




# Makine Öğrenmesi Teknikleri ile Counter-Strike: Global Offensive Raunt Sonuçlarının Tahminlenmesi

Vahid Sinap<sup>1\*</sup> 

<sup>1</sup>Ufuk Üniversitesi, Yönetim Bilişim Sistemleri Bölümü, Ankara, Türkiye

vahidsinap@gmail.com

## Öz

Kamuya açık şekilde sunulan yapılandırılmış ve yapılandırılmamış büyük miktarlardaki verilerle birlikte Esport tahminlemeleri üzerine yapılan çalışmalar her geçen gün artmaktadır. Esport etkinliklerine yönelik tahminleme çalışmaları insan faktöründen büyük ölçüde etkilense de doğru çıktılara ulaşmada önemli birçok parametre sunan yapıyla tahminlemelerin başarısını artırmaktadır. Bu bağlamda modellerin nasıl oluşturulacağı ve hangi makine öğrenmesi algoritmalarının seçileceği önem taşımaktadır. Bu çalışmada, Counter-Strike: Global Offensive adlı çevrimiçi oyundaki rauntların sonuçlarının tahminlemeye yönelik çeşitli makine öğrenmesi algoritmaları kullanılarak sınıflandırmalar gerçekleştirilmiştir. Araştırmada, Lojistik Regresyon, Karar Ağaçları, Rastgele Orman, XGBoost, Naive Bayes, K-En Yakın Komşu ve Destek Vektör Makinesi olmak üzere toplam yedi adet denetimli sınıflandırma algoritması kullanılmıştır. Bu algoritmaların performans ölçümünde Doğruluk, Kesinlik, Duyarlılık, F-Skor ve AUC değerleri hesaplanmıştır. Ayrıca, ROC eğrileri ve karışıklık matrisleri değerlendirilerek algoritmalar karşılaştırılmıştır. Bu ölçümler ve değerlendirmeler sonucunda Rastgele Orman algoritması %88 doğruluk oranı ile en başarılı algoritma olmuştur. Bunlara ek olarak, rauntların kazanılma durumları bağlamında Keşifsel Veri Analizleri yürütülerek Esport organizasyonlarına yönelik bazı önerilerde bulunulmuştur.

**Anahtar kelimeler:** Esport, CSGO, Makine Öğrenmesi, Sınıflandırma Algoritmaları, Kazanan Tahminleme

## Prediction of Counter-Strike: Global Offensive Round Results with Machine Learning Techniques

### Abstract

With the large amounts of structured and unstructured data available to the public, studies on Esports forecasting are increasing day by day. Although prediction studies for esports events are greatly affected by the human factor, it increases the success of predictions with its structure that offers many important parameters in achieving accurate outputs. In this context, it is important how to create models and which machine learning algorithms to choose. In this study, classifications were carried out using various machine learning algorithms to predict the results of the rounds in the online game Counter-Strike: Global Offensive. In the research, a total of seven supervised classification algorithms, namely Logistic Regression, Decision Trees, Random Forest, XGBoost, Naive Bayes, K-Nearest Neighbor and Support Vector Machine were used. Accuracy, Precision, Sensitivity, F-Score and AUC values were calculated in the performance measurement of these algorithms. In addition, algorithms are compared by evaluating ROC curves and confusion matrix. As a result of these measurements and evaluations, the Random Forest algorithm was the most successful algorithm with an accuracy rate of 88%. In addition to these, some suggestions were made for Esports organizations by conducting Exploratory Data Analysis in the context of the winning status of the rounds.

**Keywords:** Esports, CSGO, Machine Learning, Classification Algorithms, Winning Prediction

## 1. Giriş (Introduction)

Günümüzde bilgisayar ve internet teknolojilerinin hızlı gelişimleri ile çevrimiçi rekabetçi (competitive)

oyunların popülaritesi giderek artmaktadır. Bu popülarite 1972 yılında ilk uygulamalarına rastlanan ve 2000'li yılların başından itibaren giderek yaygın hale gelmiş olan Esport (Esports) kavramını hayatımıza sokmuştur. Elektronik sporun (electronic sports)

