



Bilişim Teknolojileri Öğretmenlerinin Blok Tabanlı Kodlama Araçlarına İlişkin Öz Yeterlik İnançlarının Evrişimsel Sinir Ağı ile Sınıflandırılması

Burak Koca^{1*}, Kemal Adem²

^{1*} Aksaray Üniversitesi, Sosyal Bilimler Enstitüsü, Yönetim Bilişim Sistemleri Bölümü, Aksaray, Türkiye, (ORCID: 0000-0001-5703-3178), burak.koca@asu.edu.tr

² Aksaray Üniversitesi, Mühendislik Fakültesi, Yazılım Mühendisliği Bölümü, Aksaray, Türkiye (ORCID: 0000-0002-3752-7354), kemaladem@aksaray.edu.tr

(1st International Conference on Engineering and Applied Natural Sciences ICEANS 2022, May 10-13, 2022)

(DOI: 10.31590/ejosat.1113087)

ATIF/REFERENCE: Koca, B. & Adem, K. (2021). Bilişim Teknolojileri Öğretmenlerinin Blok Tabanlı Kodlama Araçlarına İlişkin Öz Yeterlik İnançlarının Evrişimsel Sinir Ağı ile Sınıflandırılması. *Avrupa Bilim ve Teknoloji Dergisi*, (36), 50-54.

Öz

Bu çalışmada, bilişim teknolojileri öğretmenlerinin blok tabanlı kodlama araçlarının kullanımına ilişkin öz yeterlik inançlarının makine öğrenmesi ve derin öğrenme yöntemleri ile sınıflandırılması amaçlanmıştır. Veri toplama aracı olarak daha önceden geliştirilmiş likert tipinde maddelerden oluşan T-SECT ölçeği Türkçeye adapte edilerek kullanılmıştır. Veri seti bilişim teknolojileri öğretmenlerinden oluşan 190 örnek ve 39 öznelikten oluşmaktadır. Örnek sayısının azlığı nedeniyle dengesiz veri sorunundan kaçınmak için SMOTE yöntemi kullanılarak veri çoğaltılmış ve örnek sayısı 262 ye çıkarılmıştır. Veri seti WEKA yazılımına aktarılarak üzerinde makine öğrenmesi yöntemleri ve Evrişimsel Sinir Ağı (ESA) kullanılmıştır. Bu amaç doğrultusunda J48, Random Forest (RF), K-Star, Multilayer Perceptron (MLP), NaivesBayes, SMO ve IBK yöntemleri ile sınıflandırma başarıları hesaplanmıştır. Veri seti üzerinde en yüksek sınıflandırma başarıları gösteren makine öğrenmesi yöntemleri SMO, MLP, IBK, J48 ve RF olarak bulunmuştur. ESA ile yapılan sınıflandırmada makine öğrenmesi yöntemlerinden daha başarılı sonuçlar elde edilmiştir. Bilişim teknolojileri öğretmenlerinin öz yeterlik inançları ESA kullanılarak %99.30 doğruluk oranıyla başarılı bir şekilde sınıflandırılmıştır.

Anahtar Kelimeler: Makine öğrenmesi, Blok tabanlı kodlama, Bilgi işlemsel düşünme, Özyeterlik inancı, Evrişimsel Sinir Ağları.

Classification of Self-Efficacy Beliefs of Information Technology Teachers on Block-Based Coding Tools by Convolutional Neural Network

Abstract

In this study, it is aimed to classify the self-efficacy beliefs of information technology teachers regarding the use of block-based coding tools by machine learning and deep learning methods. As a data collection tool, the T-SECT scale, which consists of previously developed likert-type items, was adapted to Turkish and used. The data set consists of 190 examples and 39 attributes of information technology teachers. In order to avoid the problem of unbalanced data due to the small number of samples, the data was amplified using the SMOTE method and the number of samples was increased to 262. The data set was transferred to WEKA software and machine learning methods and Convolutional Neural Network (CNN) were used on it. For this purpose, classification success was calculated with J48, Random Forest (RF), K-Star, Multilayer-Perceptron (MLP), NaivesBayes, SMO and IBK methods. The machine learning methods with the highest classification success on the data set were found to be SMO, MLP, IBK, J48 and RF. In the classification made with CNN, more successful results were obtained than the machine learning methods. Self-efficacy beliefs of information technology teachers were successfully classified using CNN with an accuracy rate of 99.30%.

Keywords: Machine learning, Block-based coding, Computational thinking, Self-efficacy belief, Convolutional Neural Networks.

