



POLİTEKNİK DERGİSİ

*JOURNAL of POLYTECHNIC*

ISSN: 1302-0900 (PRINT), ISSN: 2147-9429 (ONLINE)

URL: <http://dergipark.gov.tr/politeknik>



# Fiziksel ve motor engelli çocukların öz bakım problemlerinin derin sinir ağları ile sınıflandırılması

*Self-care problems classification of children with physical and motor disability by deep neural networks*

*Yazar(lar) (Author(s)): Abdulkadir KARACI*

*ORCID : 0000-0002-2430-1372*

**Bu makaleye şu şekilde atıfta bulunabilirsiniz (To cite to this article):** Karacı A., “Fiziksel ve motor engelli çocukların öz bakım problemlerinin derin sinir ağları ile sınıflandırılması”, *Politeknik Dergisi*, 23(2): 333-341, (2020).

**Erişim linki (To link to this article):** <http://dergipark.gov.tr/politeknik/archive>

**DOI:** 10.2339/politeknik.522641

# Fiziksel ve Motor Engelli Çocukların Öz Bakım Problemlerinin Derin Sinir Ağları ile Sınıflandırılması

*Araştırma Makalesi / Research Article*

**Abdulkadir KARACI\***

Mühendislik Fakültesi, Bilgisayar Müh. Bölümü, Kastamonu Üniversitesi, Türkiye

(Geliş/Received : 05.02.2019 ; Kabul/Accepted : 19.04.2019)

## ÖZ

Fiziksel ve motor engellilik bazı bireysel ana yaşam aktivitelerini büyük ölçüde sınırlayan bir bozukluktur. Bu bozukluklar dünyanın birçok ülkesinde çocukları etkilemektedir. Bunun yanı sıra fiziksel ve motor engelli bireylerin doktorlar tarafından uygun mesleki tedavilerle sınıflandırılmaları zor bir süreçtir. Çünkü değerlendirilmesi gereken birçok değişken vardır. Bu çalışmadaki amaç, fiziksel ve motor engelli çocukların öz bakım beceri problemlerini derin sinir ağlarını (DSA) kullanarak en az hata ile sınıflandırmaktır. Bu amaçla farklı parametrelere sahip DSA modelleri oluşturulmuştur. Modellerin oluşturulmasında gizli katman sayısı, gizli katmanlardaki nöron sayısı, aktivasyon fonksiyonu, optimizasyon algoritması, kayıp fonksiyonu ve epoch değeri parametreleri dikkate alınmıştır. Oluşturulan DSA modelleri SCADI (Self-Care Activities Dataset based on ICFCY) veri seti vasıtasıyla eğitilmiş ve test işlemi gerçekleştirilmiştir. Modellerin sınıflandırma performansları F-1 puanı, kesinlik (precision-P), hassasiyet (recall-R) ve doğruluk (accuracy-ACC) metrikleri kullanılarak ortaya konulmuştur. En iyi sınıflandırma performansına sahip 8 modelin ayrıntıları sunulmuştur. Elde edilen bulgulara göre en iyi sınıflandırma performansı Adadelta optimizasyon algoritmasını, Elu aktivasyon fonksiyonunu ve Categorical crossentropy kayıp fonksiyonunu kullanan DSA-1 modelinde elde edilmiştir. Bu modelin P, R, ACC ve F1 puanı değerleri 1'dir. Yani bu model fiziksel ve motor engelli çocukların öz bakım beceri problemlerini %100 doğrulukla tahmin etmektedir. Ayrıca, en iyi üç modelin (DSA-1, DSA-2 ve DSA-3) geçerliliğini artırmak için 10-fold çapraz doğrulama yöntemi ile eğitim ve test işlemi tekrar gerçekleştirilmiştir. Ortalama çapraz doğrulama accuracy değerleri sırasıyla %85.71, % 85.71 ve % 87.14 olarak hesaplanmıştır. Mesleki terapistler, geliştirilen DSA modellerini öz bakım problemlerini teşhis etmede doğrulayıcı bir araç olarak kullanılabilirler.

**Anahtar Kelimeler:** Makine öğrenmesi, derin sinir ağı, fiziksel ve motor engellilik, öz bakım.

## Self-Care Problems Classification of Children with Physical and Motor Disability by Deep Neural Networks

### ABSTRACT

Physical and motor disability is a disorder that greatly limits some of the individual main life activities. These disorders affect children in many countries of the world. In addition, it is a difficult process for physically and motorly disabled individuals to be classified by doctors with appropriate occupational treatments. Because, there are many variables that must be considered. The aim of this study is to classify the self-care skill problems of children with physical and motor disabilities by the minimal error using deep neural networks (DNN). For this purpose, DNN models with different parameters were created. The number of hidden layers, the number of neurons in the hidden layers, the activation function, the optimization algorithm, the loss function and the epoch value are taken into consideration in the creation of the models. The DSA models were trained and tested with the SCADI (Self-Care Activities Dataset based on ICFCY) data set. The classification performance of the models was demonstrated by using the F-1 score, precision (P), recall (R) and accuracy (ACC) metrics. Details of the 8 models with the best grading performance are presented. According to the findings, the best classification performance was obtained in the DSA-1 model using Adadelta optimization algorithm, Elu activation function and Categorical crossentropy loss function. The P, R, ACC and F1 scores of this model are 1. In other words, this model predicts the self-care skills problems of physical and motor disability children with 100% accuracy. In addition, in order to increase the validity of the three best models (DSA-1, DSA-2 and DSA-3), the training and testing process was performed with 10-fold cross-validation method. Mean cross validation accuracy values were calculated as 85.71%, 85.71% and 87.14% respectively. Occupational therapists can be used developed DSA models as a validating tool for diagnosing self-care problems.

