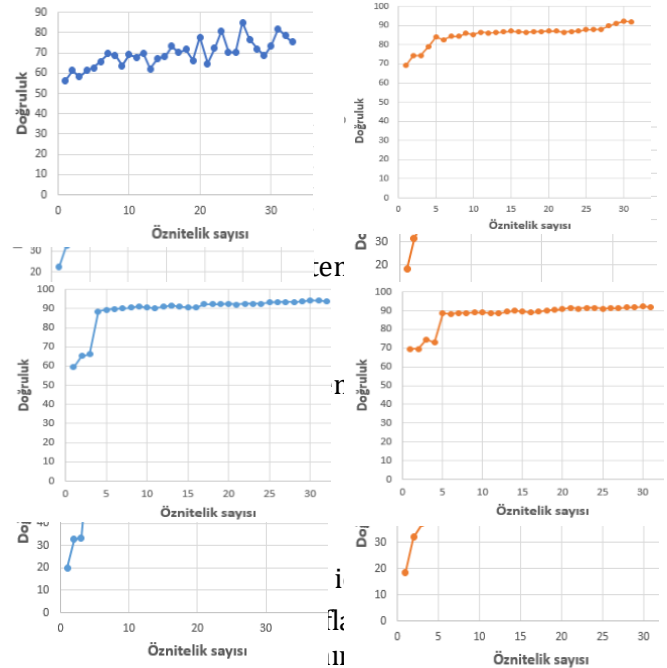


(b) Portekizce

Şekil 5. Matematik ve portekizce dersleri için iki seviyeli ve beş seviyeli sınıflandırmanın SMOTE ve ağırlık atama işleminden sonra sınıf dağılımı

ve beş-seviyeli seviyeli sınıflandırma için SMOTE algoritması ve ağırlık atama işlemleri gerçekleştirildikten sonra elde edilen karmaşıklık matrisleri gösterilmektedir. Şekil 5'de görüldüğü üzere SMOTE yöntemi ile ağırlık atama yöntemine kıyasla doğruluk ve f-skoru değerleri için tüm veri setleri ile daha iyi sonuçlar elde edilmektedir.


Öznitelik seçme işlemi için filtreleme ve ÖÖÇ yöntemleri kullanılmaktadır. Şekil 6 ve Şekil 7'de Matematik (mavi renk) ve Portekizce (turuncu renk) dersleri için en uygun öznitelik sayısının belirlenmesi doğruluk değerleri üzerinden belirlenmeye çalışılmaktadır. Grafıklara bakıldığında öznitelik sayısı arttıkça doğruluğun çok az fark ile değişiklik gösterdiği görülmektedir. Bu testler 10 kez tekrarlanarak öznitelik seçim yöntemleri ile her bir veri için en uygun öznitelik sayısı tespit edilmektedir.




(b) ÖÖÇ yöntemi için doğruluk grafiği

Şekil 7. Beş seviyeli sınıflandırma için öznitelik seçimi algoritmalarının doğruluk grafikleri

Şekil 8 ve Şekil 9’da da görüldüğü üzere belirli bir devir sayısı değerinden sonra doğruluk ve kayıp fonksiyonunda çok az farkla değişiklikler olduğu




(a) İki seviyeli sınıflandırma




(b) Beş seviyeli sınıflandırma

Şekil 8. Matematik dersi için iki seviyeli ve beş seviyeli sınıflandırmanın devir sayına göre doğruluk ve kayıp grafiği

gözlemlenmektedir.



(a) İki seviyeli sınıflandırma



(b) Beş seviyeli sınıflandırma

Şekil 9. Portekizce dersi için iki seviyeli ve beş seviyeli sınıflandırmanın devir sayına göre

doğruluk ve kayıp grafiği

Yapay sinir ağı algoritması için en uygun hiper-parametre setinin belirlenmesi için Tablı 4 ile verilen değer aralıkları rasgele arama algoritması ile optimize edilmektedir.