* Sorumlu Yazar: burak.koca@asu.edu.tr

1. Giriş

Teknolojide meydana gelen hızlı değişimler başta ekonomi olmak üzere sağlık, eğitim, üretim gibi pek çok alanda etkili olmuştur (Ersoyve diğ., 2011). Bahsedilen alanlarda teknolojinin daha çok kendine yer bulması insanların daha farklı becerilere sahip olmasını zorunlu kılmıştır. Bu beceriler son yıllarda 21. yy. becerileri olarak adlandırılmaya başlanmıştır. Problem çözme, bilgi işlemsel düşünme, yaratıcılık, varsayımsal düşünme, eleştirel düşünme, girişimcilik ve iletişim gibi üst bilişsel beceriler 21.yy becerileri kapsamında yer almaktadır. Geleceğin iş gücünü oluşturacak 21. Yy. becerilerine sahip bireylerin ekonomik kalkınmada kilit rol oynayacağı bir gerçektir. Ekonomik kalkınmanın gerekliliği eğitimle ilgili politikalar üzerinde de değişimi zorunlu kılmaktadır. Sanayi, savunma, sağlık gibi önemli alanlarda bilgisayar tabanlı teknolojilerin kullanılması, eğitim-öğretim sürecinde bilgi işlemsel düşünme becerilerine daha çok önem verilmesini gerektirmektedir. Bu bağlamda bilgi işlemsel düşünmenin temel basamağını kodlama eğitimi oluşturmaktadır (Sayın ve Seferoğlu, 2016). Pek çok ülke bilgi işlemsel düşünmenin; bireye kazandıracığı beceriler, toplumsal fayda ve ekonomik katkı gibi faydaları sebebiyle ders içeriklerine seçmeli/zorunlu olarak kodlama eğitimi dahil etmişlerdir (Bocconi ve diğ., 2016; Göncü ve diğ., 2018). Ülkemizde de bilişim teknolojileri ve yazılımı öğretim programında revizyona gidilerek birçok kademede kodlama eğitimine yer verilmeye başlanmıştır. Öğretim programıyla hedeflenen kodlama becerilerini öğrencilerin kazanabilmeleri için öğretmenlerin kodlamanın gerektirdiği alan bilgisine ve pedagojik bilgiye ihtiyaçları vardır (Göncü ve diğ., 2020).

Literatürde yer alan çalışmalarda, bilişim teknolojileri öğretmenlerinin büyük bir kısmı kodlama eğitimi hakkında kendilerini yeterli bulmamakta veya sadece temel seviyede yeterli gördüklerini düşünmektedirler (Türker ve Pala,2018). Bunun sebebi öğretmenlerin lisans eğitimde kodlama eğitimi ile ilgili eğitim almamaları veya geçerliliğini yitirmiş programlama dillerinde eğitim almış olmaları olabilir (Ozoran ve diğ., 2012). Eğitim kurumlarında programların uygulayıcısı olan öğretmenlerin kodlama konusunda donanımlı ve kodlamanın öğretiminde izlenecek adımlar konusunda deneyimli olması önemlidir (Göncü ve diğ., 2018). Bu bağlamda, bu çalışmada bilişim teknolojileri öğretmenlerinin blok tabanlı kodlama araçlarına yönelik özyeterlik inançlarının makine öğrenmesi ve derin öğrenme yöntemleriyle sınıflandırılması amaçlanmaktadır. Makine öğrenmesi ve derin öğrenme yöntemleri eğitimde sınıflandırma ve tahmin etme amaçlı kullanılabilir. Makine öğrenmesi çok büyük verileri analiz etme ve yüksek seviye bilgileri ayıklama işlemlerinde kullanılmaktadır (Breiman,2001). Derin öğrenme, insan beynine benzer şekilde kompleks problemleri çözmek için kullandığı yöntem ve yeteneklerini taklit eden, büyük miktarda veriden yararlanarak öznitelik çıkarma, sınıflandırma ve dönüştürme işlemlerini gerçekleştiren bir makine öğrenmesi tekniğidir (Albannai, 2019; Adem ve Kılıçarslan, 2019; Adem ve Közkurt, 2019; Cömert ve diğ., 2019). Literatüre bakıldığında eğitim alanında özyeterliğin araştırıldığı çalışmalara rastlanmaktadır. Özyeterliğin tahmin edilmesi amacıyla yapılan bir çalışmada üniversite öğrencilerinin bir derse yönelik ön performansları göz önünde bulundurulurken makine öğrenmesi yöntemleri kullanılmıştır. (Jamjoom ve diğ., 2021). Üniversite öğrencileri ile gerçekleştirilen başka bir çalışmada ise Wirojcharoenwong ve diğ. (2014) öğrencilerin bilgisayar özyeterliliklerinin karar ağacı