**Keywords:** Machine learning, deep neural network, physical and motor disability, self-care.

### 1. GİRİŞ (INTRODUCTION)

Engellilik cinsiyete, yaşa, diğer kültürel ve sosyal faktörlere bağlı olarak doğuştan gelen rolleri

engelleyebilen veya azaltabilen bozuklukların sonucudur [1]. Bunun yanı sıra, engellilik, dünya sağlık örgütü tarafından bozukluklar, aktivite kısıtlamaları ve katılım sınırlamaları için bir terim olarak kavramsallaştırılmıştır [2]. Fiziksel engellilik bir veya daha fazla ana yaşam aktivitesini büyük ölçüde sınırlayan bir bozukluk

\*Sorumlu Yazar (Corresponding Author)  
e-posta : akaraci@kastamonu.edu.tr

olarak tanımlanmaktadır. Fiziksel ve motor engellilik bireysel aktiviteleri kısıtlayan bozukluklardır [1, 3]. Motor engellilik, dünyanın birçok ülkesinde çocukların büyük bir engelidir [4]. Motor engeli olan kişiler ince motor kontrolü, güç ve hareket aralığı konusunda sınırlamalar yaşarlar. Bu eksiklikler, giyinme, saç taraması ve banyo gibi günlük işleri bağımsız olarak gerçekleştirme yeteneklerini önemli ölçüde sınırlandırabilir [5].

Çocukların gerçek problemlerinin doktorlar tarafından uygun mesleki tedavi ile sınıflandırılması zor bir işdir. Çünkü değerlendirilmesi gereken birçok öznelik vardır [6]. Çocuklar ve gençler için uluslararası işlevsellik, engellilik ve sağlık sınıflandırma sistemi (International Classification of Functioning, Disability, and Health for Children and Youth (ICF-CY)) 2001 yılında dünya sağlık birliği tarafından kabul edilmiş ve yaygın olarak kullanılmaya başlanmıştır [7, 8]. ICF-CY sisteminde öz bakım; beslenme, içme, giyinme, tuvalete gitme, yıkanma, vücut bölgeleri için bakım, sağlığına dikkat etme, güvenliğine dikkat etme gibi aktiviteleri ifade etmektedir [9].

Literatürde öz bakım problemlerini makine öğrenmesi yöntemleri ile sınıflandıran çalışmalar sınırlı sayıdadır. Zarchi ve arkadaşları [1] yapay sinir ağı (YSA) ile öz bakım problemlerini %83.1 doğruluk oranı ile sınıflandırmışlardır. Le ve Baik [10] öz bakım problemlerini aşırı gradyan artırma (extreme gradient boosting) algoritmasını kullanarak %85.4 doğruluk oranında sınıflandırmışlardır. Islam ve ark. [11] destek vektör makinesi algoritması ile öz bakım problemlerini %84.29 doğruluk oranıyla sınıflandırmışlardır. Choudhury [12] öz bakım problemlerini sınıflandırmak için farklı makine öğrenmesi yöntemleri geliştirmiş, en yüksek sınıflandırma performansını % 83.28 doğruluk oranı ile Random Forest makine öğrenmesi yöntemi ile elde etmiştir. Öznitelik seçimi yaptığında ise bu oran %84.75'e yükselmiştir. Putatunda [13] ise derin öğrenme kullanarak öz bakım problemlerini %84.29 doğruluk oranında sınıflandırmıştır. Putatunda'nın yapmış olduğu çalışma bu çalışmayla doğrudan ilişkilidir. Ancak bu çalışmanın ana problemi gerek Putatunda'nın geliştirmiş olduğu, gerekse literatürdeki diğer çalışmalarda geliştirilen modellerden daha yüksek sınıflandırma performansına sahip DSA modellerini geliştirmek ve bu modelleri önemli parametreleri ile ayrıntılı olarak ortaya koymaktır. Makine öğrenmesi yöntemlerinde öğrenme parametreleri iyi değerlendirilir ve optimum şekilde ayarlanırsa sınıflandırma ve tahmin performansı artmaktadır. Bu nedenle diğer çalışmalarda elde edilen sınıflandırma performansından daha yüksek performans sağlayan modeller elde etmek mümkündür. Böylece öz bakım problemlerinin daha az hata ile sınıflandırılması sağlanabilir.

Öz bakım problemlerinin sınıflandırılması ile ilgili olmamakla birlikte öğrenme engeli ya da güçlüğü makine öğrenmesi ile sınıflandıran bir takım çalışmalar da mevcuttur. Bu çalışmaların hiç birinde SCADI (Self-Care Activities Dataset based on ICF-CY) veri seti

kullanılmamaktadır. Wu ve ark. [14] öğrenme güçlüğü problemini belirlemek ve teşhis etmek için yapay sinir ağları ve destek vektör makinelerini kullanarak sırasıyla %65.6 ve %76 doğruluk oranıyla sınıflandırmışlardır. David ve Balakrishnan [15] ise okul çağındaki çocukların öğrenme güçlüklerini karar ağaçları ve destek vektör makinelerini kullanarak sırasıyla %97.47 ve %97.86 doğruluk oranlarında tahmin etmişlerdir. Bunun yanı sıra Muangnak ve ark. [16] öğrenme engelli çocukları naive bayes ve karar ağacı öğrenme algoritmaları ile sırasıyla %94.23 ve %96.15 doğruluk oranlarında sınıflandırmışlardır.

Derin öğrenme, makine öğrenmesi olarak adlandırılan yapay zekanın alt alanıdır [17]. Derin öğrenmeyi kullanarak derin mimarilere sahip derin sinir ağları (DSA) kurulabilir. Derin mimariden dolayı, DSA çoklu doğrusal olmayan dönüşüm ve yaklaşık karmaşık doğrusal fonksiyonlar vasıtasıyla ham veride bulunan temsili bilgileri uyarlamalı olarak küçük bir hata ile yakalayabilir [18]. Derin sinir ağlarının performansı birçok parametreye bağlıdır [17]. Bu nedenle oluşturulan DSA modelinin tüm parametrelerinin göz önünde bulundurularak modelin eğitilmesi önem arz etmektedir.

Bu çalışmada, fiziksel ve motor engelli çocukların öz bakım beceri problemleri DSA kullanılarak sınıflandırılmıştır. Zarchi ve arkadaşları [1] tarafından üretilen SCADI veri seti kullanılmıştır. Çalışmanın geriye kalan kısmı şu şekilde düzenlenmiştir. Bölüm 2'de çalışmada kullanılan veri setinin ve DSA modelinin ayrıntıları açıklanmıştır. Modelden elde edilen bulgular ve sonuçlar Bölüm 3'de irdelenmektedir. Bölüm 4'de ise çalışmadan elde edilen önemli sonuçlar özetlenmektedir.