Tablo 4. Rastgele algoritmasında kullanılan hiper-parametre seti

Nöron sayısı	[2,6,12,18,24,32,64,72]
Devir sayısı	[25,75,100,150,200]
Grup ölçüsü	[6,12,18]
Öğrenme oranı	[0.001, 0.01, 0.1, 0.2, 0.3]
Seyreltme ölçüsü	[0.0, 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9]
Ağırlık başlatma fonksiyonu	['uniform', 'lecun_uniform', 'normal', 'zero', 'glorot_normal', 'glorot_uniform', 'he_normal', 'he_uniform']
Optimizasyon fonksiyonu	['rmsprop', 'adam', 'sgd', 'adamax', 'nadam']
Aktivasyon fonksiyonu	['softmax', 'softplus', 'softsign', 'relu', 'tanh', 'sigmoid', 'hard_sigmoid', 'linear']

Tablo 5 ve Tablo 6’da sırasıyla her bir veri seti için en uygun hiper-parametre setleri ve bu hiper-parametre setleri için hesaplanan performans ölçütleri değerleri verilmektedir.

Tablo 5. Rastgele arama algoritması kullanarak bulunan en iyi hiper-parametreler kümesi

	Tüm veri	Filtreleme	ÖÖÇ	Tüm veri	Filtreleme	ÖÖÇ
Optimizasyon yöntemi	Adam	Adam	Adam	Rmsprop	Adam	Adam
Nöron sayısı	24	32	32	32	18	64
Öğrenme oranı	0.001	0.01	0.01	0.01	0.01	0.01
Ağırlık başlatma fonksiyonu	He_normal	He_uniform	He_uniform	He_uniform	Normal	He_normal
Devir sayısı	200	100	150	100	150	150
Seyreltme derecesi	0.2	0.2	0.1	0.0	0.0	0.4
Grup sayısı	12	6	8	18	8	6
Aktivasyon fonksiyonu	relu	relu	tanh	tanh	relu	relu
	(a) Matematik dersi iki seviyeli sınıflandırma için rastgele arama algoritması ile bulunan en uygun hiper-parametre kümesi			(b) Matematik dersi beş seviyeli sınıflandırma için rastgele arama algoritması ile bulunan en uygun hiper-parametre kümesi		
Optimizasyon yöntemi	Adamax	Adamax	Adamm	Adam	Adam	Adam
Nöron sayısı	64	32	64	32	32	72
Öğrenme oranı	0.01	0.01	0.001	0.01	0.01	0.01
Ağırlık başlatma fonksiyonu	He_uniform	He_uniform	He_normal	He_uniform	He_uniform	Lecun_uniform
Devir sayısı	100	150	100	150	150	200
Seyreltme derecesi	0.5	0.6	0.4	0.1	0.2	0.5
Grup sayısı	18	8	12	18	18	12
Aktivasyon fonksiyonu	relu	relu	relu	relu	relu	relu
	(c) Portekizce dersi iki seviyeli sınıflandırma için rastgele arama algoritması ile bulunan en uygun hiper-parametre kümesi			(d) Portekizce dersi beş seviyeli sınıflandırma için rastgele arama algoritması ile bulunan en uygun hiper-parametre kümesi		

Tablo 6. Matematik ve portekizce dersleri için iki-seviyeli ve beş-seviyeli sınıflandırmanın test sonuçları

