

## Gerçek Judo Müsabaka Sonuçlarının Yapay Sinir Ağları Yöntemi Yolu ile Karşılaştırılması

Ömer DEĞER<sup>1</sup>, Emin SÜEL<sup>2</sup>

### Özet

#### Yayın Bilgisi

Gönderi Tarihi: 19.10.2021

Kabul Tarihi: 21.07.2022

Online Yayın Tarihi:

21.07.2022

#### Anahtar Kelimeler

Judo, Tahmin, Yapay Sinir Ağları.

#### DOI:

10.55238/seder.1011913

Bu çalışmada, yapay sinir ağları ile Judo müsabaka sonuçlarının tahmin edilmesi amaçlanmaktadır. Bu amaç doğrultusunda yapay sinir ağında katman sayıları, nöron sayıları ve optimizasyon yöntemleri (SGD, RMSprop, Adam, Adadelta, Adagrad, Adamax, Nadam) hiperparametleri ile 21 farklı model oluşturulmuştur. Çalışmanın örneklemini 2017:01-2021:03 tarihleri arasında uluslararası büyükler judo müsabakalarında yarışan 7758 sporcu oluşturmaktadır. Bu dönemde yapılan 53775 judo müsabakasından elde edilen verilerden her sporcuya ait 14 farklı öznitelik hesaplanmıştır. Müsabık iki sporcuya ait öznitelikler sinir ağının giriş katmanına gönderilerek 28 adet girdi verisi 1 adet çıktı verisi oluşturulmuştur. Uygulama, tek gizli katmanında 64 nöron, iki gizli katmanında sırasıyla 32-64 nöron ve üç gizli katmanında sırasıyla 64-128-64 nöron bulunan sinir ağında yedi ayrı optimizasyon yöntemi ile sırasıyla eğitilmiştir. Uygulama sonucunda en başarılı modelin (%78.6 doğruluk, %44.4 hata) tek katmanında 64 nöron, RMSprop optimizasyon yöntemi kullandığı belirlenmiştir. Başarı oranı en düşük modelin (%74.1 doğruluk, %51.8 hata) iki gizli katmanında 32-64 nöron, Adadelta optimizasyon yöntemi kullandığı belirlenmiştir. Optimizasyon yöntemlerinden RMSprop ve Adamax'ın diğer yöntemlere kıyasla daha başarılı olduğu, Adadelta yönteminin ise daha başarısız olduğu belirlenmiştir. Sonuç olarak uygun veri seti ve hiperparametreler kullanılarak Judo müsabaka sonuçlarının yapay sinir ağları ile tahmin edilebileceği ortaya konulmuştur.

## Comparison of Real Judo Competition Results with Artificial Neural Networks Method

### Abstract

#### Article Info

Received: 19.10.2021

Accepted: 21.07.2022

Online Published:

21.07.2022

#### Keywords

Judo, Predicting, Artificial Neural Network.

In this study, it is aimed to predict Judo competition results with artificial neural networks. For this purpose, 21 different models were created with hyperparameters of the number of layers, number of neurons and optimization methods (SGD, RMSprop, Adam, Adadelta, Adagrad, Adamax, Nadam) in the artificial neural network. The sample of the study consists of 7758 athletes competing in international judo competitions between 2017:01-2021:03. 14 different attributes of each athlete were calculated from the data obtained from 53775 judo competitions held in this period. By sending the attributes of two contestants to the input layer of the neural network, 28 input data and 1 output data were created. The application is trained with seven different optimization methods in the neural network with 64 neurons in one hidden layer, 32-64 neurons in two hidden layers, and 64-128-64 neurons in three hidden layers, respectively. As a result of the application, it was determined that the most successful model (78.6% accuracy, 44.4% error) used 64 neurons in a single layer, RMSprop optimization method. It was determined that the model with the lowest success rate (74.1% accuracy, 51.8% error) used the Adadelta optimization method with 32-64 neurons in its two hidden layers. It was determined that the optimization methods RMSprop and Adamax were more successful than the other methods, while the Adadelta method was more unsuccessful. As a result, it has been revealed that Judo competition results can be predicted with artificial neural networks by using appropriate dataset and hyperparameters.

<sup>1</sup> Aksaray Üniversitesi, Sosyal Bilimler Enstitüsü, Aksaray/Türkiye.

<sup>2</sup> Niğde Ömer Halisdemir Üniversitesi, Spor Bilimleri Fakültesi, Niğde /Türkiye.

\* Bu çalışma Yüksek Lisans tezinden üretilmiştir.

