



**T.C.
AKSARAY ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
BEDEN EĞİTİMİ VE SPOR ANA BİLİM DALI**

**GERÇEK JUDO MÜSABAKA SONUÇLARININ YAPAY SİNİR AĞLARI
YÖNTEMİ YOLU İLE KARŞILAŞTIRILMASI**

YÜKSEK LİSANS TEZİ

ÖMER DEĞER

**DANIŞMAN
DOÇ. DR. EMİN SÜEL**

AKSARAY 2021

**T.C.
AKSARAY ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
BEDEN EĞİTİMİ VE SPOR ANA BİLİM DALI**

**GERÇEK JUDO MÜSABAKA SONUÇLARININ YAPAY SİNİR AĞLARI
YÖNTEMİ YOLU İLE KARŞILAŞTIRILMASI**

YÜKSEK LİSANS TEZİ

ÖMER DEĞER

**DANIŞMAN
DOÇ. DR. EMİN SÜEL**

AKSARAY 2021

TELİF HAKKI VE TEZ FOTOKOPİ İZİN FORMU

Bu tezin tüm hakları saklıdır. Kaynak göstermek koşuluyla tezin teslim tarihinden itibaren 6 (altı) ay sonra tezden fotokopi çekilebilir.

YAZARIN

Adı : Ömer

Soyadı : DEĞER

Bölümü : Beden Eğitimi ve Spor Ana Bilim Dalı

İmza :

Teslim tarihi :

TEZİN

Türkçe Adı: Gerçek Judo Müsabaka Sonuçlarının Yapay Sinir Ağları Yöntemi
Yolu ile Karşılaştırılması

İngilizce Adı: Comparison of Real Judo Competition Results with Artificial
Neural Networks Method

ETİK İLKELERE UYGUNLUK BEYANI

Tez yazma sürecinde bilimsel ve etik ilkelere uyduđumu, yararlandıđım tüm kaynakları kaynak gösterme ilkelerine uygun olarak kaynakçada belirttiđimi ve bu bölümler dışındaki tüm ifadelerin şahsıma ait olduđunu beyan ederim.

Yazar Adı Soyadı: Ömer DEĞER

İmza:

T.C.
AKSARAY ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ

JÜRİ ONAY SAYFASI

Ömer DEĞER tarafından hazırlanan “Gerçek Judo Müsabaka Sonuçlarının Yapay Sinir Ağları Yöntemi Yolu ile Karşılaştırılması” başlıklı tez çalışması aşağıdaki jüri tarafından oy birliği ile Aksaray Üniversitesi Beden Eğitimi ve Spor Anabilim Dalı’nda Yüksek Lisans tezi olarak kabul edilmiştir.

İMZA

Danışman: Doç. Dr. Emin SÜEL

Hareket ve Antrenman Bilimleri, Niğde Ömer Halisdemir Üniversitesi

Üye: Prof. Dr. Hüseyin ÜNLÜ

Beden Eğitimi ve Spor Anabilim Dalı, Aksaray Üniversitesi

Üye: Prof. Dr. Rüçhan İRİ

Hareket ve Antrenman Bilimleri, Niğde Ömer Halisdemir Üniversitesi

Tez Savunma Tarihi:/...../.....

Sosyal Bilimler Enstitüsü Yönetim Kurulu’nuntarih ve
sayılı kararı ile onaylanmıştır.

Sosyal Bilimler Enstitüsü Müdürü

Doç. Dr. Sevilay USLU DİVANOĞLU

İmza

TEŞEKKÜR

Bu çalışmanın yürütülmesi sırasında kıymetli bilgi, birikim ve tecrübeleri ile bana yol gösteren ve destek olan değerli danışmanım Doç. Dr. Emin SÜEL'e, çalışmanın düzenlenmesi aşamasında destek ve yardımlarını esirgemeyen kıymetli dostum Emine COŞKUN ve babam Nihat Bayram DEĞER'e teşekkür ve saygılarımı sunarım.

Her daim arkamda duran, güçlü ve özel hissetmemi sağlayan aileme, bir an olsun desteğini esirgemeyen, her anıma sabreden, bana benden çok güvenen, varlığıyla güç veren sevgili eşim Ayşegül DEĞER'e sonsuz şükranlarımı sunarım.

AKSARAY ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
GERÇEK JUDO MÜSABAKA SONUÇLARININ YAPAY SİNİR
AĞLARI YÖNTEMİ YOLU İLE KARŞILAŞTIRILMASI

(Yüksek Lisans Tezi)

Ömer DEĞER Aksaray 2021

ÖZET

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.

Bilim Kodu: 130113

ORCID No: 0000-0002-6131-0585

Anahtar Kelimeler: Judo, Tahmin, Yapay Sinir Ağları

Sayfa Adedi: 66

Danışman: Doç. Dr. Emin SÜEL



AKSARAY UNIVERSITY
GRADUATE SCHOOL OF SOCIAL SCIENCES
COMPARISON OF REAL JUDO COMPETITION RESULTS WITH
ARTIFICIAL NEURAL NETWORKS METHOD

(M.A. Thesis)

Ömer DEĞER Aksaray 2021

ABSTRACT

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, Adadelata, 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 Adadelata 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 Adadelata 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.

Science Code: 130113

ORCID Number: 0000-0002-6131-0585

Key Words: Judo, Predicting, Artificial Neural Network

Number: 66

Supervisor: Assoc. Prof. Emin SÜEL



İÇİNDEKİLER

TELİF HAKKI VE TEZ FOTOKOPİ İZİN FORMU	i
ETİK İLKELERE UYGUNLUK BEYANI	ii
JÜRİ ONAY SAYFASI.....	iii
TEŞEKKÜR.....	iv
ÖZET	v
ABSTRACT	vii
İÇİNDEKİLER.....	ix
ŞEKİLLER LİSTESİ.....	xii
TABLolar LİSTESİ.....	xiii
SİMGELER ve KISALTMALAR LİSTESİ.....	xiv
1. GİRİŞ.....	1
1.1. Problem Durumu.....	1
1.2. Problem Cümlesi	2
1.3. Araştırmanın Amacı.....	3
1.4. Araştırmanın Önemi	3
1.5. Varsayımlar.....	3
1.6. Sınırlılıklar	3

1.7. Tanımlar	3
2. KURAMSAL ÇERÇEVE	5
2.1. Yapay Öğrenme	5
2.2. Yapay Öğrenme Yaklaşımları.....	5
2.2.1. Gözetimli Öğrenme.....	5
2.2.2. Gözetimsiz Öğrenme	6
2.2.3. Pekiştirmeli Öğrenme.....	7
2.3. Yapay Sinir Ağları.....	8
2.3.1. Yapay Sinir Hücresi	10
2.3.1.1. Girdiler	10
2.3.1.2. Ağırlıklar	10
2.3.1.3. Toplama Fonksiyonları	11
2.3.1.4. Aktivasyon Fonksiyonları	11
2.3.1.5. Çıktı.....	12
2.3.2. Algılayıcı	12
2.3.3. Çok Katmanlı Algılayıcılar.....	14
2.3.3.1. İleri Beslemeli Yapay Sinir Ağları	15
2.3.3.2. Geri Beslemeli Yapay Sinir Ağları.....	15
2.4. Judo	16
2.4.1. Judogi (Judo Elbisesi)	17
2.4.2. Kyu (Kuşak) Derecesi.....	18
2.4.3. Dan (Ustalık) Derecesi.....	18
2.4.4. Teknikler	19

2.4.5. Judo Müsabakası	20
3. YÖNTEM.....	23
3.1. Araştırma Modeli	23
3.2. Evren ve Örneklem.....	23
3.3. Veri Toplama Aracı.....	24
3.4. Verilerin Analizi	24
4. BULGULAR	26
4.1. Veri Setinin Hazırlanması	26
4.1.1. Verilerin Temizlenmesi ve Etiketlenmesi.....	27
4.1.2. Doğrudan Kullanılan Veriler	28
4.1.3. Türetilerek Elde Edilen Veriler	30
4.1.4. Veri Tablolarının Oluşturulması	32
4.2. Çok Katmanlı Algılayıcı Modelinin Kurulması	34
4.2.1. Hiperparametreler.....	35
4.2.2. Katmanlar ve Nöron Sayıları	35
4.2.3. Optimizasyon Yöntemleri	35
5. TARTIŞMA, SONUÇ ve ÖNERİLER	42
5.1. Uygulama Sonucunun Genel Değerlendirmesi.....	42
5.2. Öneriler ve İleri Çalışmalar	43
6. KAYNAKLAR.....	44
TEZ DEĞERLENDİRME FORMU	49

ŞEKİLLER LİSTESİ

Şekil 1. Gözetimli Öğrenme Süreç Şeması.....	6
Şekil 2. Gözetimsiz Öğrenme Kümelenme Şeması	7
Şekil 3. Sinir Hücresinin Yapısı (Jarosz, 2009)	8
Şekil 4. Giriş, Gizli ve Çıkış Olmak Üzere Üç Katmana Sahip Yapay Sinir Ağı	9
Şekil 5. Yapay Sinir Hücresi.....	10
Şekil 6. Doğrusal ve Doğrusal Olmayan Problem Gösterimleri.....	13
Şekil 7. Bir giriş, iki gizli, bir çıkış katmanına sahip Çok Katmanlı Algılayıcı modeli.....	14
Şekil 8. Judo Tekniklerinin Sınıflandırılması	20
Şekil 9. 8’lik Sistemde Kura Sonucu Oluşacak Havuz.....	22
Şekil 10. Yıllara Göre Toplam Müsabaka Sayısı.....	26
Şekil 11. En Fazla Sporcu Bulunduran 10 Ülke	30
Şekil 12. 2 Numaralı Modelin Hata Matrisi.....	40

TABLÖLAR LİSTESİ

Tablo 1 Toplama Fonksiyon Çeşitleri.....	11
Tablo 2 Aktivasyon Fonksiyon Çeşitleri	12
Tablo 3 Mantıksal İşlevlerde Algılayıcıdan Beklenen Sonuçlar	13
Tablo 4 Kyu (kemer) derece tablosu.....	18
Tablo 5 Dan (ustalık) derece tablosu	19
Tablo 6 Büyükler ve Gençler Ferdi Müsabaka Ağırlık Kategorileri	21
Tablo 7 Judo Puanlama Tablosu	22
Tablo 9 Turnuva Tipleri ve Müsabaka Sayısı.....	28
Tablo 8 Sporcuların Sıkletlere Göre Dağılımı	29
Tablo 10. Turnuva türleri ve Puan Tablosu	31
Tablo 11 Sporcu Öznitelikleri Ortalama ve Standart Sapma Değerleri.....	33
Tablo 12 Nöron Sayısı ve Optimizasyon Yöntemi Sonuçları.....	37
Tablo 13 Başarım Oranı En Yüksek 5 Modelin Gösterge ve Grafikleri.....	38
Tablo 14 Başarım Oranı En Düşük 5 Modelin Gösterge ve Grafikleri	39
Tablo 15 2 Numaralı Modelin Hassasiyet, Geri Çağırma ve f1 skoru.....	41

SİMGELER VE KISALTMALAR LİSTESİ

ÇKA: Çok Katmanlı Algılayıcılar

UJF: Uluslararası Judo Federasyonu

YSA: Yapay Sinir Ağları

1. GİRİŞ

Bu bölümde; çalışmaya konu olan problem durumu, problem cümlesi, alt problemler, sınırlılıklar, araştırmanın amacı, önemi ve ilgili araştırmalar yer almaktadır.