	doğruluk	kesinlik	duyarlılık	F skoru	doğruluk	kesinlik	duyarlılık	F skoru
Tüm veri	%94.8	%94.1	%95.1	%94.6	%96.4	%97.3	%97.08	%97.1
Filtreleme	%93.1	%92.7	%90.5	%90.4	%96.5	%97.2	%94.1	%95.5
ÖÖÇ	%94.2	%94.7	%93.6	%94.1	%97.0	%97.8	%97.4	%97.5
	(a) Matematik sınıflandırma			iki-seviyeli	(b) Rastgele arama algoritması ile Matematik iki-seviyeli sınıflandırma			
Tüm veri	%92.2	%93.7	%91.9	%92.8	%97.6	%98.5	%96.4	%97.6
Filtreleme	%92.1	%92.9	%89.2	%91.04	%96.5	%98.2	%94.1	%96.1
ÖÖÇ	%92.6	%94.2	%90.09	%92.01	%95.6	%97.05	%94.4	%95.6
	(c) Portekizce sınıflandırma			iki-seviyeli	(d) Rastgele arama algoritması ile Portekizce iki-seviyeli sınıflandırma			
Tüm veri	%80.5	%85.01	%90.5	%87.4	%88.7	%95.7	%93.7	%94.6
Filtreleme	%80.6	%85.9	%89.3	%87.4	%88.9	%93.6	%93.8	%93.5
ÖÖÇ	%81.3	%90.4	%91.3	%90.7	%92.3	%95.2	%95.2	%95.2
	(e) Matematik sınıflandırma			beş-seviyeli	(f) Rastgele arama algoritması ile Matematik beş-seviyeli sınıflandırma			
Tüm veri	%71.3	%82.2	%78.5	%80.2	%87.9 %	%91.6	%93.2	%92.3
Filtreleme	%73.9	%83.6	%81.2	%82.3	%87.5 %	%92	%93.2	%92.4
ÖÖÇ	%71.3	%82.9	%80.7	%81.7	%85.9 %	%93.9	%90.2	%91.8
	(g) Portekizce sınıflandırma			beş-seviyeli	(h) Rastgele arama algoritması ile Portekizce beş-seviyeli sınıflandırma			

Tablo 6 (a)'da görüldüğü üzere Matematik dersi için kesinlik ölçütünün ÖÖÇ yöntemi uygulandıktan sonra %94.1 'den %94.7 'e, Tablo 6 (c)'ye bakıldığında ise Portekizce dersi için ÖÖÇ yöntemi uygulandıktan sonra doğruluk ölçütünün %92.2 'den %92.6'ya, kesinlik ölçüsünün ise %93.7'den %94.2 'e yükseldiği görülmektedir. Tablo 6 (e)'de Matematik dersi için filtreleme yöntemi uygulandıktan sonra doğruluğun %80.5 'den %80.6 'ya, kesinlik değerinin %85.01'den %85.9'a, Tablo 6(g)'de Portekizce dersi için filtreleme yöntemi uygulandıktan sonra doğruluğun %71.3 'den %73.9 'a, kesinliğin %82.2'den %83.6'ya, duyarlılığın %78,5'den %81.2'ye f-skorunun %80.2 'den %82.3'e yükseldiği görülmektedir. Tablo 6 (e)'de ÖÖÇ yöntemi uygulandıktan sonra Matematik dersi için

doğruluk %80.5'den %81.3'e, kesinlik değerinin %85.01'den %90.4'e, duyarlılık değerinin %90.5'den %91.3'e, f-skorunun %87.4 'den %90.7'e yükseldiği gözlemlenmektedir. Tablo 6 (g)'de ÖÖÇ yöntemi ile Portekizce dersi için kesinlik değeri %82.2'den %82.9'a, duyarlılık değeri %78.5'den %80.7'e, f- skoru %80.2'den %81.7'ye yükselmektedir. Tüm sonuçlar deneylerin 10 kez tekrarlanması sonucunda elde edilmektedir. Tablo 6 (b), (d), (f), (h)'de rastgele arama algoritması ile elde edilen sonuçlara bakıldığında hem Matematik, hem de Portekizce dersi için oluşturulan veri kümesi üzerinde yapılan iki-seviyeli ve beş-seviyeli sınıflandırma sonuçlarının iyileştiği gözlemlenmektedir.

## 5 Sonuç

Öğrencilerin akademik performanslarının tahmini üzerine veri madenciliği algoritmaları kullanılarak çok sayıda çalışmalar yapılmaktadır. Uygun veri önileme süreci ve doğru algoritmanın seçimi ile tahmin sonuçlarını iyileştirmek mümkündür. Bu çalışmada, ortaokul öğrencilerinin Matematik ve Portekizce derslerindeki başarısını tahmin etmek için yeni bir yapay sinir ağı algoritması önerilmektedir. Önerilen algoritma ile veri önileme adımında dengesiz sınıf dağılımı problemi iki farklı yöntem (SMOTE algoritması ve ağırlık atama) ile ele alınmaktadır. Öznitelik seçim aşamasında ise filtreleme ve özyinelemeli özellik çıkarma yöntemleri kullanılmaktadır. Verilerin [0, 1] aralığına normalizasyonundan sonra eğitim aşamasında iki-seviyeli ve beş-seviyeli sınıflandırma için önerilen yapay sinir ağı algoritması için hiper-parametre ayarlaması gerçekleştirilmektedir. En uygun hiper-parametre kümesini bulmak için rastgele arama algoritması kullanılmaktadır. Yapılan deneyler ile dengesiz sınıf dağılımı problemi için en uygun yöntemin SMOTE yöntemi olduğu öznitelik seçim işlemini uygulamak yerine tüm özniteliklerin kullanılarak önerilen algoritma ile daha yüksek doğruluk değerleri elde edildiği gösterilmektedir.