\* Sorumlu yazar  
E-posta adresi: vahidsinap@gmail.com

Alındı : 15 Ocak 2023  
Kabul : 22 Haziran 2023

kısaltması olan Espor, video oyunları üzerine kurulu bir rekabet biçimidir (Hamari ve Sjöblom, 2017). Esporlar, özellikle profesyonel oyuncuların bireysel veya takımlar halinde katılımlarıyla düzenlenen, çok oyunculu (multiplayer) video oyunu müsabakaları şeklinde gerçekleşmektedir. Uluslararası Olimpiyat Komitesi (UOK - International Olympic Committee) Esporu resmi olarak bir spor dalı ilan etmiş ve 2023 yılı haziran ayında Olimpik Espor Haftası düzenleyeceğini duyurmuştur (UOK, 2023). Bu gibi gelişmeler Esporun bilinirliğini geleneksel spor türlerinin seviyesine yaklaştırmaktadır. Geleneksel sporlarda oyuncular bireysel beceri çalışmalarının yanı sıra takım arkadaşlarıyla iş birliği içerisinde hareket etme becerisi kazanma antrenmanları yapmaları gerekmektedir. Espor da aynı felsefe ile benzer beceri gereksinimlerine sahiptir. Bireysel yetenekler ve ekip çalışması kabiliyeti Espor takımlarının oyunu kazanmalarında önemli bir rol oynamaktadır. Her iki spor türünde de oyuncuların bireysel becerilerini geliştirmek, takım içi çalışmalara yardımcı olacak uygulamalar hazırlamak, müsabakalar sırasında gerçekleştirilen hataları tespit etmek, rakip takımların analizini yapmak takımın başarıya ulaşmasında kritik etmenlerdir.

Basketbol veya futbol gibi geleneksel sporlar, oyuncuları ve müsabakaları analiz etmek, takım başarısını etkileyen kistasları değerlendirmek için belirli veriler toplamaktadırlar. Bu verilerin toplanmasında oyuncuların giydiği sensörler, oyuncu hareketini izleyen kameralar gibi genişletilmiş veri toplama yöntemlerinin yanı sıra takım analistlerinin hazırladığı gözlem notları gibi yöntemler de kullanılmaktadır (Xenopoulos vd., 2021). Bununla birlikte, oyuncuların birçok eyleminin ve müsabakalar sırasında gerçekleşen çeşitli durumların belirli algoritmalar aracılığıyla kayıt altına alınabilmesi bakımından Espor benzersiz bir yapıdadır. Espor denildiğinde akla gelen ilk oyunlardan biri olan Counter-Strike: Global Offensive (CSGO), takım tabanlı (team-based), çok oyunculu, birinci şahıs nişancı (first person shooter) oyunudur. Bu tür oyunlarda, oyun sırasında gerçekleşen birçok eylem ve durum, demo dosyası denilen bir günlük dosyasına kaydedilmektedir. CSGO demo dosyalarının elde edilmesi ve ayrıştırılması diğer oyunların demo dosyalarına göre daha kolay olduğu için oyuncuların ve takımların değerlemesinde Espor analitiği açısından önemli veriler sunmaktadır.

CSGO oyununda her biri beş oyuncudan oluşan iki takım, bir haritayı (map) kazanmaya yetecek kadar raunt (round) kazanmak amacıyla birden fazla rauntta yarışır. Haritanın kazanılması için gerekli raunt sayısı 16'dır. Takımlar oyun başında Teröristler (Terrorists - T) ve Terörle Mücadele (Counter Terrorists - CT) olmak üzere iki tarafa ayrılır. T'nin hedefi raunt süresi bitmeden patlayıcıyı (C4) her haritada belirli alanlarından birine yerleştirmek ve patlayıcı patlayana kadar CT'ler tarafından etkisiz hale getirilmesini (defuse) önlemektir. CT'nin hedefi ise patlayıcı yerleştirildikten sonra patlayıcıyı etkisiz hale getirmek veya patlayıcı yerleştirilmeden raunttaki tüm düşmanları ortadan

kaldırmaktır. Çoğu maç (match), 1'in en iyisi (best-of-1), 3'ün en iyisi (best-of-3) veya 5'in en iyisi (best-of-5) ayarlarında oynanmaktadır. Buna göre, belirli sayıdaki haritanın çoğunluğunu kazanan takım karşılaşmanın kazananı olmaktadır.

Bir raunt, her iki takımın da satın alma süresi (buy time) boyunca satın alma bölgelerinde (buy zones) hareket edemez şekilde bulunmasıyla başlamaktadır. Takımlar rauntun başında, rauntun kazanma şanslarını en üst düzeye çıkarmak için zırh (armor), el bombaları (utility) ve silahlar (weapon) satın alırlar. Her rauntun başında, her iki takım da bir önceki rauntun kazanma durumlarına ve rauntları arka arkaya kaybetme serilerine göre bonus para almaktadırlar. Kaybeden tarafın aldığı bonus para kaybetmeye devam ettiği her raunt için belirli düzeyde artmaktadır. Kazanan taraf ise yüksek kazanma bonusu elde etmesinin yanı sıra hayatta kalan oyuncuların bir önceki raunttan sakladıkları ekipmanları bir sonraki rauntta kullanma şansına sahip olur ve böylece yeniden ekipman satın almak zorunda kalmazlar. Oyunlar sırasında iyi yönetilmiş bir ekonomi, rauntların kazanılmasında doğrudan rol oynayan ekipmanların satın alınmasında, dolayısı ile oyunun galibiyetle sonuçlanmasında çok önemli bir yere sahiptir. Buna ek olarak, bir raunt sırasında raunt süresinin ne kadar kaldığı, patlayıcının yerleştirilme durumu, hayattaki oyuncu sayıları, oyuncuların oyun içerisindeki sağlık durumları, oyuncuların harita içerisindeki konumları gibi birçok unsur rauntların kazanılmasında önemli parametrelerdir.