1.1. Problem Durumu

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, Solieman ve Chen, 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 algorithmadan 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 diğerleri, 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 diğerleri, 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 diğerleri, 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 sıkletler 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).

1.2. Problem Cümlesi

Judo müsabaka sonuçlarının tahmin edilmesinde yapay sinir ağları alt alanında Çok Katmanlı Algılayıcılar (ÇKA) modelinin performansı nasıldır?

1.3. Araştırmanın Amacı

Bu çalışma, sportif ve istatistiki olmak üzere iki tür amaç içermektedir. Sportif açıdan bireysel sporlarda çeşitli yöntem ve teknikler ile müsabaka sonuçlarını tahmin etmeye farklı bir bakış açısı getirmek; istatistiki açıdan ise ÇKA algoritmasının spor müsabakalarında performansına ilişkin bulgulara erişmektir.

1.4. Araştırmanın Önemi

Bu çalışma, YSA ile bireysel maç sonuçlarının tahmin edilmesine yol göstermesi, spor literatürüne katkı sağlaması ve sonraki çalışmalara ışık tutması açısından önemli görülmektedir.

1.5. Varsayımlar

- Bu çalışmanın verileri <https://judobase.ijf.org>'dan alınmıştır, bu verilerin eksiksiz ve doğru olduğu,
- Çalışmada kullanılan örneklemin evrenin tüm özelliklerini taşıdığı ve evreni yeterli oranda temsil ettiği varsayılmıştır.

1.6. Sınırlılıklar

- Çalışma Uluslararası Judo Federasyonunda tarafından 2017:01 2021:03 tarihleri arasında kayıt altına alınan büyükler kategorisinde bulunan sporcularla sınırlandırılmıştır.
- Çalışmada müsabaka verileri karşılaştırılmamıştır. Kadın, erkek ve sıkletler aynı eğitim verisinde kullanılacak şekilde sınırlandırılmıştır.
- Çalışmada kullanılan model Çok katmanlı algılayıcılar ileri beslemeli geri yayılım (Back-Propagation) ağı modeli ile sınırlandırılmıştır.

1.7. Tanımlar

Yapay Sinir Ağı: İnsan beynindekilere benzer, birbirine bağlı nöronlardan veya "düğümlerden" 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: Çok Katmanlı Algılayıcı (ÇKA), diğer YSA tekniklerinde olduğu gibi kategorik (sınıflandırma) veya sürekli (regresyon) bir değişkeni tahmin etmek için kullanılan modeldir (Theobald, 2017).

Judo: Judo, Japonya'nın feodal günlerinden kalma jujitsu üzerine temellendirilmiş fırlatma, boğma, rakibi kontrol altında tutma, kolu veya bacağı acı verecek hatta kırarak şekilde bükme ve burkma tekniklerini uygulama ve bunlardan korunma felsefesidir (Kano, 2005).



2. KURAMSAL ÇERÇEVE

Bu bölümde Yapay Sinir Ağları, Çok Katmanlı Algılayıcılar ve Judo konularına yer verilmektedir.

2.1. Yapay Öğrenme

Yapay öğrenme; verilerden öğrenebilen, optimizasyon ve tekrarlar yoluyla belirli bir soru için "en iyi" analitik çözümü bulabilen algoritmaları kapsamaktadır (Houston, 2018). Bilgisayarların örnek veri ya da geçmiş deneyimi kullanarak başarımı arttıracak biçimde programlanmasıdır (Alpaydin, 2017). Yapay öğrenme algoritmaları; sonuçları açıkça belirtilmeden programlanmış, tahminler veya kararlar almak için "eğitim verileri" olarak bilinen örnek verilere dayalı bir model oluşturur (Koza, Bennett, Andre ve Keane, 1996). Bu modeller ihtiyaç duyulan görevleri gerçekleştirmek için geleneksel algoritmalar geliştirmenin zor veya olanaksız olduğu e-posta filtreleme ve yüz tanıma gibi çok çeşitli uygulamalarda kullanılır. Yapay öğrenmeye yönelik en popüler yaklaşımlardan biri de yapay sinir ağlarıdır (Negnevitsky, 2011).

2.2. Yapay Öğrenme Yaklaşımları


Yapay öğrenme yaklaşımları, öğrenme sistemi tarafından kullanılabilen "sinyal" veya "geri bildirim" in doğasına bağlı olarak üç kategoriye ayrılır:

2.2.1. Gözetimli Öğrenme

Gözetimli öğrenme, çeşitli bağımsız değişkenleri ve istenen çözümü "bağımlı değişkeni" (girdi- çıktı) içeren verilerle çalışır. Hem girdi hem de çıktı değerlerinin bilinmesi, veri

kümesinin "etiketli" olarak nitelendirilmesini sağlar. Algoritma, daha sonra giriş ve çıkış değerleri arasında var olan kalıpları deşifre eder ve bu bilgiyi tahmin yapmak için kullanır (Theobald, 2017). Gözetimli öğrenmede algoritmayı eğittiğimiz veri seti, etiket adı verilen çözümleri içerir (Géron, 2019). Etiketler bir gözetmen tarafından sisteme girilir.

Gözetimli öğrenme süreci, verilerin toplanmasıyla başlar. Gözetimli öğrenim için veriler girdi ve çıktı olmak üzere iki grupta toplanır. Girdi; e-posta mesajları, resimler veya ölçümler gibi herhangi bir değer alabilir. Çıktılar genellikle ikili değerler veya etiketlerden oluşur (ör. "1", "0", "Kedi", "Köpek" vb.) (Burkov, 2019).



Şekil 1. Gözetimli Öğrenme Süreci Şeması

Şekil 1’de ifade edildiği üzere büyük “X” ile bağımsız değişkenler tanımlanırken küçük “y” ile bağımlı değişkenler tanımlanır. Model katmanı ile X matrisi işlenerek bağımlı y vektörü bulunmaya çalışılır.


Gözetimli öğrenmede amaç, girdi ile doğru değeri bir gözetmen tarafından verilen çıktı arasında bir eşleme öğrenmektir (Alpaydin, 2017). Bu araştırmada kullanılan ÇKA algoritması gözetimli öğrenme algoritmalarına bir örnektir.

2.2.2. Gözetimsiz Öğrenme

Gözetimsiz öğrenmede çıktı değişkenleri etiketlenmez, girdi ve çıktı değişkenlerinin arasındaki bağ bilinmez. Algoritmalar girdi değişkenleri arasındaki ilişkileri analiz eder ve olası çıktılarla ilgili yeni etiketler çıkarmaya odaklanır (Theobald, 2017).

Gözetimsiz öğrenmede gözetimli öğrenmenin aksine bir gözetmen yoktur ve elimizde sadece girdi verisi vardır; amaç, girdideki düzenlilikleri bulmaktır (Alpaydin, 2017).

Elimizde limon, mandalina ve portakal meyvelerine ait özellikler bulunmakta, bu özelliklerin kaç meyveye ve hangisine ait olduğu bilinmemektedir. Sistemden, bu özellikleri istatistiki değerlendirerek ortak özellikleri taşıyanların kümelenmesi istenmektedir (Nabiyev, 2016). Bu kümelenmenin sağlanması gözetimsiz öğrenmeye bir örnektir.



Şekil 2. Gözetimsiz Öğrenme Kümelenme Şeması

Şekil 2’de etiketlenmemiş verileri, x_1 ve x_2 verilerine dayalı olarak üç farklı grupta organize etmek için kümelemenin nasıl uygulanabileceğini göstermektedir.

2.2.3. Pekiştirmeli Öğrenme

Pekiştirmeli öğrenmede algoritma eylemleri seçip gerçekleştirebilir ve karşılığında ödüller (negatif ödüller şeklinde cezalar) alabilir. Daha sonra zaman içinde en fazla ödülü almak için politika adı verilen en iyi stratejinin ne olduğunu kendi kendine öğrenir. Politika, belirli bir durumda algoritmanın hangi eylemi seçmesi gerektiğini ifade eder. Deneme yanılma yoluyla geri bildirim alarak ve önceki yinelemelerden elde edilen öngörülerden yararlanarak bir tahmin modeli oluşturur (Géron, 2019).

Pekiştirmeli öğrenmede amaç, çevre ile etkileşimlere dayalı olarak algoritmanın performansını artıran bir sistem geliştirmektir. Algoritma çevre ile etkileşimi sayesinde,

keşif yoluyla bir deneme-yanılma yaklaşımı veya bilinçli planlama yoluyla bu ödülü en üst düzeye çıkaran bir dizi eylemi öğrenmek için pekiştirmeli öğrenmeyi kullanır. Her durum olumlu veya olumsuz bir ödülle ilişkilendirilebilir ve ödül, bir oyunu kazanmak veya kaybetmek gibi genel bir hedefe ulaşmak olarak tanımlanabilir (Raschka ve Mirjalili, 2019).


2.3. Yapay Sinir Ağları

Yapay sinir ağları nörofizyolog Warren McCulloch ve matematikçi Walter Pitts tarafından ilk kez 1943'te tanıtıldı. McCulloch ve Pitts sinir hücresinin karmaşık hesaplamalar yapmak için hayvan beyniyle birlikte nasıl çalışabileceğine dair basitleştirilmiş bir hesaplama modeli sundu (McCulloch ve Pitts, 1943). Bu, ilk yapay sinir ağı mimarisiydi. O zamandan günümüze başka birçok mimari oluşturuldu.

Yapay sinir ağları; insan beynindekilere benzer, birbirine bağlı nöronlardan veya "düğümmlerden" 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)

YSA'ları anlamak için sinir hücresine daha yakından bakmak gerekir. Şekil 3'te gösterildiği üzere biyolojik bir sinir hücresi temelde üç bölgeye ayrılır. Bunlar;

- Soma (Hücre Gövdesi) – Hücreyi denetler ve hücre etkinliklerinin tümünü yönetir.
 - Akson (Axon) – Gövdedeki bilgiyi diğer nöronların dentritlerine taşır.
 - Dentritler – Diğer nöronlardaki bilgileri aksonlardan alarak hücre gövdesine taşır.
- (Nabiyev, 2016).