yöntemi ile sınıflandırılmasını hedeflemişlerdir. Bu çalışmada olduğu gibi likert tipi anket aracılığıyla verilerin toplandığı bir çalışmada ise Çiftçi ve diğ. (2018) eğitim performansının makine öğrenmesi yöntemleri ile belirlemeye çalışmışlardır. Literatürde eğitim alanında yapılan tahmin ve sınıflandırma çalışmalarda genellikle makine öğrenmesi yöntemlerinin kullanıldığı görülmüştür. Likert tipi anketlerden elde edilen verilerin derin öğrenme yöntemleriyle sınıflandırılmasına ilişkin müşteri memnuniyetini temel alan bir çalışma bulunmaktadır (Ünal, 2019). Ancak eğitim alanında özyeterliğin sınıflandırılmasına ilişkin likert tipi anket verilerinin derin öğrenme yöntemleri ile analiz edildiği bir çalışmaya rastlanılmamıştır. Bu çalışmanın likert tipi anketlerle elde edilmiş veriler kullanılarak özyeterliğin derin öğrenme yöntemleriyle sınıflandırılmasına yönelik öncü çalışmalardan olacağı düşünülmektedir.

2. Materyal ve Metot

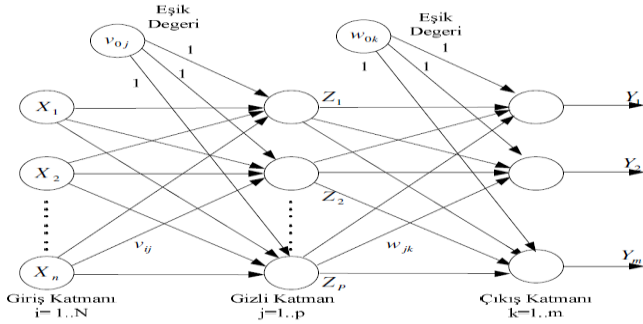
2.1. Veri Kümesi

Bu çalışmada bilişim teknolojileri öğretmenlerinin özyeterlik düzeylerini belirlemek amacıyla özel ve devlet okullarında çalışmakta olan 190 örnek ve 29 öznitelik veri kümesini oluşturmaktadır. Veriler daha önce Bean ve diğ. (2015) tarafından 29 özniteliklik bulunduğu likert tipinde geliştirilmiş TSECT anketi ile elde edilmiştir. Bu anket alan uzmanlarının yardımı ile Türkçeye adapte edilerek kullanılmıştır. Smote algoritması kullanılarak sınıflar üzerindeki dengesiz veri dağılım sorununun önüne geçilmek istenmiş ve örnek sayısı bu yöntemle 262'ye çıkarılmıştır.

Çalışmada çeşitli makine öğrenmesi ve derin öğrenme yöntemleri ile bilişim teknolojileri öğretmenlerinin özyeterlik düzeyleri yeterli/yeterli değil şeklinde sınıflandırılmaya çalışılmıştır. Makine öğrenmesi yöntemlerinden en başarılı sınıflandırma performansını gösteren MLP, SMO, Random Forest, J48, K-star, Naive Bayes algoritmaları ile işlemler gerçekleştirilmiştir. Derin öğrenme yöntemlerinden ise ESA kullanılarak sınıflandırma gerçekleştirilmiştir.

2.2. Çok Katmanlı Algılayıcı (MLP)

Çok katmanlı algılayıcılar en popüler sinir ağı mimarileri arasındadır (Süt ve Çelik, 2011). Bunun sebebi MLP'nin öğrenme ve genelleme yeteneği, daha küçük eğitim seti gereksinimleri, hızlı çalışma ve uygulama kolaylığı gibi özelliklere sahip olmasıdır (Güler ve Ubeyli,2005). MLP ağlarında nöronlar girdi, çıktı ve gizli katman olmak üzere üç farklı katmanda yer almaktadır. İlk katman olan girdi katmanı, çözüme ulaştırılması beklenen probleme ait bilgilerin yapay sinir ağına aktarılmasını sağlar (Güler ve Ubeyli, 2005). Çıktı katmanı ağ içerisinde işlenen bilginin ağ dışına iletiği katmandır (Kaynar ve Taştan, 2009). Gizli katman, girdi ve çıktı katmanlarının arasında bulunur ve gizli katman sayısı birden fazla bulunabilir (Süt ve Çelik, 2011). Standart bir MLP ağının katman yapısı Şekil 1'de yer almaktadır.