## 2. MATERYAL VE METOD (MATERIAL and METHOD)

### 2.1. Veri Seti (Data Set)

Bu çalışmada, fiziksel ve motor engelli çocukların öz bakım beceri problemlerini derin sinir ağı ile sınıflandırmak amacıyla Zarchi ve ark. [1] tarafından üretilen SCADI veri seti kullanılmıştır. Zarchi ve ark. [1] öz bakım aktiviteleri ile ilgili standart bir veri setinin bulunmadığını vurgulamışlar ve SCADI adını verdikleri yeni bir veri seti ortaya koymuşlardır. SCADI, fiziksel ve motor engelli çocukların öz bakım faaliyetleri ile ilgili olarak mesleki terapistler ile işbirliği içinde toplanan ve yayınlanan ilk standart veri setidir [1]. Bu veri setinden 29 aktiviteye göre fiziksel ve motor engelli çocukların öznelikleri belirlenmiştir. Ayrıca çocukların bu 29 aktiviteyi gerçekleştirememeye yani engel durumları 7 farklı kategoride (engel yok, hafif engelli, orta engelli, tamamen engelli vb.) değerlendirilmiştir. Sonuç olarak 29 aktivitenin 7 farklı durumu göz önüne alınarak 203 farklı öznelik ortaya çıkarılmıştır. Bu 203 farklı öznelik 0 ve 1 şeklinde sayısal verilerden oluşmaktadır. Bu özneliklere cinsiyet ve yaş öznelikleri de eklenerek her çocuk için toplam 205 öznelik oluşturulmuştur. Cinsiyet özneliği 0 (erkek) ve 1 (kız) şeklinde kodlanmıştır. Yaş özneliği ise [6-18] aralığındaki

sayısal verilerden oluşmaktadır. Sonuç olarak veri seti 70 çocuğa ait 205 öznitelik şeklinde sunulmuştur. Ayrıca bu 70 çocuğa ait 205 öznitelik ayrı, ayrı değerlendirilerek çocuklarda bulunan öz bakım problemleri 7 kategori halinde veri setinde belirlenmiştir. Veri setindeki bu 7 adet öz bakım problemleri kategorileri ve örnek aktiviteler Çizelge 1’de verilmektedir [1].

setinde C-1’den C-7’ye öz bakım problemlerinin bulunduğu son sütundaki değerler [0-6] kapalı aralığında kodlanmıştır. Oluşturulan DSA modeli Şekil 1’de gösterilmektedir.


**Çizelge 1.** Öz bakım problemi kategorileri ve örnek aktiviteler (Self-care problem categories and sample activities)

Problem Kodu	Öz bakım problemi	Örnek aktivite
C-1	• Vücut bölgeleri için bakım problemi	• Cilt bakımı • Diş bakımı • Saç bakımı • Burun bakımı vs.
C-2	• Tuvalet problemi	• İdrarın uygun şekilde yapma • Defekasyonu uygun şekilde yapmak • İdrara çıkma ihtiyacını belirtme vs.
C-3	• Giyinme problemi	• Giysi giyme • Giysi çıkarma • Ayakkabı çıkarma vs.
C-4	• Yıkama, Vücut bölgeleri için bakım ve Giyinme problemi	• Vücut bölümlerini yıkama • Tüm vücudu yıkama • Kendi kendine kurulanma • C-1 ve C-3’teki aktiviteler
C-5	• Yıkama, Vücut bölgeleri için bakım, Tuvalet ve Giyinme problemi	• C-1, C-2, C-3 ve C-4’teki aktiviteler.
C-6	• Beslenme, İçme, Yıkama, Vücut bölgeleri için bakım, Tuvalet, Giyinme, • Sağlığına dikkat etme ve Güvenliğine dikkat etme problemi	• Yeme ihtiyacını belirtme • Uygun şekilde yemek yeme • İçme ihtiyacını belirtme • Uyuşturucu veya alkolün kötüye kullanılması riskinden kaçınma • İlaç tedavisini uygulama ve sağlık tavsiyelerini izleme
C-7	• Problem yok	

## 2.2. Derin Sinir Ağı Modeli (Deep Neural Network Model)

Bu çalışmada fiziksel ve motor engelli çocukların öz bakım problemlerini tahmin etmek için Python dilinin Keras Kütüphanesi kullanılarak DSA modeli oluşturulmuştur. DSA modeli oluşturulurken öncelikle gizli katmanların ve bu gizli katmanlardaki nöron sayıları belirlenmiştir.

YSA’larda gizli katmanlardaki nöronların sayısı, sınıflandırma doğruluğunda hayati bir rol oynamaktadır [1]. Benzer durum DSA’lar için de geçerlidir. Gizli katman ve katmanlardaki nöronların sayısı belirlenirken farklı modeller denenmiştir. Bu denemeler sonucunda 16, 32 ve 36 nörona sahip 3 gizli katmanlı model oluşturulmuştur. DSA modelinin giriş katmanı 205 nörondan oluşmaktadır. Bu nöronlardan ilk ikisi yaş ve cinsiyettir. Geriye kalan 203 nöron ise veri seti başlığında açıklanan fiziksel ve motor engelli çocukların öz bakım öznitelikleridir. Bunun yanı sıra DSA modelinin çıkışı 7 nörondan oluşmaktadır. Her bir nöron bir öz bakım problemini temsil etmektedir. Yani DSA çıkışı 7 öz bakım probleminden biri olmaktadır. Bunun için veri



**Şekil 1.** DSA modeli (DNN model)

### 2.2.1. DSA modellerinin eğitilmesi (Training of DNN models)

Modellerin eğitilmesinde iki farklı yöntem kullanılmıştır. Birinci yöntemde veri seti, %70 ve %30 oranlarında rastgele bölünmüştür. Verilerin % 70’i (49 veri) DSA

modelini eğitmek için kullanılırken %30'u (21 veri) modeli test etmek için kullanılmıştır. Ayrıca test işleminin geçerliliğini ve güvenilirliğini artırmak amacıyla 2-10 arasındaki değerler için veri seti k-fold yöntemi ile eşit parçalara bölünmüştür. K-fold yönteminden elde edilen test verileri ile en iyi DSA (DSA-1) modeli test edilmiştir. Yani test işlemi 54 farklı test verisiyle gerçekleştirilmiştir. İkinci yöntemde ise, birinci yöntemde elde edilen en iyi üç DSA modeli üzerinde k-fold çapraz doğrulama yöntemi ile eğitim ve test işlemi gerçekleştirilmiştir. K-fold yönteminde veri seti k eşit parçaya bölünmektedir. Bir parça test, geriye kalan k-1 parça ise eğitim için kullanılmaktadır. Bu işlem k defa yinelenmektedir [13]. K-fold çapraz doğrulama yönteminde modellerin performansını belirlemek için her yinelemede elde edilen acc değerlerinin ortalaması kullanılmıştır.