Şekil 3. Sinir Hücresinin Yapısı (Jarosz, 2009)

Biyolojik nöronlar, beyinde kimyasal ve elektrik sinyallerinin işlenmesi ve iletilmesinde rol alan birbirine bağlı sinir hücreleridir (Raschka ve Mirjalili, 2019).

Tek başına bir nöron oldukça basit bir şekilde davranıyor gibi görünmektedir; ancak her bir nöronun binlercesine bağlı olduğu bir ağda milyarlarca nöron birbiriyle organize olur. Oldukça karmaşık hesaplamalar, oldukça basit nöronlardan oluşan bir ağ tarafından yapılabilir.

YSA, insan beyninden ve beyinde bulunan nöron ağından ilham almıştır. YSA; giriş katmanı, gizli katmanlar ve çıkış katmanı olmak üzere üç katmandan oluşur. Doğrusal olmayan bir istatistiksel veri modelleme aracıdır, girdi ve çıktı arasındaki karmaşık ilişkiyi modelleyebilir (Cao, 2012).




Şekil 4. Giriş, Gizli ve Çıkış Olmak Üzere Üç Katmana Sahip Yapay Sinir Ağı

Şekil 4'te üç katmana sahip YSA temsil edilmiştir. Bu modelde:

- Girdi Katmanı, dış dünyadan gelen bilgileri ara katmanlara taşır. Bazı ağlarda girdi katmanında herhangi bir işlem yapılmaz.
- Ara Katmanlar; girdi katmanından gelen bilgilerin işlenerek çıktı katmanına gönderilmesini sağlar, bir ağ için birden fazla ara katman bulunabilir.
- Çıktı Katmanı, ara katmandan gelen verileri işleyerek çıktı üretir. Üretilen çıktı dış dünyaya gönderilir (Öztemel, 2016).

2.3.1. Yapay Sinir Hücresi

Biyolojik sinir hücrelerine benzer şekilde yapay sinir ağları da sinir hücrelerine sahiptir ve her sinir hücresi beş temel elemandan oluşmaktadır.



Şekil 5. Yapay Sinir Hücresi

2.3.1.1. Girdiler

Girdi ya doğrudan dış dünyadan gelir ya da öteki çıktıları girdi olarak alır (Alpaydin, 2017). Yapay sinir hücresine dış dünyadan, diğer hücrelerden veya kendisinden gelen tüm bilgiler girdi olarak adlandırılır. Bir nöronun çevreyi algılamasına bağlı olarak sınırsız sayıda girişi olabilir fakat her bir nöronun sadece tek bir çıkışı olmak zorundadır (Öztemel, 2016).

2.3.1.2. Ağırlıklar

Ağırlıklar, YSA'larda uzun süreli hafızayı temsil eder. Her bir girdinin gücünü veya başka bir deyişle önemini ifade eder. Bir sinir ağı, bu ağırlıkların tekrar tekrar ayarlanmasıyla "öğrenir" (Negnevitsky, 2011).

Ağırlıklar bir yapay hücreye gelen bilginin önemini ve hücre üzerindeki etkisini gösterir. Önemli olup olmadıkları büyüklük veya küçüklükleri ile belirlenmez; sıfır, pozitif, negatif, değişken veya sabit değerler alabilirler (Öztemel, 2016).

2.3.1.3. Toplama Fonksiyonları

Bütün sinir ağı hücrelerinde giriş değerleri ile ağırlık katsayıları çarpılarak toplanır böylece ağı giren net girdi değeri bulunmuş olur. En yaygın kullanılan toplama fonksiyonu ağırlıklı toplamı bulma fonksiyonudur (Nabiyev, 2016; Öztemel, 2016).







Tablo 1
Toplama Fonksiyon Çeşitleri

Net Giriş	Açıklama
Çarpım	Ağırlık değerleri girdiler ile çarpılır, daha sonra bulunan değerler birbirleri ile çarpılarak net girdi hesaplanır.
Maksimum	N adet girdi ağırlıklar ile çarpıldıktan sonra en büyüğü hücre girdisi olarak kabul edilir.
Minimum	N adet girdi ağırlıklar ile çarpıldıktan sonra en küçüğü hücre girdisi olarak kabul edilir.
Çoğunluk	N adet girdi ağırlıklar ile çarpıldıktan sonra pozitif ve negatif olanlar kümelenir. Büyük küme sayısı net girdi kabul edilir.
Kümülatif Toplam	Hücreye gelen bilgiler ağırlıklı olarak toplanır, daha önce gelen bilgilere eklenerek hücrenin net girdisi bulunur

2.3.1.4. Aktivasyon Fonksiyonları

Aktivasyon fonksiyonları, özellikle yapay sinir ağlarında kullanılır. Girdi, aktivasyon fonksiyonundan geçirilerek bir çıktıya dönüştürülür ve bir sonraki katman bu çıktıyı girdi olarak alır (Sharma, Sharma ve Athaiya, 2020). Bazı modeller aktivasyon fonksiyonunun türevinin alınabilir olması şartını koşmaktadır; bir problem için en iyi fonksiyon, tasarımcının denemeleri sonucunda belirlenir. Günümüzde yaygın olarak kullanılan ÇKA modelinde daha çok sigmoid fonksiyonu kullanılır (Öztemel, 2016).

Tablo 2
Aktivasyon Fonksiyon Çeşitleri

Adı	Çizim	Fonksiyon	Türevi $f'(x)$	Aralık
Birim Fonksiyon		x	1	$(-\infty, \infty)$
Basamak Fonksiyonu		$\begin{cases} 0 & \text{if } x < 0 \\ 1 & \text{if } x \geq 0 \end{cases}$	$\begin{cases} 0 & \text{if } x \neq 0 \\ \text{tanımsız} & \text{if } x = 0 \end{cases}$	$\{0, 1\}$
Sigmoid		$\sigma(x) = \frac{1}{1 + e^{-x}}$	$f(x)(1 - f(x))$	$(0, 1)$
tanh		$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	$1 - f(x)^2$	$(-1, 1)$
ReLU		$\begin{cases} 0 & \text{if } x \leq 0 \\ x & \text{if } x > 0 \end{cases}$	$\begin{cases} 0 & \text{if } x < 0 \\ 1 & \text{if } x > 0 \\ \text{tanımsız} & \text{if } x = 0 \end{cases}$	$[0, \infty)$
Sızıntı ReLU		$\begin{cases} 0.01x & \text{if } x < 0 \\ x & \text{if } x \geq 0 \end{cases}$	$\begin{cases} 0.01 & \text{if } x < 0 \\ 1 & \text{if } x \geq 0 \end{cases}$	$(-\infty, \infty)$
Swish		$\frac{x}{1 + e^x}$	$\frac{1 + e^x + xe^x}{(1 + e^{-x})^2}$	$[-0.278 \dots, \infty)$

Aktivasyon Fonksiyonları (Alpaydin, 2017; Öztemel, 2016)

2.3.1.5. Çıktı


Aktivasyon fonksiyonu tarafından belirlenen değerdir. Üretilen çıktı, dış dünyaya veya başka bir hücreye gönderilir. Hücre kendi çıktısını kendisine girdi olarak da gönderebilir. Aktivasyon fonksiyonundan geçildikten sonra elde edilen sonuca çıktı değeri denilir (Karahana, 2011; Öztemel, 2016).

2.3.2. Algılayıcı

Algılayıcı (perceptron); 1958 yılında Frank Rosenblatt tarafından formüle edilmiş tek katmanlı (gizli katmanı olmayan), en basit YSA mimarilerinden biridir (Rosenblatt, 1958). Bu mimari bir giriş katmanı ve bir çıkış katmanından oluşmaktadır.

İlk YSA modellerinden olan algılayıcı, son derece sınırlı olmalarına karşın daha sonra geliştirilen modellere temel olmaları ve mevcut algoritmalarla yakın ilişki içinde olmaları nedeniyle oldukça önemlidir.

Algılayıcı, temel yapay sinir ağı birimidir. Girdisi ya doğrudan dış dünyadan gelir ya da öteki algılayıcıların çıktılarını girdi olarak alır (Alpaydin, 2017). Doğrusal bir fonksiyonla iki parçaya bölünebilen problemlerde kullanılabilir. Şekil 6’da doğrusal ve doğrusal olmayan problemler görselleştirilmiştir.



Şekil 6. Doğrusal ve Doğrusal Olmayan Problem Gösterimleri

Algılayıcı aşağıdaki lineer formül ile ifade edilir.

$$f(x) = \begin{cases} 1, & \text{eğer } wx + b > 0, \\ 0, & \text{diğer durumlar} \end{cases}$$

$y = Wx + b$; Doğrusal fonksiyonlarda x ifadesi girdilerden oluşan bağımsız değişken, W, b ifadesi fonksiyon parametreleri, y ise x 'in değerine bağlı olduğu için bağımlı değişken olarak tanımlanmaktadır. Algılayıcı doğrusal bir fonksiyon üzerinde çalışır, böylece algılayıcı “VE”, “VEYA”, “DEĞİL” işlevlerine cevap verebilir. Bu durum aşağıdaki tabloda gösterilmiştir.


Tablo 3
Mantıksal İşlevlerde Algılayıcıdan Beklenen Sonuçlar

A	B	A VE B	A VEYA B	A DEĞİL
0	0	0	0	1
0	1	0	1	1
1	0	0	1	0
1	1	1	1	0

Tek bir algılayıcının yetersiz olduğu bazı alanlar vardır fakat birden fazla algılayıcıyı bir arada kullanarak bu problemlerin ortadan kaldırılabileceği keşfedilmiştir. Böylece tek bir katman yerine ağa gizli katmanlar ekleyerek bir tane doğrusal fonksiyon kullanmak yerine birçok doğrusal fonksiyonun birleştirilmesiyle yeni bir model geliştirilmiştir. Ortaya çıkan YSA modeli, çok katmanlı algılayıcılar olarak adlandırılmıştır.

2.3.3. Çok Katmanlı Algılayıcılar

Çok Katmanlı Algılayıcı (ÇKA), diğer YSA tekniklerinde olduğu gibi kategorik (sınıflandırma) veya sürekli (regresyon) bir değişkeni tahmin etmek için kullanılan modeldir (Theobald, 2017). Çok katmanlı bir ağda öğrenme, bir algılayıcı ile aynı şekilde ilerler. Ağda bir eğitim seti girdi olarak verilir. Ağ, çıktı modelini hesaplar ve bir hata varsa -başka bir deyişle beklenen çıktı ile elde edilen sonuç arasında bir fark varsa- ağırlıklar bu hatayı azaltmak için güncellenir. Bir algılayıcıda, her giriş için yalnızca bir ağırlık ve yalnızca bir çıkış vardır. Ancak çok katmanlı ağda, her biri birden fazla çıktıya katkıda bulunan birçok ağırlık vardır (Negnevitsky, 2011). Genel olarak çok katmanlı algılayıcılar, zaman veya hesaplama kısıtlamaları olmaksızın büyük ve karmaşık veri kümelerini yorumlamak için idealdir (Theobald, 2017).