## Giriş

Tarihsel kanıtlara dayanarak sonuçları doğru bir şekilde tahmin etmek uzun zaman boyunca birçok araştırmacının hedefi olmuştur. Bu motivasyon, spora özgü birçok tahmin aracının gelişmesine yol açmış, bu araçlar kullanılarak spor verilerindeki eğilimler kişisel, rekabetçi veya ekonomik avantajlar için kullanılabilir ve manipüle edilebilir hale gelmiştir (Schumaker ve ark., 2010). Spor alanında çeşitli konular üzerinde tahmin çalışmaları bulunmaktadır, maç stratejisi, taktikleri ve analizi, oyuncuların oyun tarzlarını belirleme, oyuncu edinimi, oyuncu değerlendirme ve takım harcamaları, antrenman rejimleri ve odaklanma, yaralanma öngörü ve önleme, performans yönetimi ve tahmini, maç sonucu ve lig tablosu tahmini, turnuva planlama ve çizelgeleme bunlardan bazılarıdır (Herbinet, 2018). Bilgisayarlar ile veriden anlamlı çıktılar üretmek için verilerin belirli sırada bir algoritmadan geçmesi gerekmektedir. Algoritma, içerisinde veriye uygulayacağı birtakım komutları içermektedir; ancak bazı işler için bilinen herhangi bir algoritma yoktur (Alpaydin, 2017). Örneğin; bir spor dalında kimin galip geleceğini tahmin edilebilirken bu galibiyeti hesaplayacak bir formül yoktur.

Yapay öğrenme teknikleri, spor karşılaşmalarıyla ilgili tahminde bulunmada bir yöntem olarak kullanılmaktadır (Schumaker ve ark., 2010). Yapay öğrenme; verilerden öğrenebilen, optimizasyon ve tekrarlar yoluyla belirli bir soru için "en iyi" analitik çözümü bulabilen algoritmaları kapsamaktadır (Houston, 2018). Yapay öğrenmenin çözmesi için ortaya çıkarılan problemler sıradan hesaplama problemleri değildir, bilgisayarlar için zor fakat uzman insanların çözebileceği türde problemlerdir (Nabiyev, 2016). Problem çözme ve karar vermede belirsizlik kaçınılmaz olsa da bunu azaltmanın bir yolu, bir uzmandan tavsiye almaktır. Belirsizliği azaltmak için bilgisayarları kullandığımızda bilgisayarın kendisi çeşitli yöntemlerle belirli bir alanda "uzman" haline gelebilir (Schumaker ve ark., 2010). Ancak herhangi bir insan analizi olmaksızın modelin performansını belirlemek her zaman mümkün değildir. Çoğu yapay öğrenme algoritmasının düzgün çalışması için çok fazla veri gerekir. Çok basit problemler için bile tipik olarak binlerce örnek veriye ihtiyaç vardır (Géron, 2019). Veri, modern spor analizinin can damarıdır. Eskiden veriler, tarihsel amaçlarla saklanan bir kayıt olarak görülürken (Schumaker ve ark., 2010) günümüzde çıkarım yapmak, veri madenciliği ve yapay öğrenme alanlarında kullanılmak üzere federasyonlar veya kulüpler tarafından istihdam edilen istatistikçiler tarafından detaylı olarak kayıt altına alınmaktadır. Uluslararası Judo Federasyonu (UJF) tarafından istihdam edilen hakemler tarafından her yıl yaklaşık elli uluslararası turnuvada on yedi bin judo müsabakası, bilgisayar ortamına anlık kaydedilmekte ve kaydedilen veriler eş zamanlı olarak internet aracılığıyla tüm dünya ile paylaşılmaktadır.

Judo, yüksek bilinirliğe sahip sporlardan biridir ve dünya çapında kırk milyondan fazla insanın judo yaptığı bilinmektedir (Messner, 2019). Tüm sporlar gibi judo da rekabeti düzenleyen ve güvenliği sağlayan katı kurallar ile yönetilmektedir. Müsabakalar, kadınlar ve erkekler ayrı olmak üzere tüm yaş kategorilerinde, belirli sıklıklar üzerinden yapılmaktadır.

Judoda başarı, teknik becerinin optimal düzeyde uygulanmasına ve bu becerinin altında yatan biyomekanik güçlere bağlıdır. Amaç; direnen ve motive olmuş bir rakibi atmak, tutuş pozisyona almak, boğmak veya kolunu kilitlemektir. Judo, güreş ve benzeri dövüş sporlarının amacı hareketi kontrol etmektir.

Bir sporcu kendi hareketini ve rakibinin hareketini ne kadar iyi kontrol ederse sonuç o kadar iyi olacaktır (Scott ve Bergman, 2018).

Bu çalışmanın da amacı gerçek judo müsabaka sonuçlarının yapay sinir ağları yöntemi yolu ile karşılaştırılmasıdır.