Gelecekte yapılacak çalışmalar arasında, farklı sınıflandırma algoritmaları ile öğrenci akademik performansının tahmin edilmesi ve bu algoritmaların hiper-parametrelerin otomatik – makine öğrenmesi yöntemleri ile öğrenilmesi gösterilebilir. Yine, öğretmen performansının veri madenciliği algoritma ve teknikleri ile analiz edilmesi de gelecekte yapılacak çalışmalar arasındadır.

## Kaynaklar

- [1] Abdullah A. "Beşeri Sermayenin Kalkınma Üzerine Etkisi". *Uluslararası Ekonomi Siyaset İnsan ve Toplum Bilimleri Dergisi*, 1(1), 28-34, 2018.
- [2] Kayadibi F. "Eğitim kalitesine etki eden faktörler ve kaliteli eğitimin üretime katkısı". *İstanbul Üniversitesi İlahiyat Fakültesi Dergisi*, 0(3), 2001.
- [3] Romero C, Ventura S. "Educational data mining and learning analytics: An updated survey". *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 10(3), 2020.
- [4] Salloum S A, Alshurideh M, Elnagar A, Shaalan K. "Mining in Educational Data: Review and Future Directions". *Joint European-US Workshop on Applications of Invariance in Computer Vision*, 92-102, April 2020.
- [5] Peña-Ayala A. "Educational data mining: A survey and a data mining-based analysis of recent works". *Expert systems with applications*, 41(4) 1432-1462, 2014.
- [6] Shahiri A M, Husain W. "A review on predicting student's performance using data mining techniques". *Procedia Computer Science*, 72, 414-422, 2015.
- [7] Satyanarayana A, Nuckowski M. "Data mining using ensemble classifiers for improved prediction of student academic performance". *Spring 2016 Mid-Atlantic ASEE Conference*, GWU, 8-9 April 2016.
- [8] Chaudhury P, Mishra S, Tripathy H K, Kishore B. "Enhancing the capabilities of student result prediction system". *ICTCS '16: Proceedings of the Second International Conference on Information and Communication Technology for Competitive Strategies*, March 2016.
- [9] Salal Y, Abdullaev S, Kumar M. "Educational Data Mining: Student Performance Prediction in Academic". *IJ of Engineering and Advanced Tech*, 8(4C), 54-59, 2019.
- [10] Hamoud A. "Selection of best decision tree algorithm for prediction and classification of students' action". *American International Journal of Research in Science, Technology, Engineering & Mathematics*, 16(1), 26-32, 2016.
- [11] Pojon M. "Using machine learning to predict student performance". 2017. MSc Thesis, University of Tampere, Tampere, Finland, 2017.
- [12] Başer S H, Hökeleki O, Kemal A. "Ortaöğretimde Öğrenim Gören Öğrenci Performanslarının Veri Madenciliği Yöntemleri İle Tahmin Edilmesi". *Bilgisayar Bilimleri ve Teknolojileri Dergisi*, 1(1), 22-27, 2020.
- [13] Ünal F. "Data Mining for Student Performance Prediction in Education". *IntechOpen*, 2020.
- [14] Athani S S, Kodli S A, Banavasi M N, Hiremath P S. "Student academic performance and social behavior predictor using data mining techniques". *IEEE International Conference on Computing, Communication and Automation (ICCCA)*, May 2017.
- [15] Ma X, Zhou Z. "Student pass rates prediction using optimized support vector machine and decision tree". *IEEE 8th Annual Computing and Communication Workshop and Conference (CCWC)*, 2018.
- [16] Troussas C, Virvou M, Mesaretzidis S. "Comparative analysis of algorithms for student characteristics classification using a methodological framework". *IEEE 6th International Conference on Information, Intelligence, Systems and Applications (IISA)*, 2015..
- [17] Singh M, Verma C, Kumar R, Juneja P. "Towards enthusiasm prediction of Portuguese school's students towards higher education in realtime".