Şekil 7. Bir giriş, iki gizli, bir çıkış katmanına sahip Çok Katmanlı Algılayıcı modeli

Çok katmanlı sinir ağlarının mimarisi, ileri beslemeli yapay sinir ağları olarak adlandırılır çünkü ardışık katmanlar, girdiden çıktıya ileri yönde birbirini besler. İleri beslemeli ağların varsayılan mimarisi, bir katmandaki tüm düğümlerin bir sonraki katmandaki düğümlere bağlı olduğunu varsayar. Bu nedenle sinir ağının mimarisi, katman sayısı ve her katmandaki düğüm sayısı tanımlandıktan sonra ağ neredeyse tamamlanmıştır. Geriye bir tek, çıktı katmanında optimize edilecek kayıp işlevi kalmaktadır (Aggarwal, 2018).

Çok katmanlı algılayıcılar, İleri Beslemeli ve Geri Beslemeli YSA olarak ikiye ayrılır.

2.3.3.1. İleri Beslemeli Yapay Sinir Ağları

İleri beslemeli yapay sinir ağlarında bir katmandaki tüm düğümlerin bir sonraki katmandaki düğümlere bağlı olduğu varsayılır, katmanlar girdiden çıktıya doğru birbirini ileri yönde besler. Genellikle aktivasyon fonksiyonu olarak “sigmoid” kullanılsa da zorunlu değildir, türevi alınabilen bir fonksiyon kullanılabilir. Gizli katmanlarda birden çok katman kullanırken algılayıcı sayısına dikkat edilmesi işlem süreleri açısından önemlidir, “kısa-şışman” bir ağ kullanmaktansa “uzun-ince” ağlar tercih edilmelidir (Aggarwal, 2018; Alpaydin, 2017; Öztemel, 2016).

2.3.3.2. Geri Beslemeli Yapay Sinir Ağları

Geri beslemeli yapay sinir ağları, ağın ağırlıklarını ayarlamak ve mevcut hatayı azaltmak için gerçek ağ çıktısı ile hedef çıktı arasındaki farkı hesaplayarak geriye bildirim gönderir. Buradaki amaç hatanın en aza indirilmesidir. Bu hata hesaplama ve düzeltme işlemi her birim için gerçekleştirilir. Çok katmanlı algılayıcılar girdi, gizli ve çıktı olmak üzere 3 katmandan oluşur. Giriş katmanı bir vektörden girdileri alır. Gizli katman, giriş katmanından gelen verilerle birlikte ağırlık girdisini alır ve bir aktivasyon işlevi kullanarak işler. Gizli katmanda yapılan işlemlerin sonucu, çıktı katmanına bir ağırlık girdisi ile birlikte gönderilir ve işlenir. Çıkış katmanı nöronlarının çıktıları, sinir ağının çıktılarıdır. Çok az gizli nörona sahip bir mimari, kalıpları ayırt edemeyen bir ağla, çok fazla gizli nörona sahip bir mimari, eğitim seti modellerini ezberleyen bir ağla sonuçlanabilir. Geri beslemeli sinir ağında ağ aşığdaki işlem basamaklarına göre güncellenir:

- Her geiş bir devir olarak adlandırılır.
- Bir vektör, ağın giriş katmanına aktarılır. Algoritma daha sonra bu katmandaki tüm nöronların çıktısını hesaplar. Sonuç bir sonraki katmana aktarılır ve son katmanın çıktısı olan çıktı katmanı elde edilene kadar böyle devam eder. Bu ileriye doğru geiş tahmin yapmaya benzer ancak tüm ara sonuçlar geri gelmek için gerekli olduğundan korunur.
- Daha sonra algoritma ağın çıktı hatasını ölçer (yani istenen çıktı ile ağın gerçek çıktısını karşılaştıran ve hatanın bir ölçüsünü veren kayıp işlevi kullanır).
- Daha sonra algoritma, bu hataları ölçer yine zincir kuralını kullanarak algoritma giriş katmanına ulaşana kadar geriye doğru çalışır.
- Son olarak algoritma, hesapladığı hata eğimini kullanarak ağıdaki tüm ağırlıkları ayarlamak için “Eğim İniş” adımı gerçekleştirir (Alpaydin, 2017; Géron, 2019; Öztemel, 2016; Purucker, 1996).

2.4. Judo

Judo, Japonya’nın feodal günlerinden kalma jiu jitsu üzerine temellendirilmiş fırlatma, boğma, rakibi kontrol altında tutma, kolu veya bacağı acı verecek hatta kıracak şekilde bükme ve burkma tekniklerini uygulama ve bunlardan korunma felsefesidir. Üç yüz – üç yüz elli yıl öncesinde bile var olan bu teknikler Jigaro Kano tarafından 1882 yılında sistemli bir şekilde öğreti haline getirilmiştir (Kano, 2005).

Judo, Japonca iki kelimenin birleşiminden meydana gelmektedir. Ju “yumuşak huylu, yol vermek”, do “yol, ilke” anlamına gelmektedir. Buna göre judo, yumuşak huyluluğun yolu veya sonunda zafere ulaşmak için önce yol vermek anlamına gelir (Kano 2005). Judo, yüksek bilinirliğe sahip sporlardan biridir ve dünya çapında kırk milyondan fazla insanın judo yaptığı bilinmektedir (Messner, 2019).

Judoda rakibe acı vererek değil acı sınırlarını zorlayarak üstünlük sağlanır. Judonun temel özelliğı rakibin kuvvetine karşı koymadan, fizik kurallarındaki kaldıraç, moment ve merkezkaç prensiplerini içeren tekniklerle rakibin dengesini bozarak alt etmektir (Karakoç, 2014).

Judonun temel sekiz ahlak prensibi; saygı, dürüstlük, özdenetim, dostluk, nezaket, şeref, cesaret ve alçakgönüllülük olarak belirlenmiştir. Her judo sporcusu mindere girdiğı ilk günden itibaren bu değerler üzerine eğitilmektedir (“Clean Judo / IJF.org”, y.y.).

Judo Olimpiyatlarda ilk kez 1964 yılında Tokyo’da düzenlenen Olimpiyat Oyunlarında erkekler kategorisinde yapılan müsabakalarla temsil edildi. Japonlar dört altın madalyadan üçünün sahibi oldu (Sato, 2013). Kadınlarda ise 1988 yılında gösteri sporu olarak yer alırken 1992 yılında Barselona Olimpiyat oyunlarında ilk defa erkeklerle birlikte yer aldı (Defrantz, 1988; Miarka, Marques ve Franchini, 2011).

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).

2.4.1. Judogi (Judo Elbisesi)

Judogi, Judo antrenmanı ve müsabakası için kullanılan giysiye verilen isimdir. Jigaro Kano tarafından 20. yy. başlarında geleneksel Japon giysisi kimonodan esinlenerek oluşturulmuştur; ceket (uwagi), kemer (obi) ve pantolon (shitabaki) olmak üzere üç parçadan meydana gelir.

Judogi kumaşı rakibin kavraması için çok kalın, çok sert veya kaygan olmamalıdır. Kumaş %70 oranında pamuk ihtiva etmeli, sağlam olmalı zayıf kumaşlar tercih edilmemeli, yıkanıp kuruduktan sonra ağırlığı 700gr/m² ile 1000gr/m² arasında olmalıdır (*Information for IJF Approved Judogi*, 2011).

Judo müsabakaları uzun yıllar boyunca sadece beyaz elbiselerle yapılmıştır. Mavi judogi ilk defa 1997 yılında uluslararası müsabakada kullanılmış ve kabul görmüştür. Bu değişim hem seyircilerin hem de hakemlerin judo müsabakalarında sporcuları ayırt etmeleri ve hareketleri algılamaları açısından önem teşkil etmektedir (Matsumoto, Konno, Hata ve Takeuchi, 2007).

UJF, yarışmalarda giyilecek elbise için standart kurallar getirmiş ve bu kurallar haricindeki elbiseleri müsabakalarda kabul etmemektedir. Kurallara uygun elbiseler “approved” imzalı amblem taşımak zorundadırlar (*Sport and Organisation Rules of the International Judo Federation - Version: 8*, 2020). Müsabaka cetveline göre ismi ilk okunan sporcu beyaz, ikinci okunan sporcu mavi elbiseyle mindere çıkmaktadır.

2.4.2. Kyu (Kuşak) Derecesi

Judoda kemer hem bir nesne hem de güçlü bir semboldür, kemer rengi bir judokanın sahip olduğu teknik seviyeyi temsil etmektedir. Kemer, ceketin önünü kapalı tutmak için kullanılır fakat rengi judo sporcusunun yaşamı boyunca spordaki ilerlemesini gösterir. Judoda siyah kuşak olmak, başkalarının bilmediği şeyleri bilmek demektir. Bugün bildiğimiz haliyle renkli kemerler (beyazdan kahverengiye) 1920’lerin ortalarında İngiltere’de icat edildi, bazı ülkelerde (beyaz-sarı, sarı-turuncu, turuncu-yeşil veya yeşil-mavi) orta dereceleri temsil eden iki tonlu kayışlar tanıtıldı (Messner, 2020). Judoda her 6 ayda bir kyu (kemer) imtihanı yapılarak sporcuların derecesi ölçülür. Beyaz kuşakla başlayan sporcu 7 yaşından itibaren her imtihandan sonra sarı (TJF 2013 yılında beyaz kemer ile sarı kemer arasında beyaz üstü sarı kemer getirmiştir), turuncu, yeşil, mavi ve kahverengi kemere ulaşarak, minderde ulaştığı kemeri takmaya hak kazanır. Judoka 15 yaşına geldiğinde dan (ustalık) sınavına girmeye hak kazanır (*Türkiye Judo Federasyonu Judo Kyu (Kemer) Ve Dan (Ustalık) Sınavları Talimatı*, y.y.).

Tablo 4
Kyu (kemer) derece tablosu

6. Kyu Rokko-Kyu	5. Kyu Go-Kyu	4. Kyu Shi-Kyu	3. Kyu San-Kyu	2. Kyu Ni-Kyu	1. Kyu Ik-Kyu
Beyaz	Sarı	Turuncu	Yeşil	Mavi	Kahverengi
					

2.4.3. Dan (Ustalık) Derecesi

İlk siyah kuşak 15 yaşından itibaren elde edilmektedir. Siyah kuşaktan itibaren alınan her seviyeye dan adı verilmektedir. Siyah kuşak birinci ve beşinci dereceleri kapsar. Kırmızı ve beyaz şeritlere sahip kuşak altı ve sekizinci dereceyi gösterir. Dokuz ve onuncu dereceyi ise kırmızı kuşak ifade eder. (Messner, 2020; *Türkiye Judo Federasyonu Judo Kyu (Kemer) Ve Dan (Ustalık) Sınavları Talimatı*, y.y.). Judo sporcusunun bir Dan alması için sonraki dan seviyesinin derecesi kadar yıl beklemesi gereklidir. Örneğin üçüncü dan’a sahip bir sporcu dördüncü dan’a sahip olmak için 4 yıl beklemektedir. 10. Dan’a sahip olmak isteyen bir sporcunun 54 yıl beklemesi ve çalışması gerekmektedir.