Esporun 2022 yılındaki pazar büyüklüğü 1.44 milyar dolar olmakla birlikte bunun 2029 yılında 5.48 milyar dolar seviyelerine ulaşacağı ön görülmektedir (Statista, 2023). Geleneksel endüstriler kendilerini sponsor olarak Espor faaliyetlerine dahil etmektedirler. Ancak, endüstrideki en büyük destekleyici güçlerden biri bahis endüstrisidir (Davis, 2021). Pazar hacminin bu denli büyük olduğu ve bahis faaliyetlerinin düzenlendiği Espor alanında teknolojik gelişmelerden faydalanılarak tahminleme çalışmalarının yürütülmesi kaçınılmazdır. Bahis şirketleri maçlardaki bahis oranlarının belirlenmesi gibi işlemlerde tahminleme çalışmalarından yararlanabilmektedirler. Bunlara ek olarak, oyun yapımcıları, rastgele bir araya gelen oyuncuların oluşan takımların kazanma olasılıklarını %50 olarak ayarlayabilmek için derecelendirme sistemi oluştururken bu tür teknolojilerden istifade etmektedirler.

Günümüzde, yapay zekâ teknolojilerindeki ilerlemeler Espor alanında sıklıkla kullanılmaya başlanmıştır. Mevcut durumdaki veriler üzerinden bir öğrenme işlemi gerçekleştirerek daha sonraki durumlar hakkında tahminler üretmeye yarayan makine öğrenmesinin özellikle son yıllarda giderek bilinirliği artmıştır. Makine öğrenmesi, belli bir duruma etki eden parametreler altındaki veriler aracılığıyla yeni durumlar hakkında dengeli tahminlemeler gerçekleştirebilmektedir (Sevli, 2022).

Alanyazında farklı makine öğrenmesi algoritmaları ile Espor maçları çıktılarının tahminlenmesine yönelik bazı önemli çalışmalar bulunmaktadır. Bu araştırmalarda Karar Ağaçları (KA), Naive Bayes (NB), Lojistik Regresyon (LR), K-En yakın Komşu (KNN), Rastgele Orman (RO), Destek Vektör Makinesi (DVM) ve Yapay Sınır Ağları (YSA) gibi algoritmalar sıklıkla kullanılmaktadır. Bu araştırmalar aşağıda özetlenmiştir.

Hood ve diğerleri (2017), Defense of the Ancients 2 (DotA 2) adlı çok oyunculu çevrimiçi savaş arenası (multiplayer online battle arena – MOBA) türündeki oyunda canlı profesyonel maçlar için tahmin modelleri oluşturmuş ve RO algoritması ile %77.51'lik bir doğruluk oranı elde etmiştir. Yang (2018), Overwatch adlı bir video oyununda, takımdaki kahramanların (hero) takım içi uyumlarına odaklanarak kazanan takımı tahmin etmek için bir model oluşturmuştur. Oluşturulan model, maç öncesinden ziyade maç sırasındaki sonucu tahmin etmek için tasarlanmıştır. Araştırmacı, diğer modellerin düşük performans gösterdiği bir aşama olan oyunun erken aşamasındaki tahminin doğruluğunu artırmayı hedeflemiştir. Araştırmada sınıflandırma algoritmalarından LR kullanılmıştır ve oyunun erken aşamasında kazanan takımı tahminleme açısından yaklaşık %58 doğruluğa ulaşmıştır. Makarov ve diğerleri (2018), CSGO'da patlayıcı kurulduktan sonraki senaryolarda, diğer bir deyişle raundun son aşamasında, KA ve LR kullanarak raundun kazananı tahminlemeyi hedeflemişler ve %62'lik bir doğruluk oranı elde etmişlerdir. Xenopoulos ve diğerleri (2020), CSGO'da bir takımın kalan oyuncuları ve ekipman durumları gibi girdi özellikleriyle takımın kazanma olasılığını tahminleyen çalışmalarında XGBoost kullanmışlardır ve %79.1'lik bir doğruluk oranı yakalamışlardır. Shen (2022), MOBA türündeki League of Legends isimli oyunda orta düzeydeki amatör oyuncuların maçlarının ilk 10 dakikasını LR, RO, KA, NB gibi algoritmalarla incelemiş ve %72.68 doğruluğa ulaşmıştır.