*International Conference on Computation, Automation and Knowledge Management (ICCAKM)*, 2020.

- [18] Walia N, Kumar M. "Student's Academic Performance Prediction in Academic using Data Mining Techniques". *International Conference on Intelligent Communication and Computational Research (ICICCR-2020)*, 2020.
- [19] Srivastava A, Chaudhary A, Gautam A, Singh D, Khan R. "Prediction of Students Performance using KNN and Decision Tree-a Machine Learning Approach". *Strad Research*, 7(9), 119-125, 2020.
- [20] Zaffar M, Hashmani M A, Savita K S, Rizvi S S H, Rehman M. "Role of FCBF Feature Selection in Educational Data Mining". *Mehran University Research Journal of Engineering and Technology*, 39(4), 772-778, 2020.
- [21] Murat G. "Makine öğrenmesi yöntemleri ile akademik başarının tahmin edilmesi". *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji*, 5(3), 139-148, 2017.
- [22] Haykin S S. *Neural networks and learning machines*. Prentice Hall, New York, 2009.
- [23] Ataseven B. "Yapay sinir ağları ile öngörü modellemesi". *Öneri Dergisi*, 10(39), 101-115, 2013.
- [24] Öztemel E. *Yapay sinir ağları*. Papatya Yayıncılık, İstanbul, 2003.
- [25] Tran N, Schneider J G, Weber I, Qin A K. "Hyper-parameter optimization in classification: To-do or not-to-do". *Pattern Recognition*, 103, 107245, 2020.
- [26] Young S R, Rose D C, Karnowski T P, Lim S H, Patton R M. "Optimizing deep learning hyper-parameters through an evolutionary algorithm". *Workshop on Machine Learning in High-Performance Computing Environments*, November 2015.
- [27] Syarif I, Prugel-Bennett, Wills G. "SVM parameter optimization using grid search and genetic algorithm to improve classification performance". *Telkomnika*, 14(4), 1502, 2016.
- [28] Cortez P, Silva A M G. "Using data mining to predict secondary school student performance." *5th Annual Future Business Technology Conference*, Porto, Portugal, 2008.
- [29] Bergstra J, Bengio Y. "Random search for hyper-parameter optimization". *The Journal of Machine Learning Research*. 13(1), 281-305, 2012.
- [30] Erten, G E, Deutsch C V, Yavuz M. "Managing Estimation Artifacts in Machine Learning Spatial Estimation". *Paper 105, CCG Annual Report 22*, 2020.
- [31] Budak H. "Özellik Seçim Yöntemleri ve Yeni Bir Yaklaşım". *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 22, 21-31, 2018.
- [32] Maxwell A, Li R, Yang B, Weng H, Ou A, Hong H, Zhou Z, Gong P, Zhang C. "Deep learning architectures for multi-label classification of intelligent health risk prediction". *BMC bioinformatics*, 18(14), 121-131, 2017.
- [33] Ohsaki M, Wang P, Matsuda K, Katagiri S, Watanabe H, Ralescu A. "Confusion-matrix-based kernel logistic regression for imbalanced data classification". *IEEE Transactions on Knowledge and Data Engineering*, 29(9), 1806-1819, 2017.
- [34] Cabena P, Hadjinian P, Stadler R, Verhees J, Zanasi A. *Discovering data mining: from concept to implementation*. Prentice-Hall, Inc, 1998.
- [35] Gazel S, Bati C T, "Derin Sinir Ağları ile En İyi Modelin Belirlenmesi: Mantar Verileri Üzerine Keras Uygulaması". *Yüzüncü Yıl Üniversitesi Tarım Bilimleri Dergisi*, 29(3), 406-417, 2019.