Tablo 5
Dan (ustalık) derece tablosu

1. Dan Sho-dan Siyah 	2. Dan Ni-dan Siyah 	3. Dan San-dan Siyah 	4. Dan Yon-dan Siyah 	5. Dan Go-dan Siyah 
6. Dan Roku-dan Kırmızı- Beyaz 	7. Dan Shichi-dan Kırmızı- Beyaz 	8. Dan Hachi-dan Kırmızı- Beyaz 	9. Dan Ku-dan Kırmızı 	10. Dan Jū-dan Kırmızı 

2.4.4. Teknikler

Judoda çok fazla teknik vardır, bu teknikler uygulamalarına göre üç ana kategoriye ayrılmıştır: Nage-waza (Atma Teknikleri), Katame-waza veya Ne-waza (Minder Üzerinde Yakalama Teknikleri) ve Atemi-waza (Vurma Teknikleri). Nage-waza ve Katame-waza hem antrenmanlarda hem de müsabakalarda kullanılır. Atemi-waza, rakibin hayati noktalarına vurmak veya tekme atmak için kullanılır. Serbest uygulamada kullanıldıklarında tehlikeli olduklarından sadece kata denilen hareketlerin kontrollü yapıldığı gösterilerde uygulanır (Inokuma ve Sato, 1979). Judo teknikleri hem güç hem de beceriyi aynı anda içinde barındırır (Scott ve Bergman, 2018).

Nage-waza (atma teknikleri) kendi içinde Tachi-waza (ayakta teknikler) ve Sutemi-waza (yatarak teknikler) olmak üzere iki kategoriye ayrılır. Tachi-waza ise kendi içinde üç kategoride incelenir bunlar Te-waza (el teknikleri), Koshi-waza (kalça teknikleri) ve Ashi-waza (ayak teknikleri) dır. Sutemi-waza kendini feda ederek yapılan teknikler anlamına gelir kendi içinde iki kategoride incelenir Ma-sutemi-waza (sırt üstü feda etme), Yoko-sutemi-waza (yan yatarak feda etme). Katame-waza (yakalama teknikleri) kendi içinde üç kategoriye ayrılır. Oseakomi-waza (tutma teknikleri), Shime-waza (boğma teknikleri) ve Kansetsu-waza (kıırma teknikleri) dır.



Şekil 8. Judo Tekniklerinin Sınıflandırılması

2.4.5. Judo Müsabakası

Judo, açıkça tanımlanmış bir dizi kurala sahiptir. Bu kurallar diğer spor dallarında olduğu gibi hem olimpiyatlarda hem de dünya şampiyonalarında sporcuların birbiri ile rekabet etmelerine izin verir. Biri beyaz biri mavi judogi giyen iki müsabık minimum 8m x 8m maksimum 10m x 10m ve en az 3 metre güvenlik alanına sahip minder üzerinde rekabet eder. Bir sporcu rakibini atarak, belirli bir süre sırt üstü tutarak, boğarak, eklemlerini kırış pozisyonuna alarak veya rakibin belirli kural ihlalleri yapması durumunda müsabakayı kazanabilir (Sato, 2013; *Sport and Organisation Rules of the International Judo Federation - Version: 8*, 2020).

1900’lü yıllarda Kodokan judonun resmi kurallarını oluşturdu, 1951’de kurulan UJF 1967 yılında kendi kurallarını oluşturdu ve sistemde ikilik meydana geldi. Judo Japonların tekelinden çıkarak uluslararası bir statü kazandı. 1974 yılında UJF judoya “shido (not), chui (dikkat), keikoku (uyarı) ve hansoku-make (diskalifiye)” birikimli ceza sistemi ve başka kurallar getirse de 2012 yılında birikimli ceza uygulamasını kaldırdığını duyurdu (Sato, 2013). Judo kuralları sürekli bir değişim içindedir; müsabaka süresi, izin verilen hareketler, sporcuların aldığı cezalar, puanlar da buna dâhildir. Sporcular kendilerini bu değişime adapte etmektedirler (Gutiérrez-Santiago, Gentico-Merino ve Prieto-Lage, 2019).


Müsabakalar kadınlarda yedi erkeklerde yedi olmak üzere on dört ağırlık kategorisine ayrılmıştır (*Sport and Organisation Rules of the International Judo Federation - Version: 8, 2020*). Ağırlıkları kategorize etmedeki amaç; güç, çeviklik gibi değişkenlerin eşit kullanılması açısından adaleti sağlamaktır. Bununla birlikte judo sporcuları kas kütlelerini arttırarak yağlanmayı azaltırlar böylece sıkletlerindeki zayıf rakiplerine karşı avantaj elde ederler (Artioli ve diğerleri, 2010).

Tablo 6
Büyükler ve Gençler Ferdi Müsabaka Ağırlık Kategorileri

Kadınlar	Erkekler	Tanım
-48 kg	-60 kg	Ekstra hafif sıklet
-52 kg	-66 kg	Yarı hafif sıklet
-57 kg	-73 kg	Hafif sıklet
-63 kg	-81 kg	Yarı orta sıklet
-70 kg	-90 kg	Orta sıklet
-78 kg	-100 kg	Yarı ağır sıklet
+78 kg	+100 kg	Ağır sıklet

Judo müsabakalarında kura çekilişleri yapılarak sporcuların pozisyonları belirlenir. Kuralar müsabaka gününden bir gün önce bilgisayar yardımı ile yapılır. Kuranın amacı her kategorideki en güçlü rakipleri birbirinden ayırmaktır, böylece iyi sporcuların mümkün olduğunca geç bir aşamada birbirleriyle karşılaşması sağlanır. Örneğin en iyi iki sporcu finale kadar, ilk dördü yarı finale kadar ve ilk sekizi çeyrek finale kadar bir araya gelmemelidir. Kurada aynı ülkeden iki sporcu farklı havuzlara atılmaya çalışılır. Eleme grubu sisteminde Şekil 10'da gösterilen yerleşim kurularak kura sonuçları tamamlanır (*Sport and Organisation Rules of the International Judo Federation - Version: 8, 2020*).

- A havuzunda 1 numaralı seri başı sporcu ile 8 numaralı kura sporcusu,
- C havuzunda 2 numaralı seri başı sporcu ile 7 numaralı kura sporcusu,
- D havuzunda 3 numaralı seri başı sporcu ile 6 numaralı kura sporcusu,
- B havuzunda 4 numaralı seri başı sporcu ile 5 numaralı kura sporcusu karşılaşır.



Şekil 9. 8'lik Sistemde Kura Sonucu Oluşacak Havuz

Judoda yapılan tekniğin kusursuzluğu ve rakibin düşüşüne göre puanlama yapılır. Rakip sporcu yapılan teknik sonucu sırt üstü veya köprü pozisyonunda düşmesi durumunda hakem bu tekniği ippon olarak değerlendirecek, sporcu tam puan alarak müsabakayı sonlandıracaktır. Teknikte yapılan kusurlar sonucu rakip sırt üstü düşmekten imtina ederse yarım puan olan waza-ari, yan düşerse çeyrek puan olan yuko alarak müsabakanın devam etmesi sağlanacaktır. Rakibi kontrol altına alarak sırtını yerde tutmak suretiyle 10 saniyeden fazla sürede tutuş yapılırsa tutuş yapılan süreye göre tablo 6'da belirtilen aralıkta puan alınacaktır. UJF tarafından belirlenmiş yasaklı hareketleri yapan sporcu Hansoku-make (diskalifiye) ile cezalandırılacaktır (Karakoç, 2014; Papur, 2014).

Tablo 7
Judo Puanlama Tablosu

Puan	Teknik Puan	Tutuş Süresi	Ceza
Yuko	5	10-14 sn.	1. Shido
Waza-ari	7	15-19 sn.	2. Shido
İppon	10	20 sn.	3. Shido*

* Shido'ların puan değeri yoktur. 4. Shido'yu alan sporcu diskalifiye edilecektir.

3. YÖNTEM

Bu bölümde araştırmanın türü, evren ve örneklem, verilerin toplanması ve verilerin analizi konularına yer verilmektedir.

3.1. Araştırma Modeli

Verilerin duygusal dış etmenlerden etkilenmeden nesnel olarak gözlenip analiz edildiği ve tahminlerde bulunulduğu felsefi bakış açısına nicel bakış açısı denir. Bir sorunu çözmeye, bir durumu geliştirmeye veya iyileştirmeye dönük araştırma-geliştirme çalışmalarına ise uygulamalı araştırmalar denir (Büyüköztürk, Kılıç Çakmak, Akgün, Karadeniz ve Demirel, 2017).

Bu kapsamda bu çalışmada felsefi bakış açısı olarak nicel bakış açısını temel almış, amacına göre uygulamalı araştırma yöntemi kullanılmıştır.

3.2. Evren ve Örneklem

Bir araştırmada iki tür evrenden söz edilir. Hedef evren, ulaşılması hemen hemen imkânsız olan ideal evreni temsil eder. Ulaşılabilir evren ise araştırma için gerçekçi seçimi, ulaşılabilir olanı ifade eder, “araştırmanın evreni” olarak tanımlanır (Büyüköztürk ve diğerleri, 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 alarak 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.

3.3. Veri Toplama Aracı

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.

3.4. Verilerin Analizi

YSA; insan beynindekilere benzer, birbirine bağlı nöronlardan veya "düğümlerden" 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 diğerleri, 2020). Bu araştırmada 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 diğerleri, 2011). Eğitim ve test verilerinin oransal bölünmesi için Scikit-Learn'ün 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 araştırmada 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.


4. BULGULAR

Bu bölümde, uygulanan modelin bulguları ve buldular doğrultusunda açıklamalar yer almaktadır.

4.1. Veri Setinin Hazırlanması

Judo müsabakalarında sonucu tahmin etmek için karşılaşan 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 10. Yıllara Göre Toplam Müsabaka Sayısı

Şekil. 10'daki grafikte, 2017 ve 2021 yılları arasında oynanan müsabakaların kadın erkek dağılımları ve yıllara göre toplamı 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.

4.1.1. Verilerin Temizlenmesi ve Etiketlenmesi

Gözetimli öğrenme, çeşitli bağımsız değişkenleri ve istenen çözümü “bağımlı değişkeni” (girdi- çıktı) içeren verilerle çalışır. Ham olarak internetten alınan veriler, kurulan Çok Katmanlı Algılayıcılar modelinde eğitilmek için uygun değildir. Verilerin bazı işlemlerden geçmesi ve modelin yapısına uygun olması gerekmektedir.