DSA modelinin eğitiminde 4 farklı parametrenin belirlenmesi önemlidir. Bu parametreler aktivasyon fonksiyonu, optimizasyon algoritması, kayıp fonksiyonu ve epoch'dur. DSA modeli muhtemel aktivasyon fonksiyonlarının, optimizasyon algoritmalarının ve kayıp fonksiyonlarının farklı eşleştirmeleri kullanılarak eğitilmiştir. Bunun yanı sıra farklı epoch değerleri denenerek en iyi sınıflandırma performansını veren parametreler tespit edilmeye çalışılmıştır.

DSA modelinin gerek oluşturulması gerekse eğitilmesinde kullanılan parametreler Çizelge 2'de gösterilmektedir.

**Çizelge 2.** DSA modelinin parametreleri (Parameters of the DSA model)

Parametreler	Değerler
Giriş katmanı nöron sayısı	205
Gizli katman sayısı	3
Gizli katman-1'deki nöron sayısı	16
Gizli katman-2'deki nöron sayısı	32
Gizli katman-3'deki nöron sayısı	36
Çıkış katmanındaki nöron sayısı	1
Gizli katmanların aktivasyon fonksiyonları	elu, tanh, linear, softsign, relu, softplus, sigmoid ve hard sigmoid
Çıkış katmanı aktivasyon fonksiyonu	softmax
Öğrenme Döngüsü	50, 150, 200, 300 Epochs
Kayıp Fonksiyonları	Categorical crossentropy, Mean absolute error, Mean square error
Optimizasyonlar (Öğrenme Algoritmaları)	Adam, Adadelta, Sgd, RMSprop, Adamax ve Nadam

Sinir ağlarının önemli bir bileşeni aktivasyon fonksiyonudur [19]. Aktivasyon fonksiyonu, biyolojik nöronun yanıt durumunu simüle etmek ve nöron çıkışını elde etmek için kullanılır [20]. DSA'ların çıkış katmanında softmax aktivasyon fonksiyonunu kullanmak birçok görevde etkili olmaktadır [19]. Bu çalışmada çıkış katmanı aktivasyon fonksiyonu olarak softmax kullanılmıştır. Çünkü diğer aktivasyon fonksiyonları çıkış katmanında kullanıldığında DSA sınıflandırma performansı düşük çıkmıştır. Bunun yanı sıra DSA'nın eğitimi sırasında gizli katmanlarda elu, tanh, linear, softsign, relu, softplus, sigmoid ve hard sigmoid aktivasyon fonksiyonları denenmiştir.

DSA eğitiminin temel bileşeni optimizasyon algoritmasıdır. Optimizasyon algoritması derin bir modelin milyonlarca hatta milyarlarca parametresinin nasıl güncellendiğini tanımlar [21]. Öğrenme algoritmasının seçimi aktivasyon fonksiyonunun seçiminden daha önemli olabilir [22]. Bu nedenle DSA'nın eğitiminde Adam, Adadelta, Sgd, RMSprop, Adamax ve Nadam optimizasyon algoritmaları denenmiş ve en iyi performansı veren optimizasyon algoritmalarına ait sonuçlar bir sonraki bölümde sunulmuştur.

Kayıp fonksiyonu başarılı bir şekilde tasarlanmış bir ağ modelinin başarımını belirlemektedir. Bu fonksiyonun değerinin çeşitli optimizasyon teknikleriyle 0'a yaklaşması istenmektedir [23]. DSA'nın eğitiminde farklı kayıp fonksiyonlarının kullanılması en iyi sınıflandırma performansına ulaşılması açısından önemlidir. Bu nedenle DSA eğitiminde Categorical crossentropy, Mean absolute error, Mean square error kayıp fonksiyonları kullanılmıştır.

Modellerin sınıflandırma performanslarını karşılaştırmak için F-1 puanı, precision (P), recall (sensitivity) (R) ve accuracy (ACC) metrikleri kullanılmıştır. Ancak hangi modelin daha iyi sınıflandırma performansına sahip olduğuna karar vermek için F-1 puanı öncelikli olarak göz önünde bulundurulmuştur. Çünkü precision ve recall metrikleri uyumlu değilse accuracy metriği o kadar çok anlamlı değildir [24]. Bunun yanı sıra precision ve recall sınıflandırma performansını değerlendirmek için yaygın olarak kullanılmaktadır [25].

F-1 puanı, precision ve recall metriklerinin harmonic ortalamasıdır ve eşitlik 1'deki gibi hesaplanır. F-1 puanının 1'e yakın olması modelin sınıflandırma performansının yüksek olduğunu gösterir [24, 26, 27].

$$F = \frac{2PR}{P+R} \quad (1)$$

Recall ve Precision metrikleri bir örnekle açıklanabilir. Örneğin, gerçek verilerin 15 adeti öz bakım problemi-2'ye ait olsun. Makine öğrenmesi modeli 6 adet veriyi öz bakım problemi-2 olarak sınıflandırır ve bunlardan 4 tanesi gerçekten öz bakım problemi-2 (true positive), geriye kalanı diğer öz bakım problemlerine (false

positive) ait olursa  $precision=4/6$ ,  $recall=4/15$  olarak hesaplanabilir.