Şekil 1. Çok katmanlı algılayıcı (Kaynar ve Taştan, 2009)

2.3. Sıralı Minimum Optimizasyonu (SMO)

Sıralı Minimum Optimizasyon (SMO), bir matris depolaması gerek duymadan ve sayısal ikinci dereceden programlama optimizasyon adımlarını kullanmadan SVM problemini basit ve hızlı bir şekilde çözebilen bir algoritmadır (Platt,1998). SMO'da hiçbir matris algoritması kullanılmadığından, sayısal hassasiyet sorunlarına en az rastlanmaktadır (Platt,1998). SMO ilk aşamada tüm çarpanlardaki kısıtlamaları hesaplayarak sınırlandırılmış maksimum değeri belirler (Kuan ve diğ., 2011). SMO'nun ana bileşeni olan iki Lagrange çarpanını çözmek için analitik bir yöntem sunar ve hangi çarpanların optimize edileceğini seçmek için bir buluşsal yöntem kullanır (Platt,1998). İki çarpanın optimize edilmesinde, kısıtlamalar bir kutu yatılı sınırlandırılmış çapraz çizgi parçası olan iki boyutlu kareyi tanımlamak olarak görülebilir (Kuan ve diğ., 2011).

2.4. Random Forest Algoritması

Random Forest (RF), Leo Breiman ve Adele Cutler tarafından geliştirilmiştir. RF, tek bir sınıflandırıcı ağaç kullanmak yerine birçok sınıflandırıcı ağacın beraber kullanılması ve ardından tahminlerinden alınan oylar ile yeni veriyi sınıflandırmayı sağlayan bir öğrenme algoritmasıdır (Nizam ve Akın, 2014). RF, tüm değişkenler arasında en iyi bölünmeyi kullanarak her düğümü bölmek yerine, her düğümü, o düğümde rasgele seçilen bir tahmin edici alt kümesi arasından en iyisini kullanarak bölmektedir (Akar ve Güngör, 2012).

2.4. J48 Algoritması

Ross Quinlan tarafından geliştirilen bu algoritma WEKA veri madenciliği aracındaki C4.5 algoritmasının açık kaynaklı bir uygulamasıdır (Gholap, 2012). J48 algoritması bir çeşit karar ağacı algoritmasıdır. Karar ağacı algoritmasında amaç farklı öznelikler üzerinden birkaç örnek için nasıl davrandığının bulunması ve eğitim örneklerine bakılarak yeni örnekler için sınıflandırma yapılabilmesidir (Kaur ve Chhabra, 2014). Bu yöntemle sınıflandırma sürecini göstermek için bir ağaç oluşturularak kritik dallanmalar belirlenir ve oluşturulan tüm örneklerle uygulanarak sınıflandırma işlemi gerçekleşir (Eraldemir ve diğ., 2017). J48 karar ağacı eksik değerleri, karar ağaçlarının budanmasını, sürekli öznelik değer aralıklarını, kuralların türetilmesini hesaba katmaktadır. Bu algoritma, verilerin sınıflandırılması için belirli bir kimliğinin üretildiği kuralları oluşturarak esneklik ve doğruluk dengesi kurulana kadar bir karar ağacının aşamalı olarak geliştirilmesidir (Kaur ve Chhabra, 2014). J48 algoritmasının temel adımları şu şekilde sıralanmaktadır:

- Örnekler aynı sınıfa ait olursa ağaç bir yaprağı temsil eder, böylece o yaprak aynı sınıfla etiketlenerek döndürülür.
- Öznelik üzerinde bir test ile verilen her nitelik için potansiyel bilgi hesaplanır. Daha sonra, öznelik üzerindeki bir testten kaynaklanacak bilgi kazancı hesaplanır.

Daha sonra mevcut seçim kriteri temelinde en iyi nitelik bulunur ve dallanma için o öznelik seçilir (Quinlan, 1992).

2.5. IBK (K-En Yakın Komşu kNN=IBK)

IBK algoritması iyi bilinen geçmişi olan basit ve etkili yapıda bir örüntü sınıflandırma yöntemi olup, makine öğrenmesi algoritmaları arasında çok tercih edilir (Taşçı ve Onan, 2016). IBK algoritması en yakın k değerine sahip verilere göre oluşmuş bir sınıflama türü algoritmadır. Aynı zamanda öğrenme işlemi, eğitim için ayrılan veriye bağlı k yakınlığa göre bir sınıflandırma ile gerçekleştirilir (Taşçı ve Onan, 2016).