## Materyal ve Yöntem

### *Araştırma Modeli*

Verilerin duygusal dış etmenlerden etkilenmeden nesnel olarak gözlenip analiz edildiği ve tahminlerde bulunduğu felsefi bakış açısına nicel bakış açısı denir. Bir sorunu çözmeye, bir durumu geliştirmeye veya iyileştirmeye dönük araştırma-geliştirme çalışmalarına ise uygulamalı araştırmalar denir (Büyüköztürk ve ark., 2017). Bu kapsamda bu çalışmada felsefi bakış açısı olarak nicel bakış açısını temel almış, amacına göre uygulamalı araştırma yöntemi kullanılmıştır.

### *Araştırma Grubu*

Bir araştırmada iki tür evrenden söz edilir. Hedef evren, ulaşılabildiği hemen hemen imkânsız olan ideal evreni temsil eder. Ulaşılabilir evren ise araştırma için gerçekçi seçimi, ulaşılabilir olanı ifade eder ve “araştırmanın evreni” olarak tanımlanır (Büyüköztürk ve ark., 2017). Olimpik yeterlilik, sporcuların Dünya Sıralama Listesinde sahip oldukları puanlara göre belirlenir. Sıralama oluşturulurken yarışma tarihinden önceki iki yıl dikkate alınır ve iki döneme ayrılır. Birinci dönem, yarışma tarihinden önceki 13-24 ay aralığını kapsar. İkinci dönem ise yarışma tarihinden önceki 12 aylık süreyi kapsar (Sport and Organisation Rules of the International Judo Federation - Version: 8, 2020). Judo sporcuları uluslararası müsabakalarda derece olarak nihai hedef olan Olimpiyat Oyunlarına hazırlanmaktadır. Sporcular Olimpiyat yeterliliğine sahip olmak için oyunlardan önce uluslararası tüm müsabakalara katılmaya çalışmakta, kayıt altına alınan sporculara ait müsabaka verilerinde bir süreklilik olmaktadır.

Bu çalışmada araştırmanın evreni uluslararası judo müsabakalarında yarışan tüm sporcuları kapsarken araştırmanın örnekleme 2017:01/2021:03 tarihleri arasında uluslararası müsabakalarda yarışan sporculardır.

### *Verilerin Toplanması*

Çalışmada kullanılan veriler, Judo müsabaka detaylarını kamuya açık bir şekilde yayınlayan Uluslararası Judo Federasyonuna ait web sitesinden (<https://judobase.ijf.org/>) elde edilmiştir.

Python; dinamik semantiğe sahip, yorumlanabilir, nesne yönelimli, üst seviye bir programlama dilidir. Kolay öğrenilebilir bir dildir ve basitliği sayesinde program bakım maliyetini düşürür. Yorumlayıcısı ve kapsamlı standart kütüphanesi, tüm büyük platformlar için açık kaynak ve ücretsiz olarak sunulur (“What is Python? Executive Summary | Python.org”, y.y.). Verilerin toplanması açık kaynak programlama dili olan Python’un 3.8.2 versiyonu ile gerçekleştirilmiştir.

İstek (urllib.request) modülü URL’lerin açılmasına yardımcı olan birçok fonksiyonu içinde barındırır. Bu fonksiyonlar ile kimlik doğrulama, yönlendirme ve daha fazla işlem yapılabilir (“urllib - URL handling modules - Python 3.8.2 documentation”, y.y.). Çalışmada kullanılan verilerin bulunduğu adresi açmak için Python programlama dili içinde bütünleşik ‘urllib’ kütüphanesi ve bu kütüphaneye ait istek (request) modülü kullanılmıştır.

“Pandas”; Python programlama dili üzerine inşa edilmiş, hızlı, güçlü, esnek ve kullanımı kolay, açık kaynak veri analiz ve işleme aracıdır (“pandas - Python Data Analysis Library”, y.y.). Verilerin bulunduğu adreslere ulaşıldıktan sonra verileri “.csv” uzantılı bir dosyaya aktarmak için (Pandas 1.2.4) kütüphanesinden yararlanılmıştır.

### **Verilerin Analizi**

YSA; insan beynindekilere benzer, birbirine bağlı nöronlardan veya "düğüm"lerden oluşan çoğunlukla tek işlemcili bir bilgisayarla, insanlar tarafından gerçekleştirilmiş örnekleri kullanarak olayları öğrenebilen, çevreden gelen olaylara karşı nasıl tepkiler üretileceğini belirleyebilen matematiksel modellerdir (Bartlett, 2006; Öztemel, 2016). Çok katmanlı algılayıcı, kategorik (sınıflandırma) veya sürekli (regresyon) bir değişkeni tahmin etmek için kullanılan modeldir (Theobald, 2017).