Alanyazındaki çalışmalara ek olarak Microsoft ekibi, oyunun kalitesini, oyunun adil olup olmadığını ve bir takımın bu oyunu kazanma olasılığını tahmin etmek için TrueSkill adlı bir derecelendirme sistemi tasarlamıştır (Minka vd., 2018). Bu sistem ile video oyunlarında benzer becerilere sahip oyuncuların eşleştirilmesi amaçlanmıştır. Çeşitli algoritmalar kullanan araştırmacılar %68'lik bir doğruluk oranı elde etmişlerdir.

Bu çalışmada, makine öğrenmesi teknolojisinin Espor alanında nasıl sonuçlar verebileceğinin anlaşılması ve oluşturulan modeller ile CSGO oyununda rauntların sonuçlarını en iyi tahminleyen makine öğrenmesi algoritmasının belirlenmesi amaçlanmıştır. Buna göre, yedi farklı makine öğrenmesi algoritması ile CSGO oyunundaki rauntları hangi takımın kazanacağına yönelik sınıflandırma çalışmaları gerçekleştirilmiştir.

## 2. Uygulanan Algoritmalar ve Yöntemler (Applied Algorithms and Methods)

Makine öğrenmesi algoritmaları; yaklaşımları, veri türleri ve problem çözme teknikleri bakımından farklılık göstermektedir. Makine öğrenmesi genellikle (1) Denetimli öğrenme, (2) denetimsiz öğrenme ve (3) pekiştirmeli öğrenme şeklinde üç alt kategoriye ayrılmaktadır (Bengio vd., 2012). Denetimli öğrenme hem girdi hem de çıktı verilerine dayalı bir tahmin modeli geliştirmektedir. Denetimsiz öğrenme, verileri yalnızca girdi verilerine dayalı olarak gruplar ve yorumlarken pekiştirmeli öğrenme, bir ödül ve ceza sistemi kullanarak modeli eğitmektedir. Denetimli öğrenme algoritmaları, sınıflandırma ve regresyon algoritmalarını içermektedir. Çıktı sınırlı bir değer kümesiyle sınırlandırıldığında sınıflandırma, bir aralık içinde herhangi bir sayısal değere sahip olduğunda ise regresyon algoritmaları kullanılmaktadır (Ray, 2019). Son zamanlarda, denetimli ve denetimsiz öğrenmenin bir kombinasyonu olan yarı denetimli öğrenme kavramı sıklıkla kullanılmaktadır. Yarı denetimli öğrenme, veri setlerindeki verilerin bir kısmının etiketlenmiş, büyük bir bölümünün ise etiketlenmemiş olduğu veri setleriyle çalışabilen algoritmaları içermektedir (Zhu ve Goldberg, 2009).

### 2.1. Denetimli sınıflandırma algoritmaları (Supervised classification algorithms)

Bu çalışmada Lojistik Regresyon, Karar Ağaçları, Rastgele Orman, XGBoost, Naive Bayes, K-En Yakın Komşu ve Destek Vektör Makinesi olmak üzere toplam yedi adet denetimli sınıflandırma algoritması kullanılmıştır.

#### 2.1.1. Lojistik Regresyon (Logistic Regression)

LR, ikili veya çok sınıflı bağımlı değişkenleri tahmin etmek amacıyla sigmoid fonksiyonlarını işe koşan istatistiksel bir modeldir. Sigmoid (lojistik fonksiyonlar), ikili sınıflandırma problemlerinin istatistiksel analizleri için herhangi bir gerçek sayıyı 0 ile 1 arasındaki aralıkta konumlandırmaktadır. LR, özel olarak verilmiş katsayılar veya ağırlıklar kullanarak, belirli bir girdi açısından olası çıktıyı hesaplayan doğrusal regresyona çok benzemektedir. Tek fark, lojistik regresyonun her zaman 0 veya 1 şeklinde ikili çıktı vermesidir. LR, Eşitlik 1 için  $\sigma(a) = (1 + \exp(-a))^{-1}$  denkleminin bir aktivasyon fonksiyonu olduğu,  $w_i$ 'nin  $x_i$  özelliğine uygulanan ağırlık (katsayı) olduğu ve  $X$ 'in  $n$  adet özelliğe sahip bulunduğu her sınıf açısından olasılıkları tahmin etmek için veri özniteliklerinin lojistik bir fonksiyonunu kullanmaktadır (Böhning, 1992).

$$P(win) = \sigma \left( w_0 + \sum_{i=1}^n w_i x_i \right) \quad (1)$$

### 2.1.2. Karar Ağaçları (Decision Trees)

KA, hem sınıflandırma hem de regresyon görevleri için kullanılan, parametrik olmayan denetimli bir öğrenme algoritmasıdır. Kök düğüm, dallar, iç düğümler ve yaprak düğümlerden oluşan hiyerarşik bir ağaç yapısına sahiptir. Bir karar ağacı, herhangi bir gelen dalı olmayan kök düğümlerle başlamaktadır. Kök düğümlerden giden dallar daha sonra karar düğümleri olarak da bilinen iç düğümleri beslemektedir. Mevcut özelliklere bağlı olarak, her iki düğüm türü de yaprak düğümler veya uç düğümler tarafından belirtilen homojen alt kümeler oluşturmak için değerlendirilmeler yürütür. Yaprak düğümler, veri kümesindeki tüm olası sonuçları temsil eder. Bu ağaç yapısı formüle edilerek bir model oluşturulur (Priyam vd., 2013).