Veri setinde hangi sınıfta olduğu bilinen verilerden faydalanılarak yeni verinin hangi sınıfa girmesi gerektiğini bulmaya çalışır (Güldal ve Çakıcı, 2017). Sınıfını belirlemek istediğimiz verinin uzaklığının hesaplanması gerekir bunun için çeşitli ölçütler kullanılabilir. Bu ölçütler, Minkowski, Öklid, Manhattan, Chebyshev ve Dilca uzaklığıdır (Taşçı ve Onan, 2016). Çok tercih edilen ölçütlerden biri iki nota arasındaki doğrusal uzaklık olan Eşitlik 3'de verilen Öklid uzaklığıdır (Taşçı ve Onan, 2016).

$$d(i, j) = \sqrt{\sum_{k=1}^p (x_{ik} - x_{jk})^2} \quad (3)$$

2.8. Evrimsel Sinir Ağları

Evrimsel sinir ağları (ESA), Le Cun tarafından 1990 yılında insan beynini temel alarak oluşturulmuş bir modeldir (Ciresan ve diğ., 2010). Görüntü / video işleme, sinyal işleme ve sınıflandırma ile 2B yapılarda sıklıkla ESA modelleri kullanılmaktadır (Deng ve Yu, 2014). ESA modelinin temelinde bir veya daha fazla evrişim katmanı, aktivasyon katmanı, normleştirme katmanı, havuzlama katmanı, tam bağlantı katmanı ve softmax katmanları yer almaktadır. Yapay sinir ağlarında ilk olarak giriş katmanında nöronlar, sonraki katmanlarının çıkış katmanlarına nöronlar yardımı ile bağlanırlar (LeCun ve diğ., 2015). ESA modellerinde ise yapay sinir ağlarındaki giriş katmanına ekstra olarak evrişim işlemi yapılır (Adem ve Kılıçarslan, 2021). Bunun sonucunda oluşturulan modele her katman sonucunda filtreler uygulanır ve sonuçlar toplanır. Genel olarak ESA modellerinin amacı problem çözmenin öğrenilmesinin sağlanmasıdır (Simard ve diğ., 2003). Bu çalışmada da anket sonucunda oluşturulan veri setleri tek boyutlu 1DCONV kullanılarak sınıflandırma işlemi yapılmıştır.

3. Araştırma Sonuçları ve Tartışma

Bu çalışmada bilişim teknoloji öğretmenlerinin blok tabanlı kodlama araçlarına yönelik öz yeterliklerini ölçmek için oluşturulan veri seti üzerinde makine öğrenmesi ve derin öğrenme yöntemlerinden oluşan modeller ile deneyler gerçekleştirilmiştir. Sınıflandırma için J48, SMO, Multilayer Perceptron (MLP), Random Forest (RF), Naive Bayes ve Evrimsel Sinir Ağı (ESA) modelleri kullanılmıştır. Çalışmada

kullanılan modeller, Intel Core-i5 10200H işlemci ve 8 GB RAM'e sahip bilgisayarda Weka Platformunda ve Google'ın geliştirdiği sanal platform olan Google Colaboratory platformunda test edilmiştir. MLP yönteminde nöron sayısı 20, öğrenme oranı 0.1 ve momentum katsayısı 0.2 olarak belirlenmiştir. SMO yönteminde kernel olarak Polinomsal fonksiyon kullanılmıştır. IBK yönteminde komşuluk sayısı 3 ve uzaklık ölçütü olarak 'Öklid' kullanılmıştır. RF yönteminde ise rastgele ormandaki ağaç sayısı 100 olarak belirlenmiştir.

3.1. Değerlendirme Kriterleri

Deneylerde kullanılan yöntemlerin objektif bir şekilde değerlendirilmesi için her bir veri seti cross validation (çapraz doğrulama) yöntemi ile eğitim ve test veri setlerine ayrılmıştır. Eğitim ve test veri setleri rastgele bir şekilde ayrılmıştır. En temel cross-validation yöntemlerinden olan K-Fold yöntemi ile veri seti rastgele olacak şekilde karıştırılır. Veri seti k gruba ayrılır. Seçilen grup validasyon seti olarak kullanılır. Diğer tüm gruplar ($k-1$ grup) train seti olarak kullanılır. Train seti kullanılarak model kurulur ve validasyon seti ile değerlendirilir. Modelin değerlendirme puanı bir listede saklanır. Son olarak k farklı değerlendirme puanının ortalaması modelin performansı olarak sunulmaktadır. Bu çalışmada, performans değerlendirmesi için sırasıyla Eşitlik 4, 5 ve 6'da verilen duyarlılık, özgüllük ve doğruluk değerleri kullanılmıştır.