Veriler, yapay sinir ağları alt alanında çok katmanlı algılayıcılar modeli ile analiz edilmiştir. Verilerin analizi açık kaynak programlama dili olan Python'un 3.8.2 versiyonu ile gerçekleştirilmiştir. NumPy, Python programlama dili için geliştirilmiş, çok boyutlu diziler ve matrislerle çalışmak için yüksek düzeyli matematiksel fonksiyonları barındıran bir kütüphanedir (Harris ve ark., 2020). Bu çalışmada toplanan verilerin dönüşümleri ve özellik çıkarımları için NumPy kütüphanesinin 1.20.3 versiyonundan yararlanılmıştır.

Scikit-learn, gözetimli ve gözetimsiz problemler için çok çeşitli yapay öğrenme algoritmalarını içeren bir Python kütüphanesidir (Pedregosa ve ark., 2011). Eğitim ve test verilerinin oransal bölünmesi için Scikit-Learn'un 0.24.2 versiyonu kullanılmıştır.

Matplotlib; Python programlama dili için geliştirilmiş, statik, animasyonlu ve etkileşimli görselleştirmeler oluşturulmasına olanak veren kapsamlı bir kütüphanedir (Hunter, 2007). Bu çalışmada görselleştirme çalışmalarında Matplotlib kütüphanesinin 3.4.2 versiyonu kullanılmıştır.

TensorFlow, araştırmacıların son teknoloji ürünü yapay öğrenme modelleri geliştirmesine ve yapay öğrenme destekli uygulamaların kolayca oluşturulmasına ve dağıtılmasına olanak tanıyan kapsamlı ve esnek araçlar içeren bir kütüphanedir. Çekirdek bölümü C programlama dilince yazılmıştır, ayrıca Python programlama dili ile hızlı prototipler çıkarmak üzere Keras isimli bir (API) uygulama ara yüzüne sahiptir (Developers, 2021). Bu çalışmada yapay sinir ağı kurulumu ve hesaplamaları için TensorFlow kütüphanesinin 2.5.0 versiyonu kullanılmıştır.

Keras, yapay öğrenme platformu TensorFlow üzerinde çalışan Python'da yazılmış bir derin öğrenme (API) uygulama ara yüzüdür. Bu çalışmada çok katmanlı algılayıcı modellerinin kurulumu Keras kütüphanesinin 2.5.0 versiyonu ile yapılmıştır.

## **Bulgular**

**Tablo 1.** Sporcuların Sıkletlere Göre Dağılımı


Cinsiyet	Sıklet	N	%
Kadın	48 kg	373	4,8
	52 kg	434	5,6
	57 kg	504	6,5
	63 kg	489	6,3
	70 kg	414	5,3
	78 kg	291	3,8
	+78 kg	275	3,5
<b>Toplam</b>		<b>2780</b>	<b>35,8</b>

Erkek	60 kg	685	8,8
	66 kg	865	11,1
	73 kg	969	12,5
	81 kg	837	10,8
	90 kg	678	8,7
	100 kg	514	6,6
	+100 kg	430	5,5
	<b>Toplam</b>	<b>4978</b>	<b>64,2</b>
<b>Toplam</b>	<b>7758</b>	<b>100,0%</b>	

Buna göre Tablo 1’de görüldüğü üzere çalışmamız 7758 sporcu ile gerçekleştirilmiştir. Bu sporcuların 2780’ü (%35,8) kadın, 4978’i (%64,2) ise erkektir. Sporcuların sıkletlere dağılımı incelendiğinde kadınlarda 57 kg 504 (%6,5) sporcu ile en kalabalık sıklet olurken 275 (%3,5) sporcu ile en az sporcu bulunan sıklet +78 kg olmuştur. Erkeklerde ise 73 kg, 969 (%12,5) sporcu ile en kalabalık sıklet olurken +100 kg, 430 (%5,5) sporcu ile en az sporcu bulunduran sıklet olmuştur.


### Veri Setinin Hazırlanması

Judo müsabakalarında sonucu tahmin etmek için karşılaşılan iki sporcunun bazı bilgilerine sahip olmak gerekmektedir. Sporcuların önceden oynadığı müsabakalarda ortaya koydukları performans istatistikleri, aldığı cezalar, kazandığı müsabakalar bu bilgilere örnek olarak verilebilir. Bu çalışma kapsamında oluşturulan veri setinde UJF tarafından yönetilen <https://judobase.ijf.org> internet sitesinden elde edilen veriler kullanılmıştır. Veri setinde 2017:01 ile 2021:03 dönemlerinde oynanan toplam 53775 müsabaka verisi ve 65 öznitelik bulunmaktadır.