### 2.1.3. Rastgele Orman (Random Forest)

RO, birden fazla karar ağacının çıktısını tek bir sonuca ulaşmak için birleştiren, yaygın olarak kullanılan bir makine öğrenme algoritmasıdır. RO, geleneksel KA algoritmalarında sıklıkla karşılaşılan aşırı öğrenme (overfitting) problemini, veri setini ve öznelikleri birçok parçaya ayırıp birden fazla ağaç üzerinde işleyerek çözüme kavuşturmaktadır (Biau ve Scorer, 2016).

### 2.1.4. Gradyan Artırıcı Karar Ağacı (Extreme Gradient Boosting)

Gradyan Artırıcı Karar Ağacı (XGBoost) ağaç tabanlı bir algoritmadır ve denetimli öğrenme problemleri için kullanılmaktadır. Topluluklar (ensemble), karar ağacı modellerinden oluşturulmaktadır. Ağaçlar topluluğa birer birer eklenerek önceki modellerin yaptığı tahmin hatalarını düzeltmek için eğitilir. Bu işlem süreci, zayıf öğrenenleri (weak learner) güçlü öğrenenlere (strong learner) dönüştürüldüğü, artırıcı olarak adlandırılan bir tür toplu makine öğrenmesi modelidir. Modeller, herhangi bir isteğe bağlı türevlenebilir kayıp fonksiyonu ve gradyan iniş optimizasyon algoritması kullanılarak eğitilmektedir. Bu işlem, tekniğe "gradyan artırma" adını vermektedir. Bunun nedeni model eğitildikçe kayıp gradyanının, tıpkı bir sinir ağı gibi en aza indirilmesidir (Chen vd., 2015).

### 2.1.5. Naive Bayes (Naive Bayes)

NB algoritması, Bayes teoremine dayanan ve sınıflandırma problemlerinin çözümünde kullanılan bir algoritmadır. NB olasılığa dayalı bir sınıflandırıcıdır, yani bir nesnenin olasılığı temelinde tahmin yapmaktadır. NB'nin avantajı, küçük bir eğitim setinde eğitildikten sonra verileri doğru bir şekilde sınıflandırabilmesidir. Basitleştirilmiş varsayımlarına rağmen, NB algoritmaları spam filtreleme ve duymu

analizi gibi gerçek dünya durumlarında etkili bir performans sergilemektedir (Zhang ve Li, 2007).

### 2.1.6. K-En Yakın Komşu (K-Nearest Neighbour)

KNN algoritması, yeni durum ile mevcut durum arasındaki benzerliği tahmin ederek yeni durumu, mevcut sınıflar arasında en çok benzeşen sınıfa atar. KNN'deki "K", sınıflama sürecinde en yakın komşu sayısını ifade eden bir parametredir. KNN eğitim verilerinden ayırt edici fonksiyonları öğrenmek yerine bütün eğitim veri setini ezberlediğinden dolayı tembel bir öğrenendir olarak geçmektedir. Bu nedenle veri setinin büyüdüğü durumlarda işlem yükü artmaktadır. Yöntem temel olarak bir metrik mesafe değerine dayanır. En yaygın kullanılan ölçü Eşitlik 2'de gösterilen Öklid mesafesidir (Cunningham ve Delany, 2021).


$$d(x, y) = \sqrt{\sum_{i=1}^n (y_i - x_i)^2} \quad (2)$$

### 2.1.7. Destek Vektör Makinesi (Support Vector Machine)

DVM, yüksek boyutlara sahip veri kümeleri için etkilidir ve hem sınıflandırma hem de regresyon için kullanılan bir algoritmadır. Bu algoritmanın arkasındaki mantık, n'nin bağımsız değişkenlerin sayısı olduğu n boyutlu uzayda bir hiper düzlem oluşturmaktır. İyi bir modelin, en yakın eğitim veri noktalarına en uzak mesafeye sahip hiper düzlemi izlemesi beklenmektedir. Hiper düzlem aynı zamanda bir sınıflandırma ayırıcı görevi görmektedir. Bu özellik, mesafe ne kadar büyükse algoritmanın genelleme hatasını o kadar düşürdüğü anlamına gelmektedir (Noble, 2006).