$$\text{Doğruluk} = \frac{TP+TN}{TP+FP+FN+TN} \times 100 \quad (4)$$

$$\text{Duyarlılık} = \frac{TP}{TP+FN} \times 100 \quad (5)$$

$$\text{Özgüllük} = \frac{TN}{TN+FP} \times 100 \quad (6)$$

Eşitliklerde görülen TP gerçek pozitif, TN gerçek negatif, FP yanlış pozitif ve FN ise yanlış negatif ifade etmektedir. Çalışmamızda oluşturduğumuz veri setine 10 farklı makine öğrenmesi yöntemi uygulanmış olup elde edilen sonuçlar Tablo 1'de verilmektedir.

Tablo 1. Makine Öğrenmesi Yöntemlerinin Deneysel Sonuçları

Sınıflandırma	Çapraz Geçerlilik (Fold)	Duyarlılık	Özgüllük	Doğruluk
NAIVEBAYES	10	0,911	0,854	%87,40
SMO	10	0,986	0,993	%98,85
MLP	10	0,978	0,944	%95,80
RF	10	0,953	0,968	%96,05
J48	10	0,959	0,968	%96,42
K-STAR	10	0,978	0,910	%93,89
IBK	10	0,966	0,993	%97,70
LOGİSTİC	10	0,924	0,908	%91,60
RANDOM TREE	10	0,959	0,951	%95,48
ZERO-R	10	0,550	0,936	%54,96

Tablo 1'de görüldüğü gibi, SMO makine öğrenmesi yönteminin duyarlılık, özgüllük ve doğruluk oranları diğer yöntemlere göre daha yüksek çıkmıştır. Performans ölçütlerinden görüleceği gibi en iyi sınıflandırma performansı gösteren beş yöntem sırası ile SMO, IBK, J48, RF ve MLP algoritmalarıdır. Sınıflandırma performansını artırmak için veri kümesine ayrıca derin öğrenme yöntemlerinden ESA modeli uygulanmıştır. ESA modelinde dört evrişim katmanı, evrişim katmanlarında filtre boyutu iki, ReLU aktivasyon fonksiyonu, drop out değeri 0.1 ve optimizer

fonksiyonu ise 'Adam' olarak belirlenmiştir. Elde edilen deneysel sonuçlar Tablo 2'de verilmektedir.

Tablo 2. Makine öğrenmesi ve ESA yöntemlerinin sonuçları

Sınıflandırma	Çapraz Geçerlilik (Fold)	Duyarlılık	Özgüllük	Doğruluk
SMO	10	0,986	0,993	%98,85
J48	10	0,959	0,968	%96,42
MLP	10	0,978	0,944	%95,80
RF	10	0,953	0,968	%96,05
IBK	10	0,966	0,993	%97,70
ESA	10	0,993	1,00	%99,6

Tablo 2'de görüldüğü gibi, ESA modeli ile elde edilen sonuçlar tüm makine öğrenmesi modellerinden elde edilen sonuçlara göre daha başarılıdır. ESA yöntemi ile %99.6 doğruluk, %99.3 duyarlılık ve %100 özgüllük değerlerine ulaşılmıştır. ESA yönteminin makine öğrenmesi modellerine göre daha iyi sonuçlar vermesinin temel nedeni, evrişim katmanında belirlenen veri kümesindeki düşük ve yüksek seviyeli öznelikleri ön plana alarak sınıflandırma başarısını artırmasıdır.