P ve R değeri eşitlik 2'deki gibi ifade edilmektedir [28]. P, pozitif belirleme ya da tahminlerin ne kadar doğru olduğunu, R ise gerçek pozitiflerin ne kadar doğru belirlendiğini ya da tahmin edildiğini ortaya koyar [29]. Yani hem P hem de R parametresinin 1'e yaklaşması modelin sınıflandırma performansını arttırdığını göstermektedir. P değerinin yüksek R değerinin düşük olması o sınıfa ait olmaması gereken (false positive) ve o sınıfa ait olması gereken tahmin sayısının (true positive) düşük olduğunu gösterir. Yani diğer sınıfların tahmini bu sınıfa karışmamıştır ancak bu sınıf için olması gereken gerçek tahmin sayısı düşüktür. Bunun tam tersi düşünüldüğünde ise diğer sınıf tahminlerinin bu sınıfı tahmin ettiği ve sınıf için olması gereken gerçek tahmin sayısının yüksek olduğu söylenebilir.

$$P = \frac{TP}{TP+FP} \quad R = \frac{TP}{TP+FN} \quad (2)$$

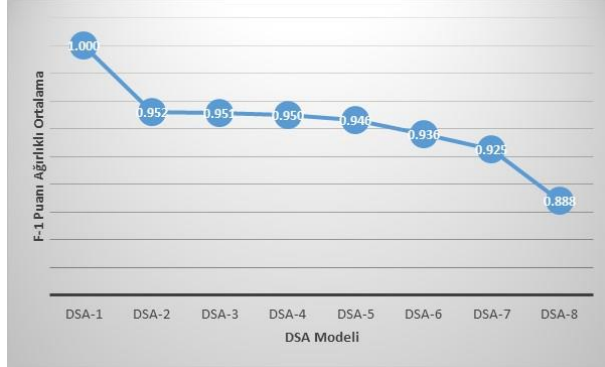
### 3. BULGULAR VE TARTIŞMA (RESULT AND DISCUSSION)

Bu çalışmada, veri seti bölümünde açıklanan 205 öznitelige göre fiziksel ve motor engelli çocukların öz bakım problemlerini sınıflandırmak için farklı DSA modelleri oluşturulmuştur. Bu modellerden en iyi 8 model bu bölümde sunulmuş ve en iyi üç model ise irdelenmiştir. Farklı aktivasyon fonksiyonları, optimizasyon algoritmaları, kayıp fonksiyonları ve epoch değerleri kullanılarak eğitilen DSA modellerinin test verileri için sınıflandırma performansları Çizelge 3'de ve Şekil 2'de gösterilmektedir. Bu çizelgede modellerin genel performansını değerlendirmek amacıyla P, R ve F1 puanlarının ağırlıklı ortalamaları ve ACC değerleri verilmektedir. Şekil 2'de ise Çizelge 1'deki modellere ait en yüksek F-1 puanı ağırlıklı ortalamaları karşılaştırmalı olarak gösterilmektedir. Çizelge 3'de de görüldüğü gibi P ve R parametrelerinin ağırlıklı ortalamaları ve ACC değerleri çok ayırt edici değildir. Modellerin genel performansını belirlemek için bu performans

**Çizelge 3.** DSA modellerinin parametreleri ve sınıflandırma performansları (Parameters of DNN models and classification performances)

Model Kodu	Optimizasyon Algoritması (Optimizers)	Aktivasyon Fonksiyonu (Activation)	Kayıp Fonksiyonu (Loss)	Precision(P) Ağırlıklı Ortalama	Recall (R) Ağırlıklı Ortalama	F1 Puanı Ağırlıklı Ortalama	Accuracy (ACC)	Epochs
DSA-1	Adadelta	Elu	Categorical crossentropy	1	1	1	1	300
DSA-2	RMSprop	Tanh	Mean absolute error	0.96	0.95	0.952	0.95	300
DSA-3	Adam	Linear	Categorical crossentropy	0.96	0.95	0.951	0.95	150
	RMSprop	Elu	Mean square error	0.96	0.95	0.951	0.95	50
	Adamax	Linear	Mean absolute error	0.96	0.95	0.951	0.95	300
	Adamax	Softsign	Mean absolute error	0.96	0.95	0.951	0.95	50
	Adamax	Relu	Mean square error	0.96	0.95	0.951	0.95	300
	RMSprop	Softplus	Categorical crossentropy	0.96	0.95	0.951	0.95	150
DSA-4	Adamax	Tanh	Categorical crossentropy	0.96	0.95	0.950	0.95	50
DSA-5	Adamax	Linear	Mean square error	1	0.90	0.946	0.90	50
	Adadelta	Sigmoid	Categorical crossentropy	1	0.90	0.946	0.90	150
	Adadelta	Hard Sigmoid	Categorical crossentropy	1	0.90	0.946	0.90	300
DSA-6	Adam	Softsign	Mean square error	1	0.90	0.936	0.90	50
DSA-7	Adamax	Softplus	Mean square error	0.96	0.90	0.925	0.90	200
	RMSprop	Hard Sigmoid	Mean square error	0.96	0.90	0.925	0.90	300
DSA-8	RMSprop	Sigmoid	Mean square error	0.95	0.86	0.888	0.85	200

ölçütlerinden en ayırt edicisi F1 puanıdır. Bu nedenle modellerin genelini sınıflandırma performansını test etmek için F1 puanı kullanılmıştır. Ancak, modellerin öz bakım problemlerine göre sınıflandırma performansları ayrı, ayrı değerlendirilirken P, R, F1 puanları ve karmaşıklık matrisleri kullanılmış ve buna göre irdelenmiştir.



Şekil 2. DSA modelleri ve F1 puanı ağırlıklı ortalamaları (DNN models and F1 points weighted average)

Çizelge 3 ve Şekil 2'deki F1 puanlarının ağırlıklı ortalamasına göre en iyi sınıflandırma performansı DSA-1 modeline aittir. DSA-1 modelinin test verileri için karmaşıklık matrisi ve her sınıf için P, R, ve F1 puanı değerleri Çizelge 4'de verilmektedir.

Çizelge 4. DSA-1 modelinin test verileri için karmaşıklık matrisi ve performans metrikleri (The complexity matrix and performance metrics of the DSA-1 model for test data)

Gerçek Değerler	Tahmin Değerleri							F1 Puanı Ağırlıklı Ortalama
	Problem Kodu	C-2	C-4	C-6	C-7	P	R	
C-2	4	0	0	0	1	1	1	1
C-4	0	4	0	0	1	1	1	
C-6	0	0	8	0	1	1	1	
C-7	0	0	0	5	1	1	1	

Çizelge 4'de de görüldüğü gibi Adamax optimizasyon algoritmasını, Elu aktivasyon fonksiyonunu ve Categorical crossentropy kayıp fonksiyonunu kullanan DSA-1 modeli hatasız olarak test verilerini sınıflandırmıştır. Her bir öz bakım problemi için performans metriklerine bakıldığında bütün problemlere ait P, R ve F1 puanları 1'dir. Bu da modelin sınıflandırma performansının kusursuz olduğunu ve iyi eğitildiğini göstermektedir.