### 2.2. Veri Doğrulama Yöntemi (Data Validation Method)

Bu araştırmada, CSGO'da oynanan rauntların sonuçlarını tahmin etmede eğitim ve test (train&test) doğrulama yöntemi kullanılmıştır. Eğitim ve test modeli doğrulama yönteminde veri seti; eğitim veri seti, doğrulama veri seti ve test veri seti olmak üzere iki veya üç farklı veri setlerine bölünür. Doğrulama veri seti her zaman kullanılmamakla birlikte kullanıldığı durumlarda genellikle nihai modelin parametre ayarları için işe koşulur. Bu yöntemde modelin eğitim veri setinde öğrenme işlemi gerçekleşir ve ardından test veri setinde değerlendirilmesi yapılır. Eğitim ve test doğrulama yöntemi modelinin akış şeması Şekil 1'de gösterilmiştir.



Şekil 1. Eğitim ve test doğrulama yöntemi (Training & test validation method)

### 2.3. Algoritmaların Karşılaştırılmasında Kullanılan Performans Metrikleri (Performance Metrics Used in Comparing Algorithms)

Sınıflandırma çalışmaları gerçekleştirildikten sonra en iyi tahminlemeyi yapan algoritmanın belirlenmesinde, doğruluk oranının yanı sıra karışıklık matrisinden (confusion matrix) faydalanılır. True positive (Doğru pozitif - TP), tahminin ve özneliğin doğru, False positive (Yanlış pozitif - FP) tahminin yanlış ancak özneliğin doğru, True negative (Doğru negatif - TN) tahminin doğru fakat özneliğin yanlış, False negative (Yanlış negatif) ise tahminin ve özneliğin yanlış olduğu durumları ifade etmektedir (Gök, 2017).

Algoritmaların karşılaştırılmasında kullanılan ilk performans metriklerinden biri doğruluk oranıdır (accuracy). Bu oran, yapılan toplam tahmin sayısına göre bir model tarafından yapılan doğru tahminlerin sayısını ölçen bir değerlendirme metriğidir. Doğru tahmin sayısını toplam tahmin sayısına bölerek hesaplanmaktadır. Doğruluk oranının hesaplanmasında kullanılan formül Eşitlik 3'te verilmiştir.

$$\text{Doğruluk} = \frac{TP + TN}{TP + FP + TN + FN} \quad (3)$$

Kullanılan performans metriklerinden diğeri ise kesinliktir (precision). Kesinlik, bir makine öğrenmesi modeli performansının, yani model tarafından yapılan doğru tahminde bulunma kalitesinin önemli bir göstergesidir. Kesinlik, doğru pozitiflerin sayısının pozitif tahminlerin toplam sayısına bölünmesiyle elde edilir. Kesinlik oranı Eşitlik 4'teki formül ile hesaplanmaktadır.

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (4)$$

Duyarlılık (recall), pozitif olarak doğru bir şekilde sınıflandırılan pozitif tahmin sayısının toplamda pozitif

olması gereken tahmin sayısına oranı şeklinde hesaplanır. Duyarlılık, modelin pozitif tahminleri tespit etme yeteneğini ölçmektedir. Duyarlılığın hesaplanmasında Eşitlik 5'teki formülden yararlanılmaktadır.

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

F-Değeri (F-Score), bir modelin kesinlik ve duyarlılık değerlerinin harmonik ortalamasıdır. F-Değeri, modelin hem pozitif vakaları yakalama (duyarlılık) hem de yakaladığı vakalarda doğru olma (kesinlik) konusundaki denge yeteneğini ortaya koymaktadır. F-Değeri Eşitlik 6'daki formül ile hesaplanabilmektedir.

$$F1 = 2 * \frac{(\text{kesinlik} * \text{duyarlılık})}{(\text{kesinlik} + \text{duyarlılık})} \quad (6)$$

Alıcı Çalışma Özelliği Eğrisi (Receiver Operating Characteristic Curve - ROC), tüm sınıflandırma eşiklerindeki bir sınıflandırma modelinin performansını resmeden grafikdir. ROC eğrisinin True Positive Rate (Doğru Pozitif Oranı - TPR) ve False Positive Rate (Yanlış Pozitif Oranı - FPR) olmak üzere iki parametresi bulunmaktadır. Sınıflandırma eşiği düşürüldüğünde daha fazla ögenin pozitif olarak sınıflandırılması sağlanır (Boyd vd., 2013). TPR, Eşitlik 7'de ifade edilen formül ile hesaplanmaktadır.

$$\text{TPR} = \frac{TP}{TP + FN} \quad (7)$$

FPR ise şu şekilde tanımlanmaktadır:

$$\text{FPR} = \frac{FP}{FP + TN} \quad (8)$$


ROC Eğrisi Altındaki Alan (Area Under the Curve Rate – AUC) ise ROC Eğrisi altında kalan alan şeklinde ifade edilmektedir. AUC oranı 0 ile 1 arasında bir değer almaktadır. Hatalı tahminleme oranı %100 olan bir modelin AUC oranı 0'dır. %100 doğru tahminleme yapan bir modelin AUC oranı ise 1 değerini almaktadır (Zhang, 2016).