4. Sonuç

Gelişen teknoloji ile geleceğin iş gücünü oluşturacağı düşünülen bireylerin kodlama bilgisine sahip olmaları büyük bir gereklilik haline gelmiştir. Kodlama eğitimin verilmesinde temel düzeyde sorumlu olan bilişim teknolojileri öğretmenleridir. Bu nedenle bu öğretmenlerin kodlamanın gerekli kıldığı becerilere tam anlamıyla sahip olmaları ve bunu uygulamalı olarak öğrencilerine aktarabilmeleri oldukça önemlidir. Bu bağlamda, bu çalışmada bilişim teknolojileri öğretmenlerinin blok tabanlı kodlama araçlarına yönelik özyeterlik düzeylerine göre sınıflandırılmasına çalışılmıştır. Bu amaçla makine öğrenmesi ve derin öğrenme yöntemleri kullanılmıştır. T-SECT anketi ile elde edilen veriler Weka ve Google Colab platformlarına aktarılarak analiz edilmiştir. Elde edilen deneysel sonuçlara bakıldığında en iyi sınıflandırma performansı gösteren makine öğrenmesi yöntemleri sırasıyla %98,6 doğrulukla SMO, %97,8 doğrulukla MLP, %96,6 doğrulukla IBK, %95,9 doğrulukla J48 ve %95,6 doğrulukla RF'dir. Ayrıca ESA modelinin sınıflandırma başarı oranı %99,3'dür. ESA ile makine öğrenmesi yöntemleri kıyaslandığında ESA ile elde edilen sonuçlar daha başarılı sınıflama performansı göstermiştir. Gelecekteki çalışmalarda farklı makine öğrenmesi ve derin öğrenme yöntemleri kullanılabilir. ESA modelindeki başarı oranını artırmak için farklı parametreler veya optimizasyon yöntemleri uygulanabilir. Örnek sayısının da artırılarak aynı yöntemlerle daha başarılı sonuçlar alınabileceği düşünülmektedir.

Kaynakça

- Adem, K., & Kılıçarslan, S. (2021). COVID-19 Diagnosis Prediction in Emergency Care Patients using Convolutional Neural Network. *Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, (2), 300-309.
- Adem, K., & Kılıçarslan, S. (2019, October). Performance analysis of optimization algorithms on stacked autoencoder. In *2019 3rd International Symposium on Multidisciplinary*