DSA-1 modeli en iyi sınıflandırma performansına sahip olduğundan dolayı bu modelin eğitim verilerini sınıflandırma performansı da önemlidir. Bu nedenle bu modele eğitim verileri giriş olarak verilmiş ve bu verileri sınıflandırma performansı Çizelge 5'de gösterilmiştir.

Çizelge 5'de de görüldüğü gibi DSA-1 modelinin eğitim verileri için sınıflandırma performansı test verilerinde olduğu gibi % 100'dür ve üst seviyededir.

Çizelge 5. DSA-1 modelinin eğitim verileri için karmaşıklık matrisi ve performans metrikleri (The complexity matrix and performance metrics of the DSA-1 model for training data)

Gerçek Değerler	Tahmin Değerleri							P	R	F1 Puanı	F1 Puanı Ağırlıklı Ortalama
	Problem Kodu	C-1	C-2	C-3	C-4	C-5	C-6				
C-1	2	0	0	0	0	0	0	1	1	1	1
C-2	0	3	0	0	0	0	0	1	1	1	
C-3	0	0	1	0	0	0	0	1	1	1	
C-4	0	0	0	8	0	0	0	1	1	1	
C-5	0	0	0	0	3	0	0	1	1	1	
C-6	0	0	0	0	0	21	0	1	1	1	
C-7	0	0	0	0	0	0	11	1	1	1	

Ayrıca en iyi model olan DSA-1 modelinin performansını farklı test verileri ile doğrulamak amacıyla veri seti rastgele olarak sırasıyla [2-10] aralığında eşit parçalara bölünmüştür (K-Fold). Daha sonra her parça için model performans metrikleri hesaplanmıştır. Elde edilen sonuçlara göre modelin sınıflandırma performansının değişmediği tespit edilmiştir (P=1, R=1, F1 puanı=1). Ayrıca DSA-1 modelinin %30'luk test veri setinde bulunmayan C-1, C-3 ve C-5 öz bakım problemlerini de doğru sınıflandırdığı tespit edilmiştir. Tüm veri setlerinden elde edilen karmaşıklık matrislerinin ve performans metriklerinin çalışma kapsamında ayrıntılı olarak verilmesi mümkün olmadığı için sadece üç parçaya bölünen (3-Fold) veri setleri için DSA-1 modelinin sınıflandırma performansı Çizelge 6'da gösterilmektedir.

Çizelge 6. DSA-1 modelinin 3-fold ile bölünen veri setleri için sınıflandırma performansı (Classification performance for data sets divided by 3-fold of the DSA-1 model)

Gerçek Değerler	Tahmin Değerleri							P	R	F1 Puanı	F1 Puanı Ağırlıklı Ortalama
	Problem Kodu	C-1	C-2	C-3	C-4	C-5	C-6				
C-1	1	0	0	0	0	0	0	1	1	1	1
C-2	0	2	0	0	0	0	0	1	1	1	
C-3	0	0	1	0	0	0	0	1	1	1	
C-4	0	0	0	4	0	0	0	1	1	1	
C-5	0	0	0	0	1	0	0	1	1	1	
C-6	0	0	0	0	0	10	0	1	1	1	
C-7	0	0	0	0	0	0	4	1	1	1	

Gerçek Değerler	Tahmin Değerleri							P	R	F1 Puanı	F1 Puanı Ağırlıklı Ortalama
	Problem Kodu	C-1	C-2	C-4	C-5	C-6	C-7				
C-1	1	0	0	0	0	0	0	1	1	1	1
C-2	0	1	0	0	0	0	0	1	1	1	
C-4	0	0	4	0	0	0	0	1	1	1	
C-5	0	0	0	2	0	0	0	1	1	1	
C-6	0	0	0	0	11	0	0	1	1	1	
C-7	0	0	0	0	0	5	1	1	1	1	

Gerçek Değerler	Tahmin Değerleri							P	R	F1 Puanı	F1 Puanı Ağırlıklı Ortalama
	Problem Kodu	C-2	C-4	C-6	C-7						
C-2	4	0	0	0	1	1	1	1	1	1	
C-4	0	4	0	0	1	1	1	1	1		
C-6	0	0	8	0	1	1	1	1	1		
C-7	0	0	0	7	1	1	1	1	1		

İkinci en iyi sınıflandırma performansı DSA-2 modelinden elde edilmiştir. Bu modelde RMSprop optimizasyon algoritması, Tanh aktivasyon fonksiyonu ve Mean absolute error kayıp fonksiyonu kullanılmıştır. Bu modele ait karmaşıklık matrisi ve her sınıf için P, R, ve F1 puanı değerleri Çizelge 7’de verilmektedir.

**Çizelge 7.** DSA-2 modelinin test verileri için karmaşıklık matrisi ve performans metrikleri (The complexity matrix and performance metrics of the DSA-2 model for test data)

Gerçek Değerler	Tahmin Değerleri				P	R	F1 Puanı	F1 Puanı Ağırlıklı Ortalama
	Problem Kodu	C-2	C-4	C-6				
C-2	4	0	0	0	1	1	1	0.952
C-4	0	4	0	0	0.80	1	0.89	
C-6	0	0	8	0	1	1	1	
C-7	0	1	0	4	1	0.80	0.89	

Çizelge 7’de de görüldüğü gibi C-4’ün P katsayısı ve C-7’nin R katsayısı 0.80 olarak hesaplanmıştır. P ve R parametresine bağlı olan F1 puanı ise C-4 ve C-7 için 0.89 olarak hesaplanmıştır. C-4 için P katsayısının düşük olması, C-4 olarak sınıflandırılmaması gereken bazı örneklerin olduğunu göstermektedir. Ayrıca C-7 için R katsayısının düşük olması C-7 olarak sınıflandırılması gereken tüm örneklerin doğru bir şekilde sınıflandırılmadığı anlamına gelmektedir. Bu durum C-4 ve C-7’nin F1 puanlarından da görülmektedir. Doğru sınıflandırılmayan ya da sapma gösteren örneklerin sayısını belirlemek için karmaşıklık matrisine bakılmalıdır. Bu matrise göre C-7 olarak sınıflandırılması gereken bir örnek C-4 olarak sınıflandırılmıştır. Yani DSA-2 modelinde bir örnek hatalı sonuç vermiştir. Modele ait F1 puanlarının ağırlıklı ortalaması ise 0.952’dir. Bu açıdan bakıldığında bu modelin de sınıflandırma performansının yüksek olduğu söylenebilir.