Şekil 1. Yıllara Göre Toplam Müsabaka Sayısı

Şekil. 1’deki grafikte, 2017 ve 2021 yılları arasında oynanan müsabakaların kadın erkek dağılımları ve yıllara göre toplamları verilmiştir. 2017 yılından 2019 yılına kadar müsabaka sayıları düzenli bir artış göstermiştir. 2020 yılında Covid-19 salgını nedeniyle iptal edilen etkinlikler sebebiyle toplam müsabaka sayılarında düşüş olduğu gözlenmektedir.



**Şekil 2.** En Fazla Sporcu Bulunduran 10 Ülke

Şekil 2’deki grafikte 2017-2021 sezonu Uluslararası müsabakalara en çok sporcu gönderen 10 ülke gösterilmiştir. Rusya Federasyonu (n=476) en çok katılımı gösteren ülke olurken onuncu sırada Hollanda (n=161) yer almıştır. Türkiye ise 182 (n=82) ülke arasında 77. sırada yer almıştır.

**Tablo 2.** Turnuva Tipleri ve Müsabaka Sayısı

Turnuva Tipi	Müsabaka Sayısı
Open	14913
Prix	11091
Cup	10457
Slam	9675
Championship	4501
World Championship	1667
Masters	1453
<b>Toplam</b>	<b>53775</b>

Veri setinde bazı değişkenlerin değerleri eksiktir. Boş değerler sayısal değişkenin ortalamasıyla doldurulabilir ya da diğer değerlere bakarak bir kestirimde bulunulabilir. Eksik değerler için en iyi yöntem boş verinin veri setinden kaldırılmasıdır (Alpaydin, 2017).

Veri setinde 21.169 boş değer içeren müsabaka verisi, sonuçları etkilememesi açısından veri setinden kaldırılmıştır. Judoda müsabaka bir ippon puanıyla bitmektedir, bazı ippon puanı değerlerinin 2 olduğu gözlenmiştir. Waza-ari puanı değeri ise 2 olduğu zaman müsabaka bitmektedir, bazı waza-ari puanlarının değerinin 2’den büyük olduğu görülmüştür. Verileri kaydeden hakemlerden kaynaklanan bu hataları değerleri limit noktalarına eşitleyerek 1 değerinden büyük ippon puanları 1’e eşitlenirken 2 değerinden büyük Waza-ari puanları 2’ye eşitlenerek çözüm yoluna gidilmiştir.

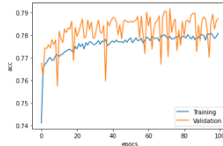
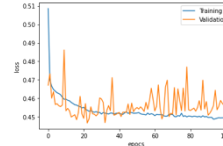
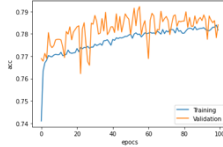
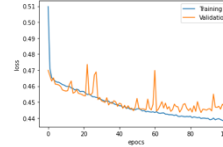
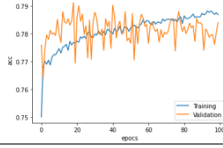
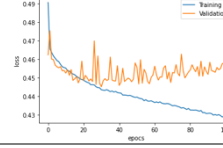
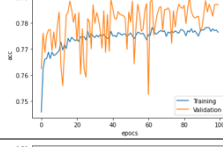
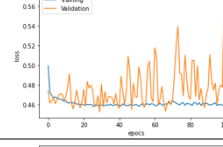
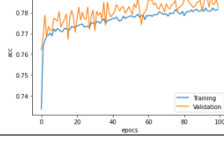
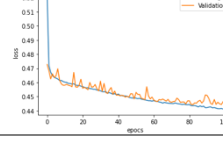
**Tablo 3.** Turnuva Türleri ve Puan Tablosu

Turnuva Türü	Kazananın Puanı	Kaybedenin Puanı
Continental Open International	10	1
Continental Championships Continental	70	6
Grand Prix International Entry	70	6
Grand Slam International Entry	100	10
Masters Top 36 Invitation	216	200
World Championships Seniors	200	20