Uluslararası Judo Federasyonu tarafından kaydedilen verilerde bir müsabaka hakkında birçok bilgi bulunmaktadır. Bu bilgiler sporcuların adı, kilosu, uyruğu, fotoğrafı gibi kişisel bilgileri içerirken müsabaka süresi, alınan puanlar, alınan cezalar ve müsabakanın kazananı gibi müsabakaya yönelik bilgiler de içermektedir.

Kurulan modelin sağlıklı, hızlı sonuç üretmesi ve hata vermemesi için ham verilerden sayısal olmayan değerler çıkarılmıştır. Bu değerler içinde sporcuların adı, ülkeleri gibi önemli veriler sayısal değerlere dönüştürülmüş; fotoğrafı, turnuva detay bilgileri gibi bazı değerler veri setinden kaldırılmıştır. Yapılan işlemler sonucu veri setinde kalan öznitelikler Mavi Judogi ID, Beyaz Judogi ID, Kazanan Sporcu ID, Puanlar, Cezalar, Yarışma Adı, Tarih ve Sıklet bilgilerinden oluşmaktadır.

Bağımlı değişkeni oluşturmak için Kazanan Sporcu ID kolonu Mavi Judogi ID kolonu ile eşleştirilerek yeni bir kolon üretilmiş bu kolon Müsabaka Sonucu olarak kaydedilmiştir. Müsabaka sonucu kolonu her iki kolondaki değer birbirine eşitse 1 (bir) değilse 0 (sıfır) değerini almıştır.

Turnuva isimlerinin yer aldığı veri kolonu Turnuva Tipi adlı kolona dönüştürülmüştür. Dönüşümde turnuva tipi anahtar kelime olarak kabul edilmiş, turnuva isimleri veri setinden kaldırılmıştır. Türetilerek elde edilen veriler kısmında bahsedilen Sporcu başarı sırası oluştururken sporcunun kazandığı ve kaybettiği müsabakalardan aldıkları puanlar Turnuva Tipi kolonuna göre hesaplanmıştır.

Tablo 8
Turnuva Tipleri ve Müsabaka Sayısı

Turnuva Tipi	Müسابaka Sayısı
Open	14913
Prix	11091
Cup	10457
Slam	9675
Championship	4501
World Championship	1667
Masters	1453
Toplam	53775

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.

4.1.2. Doğrudan Kullanılan Veriler

Müسابaka Sonucu

Müسابaka sonucu verisi aynı zamanda çalışmanın bağımlı değişkenidir. Mavi judogi giyen sporcunun kazanması durumunda müsabaka sonucu 1 (bir), beyaz judogi giyen sporcunun kazanması durumunda 0 (sıfır) değerini alır.

Sıklet

Sıklet, özniteliği veri setinde işleme maruz kalmadan doğrudan kullanılan bağımsız değişkenlerden biridir. Ölçek türü olarak sınıflama kategorisindedir. Kadınlarda 48 kg, 52 kg, 57 kg, 63 kg, 70 kg, 78 kg, +78 kg olmak üzere yedi; erkeklerde 60 kg, 66 kg, 73 kg, 81 kg, 90 kg, 100 kg, +100 kg olmak üzere yedi toplamda on dört farklı sıklet mevcuttur.

Tablo 9
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
	Toplam	2780	35,8
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
	Toplam	4978	64,2
Toplam		7758	100,0%

Buna göre Tablo 8’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.

Ülke

Veri setinde toplam 182 ülkeden sporcu katılımı mevcuttur. Ülke verisi bağımsız değişkendir ve sınıflama ölçek türü olarak veri setinde yer almaktadır.



Şekil 11. En Fazla Sporcu Bulunduran 10 Ülke

Şekil 11’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.

4.1.3. Türetilerek Elde Edilen Veriler

Sporcunun Başarı Sıra Listesi

Uluslararası Judo Federasyonu başarılı sporcuların çekilen kurada birbirleriyle karşılaşmaması için bir başarı sıralama listesi oluşturmuştur. Bu sıralama listesi “*World Ranking List*” olarak geçmektedir. Sistem her ne kadar başarılı gözükse de her sıklette sadece ilk 100 sporcu toplamda 1400 sporcu için hesaplanır. Bu çalışmada 7758 sporcu

verisi olduğu için UJF'nin oluşturduğu sıralama sistemini kullanmak mümkün değildir. Bu sebeple Başarı Sıra Listesi adında bir alan oluşturulmuş ve her sporcu için başarı puanı hesaplanmıştır. Hesaplamalar yapılırken UJF'nin kural kitabından faydalanılmıştır.

UJF kural kitabında 7 farklı turnuva türüne katılım ve derece puanı vermektedir (*Sport and Organisation Rules of the International Judo Federation - Version: 8, 2020*). Kural kitabındaki puanlama baz alınarak bu çalışmadaki sisteme göre yeniden düzenlenmiştir.

Sporcular katıldığı müsabaka türlerine göre kazandığı ve kaybettiği olmak üzere iki durumda da puan kazanmış ve bu puanların toplanması sonucu bir sıralama listesi oluşmuştur.

Tablo 10.
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

Toplam Müsabaka Sayısı

Her bir sporcunun bireysel olarak yaptığı müsabakaların toplamını ifade etmektedir. Toplam müsabaka sayısı veri setinde olmayıp türetilerek elde edilmiştir. Bağımsız ve eşit oranlı bir ölçektir.

Kazanma Oranı

Her bir sporcunun kazandığı müsabaka sayısının toplam müsabaka sayısına bölünmesiyle elde edilir. Bağımsız ve eşit oranlı bir ölçektir.

Kazandığı Toplam Puan Ortalaması

Tüm müsabakalarda elde ettiği (Ippon-Waza-ari-Yuko) puanlarının yaptığı müsabaka sayısına bölünmesiyle elde edilir.

Kaybettiği Toplam Puan Ortalaması

Tüm müsabakalarda rakibine verdiği (Ippon-Waza-ari-Yuko) puanlarının yaptığı maç sayısına bölünmesiyle elde edilir.

Kazandığı Toplam Ceza Puanı Ortalaması

Tüm maçlarda elde ettiği ceza puanlarının yaptığı maç sayısına bölünmesiyle elde edilir.

Kaybettiği Toplam Ceza Puanı Ortalaması

Tüm maçlarda kaybettiği ceza puanlarının yaptığı maç sayısına bölünmesiyle elde edilir.

Son 3 Maç Kazanma Oranı

Son 3 maçta kazandığı maç sayısının 3'e bölünmesiyle elde edilir.

Son 3 Maç Kazandığı Toplam Puan Ortalaması

Son 3 maçta elde ettiği (Ippon-Waza-ari-Yuko) puanlarının 3'e bölünmesiyle elde edilir.

Son 3 Maç kaybettiği toplam puan ortalaması

Son 3 maçta kaybettiği (Ippon-Waza-ari-Yuko) puanlarının 3'e bölünmesiyle elde edilir.

Son 3 Maç Kazandığı Toplam Ceza Puanı Ortalaması

Son 3 maçta elde ettiği ceza puanlarının 3'e bölünmesiyle elde edilir

Son 3 Maç Kaybettiği Toplam Ceza Puanı Ortalaması

Son 3 maçta kaybettiği ceza puanlarının 3'e bölünmesiyle elde edilir.

4.1.4. Veri Tablolarının Oluşturulması

Doğrudan ve türetilerek elde edilen veriler, her sporcuya ait kimlik bilgisi öncelikli anahtar olacak şekilde yeniden yapılandırılmıştır. Sporcuların temel bilgileri tek bir satıra indirgenmiş, istenilen zamanda yeniden erişilmesinin yolu açılmıştır. Bu yöntemle istenilen iki sporcu birbiri ile daha önce karşılaşmamış olsa dahi önceki müsabakalarından elde edilen veriler müsabaka sonucu tahmini yapmaya yeterlidir.

Tablo 11
Sporcu Öznitelikleri Ortalama ve Standart Sapma Değerleri

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

Tablo 11’de her bir sporcu için tutulan öznitelikler detaylı şekilde verilmiştir.

4.2. Çok Katmanlı Algılayıcı Modelinin Kurulması

Çalışmada ileri beslemeli geri yayılım (Back-Propagation) ağı kullanılmıştır hem doğrusal hem de doğrusal olmayan modellerdeki tahmin başarısı yüksek bir mimaridir. Ayrıca kullanım kolaylığı ve yakınsama hızı da bu ağ modelinin seçilmesindeki etkenlerden biridir. Model, Python programlama dili ile programlanmış TensorFlow kütüphanesi üzerinde Keras arayüzü ile kurulmuştur.

Veriler modele aktarılmadan önce ölçeklendirme işleminden geçirilmiştir. Veri setindeki değerlerin dağılımının düzenli hale getirilmesi modelin performansını olumlu yönde etkilemektedir. Çalışmada verileri ölçeklendirmek için Min-Max yöntemi kullanılmıştır. Min-Max yönteminin amacı bir özneliğin içerisindeki en büyük ve en küçük değeri baz alarak öznelikteki diğer verileri en küçük 0 ve en büyük 1 olacak şekilde ölçeklendirmektir.

$$x' = \frac{x_i - x_{min}}{x_{max} - x_{min}}$$

Bu eşitlikte; x' = Ölçeklendirilmiş veriyi, x_i = Girdi değerini, x_{min} = Girdi seti içerisinde yer alan en küçük sayıyı, x_{max} = Girdi seti içerisinde yer alan en büyük sayıyı ifade etmektedir (Yavuz ve Deveci, 2012).

Yapay sinir ağları ve özellikle gözetimli öğrenme uygulamaları işaretlenmiş veriden öğrenmektedir. Eğitilen modelin başarısını test etmek amacıyla veri setinin bir kısmı ayrılmaktadır. Veri setini ayırmak teorikte çok pratiktir. SciKit Learn kütüphanesi içerisinde yer alan (train_test_split) fonksiyonu ve (test_size=...) parametresine gönderilen değer veri setini istenilen oranda test için ayırmaktadır. Çalışmada Eğitim seti veri setinin %70'ini oluştururken verilerin %10'u doğrulama verisi %20'si ise test verisi olarak kullanılmıştır.

TensorFlow kütüphanesi üzerinde çalışan Keras uygulama arayüzü ile 3 farklı model oluşturulmuştur. İlk model tek gizli katmanlı ve 64 nöronludur; ikinci model iki gizli katmanlı ilk gizli katmanı 32, ikinci gizli katmanı 64 nöron içermektedir; üçüncü model üç gizli katmana sahip ilk gizli katmanı 64, ikinci gizli katmanı 128, üçüncü gizli katmanı 64 nöron içermektedir. Her bir modelin eğitilmesinde giriş ve gizli katmanlarda ReLU aktivasyon fonksiyonu çıkış katmanında ise sigmoid aktivasyon fonksiyonu kullanılmıştır. Modelin döngü sayısı 100 olarak belirlenmiştir. Her üç model de 7 farklı optimizasyon yöntemine tabi tutulmuştur.