### 3. Verilerin Elde Edilmesi ve Hazırlanması (Data Acquisition and Preparation)

Yeterli miktarda ilgili veri, iyi bir tahmin modeli oluşturmak için temel koşuldur. Bu bölümde verilerin toplanması hakkında bilgi verilmiş ve veri hazırlama yöntemi sunulmuştur.

#### 3.1. Verilerin Elde Edilmesi (Data Acquisition)


Çalışmada, Kaggle platformuna Lillelund (2020) tarafından yüklenmiş olan “CS:GO Round Winner Classification” adlı veri seti kullanılmıştır. Veri seti ilk olarak Espor analizleri yürüten Skybox adlı organizasyon tarafından, 2020 ilkbaharından sonbaharına kadar devam eden “CS:GO Yapay Zeka Mücadelesi”nin bir parçası olarak yayımlanmıştır. Veri seti, 2019 ve 2020’de düzenlenen üst düzey turnuva oyunlarından elde edilen 700 demo kaydından oluşturulmuştur. Veri setinde biri raundun kazananı ifade eden sınıf değeri olmakla birlikte toplam 97 öznelik ve 122.410 örnek bulunmaktadır. Şekil 2’de RO algoritması ile oluşturulmuş, raundun kazananını tahminlemede en önemli öznelikler ifade edilmiştir.



Şekil 2. Özneliklerin önemleri (Importance of features)

Şekil 3’te ise veri setinin ısı haritası ve korelasyon matrisi resmedilmiştir.

Tablo 1’de, Şekil 2’deki ve Şekil 3’teki verilere göre raundun kazanılmasında önemli rol oynayan 20 özneliğe ve açıklamalarına yer verilmiştir.



Şekil 3. Veri setinin ısı haritası (Heatmap of the dataset)

**Tablo 1.** Veri seti öznitelikleri ve açıklamaları (Dataset features and descriptions)

Öznitelik	Açıklama
ct_armor	CT'lerin toplam zırh değeri
t_armor	T'lerin toplam zırh değeri
ct_money	CT'lerin toplam parası
t_money	T'lerin toplam parası
ct_helmets	CT'de kaç oyuncunun kafa bölgesi zırhının olduğu
t_helmets	T'de kaç oyuncunun kafa bölgesi zırhının olduğu
ct_score	İlgili raunda kadar CT'lerin kazandığı raunt sayısı
t_score	İlgili raunda kadar T'lerin kazandığı raunt sayısı
time_left	Raundun bitimine kalan süre (sn)
ct_defuse_kits	CT'lerin sahip olduğu patlayıcı imha ekipmanı sayısı
ct_health	CT'lerin toplam sağlık değeri
t_health	T'lerin toplam sağlık değeri
map	Maçta oynanan harita 1 = de_dust2                      5 = de_overpass 2 = de_mirage                    6 = de_train 3 = de_nuke                        7 = de_vertigo 4 = de_inferno                    8 = de_cache
t_weapon_ak47	T'lerin elinde bulunan AK-47 isimli silah sayısı
ct_grenade_flashbang	CT'lerin elinde bulunan ses bombası sayısı
ct_players_alive	Rauntta hayatta olan CT oyuncu sayısı
t_players_alive	Rauntta hayatta olan T oyuncu sayısı
ct_weapon_usps	CT'lerin elinde bulunan USPS isimli silah sayısı
bomb_planted	Raunt içerisinde patlayıcının yerleştirilmiş olma durumu 1 = yerleştirildi 0 = yerleştirilmedi
round_winner	Raundu kazanan takım 1 = CT kazandı 0 = T kazandı

### 3.2. Verilerin Hazırlanması (Data preparation)


Çalışmada kullanılan veri setinde 96 öznitelik ile bir sınıf değeri bulunmakta ve bu veri seti 122.410 örnekten oluşmaktadır. 96 özniteliğin 2'si kategorik, kalan 94'ü sayısal veri türündedir. Hedef sınıf değeri ise raundu CT kazandı (1) ve raundu T kazandı (0) şeklinde olup kategoriktir. Örneklerin 62.406'sında T takımı, 60004'ünde ise CT takımı raundu kazanmıştır.