**Tablo 4.** Sporcu Öznitelikleri Ortalama ve Standart Sapma Değerleri

Öznitelikler (N=7758)	Ortalama	std
<b>Sporcu ID</b>	-	-
<b>Ülke ID</b>	-	-
<b>Sıklet</b>	-	-
<b>Derece</b>	449.90	1244.60
<b>Toplam Müsabaka Sayısı</b>	13.84	20.70
<b>Kazanma Oranı</b>	0.29	0.26
<b>Toplam Kazandığı Puan Ort.</b>	24.81	23.27
<b>Toplam Kaybettiği Puan Ort.</b>	-60.82	32.00
<b>Toplam Aldırdığı Ceza Ort.</b>	-0.84	0.63
<b>Toplam Kaybettiği Ceza Ort.</b>	0.62	0.50
<b>Son 3 Kazanma Ort.</b>	0.46	0.46
<b>Son 3 Aldırdığı Ceza Ort.</b>	-1.00	0.81
<b>Son 3 Kazandığı Ceza Ort.</b>	0.87	0.84
<b>Son 3 Kazandığı Puan Ort.</b>	39.25	41.85
<b>Son 3 Kaybettiği Puan Ort.</b>	-61.20	37.66

**Tablo 5.** Başarım Oranı En Yüksek 5 Modelin Gösterge ve Grafikleri


Nöron Sayısı	Optimizasyon Yöntemi	Doğruluk Oranı	Hata Oranı	Doğruluk Grafiği	Hata Grafiği
64	RMSprop	0.7860	0.4440		
32,64	Adamax	0.7859	0.4425		
64	Nadam	0.7851	0.4518		
64,128,64	RMSprop	0.7836	0.4386		
64	Adamax	0.7834	0.4402		

Tablo 5'e göre, giriş katmanında 28, gizli katmanında 64, çıkış katmanında 1 nörona sahip tek gizli katmanlı model en iyi beş başarımlar sırasında üç farklı optimizasyon yöntemiyle yer almıştır. Tek gizli katmanlı modelin başarımları iki katmanlı ve üç katmanlı modele göre daha başarılı olduğu görülmektedir. RMSprop yöntemi 64 nöronlu tek gizli katmanlı ağ ve 64,128,64 nöronlu üç gizli katmanlı ağda, Adamax yöntemi 64 nöronlu tek gizli katmanlı ağ ve 32,64 nöronlu iki gizli katmanlı ağda, Nadam optimizasyon yöntemi ise 64 nöronlu tek gizli katmanlı ağda %78 oranında başarımları sağlamıştır.

**Tablo 6.** Başarım Oranı En Düşük 5 Modelin Gösterge ve Grafikleri

Nöron Sayısı	Optimizasyon Yöntemi	Doğruluk Oranı	Hata Oranı	Doğruluk Grafiği	Hata Grafiği
32,64	Adadelta	0.7412	0.5183		
64	Adadelta	0.7469	0.5169		
64,128,64	Nadam	0.7608	0.5719		
64,128,64	Adadelta	0.7610	0.4790		
64,128,64	Adam	0.7624	0.6015		

Tablo 6'ya göre, giriş katmanında 28, gizli katmanlarında sırasıyla 64-128-64, çıkış katmanında 1 nöron bulunan 3 gizli katmanlı model en başarısız model olmuştur. Üç gizli katmanlı modelin bir ve iki gizli katmanlı modellere göre daha başarısız olduğu görülmektedir. Adadelta, optimizasyon yöntemleri arasında 3 modelde de en düşük başarı oranı göstermiştir. Nadam ve Adam yöntemleri ise üç gizli katmanlı modelde düşük başarı göstermiştir. Üç gizli katmanlı tasarım 3 optimizasyon yöntemi ile başarı oranı en düşük modeldir. Grafikler incelendiğinde üç gizli katmana sahip modelin aşırı eğitilmiş olduğunu görmekteyiz.

**Şekil 3.** 2 Numaralı Modelin Hata Matrisi



Şekil 3'te Başarım oranı en yüksek 2 numaralı modelin hata matrisi verilmiştir. Buna göre Beyaz Judogi giyen sporcuların kazandığı 6249 müsabakadan 5366 (%86) tanesi doğru, 883 (%14) tanesi ise yanlış tahmin edilmiştir. Mavi judogi giyen sporcuların kazandığı toplam 4506 müsabakadan 3082 (%68) tanesi doğru, 1424 (%32) tanesi yanlış tahmin edilmiştir.

$$\begin{aligned} \text{Doğruluk} &= \frac{\text{Doğru Pozitif} + \text{Doğru Negatif}}{N} = \frac{5366 + 3082}{10755} = 0.78 \\ \text{Hassasiyet} &= \frac{\text{Doğru Pozitif}}{\text{Doğru Pozitif} + \text{Yanlış Pozitif}} = \frac{5366}{5366 + 883} = 0.86 \\ \text{Geri Çağırma} &= \frac{\text{Doğru Pozitif}}{\text{Doğru Pozitif} + \text{Yanlış Negatif}} = \frac{5366}{5366 + 1424} = 0.79 \\ f1 - \text{skoru} &= \frac{2 \times \text{Geri Çağırma} \times \text{Hassasiyet}}{\text{Geri Çağırma} + \text{Hassasiyet}} = \frac{2 \times 0.79 \times 0.86}{0.79 + 0.86} = 0.82 \end{aligned}$$