4.2.1. Hiperparametreler

Bir sinir ağının mimarisi, düzenlemesi ve optimizasyonu hiperparametre seçimine geniş oranda bağlıdır. Hiperparametrelerin ayarlanması, karmaşık ve dikkatle tasarlanmış yapıya sahip bir model için önem arz etmektedir. Yaygın kullanılan modellerde, araştırmacılar önceki çalışmalardan örnek alabileceğinden, hiperparametreler elle ayarlanabilmektedir (Altun ve Talu, 2020).

Önemli Hiperparametreler şu şekilde sıralanabilir:

- Öğrenme Oranı (Optimizasyon yönteminin varsayılan değeri kullanılmıştır)
- Kayıp Fonksiyonu (Optimizasyon yönteminin varsayılan değeri kullanılmıştır)
- Eğitim Yineleme Sayısı (100)
- Gizli Katman Sayısı (64, 32-63, 64-128-64)
- Aktivasyon Fonksiyonu (Giriş ve gizli katman ReLU, çıkış katmanı sigmoid)
- Optimizasyon yöntemi (SGD, Adagrad, Adadelata, RMSprop, Adam, Adamax, Nadam)(Raffel, 2015)

Sinir ağlarının en iyi duruma getirilmesi için birçok hiperparametre bulunmaktadır. Bu çalışmada modelin performansını test etmek için gizli katman ve nöron sayısı ve optimizasyon yöntemi hiperparametreleri karşılaştırılacaktır.

4.2.2. Katmanlar ve Nöron Sayıları

Çoğu sorun için tek bir gizli katman ile makul sonuçlar elde etmek mümkündür. Tek gizli katmana sahip bir ÇKA, yeterli nörona sahip olması koşuluyla en karmaşık işlevleri bile teorik olarak modelleyebilir. Giriş ve çıkış katmanlarındaki nöron sayıları elimizdeki veri türüne göre şekillenir. Gizli katmanda bulunan nöron sayısı belirlemek için nöron sayısını kademeli olarak arttırmak çok kullanılan bir yöntemdir (Géron, 2019).

4.2.3. Optimizasyon Yöntemleri

Çok Katmanlı Algılayıcı modelleri, ileri beslemeli geri yayılım algoritması ile çalışmaktadır. Geri yayılım algoritmasının çalışma prensibi temel olarak şu şekildedir: Birinci aşamada değişkenler eğitim ağına sunulur, her bir nöron için bir ağırlık değeri belirlenir. Değişkenler

ağırlıklar ile çarpılıp bias ile toplandıktan sonra bir aktivasyon fonksiyonu ile çarpılmak üzere bir sonraki katmanda bulunan nöronlara aktarılır. Çıkış katmanında benzer işlemler gerçekleştirildikten sonra bir çıktı değeri elde edilerek çıktı ile gerçek değer karşılaştırılır ve hata değeri elde edilir. İkinci aşamada çıkış katmanından elde edilen hatalar geriye doğru diğer katmanlara yayılır. Bu hatalar, ağıdaki ağırlıklara göre kayıp işlevinin eğimini hesaplamak için kullanılır. Daha sonra kayıp fonksiyonunu (hatayı) en aza indirmek amacıyla ağırlıkları güncellemek için **optimizasyon yöntemi** kullanılır (Li, 2017; Ser ve Bati, 2019).

Optimizasyon, ağıın ürettiği çıkış değeri ile gerçek değer arasındaki farkı yani hatayı en aza indirmek için kullanılan yöntemlerdir. Gradyan inişi yöntemini esas alan çeşitli (Rmsprop, Adagrad, Adam, Nadam) yöntemler mevcuttur (Géron, 2019).

SGD (Olasılıksal Eğim Düşümü): Bu yöntem ile tüm eğitim verisi yerine her eğitim örneği için bir güncellemesi yapılır.

Adagrad: Her parametrenin kendi öğrenme hızı vardır ve güncelleme işleminde öğrenme katsayısı değerinin bölüldüğü ifadenin eğitim süresince büyümeye devam etmesi sonucunda öğrenme katsayısı aşırı küçülmektedir.

Adadelta: Önceki öğrenme karelerini hafızada tutmak yerine geçmiş tüm öğrenme karelerinin ortalamasını tutar. Adagrad'ın aşırı derecede azalan öğrenme oranını düzeltmek ihtiyacıyla geliştirilmiştir.

RMSprop: Adagrad algoritmasında öğrenme katsayısının aşırı derecede azalması sorununa bir çözüm yolu olarak geliştirilmiştir. Adagrad'daki geçmiş bütün eğimlerin karelerinden elde edilen değerlerin tamamını kullanmak yerine değer miktarını belli bir çerçeve boyutu ile kısıtlamıştır.

Adam: Adadelta ve RMSprop gibi geçmiş eğilimlerin karelerinin üstel olarak ortalamasını depolar.

Adamax: Adam güncelleme kuralındaki eğimi, önceki eğimlerin normuna ters orantılı olarak ölçeklendirir











Nadam: Nadam, Adam ve NAG yöntemlerinin birleşiminden oluşmaktadır. NAG algoritmasını Adam algoritmasına dahil etmek için momentum ifadesinde değişiklik yapılarak sonuçta mevcut güncelleştirme kuralı elde edilir (Ruder, 2016).

Tablo 12
Nöron Sayısı ve Optimizasyon Yöntemi Sonuçları

Gizli Katman ve Nöron Sayısı	Model Numarası	Optimizasyon Yöntemi	Doğruluk Oranı	Hata Oranı
1 Gizli Katman 64 Nöron	1	SGD	0.7792	0.4476
	2	RMSprop	0.7860	0.4440
	3	Adam	0.7778	0.4420
	4	Adadelta	0.7469	0.5169
	5	Adagrad	0.7724	0.4615
	6	Adamax	0.7834	0.4402
	7	Nadam	0.7851	0.4518
2 Gizli Katman 32, 64 Nöron	8	SGD	0.7828	0.4465
	9	RMSprop	0.7809	0.4653
	10	Adam	0.7778	0.4420
	11	Adadelta	0.7412	0.5183
	12	Adagrad	0.7750	0.4578
	13	Adamax	0.7859	0.4425
	14	Nadam	0.7812	0.4578
3 Gizli Katman 64, 128, 64 Nöron	15	SGD	0.7831	0.4442
	16	RMSprop	0.7836	0.5141
	17	Adam	0.7624	0.6015
	18	Adadelta	0.7610	0.4790
	19	Adagrad	0.7755	0.4552
	20	Adamax	0.7744	0.4828
	21	Nadam	0.7608	0.5719











Tablo 12'ye göre tek gizli katmanlı RMSprop optimizasyon yöntemine sahip 2 numaralı model (doğruluk=0.7860, hata=0.4440), iki gizli katmanlı Adamax optimizasyon yöntemine sahip 13 numaralı model (doğruluk=0.7859, hata=0.4425) ve üç gizli katmanlı RMSprop optimizasyon yöntemine sahip 16 numaralı model (doğruluk=0.7836, hata=0.5141) kendi gizli katman gruplarında en başarılı model olarak belirlenmiştir. Bir gizli katmanlı 4 numaralı model (doğruluk=0.7469, hata=0.5169), iki gizli katmanlı 11 numaralı model (doğruluk=0.7412, hata=0.5183), üç gizli katmanlı 21 numaralı model (doğruluk=0.7608, hata=0.5719) kendi gizli katman gruplarında en başarısız model olarak belirlenmiştir. Modeller incelendiğinde (0.76-0.79) aralığında performans göstermektedir.

Tablo 13
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 13'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 başarımlar oranı 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 başarımlar sağlamıştır.

Tablo 14
Başımlar Oranı En Düşük 5 Modelin Gösterge ve Grafikleri

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

Tablo 14'e 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 başarımları göstermiştir. Nadam ve Adam yöntemleri ise üç gizli katmanlı modelde düşük başarımları göstermiştir. Üç gizli katmanlı tasarım 3 optimizasyon yöntemi ile başarımları en düşük modeldir. Grafikler incelendiğinde üç gizli katmana sahip modelin aşırı eğitilmiş olduğunu görmekteyiz.



Şekil 12. 2 Numaralı Modelin Hata Matrisi

Şekil 12’de Başarımları 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.

$$\text{Doğruluk} = \frac{\text{Doğru Pozitif} + \text{Doğru Negatif}}{N} = \frac{5366 + 3082}{10755} = 0.78$$

$$\text{Hassasiyet} = \frac{\text{Doğru Pozitif}}{\text{Doğru Pozitif} + \text{Yanlış Pozitif}} = \frac{5366}{5366 + 883} = 0.86$$

$$\text{Geri Çağırma} = \frac{\text{Doğru Pozitif}}{\text{Doğru Pozitif} + \text{Yanlış Negatif}} = \frac{5366}{5366 + 1424} = 0.79$$

$$f1 - \text{skoru} = \frac{2 \times \text{Geri Çağırma} \times \text{Hassasiyet}}{\text{Geri Çağırma} + \text{Hassasiyet}} = \frac{2 \times 0.79 \times 0.86}{0.79 + 0.86} = 0.82$$

Tablo 15
2 Numaralı Modelin Hassasiyet, Geri Çağırma ve f1 skoru

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

Tablo 15’te 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 sporcuyu ilk isim olarak okumasından kaynaklanmaktadır.

5. TARTIŞMA, SONUÇ VE ÖNERİLER

Bu bölümde, tartışma, sonuç ve geliştirilen öneriler yer almaktadır.

5.1. Uygulama Sonucunun Genel Değerlendirmesi

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, Adadelat yönteminin ise daha başarısız olduğu belirlenmiştir (Tablo 13 ve 14).

Literatür taraması yapıldığında Judo verileri ile müsabaka sonucu tahmini yapan bir yapay sinir ağı modeli bulunamamıştır. Doğrusal modellerle yapılan çalışmalarda %26 doğrulukla puan tahmini yapmaktadır (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).

5.2. Öneriler ve İleri Çalışmalar

- 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 karşılaştırılıp Maç fikstürü oluşturulurken güçlü iki sporcunun karşılaşmasının önüne geçmede yeni bir yöntem olarak kullanılabilir.
- Kazanma durumu ortaya koyan bir durumda yüksek doğruluk veren sonuçlar alınabilir.

İleride yapılacak çalışmalarda;

- Her bir sporcu için oluşturulan öznelikler 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.