- Studies and Innovative Technologies (ISMSIT)* (pp. 1-4). IEEE.
- Adem, K., & Közkurt, C. (2019). Defect detection of seals in multilayer aseptic packages using deep learning. *Turkish Journal of Electrical Engineering & Computer Sciences*, 27(6), 4220-4230.
- Akar, Ö., & Güngör, O. (2012). Classification of multispectral images using Random Forest algorithm. *Journal of Geodesy and Geoinformation*, 1(2), 105-112.
- Albannai, B. (2019). *Comparative Study of HVAC and HVDC Transmission Systems With Proposed Machine Learning Algorithms for Fault Location Detectio* (Doctoral dissertation, Arizona State University).
- Bean, N., Weese, J., Feldhausen, R., & Bell, R. S. (2015, October). Starting from scratch: Developing a pre-service teacher training program in computational thinking. In *2015 IEEE Frontiers in Education Conference (FIE)* (pp. 1-8). IEEE.
- Bocconi, S., Chiocciariello, A., Dettori, G., Ferrari, A., & Engelhardt, K. (2016). *Developing computational thinking in compulsory education-Implications for policy and practice* (No. JRC104188). Joint Research Centre (Seville site).
- Breiman, L. (2001). Random forests. *Machine learning*, 45(1), 5-32.
- Cireşan, D. C., Meier, U., Gambardella, L. M., & Schmidhuber, J. (2010). Deep, big, simple neural nets for handwritten digit recognition. *Neural computation*, 22(12), 3207-3220.
- Cömert, O., Hekim, M., & Adem, K. (2019). Faster R-CNN Kullanarak Elmalarda Çürük Tespiti. *International Journal of Engineering Research and Development*, 11(1), 335-341.
- Çiftçi, F., Kaleli, C., & Ünal, S. (2018). Öznitelik seçme ve makine öğrenmesi yöntemleriyle eğitim performansının tahmin edilmesi. *Anadolu Journal of Educational Sciences International*, 8(2), 419-440.
- Deng, L., & Yu, D. (2014). Deep learning: methods and applications. *Foundations and trends in signal processing*, 7(3-4), 197-387.
- Eraldemir, S. G., Arslan, M. T., & Yıldırım, E. (2017, November). The Effect of Feature Selection Algorithms in EEG Signal Analysis. In *International Advanced Researches & Engineering Congress*.
- Ersoy, H., Madran, R. O., & Gülbahar, Y. (2011). Programlama dilleri öğretimine bir model önerisi: robot programlama. *Akademik Bilişim*, 11, 731-736.
- Gholap, J. (2012). Performance tuning of J48 Algorithm for prediction of soil fertility. *arXiv preprint arXiv:1208.3943*.
- Göncü, A., Çetin, İ., & Şendurur, P. (2020). Bilişim Teknolojileri ve Yazılım Dersi Öğretmenlerinin Kodlama Eğitimine Yönelik Görüşleri. *Mersin Üniversitesi Eğitim Fakültesi Dergisi*, 16(2), 301-321.
- Göncü, A., Çetin, İ., & Top, E. (2018). Öğretmen Adaylarının Kodlama Eğitimine Yönelik Görüşleri: Bir Durum Çalışması. *Mehmet Akif Ersoy Üniversitesi Eğitim Fakültesi Dergisi*, (48), 85-110.
- Güldal, H., & Çakıcı, Y. (2017). Ders Yönetim Sistemi Yazılımı Kullanıcı Etkileşimlerinin Sınıflandırma Algoritmaları ile Analizi. *Journal of Graduate School of Social Sciences*, 21(4), 1355-1367.
- Güler, İ., & Übeyli, E. D. (2005). An expert system for detection of electrocardiographic changes in patients with partial epilepsy using wavelet-based neural networks. *Expert Systems*, 22(2), 62-71.
- J. C. Platt, (1998). "Fast training of support vector machines using sequentialminimal optimization," in *Advances in Kernel Methods of Support Vector Machine*, B. Schölkopf, C. Burges, and A. Smola, Eds. Cambridge, MA: MIT Press.
- Jamjoom, A. A., Rhodes, J., Andrews, P. J., & Grant, S. G. (2021). The synapse in traumatic brain injury. *Brain*, 144(1), 18-31.
- Kaur, G., & Chhabra, A. (2014). Improved J48 classification algorithm for the prediction of diabetes. *International journal of computer applications*, 98(22).
- Kaynar, O., & Taştan, S. (2009). Zaman serisi analizinde mlp yapay sinir ağları ve arıma modelinin karşılaştırılması. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 33, 161-172.
- Kuan, T. W., Wang, J. F., Wang, J. C., Lin, P. C., & Gu, G. H. (2011). VLSI design of an SVM learning core on sequential minimal optimization algorithm. *IEEE Transactions on Very Large Scale Integration (VLSI) Systems*, 20(4), 673-683.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
- Metz, C. E. (1978, October). Basic principles of ROC analysis. In *Seminars in nuclear medicine* (Vol. 8, No. 4, pp. 283-298). WB Saunders.
- Nizam, H., & Akın, S. S. (2014). Sosyal medyada makine öğrenmesi ile duygu analizinde dengeli ve dengesiz veri setlerinin performanslarının karşılaştırılması. *XIX. Türkiye'de İnternet Konferansı*, 1(6).
- Ozoran, D., Cagiltay, N., & Topalli, D. (2012). Using scratch in introduction to programming course for engineering students. In *2nd International Engineering Education Conference (IEEC2012)* (Vol. 2, pp. 125-132).
- Quinlan, J. R. (1992, November). Learning with continuous classes. In *5th Australian joint conference on artificial intelligence* (Vol. 92, pp. 343-348).
- Sayın, Z., & Seferoğlu, S. S. (2016). Yeni bir 21. yüzyıl becerisi olarak kodlama eğitimi ve kodlamanın eğitim politikalarına etkisi. *Akademik Bilişim Konferansı*, 2016, 3-5.
- Simard PY, Steinkraus D, Platt JC. Best practices for convolutional neural networks applied to visual document analysis. In: Proceedings of the seventh international conference on document analysis and recognition; Edinburgh, UK; 2003; 2: 958-62.
- Süt, N., & Çelik, Y. (2012). Prediction of mortality in stroke patients using multilayer perceptron neural networks. *Turkish Journal of Medical Sciences*, 42(5), 886-893.
- Taşcı, E., & Onan, A. (2016). K-en yakın komşu algoritması parametrelerinin sınıflandırma performansı üzerine etkisinin incelenmesi. *Akademik Bilişim*, 1(1), 4-18.
- Türker, P. M., & Pala, F. K. (2018). Ortaokul öğrencilerinin, öğretmenlerin ve öğrenci velilerinin kodlamaya yönelik görüşleri. *İlköğretim Online*, 17(4).
- Ünal, Z. (2019). *Likert tipi verilerde bulanık mantık ve derin öğrenme entegrasyonu*. [Yayınlanmamış doktora tezi]. Akdeniz Üniversitesi
- Van't Veer LJ, Dai H, Van De Vijver MJ, He YD, Hart AA, et al. (2002) Gene expression profiling predicts clinical outcome of breast cancer. *Nature*, 415(6871), 530-536.
- Wirojcharoenwong, W., Luangnaruedom, N., Rattanasiriwongwut, M., & Tiantong, M. (2014). Decision Tree Classifier for Computer Self-Efficacy with Best First Feature Selection. *Int. J. Comput. Internet Manag*, 22, 62-67.