Üçüncü en iyi performans ise DSA-3 modellerinde elde edilmiştir. DSA-3 modelleri optimizasyon algoritması, aktivasyon fonksiyonu ve kayıp fonksiyonu eşleşmeleri birbirinden farklı olan 8 modeli kapsamaktadır. Bu modellerin optimizasyon algoritması, aktivasyon fonksiyonu ve kayıp fonksiyonu kombinasyonları bir birinden farklı olmasına karşın sınıflandırma performansları benzerdir. Bu modellerin tümü için benzer olan karmaşıklık matrisi ve her sınıf için P, R, ve F1 puanı değerleri Çizelge 8’de verilmektedir.

Çizelge 8’e göre C-2 sınıfının R değeri 0.75, C-7 sınıfının P değeri ise 0.83 olarak hesaplanmıştır. Yani bu değerlerden de anlaşılacağı üzere diğer sınıflardan C-7’ye sapma olmuş ve C-2 için de tüm veriler doğru sınıflandırılmamıştır. Doğru sınıflandırılmayan

verilerin sayısı karmaşıklık matrisinde açıkça görülmektedir. C-2 sınıfına ait bir örnek C-7 olarak sınıflandırılmıştır. Modellerin geneline ait F-1 puanı ağırlıklı ortalamaları ise 0.951 olarak hesaplanmıştır. Bu değerlere bakıldığında DSA-3 modellerinin sınıflandırma performanslarının yeterli düzeyde olduğu söylenebilir.

**Çizelge 8.** DSA-3 modellerinin test verileri için karmaşıklık matrisi ve performans metrikleri (The complexity matrix and performance metrics of the DSA-3 model for test data)

Gerçek Değerler	Tahmin Değerleri				P	R	F1 Puanı	F1 Puanı Ağırlıklı Ortalama
	Problem Kodu	C-2	C-4	C-6				
C-2	3	0	0	1	1	0.75	0.86	0.951
C-4	0	4	0	0	1	1	1	
C-6	0	0	8	0	1	1	1	
C-7	0	0	0	5	0.83	1	0.91	

Bunun yanı sıra modellerin geçerliliğini artırmak için en iyi üç model üzerinde (DSA-1, DSA-2 ve DSA-3) 10-fold çapraz doğrulama yöntemi ile eğitim ve test işlemi gerçekleştirilmiştir. Ortalama çapraz doğrulama ACC değerleri sırasıyla %85.71, % 85.71 ve % 87.14 olarak hesaplanmıştır. Modellerin her fold’da elde edilen ACC değerleri Çizelge 9’da gösterilmektedir. Bu değerler Putatunda [13] tarafından SCADI veri seti üzerinde geliştirilen ve 10-fold çapraz doğrulama uygulanan derin öğrenme modelinin ortalama çapraz doğrulama ACC değerinden (%84.29) daha yüksektir. Yine, Islam ve arkadaşları [11] tarafından SCADI veri seti üzerinde yapılan ve 5-fold çapraz doğrulama uygulanan destek vektör makinesi modelinin ortalama çapraz doğrulama ACC değerinden (%84.29) daha yüksektir. Benzer şekilde, Le ve Baik [10] tarafından SCADI veri seti üzerinde aşırı gradyan artırma (extreme gradient boosting) algoritması kullanılarak geliştirilen ve %85.4 doğruluk oranında sınıflandırma performansına sahip olan modelden daha yüksek sınıflandırma performansına sahiptir. Bunun yanı sıra, Choudhury [12] tarafından SCADI veri seti üzerinde geliştirilen ve 10-fold çapraz doğrulama uygulanan Randoom Forest modelinin çapraz doğrulama ACC değerinden (%84.75) daha yüksektir. Ayrıca, bu çalışmada kullanılan veri setini ortaya koyan Zarchi ve ark. [1] geliştirdikleri YSA modelinin ortalama çapraz doğrulama ACC değerinden de (%83.1) daha yüksek bir değere sahiptir. Yani, DSA-1, DSA-2 ve DSA-3 modelleri yapılan literatür taramasına göre SCADI veri seti üzerinde yapılan diğer çalışmalara göre öz bakım problemlerini daha iyi sınıflandırmaktadır.

**Çizelge 9.** Modellerin 10-fold accuracy değerleri (10-fold accuracy values of models)

Model	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	Fold 6	Fold 7	Fold 8	Fold 9	Fold 10	Ortalama
DSA-1	85.71	100	100	85.71	85.71	71.43	71.43	100	85.71	71.43	85.71
DSA-2	85.71	100	100	100	85.71	71.43	71.43	100	85.71	57.14	85.71
DSA-3	85.71	100	100	100	85.71	71.43	71.43	100	85.71	71.43	87.14



#### 4. SONUÇ (CONCLUSION)

Bu çalışma kapsamında geliştirilen DSA-1 modeli fiziksel ve motor engelli çocukların öz bakım problemlerini hatasız bir şekilde tahmin ederken DSA-2 ve DSA-3 modelleri çok küçük bir hata ile tahmin etmektedir. Bu nedenle geliştirilen makine öğrenmesi modellerinin öz bakım problemlerini tahmin etmede etkili olduğu söylenebilir. Gerek veri setinin %70 ve %30 bölünmesiyle elde edilen modeller gerekse 10-fold çapraz doğrulama yöntemi ile geliştirilen modeller yapılan literatür taramasına göre SCADI veri seti üzerinde yapılan diğer çalışmalara göre öz bakım problemlerini daha iyi sınıflandırmaktadır. Geliştirilen DSA modelleri mesleki terapistlerin öz bakım sorunlarını teşhis ve tedavi etmelerine yardımcı olabilir. Özellikle teşhiste doğrulayıcı bir araç olarak kullanılabilir. Fiziksel ve motor engelli çocukların öz bakım problemlerinin teşhisinde DSA'ların kullanılması etkili bir yöntemdir.