6. KAYNAKLAR

- Aggarwal, C. C. (2018). *Neural Networks and Deep Learning. A Textbook*. Springer.
- Alpaydin, E. (2017). *Yapay Öğrenme*. (E. Kocabıyık, Ed.) (3. bs.). İstanbul: Boğaziçi Üniversitesi Yayınevi.
- Altun, S. ve Talu, M. F. (2020). Derin Sinir Ağları için Hiperparametre Metodlarının ve Kitlerinin İncelenmesi. *DÜMF Mühendislik Dergisi*, 12(2), 187–199. doi:10.24012/dumf.767700
- Artioli, G. G., Iglesias, R. T., Franchini, E., Gualano, B., Kashiwagura, D. B., Solis, M. Y., ... Junior, A. H. L. (2010). Rapid weight loss followed by recovery time does not affect judo-related performance. *Journal of Sports Sciences*, 28(1), 21–32. doi:10.1080/02640410903428574
- 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.
- Burkov, A. (2019). *The Hundred-Page Machine Learning Book*. Andriy Burkov.
- Büyüköztürk, Ş., Kılıç Çakmak, E., Akgün, Ö. E., Karadeniz, Ş. ve Demirel, F. (2017). *Bilimsel araştırma yöntemleri*. Pegem Akademi Yayıncılık. Ankara:Pegem Akademi Yayıncılık. doi:10.14527/9789944919289
- Cao, C. (2012). Sports data mining technology used in basketball outcome prediction. *Dublin Institute of Technology*.
- Clean Judo / IJF.org. (y.y.). 6 Şubat 2021 tarihinde <https://www.ijf.org/cleanjudo> adresinden erişildi.

- Defrantz, A. L. (1988). Women and Leadership in Sport. *Journal of Physical Education, Recreation & Dance*, 59(3), 46–48. doi:10.1080/07303084.1988.10606223
- Developers, T. (2021). TensorFlow. doi:10.5281/ZENODO.4758419
- Franchini, E. ve Julio, U. F. (2015). The Judo World Ranking List and the Performances in the 2012 London Olympics. *Asian Journal of Sports Medicine*, 6(3). doi:10.5812/asjsm.24045
- 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.
- Gutiérrez-Santiago, A., Gentico-Merino, L. A. ve Prieto-Lage, I. (2019). Detection of the technical-tactical pattern of the scoring actions in judo in the men's category of –73 kg. *International Journal of Performance Analysis in Sport*, 19(5), 778–793. doi:10.1080/24748668.2019.1655934
- 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. doi:10.1038/s41586-020-2649-2
- 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. doi:10.1109/MCSE.2007.55
- Information for IJF Approved Judogi*. (2011).
- Inokuma, I. ve Sato, N. (1979). *Best Judo*. Tokyo: Kodansha International.
- Jarosz, Q. (2009). Sinir Hücresinin Yapısı. 9 Aralık 2020 tarihinde https://tr.wikipedia.org/wiki/Sinir_hücresi#/media/Dosya:Neuron_Hand-tuned.svg adresinden erişildi.
- Kano, J. (2005). *Judo (Jujutsu)*. (S. Tüzün, Ed.). Okyanus Yayıncılık.
- Karahan, M. (2011). İstatistiksel tahmin yöntemleri: Yapay sinir ağları metodu ile ürün talep tahmini uygulaması, 209.

- Karakoç, Ö. (2014). *Judo Öğreniyorum*. Ankara: Spor Yayınevi ve Kitabevi.
- Koza, J. R., Bennett, F. H., Andre, D. ve Keane, M. A. (1996). Automated Design of Both the Topology and Sizing of Analog Electrical Circuits Using Genetic Programming. *Artificial Intelligence in Design '96* içinde (ss. 151–170). Dordrecht: Springer Netherlands. doi:10.1007/978-94-009-0279-4_9
- Li, P. (2017). Optimization Algorithms for Deep Learning, 1–10. <https://www.algorithms.com/deep/learning/optimization/> adresinden erişildi.
- Matsumoto, D., Konno, J., Hata, S. ve Takeuchi, M. (2007). Blue Judogis may Bias Competition Outcomes. *Research Journal of Budo*, 39(3), 1–7. doi:10.11214/budo1968.39.3_1
- McCulloch, W. S. ve Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4), 115–133. doi:10.1007/BF02478259
- Messner, N. (2019). Judo Celebrates the Planet. 15 Ekim 2020 tarihinde <https://www.ijf.org/news/show/judo-celebrates-the-planet> adresinden erişildi.
- Messner, N. (2020). The Belt: Myth and Reality of an Essential Symbol / IJF.org. 7 Şubat 2021 tarihinde <https://www.ijf.org/news/show/the-belt-myth-and-reality-of-an-essential-symbol> adresinden erişildi.
- Miarka, B., Marques, J. B. ve Franchini, E. (2011). Reinterpreting the history of women's judo in Japan. *International Journal of the History of Sport*, 28(7), 1016–1029. doi:10.1080/09523367.2011.563633
- Nabiyev, V. V. (2016). *Yapay Zeka: İnsan - Bilgisayar Etkileşimi* (5. bs.). Ankara: Seçkin Yayıncılık.
- Negnevitsky, M. (2011). *Artificial Intelligence: A Guide to Intelligent Systems (3rd Edition)* (3. bs.). Addison Wesley.
- Öztemel, E. (2016). *Yapay Sinir Ağları* (4. bs.). İstanbul: Papatya Yayıncılık Eğitim.
- pandas - Python Data Analysis Library. (y.y.). 14 Şubat 2021 tarihinde <https://pandas.pydata.org/> adresinden erişildi.
- Papur, F. (2014). *Hakem El Kitabı*. Ankara: Türkiye Judo Federasyonu.

- 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.
- Purucker, M. C. (1996). Neural network quarterbacking. *IEEE Potentials*, 15(3), 9–15. doi:10.1109/45.535226
- Raffel, C. (2015). Neural Network Hyperparameters. 25 Mayıs 2021 tarihinde http://colinraffel.com/wiki/neural_network_hyperparameters adresinden erişildi.
- Raschka, S. ve Mirjalili, V. (2019). *Python Machine Learning: Machine Learning and Deep Learning with Python, scikit-learn, and TensorFlow 2, 3rd Edition*. Packt Publishing.
- Rosenblatt, F. (1958). The Perceptron: A Probabilistic Model For Information Storage And Organization in The Brain. *Psychological Review*, 65(6), 386–408.
- Ruder, S. (2016). An overview of gradient descent optimization algorithms, 1–14. <http://arxiv.org/abs/1609.04747> adresinden erişildi.
- Sato, S. (2013). The sportification of judo: Global convergence and evolution. *Journal of Global History*, 8(2), 299–317. doi:10.1017/S1740022813000235
- Schumaker, R. P., Solieman, O. K. ve Chen, H. (2010). *Sports Data Mining*. Integrated Series in Information Systems (1. bs., C. 26). Boston, MA: Springer US. doi:10.1007/978-1-4419-6730-5
- Scott, S. ve 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. ve 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. doi:10.29133/yyutbd.505086
- Sharma, S., Sharma, S. ve Athaiya, A. (2020). Activation Functions in Neural Networks. *International Journal of Engineering Applied Sciences and Technology*, 04(12), 310–316. doi:10.33564/ijeast.2020.v04i12.054
- 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.

Türkiye Judo Federasyonu Judo Kyu (Kemer) Ve Dan (Ustalık) Sınavları Talimatı. (y.y.).

urllib — URL handling modules — Python 3.8.2 documentation. (y.y.). 14 Şubat 2021 tarihinde <https://docs.python.org/3.8/library/urllib.html> adresinden erişildi.

What is Python? Executive Summary | Python.org. (y.y.). 28 Şubat 2021 tarihinde <https://www.python.org/doc/essays/blurb/> adresinden erişildi.

Yavuz, S. ve Deveci, M. (2012). İstatistiksel Normalizasyon Tekniklerinin Yapay Sinir Ağı Performansına Etkisi. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 40, 167–187.



TEZ DEĞERLENDİRME FORMU		
Öğrencinin Adı Soyadı: Ömer DEĞER		EVET
Kapak		
1	Tez Başlığı tutanaktaki başlıkla aynı mı?	
2	Kapaktaki ay ve yıl savunmaya girilen tarihle tutarlı mı?	
3	Kapak format kılavuzdaki kapak formatına uygun mu?	
4	Kapakta yazılan tüm yazılar doğru olarak verilmiş mi?	
İçindekiler		
5	Sayfa numaraları tam verilmiş mi?	
6	Şekil, Çizelge vb. listeleri verilmiş mi? Sıralaması doğru mu?	
7	Özet, Abstract, Giriş, Sonuçlar vb. bölümler var mı?	
8	Yazım hataları kontrolü yapıldı mı?	
Giriş		
9	Hazırlanan tezin önemini anlatıyor mu?	
10	İkinci ve Üçüncü dereceden başlık içermemeli kuralına uyuldu mu?	
Özet/Abstract		
11	Kılavuza uygun mu?	
12	Ay ve yıl savunmaya girilen tarihle tutarlı mı?	
13	Özet; tek sayfa, tek aralık, tek paragraf kuralına uygun olarak yazıldı mı?	
14	Bilim kodu, sayfa adedi, anahtar kelimeler ve tez danışmanı yazıldı mı?	
Kaynakça		
15	Kaynakların tamamına metin içinde atıf yapıldı mı?	
16	Kaynak formatı Kılavuzdaki kaynak formatına uygun olarak hazırlanmış mı?	
17	Atıf formatı kılavuzdaki atıf formatına uygun mu?	
Atıf Yöntemi APA 6 ☐ CMS ☐ İSNAD ☐		
Genel Değerlendirme		
18	Etik Beyan açıklaması okundu, uyuldu ve imzalandı mı?	
19	Kabul/Onay sayfası kılavuzdaki formata uygun olarak düzenlenmiş mi?	
20	Kabul /Onay sayfasında belirtilen oy birliği/oy çokluğu seçeneklerinden uygun olanı savunmayla tutarlı olacak şekilde belirlenmiş mi?	
21	Sayfa kenar boşluklar ve sayfa numaraları kılavuzdaki formatına uygun mu?	
22	Paragraf boşlukları ve metin satır aralığı kılavuza uygun olacak şekilde düzenlenmiş mi?	
23	Başlık yazımları kılavuzdaki başlık formatlarına uygun mu?	
24	Yazı tipi ve boyutu kılavuzdaki yazı tipi ve boyutu formatına uygun mu?	
25	Şekil, Çizelge vb. açıklama ve numaralandırmaları kılavuzdaki formata uygun olarak yazılmış mı?	

Bu tezin tarafımdan “Tez yazım kuralları” okunarak dikkatlice hazırlanmış olduğunu ve doğabilecek her türlü olumsuzluktan sorumlu olacağımı kabul ederim.

Öğrencinin imzası