**Tablo 7.** 2 Numaralı Modelin Hassasiyet, Geri Çağırma ve f1 skoru

	Hassasiyet	Geri Çağırma	f1-skor	N
<b>Beyaz Kazanan (0)</b>	0.79	0.86	0.82	6249
<b>Mavi Kazanan (1)</b>	0.78	0.68	0.73	4506
<b>Doğruluk</b>			0.78	10755
<b>Ağırlıklı Ortalama</b>	0.78	0.79	0.78	10755

Tablo 7'de en başarılı model için doğruluk oranı %78 bulunmuştur. Beyaz judogi giyen sporcuların f1-skor'u %82, Mavi judogi giyen sporcuların f1-skor'u ise %73 bulunmuştur. Bu fark, müsabakalarda ilk okunan ismin beyaz judogi giyen sporcu olması ve Uluslararası Judo Federasyonunun sıralaması yüksek sporcuyla ilk isim olarak okumasından kaynaklanmaktadır.

## Tartışma ve Sonuç

Bu çalışmada çok katmanlı algılayıcılar modeli, ileri beslemeli geri yayılım (Back-Propagation) ağı kullanılarak 2017-2021 yılları arasında oynanmış 53775 müsabaka verisi üzerinde 28 öznitelik kullanılarak judo müsabaka sonuçları tahmin edilmiştir.

Çalışmada kullanılan veriler UJF'ye ait judobase.ijf.org adresinden elde edilmiştir. Toplam 53775 müsabaka verisinden 7758 sporcuya ait 14 farklı öznitelik çıkarılmıştır.

Doğruluk oranı en yüksek ÇKA modelini tespit etmek üzere; öğrenme oranı, kayıp fonksiyonu, eğitim yineleme sayısı ve aktivasyon fonksiyonu sabit tutulurken gizli katman sayısı, nöron sayısı ve optimizasyon yöntemi değiştirilerek 21 farklı model kurgulanmıştır. Giriş katmanında 28, gizli katmanında 64, çıkış katmanında 1 nöronu bulunan RMSprop optimizasyon yöntemi kullanan 2 numaralı model %78.6 doğruluk oranı ile kurulan modeller arasında en başarılı sonucu vermiştir. Tek gizli katmanlı ve 64 nöronlu modelin, iki gizli katmanlı ve üç gizli katmanlı modele göre daha başarılı sonuç verdiği belirlenmiştir.

Optimizasyon yöntemlerinden RMSprop ve Adamax yöntemlerinin diğer yöntemlere kıyasla daha başarılı olduğu, Adadelta yönteminin ise daha başarısız olduğu belirlenmiştir (Tablo 5 ve 6).

Literatür taraması yapıldığında Judo verileri ile müsabaka sonucu tahmini yapan bir yapay sinir ağı modeli bulunamamıştır. Doğrusal modellerle yapılan çalışmalarda %26 doğrulukla puan tahmini yapılmaktadır (Franchini ve Julio, 2015).

Sinir ağları ile yapılan çalışmalarda; kullanılan veri setinin yapısı, optimizasyon yöntemlerinin çeşidine bağlı olarak model performanslarının farklılaştığı bilinmektedir. Ayrıca optimizasyon algoritmalarının performansı, parametrelerin seçimine ve sinir ağının nasıl yapılandırılacağına bağlı olarak değişmektedir (Ser ve Bati, 2019).

Sonuç olarak, uygun veri seti ve hiperparametreler kullanılarak Judo müsabaka sonuçlarının yapay sinir ağları ile tahmin edilebileceği ortaya konulmuştur. Tahminler neticesinde müsabakaya hazırlanırken sporculara uygulanacak teknik ve taktik hazırlığa yönelik antrenmanlara katkı sağlayacağı düşünülmektedir.

## Öneriler

- Bu çalışmada ortaya konulan ÇKA modeli ile kulüpler ve ülkeler sporcu değerlendirme ve transferi için iki sporcu arasında tutarlı ve güvenilir bir karşılaştırma yapabileceklerdir.
- Sporcuların birbirileri karşısında üstünlüğü model yardımı ile kararlaştırılıp Maç fikstürü oluşturulurken güçlü iki sporcunun karşılaşmasının önüne geçmede yeni bir yöntem olarak kullanılabilir.
- Kazanma durumu ortaya koyan bir durumda yüksek doğruluk veren sonuçlar alınabilecektir. İleride yapılacak çalışmalarda;
- Her bir sporcu için oluşturulan öznitelikler müsabaka bilgilerinden elde edilen verilerden oluşturulmuştur. Sporcuya ait ek bilgiler (ör: boy, kas-yağ oranı, çeviklik, vb.) modelin daha doğru tahminlerde bulunmasına yardımcı olabilir.
- Çalışmada kadın ve erkekler aynı modelde kullanılmıştır. Kadın ve erkeklerin güçlerinin ve müsabaka yöntemlerinin birbirinden farklı olduğu bilinmektedir. Başka bir çalışmada kadın ve erkek sporcuların farklı modelde kurgulanması çalışmanın doğruluk oranını yükseltebilir.