#### KAYNAKLAR (REFERENCES)

- [1] Zarchi M.S., Bushehri S.M.M. F. and Dehghanizadeh M., "SCADI: A standard dataset for self-care problems classification of children with physical and motor disability", *International Journal of Medical Informatics*, 114: 81-87, (2018).
- [2] Lucas-Carrasco R., Eser E., Hao Y., McPherson K.M., Green A., Kullmann L., Group T.W.D., "The quality of care and support (QOCS) for people with disability scale: development and psychometric properties", *Res. Dev. Disabil.*, 32(3):1212-1225, (2011).
- [3] Brown R. L., Turner R. J., "Physical disability and depression: clarifying racial/ ethnic contrasts", *Journal of Aging and Health*, 22 (7): 977-1000, (2010).
- [4] Tsai C-F., Guo H-R., Tseng Y-C., Lai D-C., "Sex and geographic differences in the prevalence of reported childhood motor disability and their trends in Taiwan", *BioMed Research International*, (2018), Article ID 6754230, 7 pages, 2018. <https://doi.org/10.1155/2018/6754230>.
- [5] Chang Y.-J., Chen S.-F., Huang J.-D., "A Kinect-based system for physical rehabilitation: A pilot study for young adults with motor disabilities", *Research in Developmental Disabilities*, 32(6): 2566-2570, (2011).
- [6] Yeh Y.L., Hou T.H., Chang W.Y., "An intelligent model for the classification of children's occupational therapy problems", *Expert Syst. Appl.*, 39(5): 5233-5242, (2012).
- [7] Lollar D.J., Simeonsson R.J., "Diagnosis to function: classification for children and youths", *J. Dev. Behav. Pediatrics*, 26(4):323-330, (2005).
- [8] Keawutan P., Bell K. L., Oftedal S., Davies P. S. W., Ware R. S., Boyd R. N., "Relationship between habitual physical activity, motor capacity, and capability in children with cerebral palsy aged 4-5 years across all functional abilities", *Disability and Health Journal*, 11(4): 632-636, (2018). <https://doi.org/10.1016/j.dhjo.2018.03.006>.
- [9] Organization, W.H., International Classification of Functioning, Disability, and Health: Children & Youth Version: ICF-CY, World Health Organization, 2007.
- [10] Le T., Baik S. W., A robust framework for self-care problem identification for children with disability, *Symmetry*, 11(1), 1-12, (2019).
- [11] Islam B., Ashafuddula N. I., Mahmud, F., A machine learning approach to detect self-care problems of children with physical and motor disability, *21st International Conference of Computer and Information Technology (ICCIT)*, 21-23 December, (2018). doi: 10.1109/ICCITECHN.2018.8631960
- [12] Choudhury A., Classification of functioning, disability, and health: icf-cy self care (scadi dataset) using predictive analytics, *CoRR abs/1901.00756*, (2018).
- [13] Putatunda S., Care2Vec: A Deep learning approach for the classification of self-care problems in physically disabled children, *arXiv:1812.00715v1*, 1-14, (2018).
- [14] Wu T. K., Huang S.C., Meng Y.R., "Identifying and diagnosing students with learning disabilities using ANN and SVM", *International Joint Conference on Neural Networks*, IJCNN'06, IEEE, 4387-4394, (2006).
- [15] David J.M., Balakrishnan K., "Prediction of learning disabilities in school-age children using SVM and decision tree", *International Journal of Computer Science and Information Technologies*, 2(2):829-835, (2011).
- [16] Muangnak N., Pukdee W., Hengsanunkun T., "Classification students with learning disabilities using Naïve Bayes Classifier and Decision Tree", *The 6th International Conference on Networked Computing and Advanced Information Management*, Seoul, 189-192, (2010).
- [17] Buduma N., Lacascio N., "Fundamentals of Deep Learning", *O'Reilly Media*, United States of America, (2017).
- [18] Jia F., Lei Y., Lin J., Zhou X., Lu N., "Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data", *Mechanical Systems and Signal Processing*, 72-73:303-315, (2016). doi:10.1016/j.ymsp.2015.10.025.
- [19] Wang B., Luo X., Li Z., Zhu W., Shi Z., Osher S.J., "Deep neural nets with interpolating function as output activation", *arXiv preprint arXiv:1802.00168*, (2018)
- [20] Ding B., Qian H., Zhou J., "Activation functions and their characteristics in deep neural networks", *Chinese Control And Decision Conference (CCDC)*, Shenyang, 1836-1841, (2018). doi: 10.1109/CCDC.2018.8407425
- [21] An W., Wang H., Sun Q., Xu J., Dai Q., Zhang L., "A PID controller approach for stochastic optimization of deep networks", *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 8522-8531, (2018).
- [22] Schmidhuber J., "Deep learning in neural networks: An overview", *Neural Networks*, 61:85-117, (2015).
- [23] Kızrak M. A., Bolata B., "Comprehensive survey of deep learning in crowd analysis", *International Journal of Informatics Technologies*, 11(3):263-286, (2018).
- [24] Prasetijo A. B., Isnanto R. R., Eridani D., Soetrisno Y. A. A., Arfan M., Sofwan A., "Hoax detection system on Indonesian news sites based on text classification using SVM and SGD", *4th International Conference on Information Technology, Computer, and Electrical Engineering (ICITACEE)*, Semarang, 45-49, (2017). doi: 10.1109/ICITACEE.2017.8257673
- [25] Fawcett T., "An Introduction to ROC analysis", *Pattern Recognition Letters*, 27(8): 861-874, (2006). doi:10.1016/j.patrec.2005.10.010.
- [26] Paix'ao W. R., Paix'ao T. M. , Costa M. C. B., Andrade J. O. , Pereira F. G., Komati K. S., "Texture classification of sea turtle shell based on color features: color

- histograms and chromaticity moments”, *International Journal of Artificial Intelligence and Applications (IJAIA)*, 9(2): 55-67, (2018). doi: 10.5121/ijaia.2018.9205
- [27] Sasaki Y., “The truth of the f-measure”, *Teach Tutor mater*, 1(5):1-5, 2007.
- [28] Davis J., Goadrich M., “The relationship between precision-recall and roc curves”, in *Proceedings of the 23rd international conference on Machine learning. ACM*, 233-240, (2006).
- [29] Eschner N., Weiser L., Häfner B., Lanza G., “Development of an acoustic process monitoring system for selective laser melting (SLM)”, *Solid Freeform Fabrication 2018: Proceedings of the 29th Annual International Solid Freeform Fabrication Symposium – An Additive Manufacturing Conference Reviewed Paper*, 2097-2117, (2018).