## Kaynaklar

- Alpaydin, E. (2017). *Yapay Öğrenme*. (E. Kocabıyık, Ed.) (3. bs.). İstanbul: Boğaziçi Üniversitesi Yayınevi.
- Bartlett, R. (2006). Artificial intelligence in sports biomechanics: new dawn or false hope? *Journal of sports science & medicine*, 5(4), 474–479. <https://pubmed.ncbi.nlm.nih.gov/24357939> adresinden erişildi.
- Büyüköztürk, Ş., Kılıç Çakmak, E., Akgün, Ö. E., Karadeniz, Ş. & Demirel, F. (2017). *Bilimsel araştırma yöntemleri*. Pegem Akademi Yayıncılık. Ankara: Pegem Akademi Yayıncılık. doi:10.14527/9789944919289
- Developers, T. (2021). TensorFlow. doi:10.5281/ZENODO.4758419. pandas - Python Data Analysis Library. (y.y.). 14 Şubat 2021 tarihinde <https://pandas.pydata.org/> adresinden erişildi.
- Franchini, E. & Julio, U. F. (2015). The Judo World Ranking List and the Performances in the 2012 London Olympics. *Asian Journal of Sports Medicine*, 6(3).
- Géron, A. (2019). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems* (1. bs.). O'Reilly Media.
- Harris, C. R., Millman, K. J., van der Walt, S. J., Gommers, R., Virtanen, P., Cournapeau, D., Oliphant, T. E. (2020). Array programming with {NumPy}. *Nature*, 585(7825), 357–362.
- Herbinet, C. (2018). Predicting Football Results Using Machine Learning Techniques. 2011 Proceedings of the 34th International Convention MIPRO, 48, 1623–1627.

- Houston, T. H.-T. M. B. (2018). *Entertainment Science: Data Analytics and Practical Theory for Movies, Games, Books, and Music*. Springer.
- Hunter, J. D. (2007). Matplotlib: A 2D graphics environment. *Computing in Science & Engineering*, 9(3), 90–95.
- Messner, N. (2019). Judo Celebrates the Planet. 15 Ekim 2020 tarihinde <https://www.ijf.org/news/show/judo-celebrates-the-planet> adresinden erişildi.
- Nabiyev, V. V. (2016). *Yapay Zeka: İnsan- Bilgisayar Etkileşimi* (5. bs.). Ankara: Seçkin Yayıncılık.
- Öztemel, E. (2016). *Yapay Sinir Ağları* (4. bs.). İstanbul: Papatya Yayıncılık Eğitim.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., ... Duchesnay, E. (2011). Scikit-learn: Machine Learning in {P}ython. *Journal of Machine Learning Research*, 12, 2825–2830.
- Schumaker, R. P., Solieman, O. K. & Chen, H. (2010). *Sports Data Mining. Integrated Series in Information Systems* (1. bs., C. 26). Boston, MA: Springer US.
- Scott, S. & Bergman, J. (2018). *The Judo Advantage: Controlling Movement with Modern Kinesiology- For All Grappling Styles*. G- Reference, Information and Interdisciplinary Subjects Series. YMAA Publication Center.
- Ser, G. & Bati, C. T. (2019). Determining the best model with deep neural networks: Keras application on mushroom data. *Yuzuncu Yil University Journal of Agricultural Sciences*, 29(3), 406–417.
- Sport and Organisation Rules of the International Judo Federation Version: 8. (2020).
- Theobald, O. (2017). *Machine Learning For Absolute Beginners: A Plain English Introduction* (2 edition.). Scatterplot Press.

### Makale Alıntısı

Değer, Ö., Süel, E. (2021). Gerçek Judo Müsabaka Sonuçlarının Yapay Sinir Ağları Yöntemi Yolu ile Karşılaştırılması [Comparison of Real Judo Competition Results with Artificial Neural Networks Method], *Spor Eğitim Dergisi*, 6 (2), 88-98.



Bu eser Creative Commons Atıf-GayriTicari 4.0 Uluslararası Lisansı ile lisanslanmıştır.