Sınıflandırma algoritmalarına geçilmeden önce veri üzerinde bazı ön işlemler gerçekleştirilmiştir. İlk olarak, kayıp veri bulunan bir örnek, veri setinden çıkarılmıştır. Daha sonrasında öznitelik seçimine geçilmiştir. Yalnızca bir değer içeren altı adet öznitelik, oluşturulan modele dahil edilmemiştir. Bütün kategorik değerler sayısal değerler ile kodlanmıştır. Özniteliklerin ortalamaları kaldırılarak ve birim varyansa göre ölçeklendirerek standartlaştırma işlemi yürütülmüştür. Standartlaştırma işleminde merkezleme ve ölçeklendirme, eğitim setindeki örnekler üzerinde ilgili istatistikleri hesaplayarak her öznitelik açısından bağımsız olarak gerçekleştirilmiştir. Ortalama ve standart sapma değerleri ise dönüşümler kullanılarak daha sonraki verilerde kullanılmak üzere saklanmaktadır. (Ali vd., 2014). Bir veri setinin standardizasyonu, birçok makine öğrenmesi tahmincisi için ortak bir gerekliliktir. Verilerdeki standart dışı

dağılımlar modelin tahmin başarısını önemli ölçüde etkileyebilmektedir.

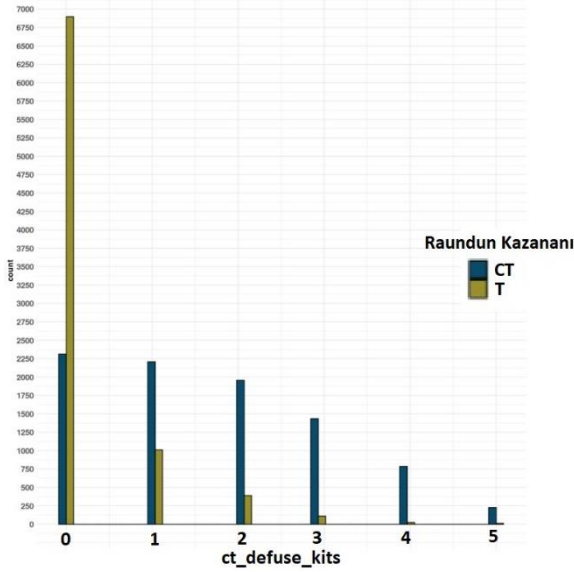
## 4. Deneysel Çalışma ve Bulgular (Experimental Study and Findings)

CSGO oyunundaki rauntların kazanan takımını tahminlemeyi amaçlayan bu çalışmada, denetimli sınıflandırma algoritmalarından Lojistik Regresyon, Karar Ağaçları, Rastgele Orman, XGBoost, Naive Bayes, K-En Yakın Komşu ve Destek Vektör Makinesi algoritmaları kullanılmıştır. Model oluşturulurken, veri seti %80 eğitim ve %20 test şeklinde olmak üzere iki parçaya bölünmüştür. Kullanılan bütün algoritmalarda rastgele durum (random state) 42 olarak belirlenmiştir. RO'da orman sayısı 12 olarak tanımlanmıştır. KNN'de komşu sayısı 5 olarak girilmiştir. XGBoost algoritmasında öğrenme oranı 0.01, tahminleyici sayısı 10, tohum (seed) sayısı ise 25 olarak belirlenmiştir. DVM'de çekirdek (kernel) olarak Radyal Tabanlı İşlev Çekirdeği (Radial basis function – RBF), C parametresi 2 olarak ayarlanmıştır. DVM optimizasyonunda C parametresi, her bir eğitim örneğinin yanlış sınıflandırılmasından ne kadar kaçınılacağını belirtmektedir. Şekil 4'te, ilgili dönemde aktif harita havuzunda bulunan 8 haritadaki CT ve T taraflarının rauntları kazanma karşılaştırmaları verilmiştir.



Şekil 4. Haritalara göre rauntları kazanan taraflar (The sides that win the rounds according to the maps)


Şekil 4 incelendiğinde de\_nuke ve de\_train haritalarının önemli ölçüde CT tarafının, de\_dust2 haritasında ise T tarafının avantajlı olduğu görülmektedir. CSGO maçlarında takımlar, haritaya hangi tarafta başlayacaklarının belirlenmesi amacıyla bıçak raundu (knife round) denilen bir seçim raundu oynamaktadırlar. Bu raundu kazanan takım hangi tarafta başlayacağını seçme hakkı elde eder. Takımlar hangi haritaya hangi tarafta başlayacaklarını bu bilgilerden yola çıkarak planlayabilirler. Şekil 5'te patlayıcı imha ekipmanı (defuse kit) sayısının raundu kazanmadaki etkisi verilmiştir.



Şekil 5. Patlayıcı imha ekipmanı sayısına göre raundu kazanan taraflar (Winners of the round based on the number of defuse kits)

Patlayıcı imha ekipmanı, yalnızca CT tarafındaki oyuncuların satın alıp kullanabildiği, her oyuncuda en fazla 1 adet, raunt içerisinde ise toplamda 5 adet bulundurulabilen, patlayıcının imha edilme süresini 10 saniyeden 5 saniyeye indiren bir ekipmandır. CT'lerin bu ekipmanı hiç satın almadığı durumlarda T tarafının raundu kazanma olasılığının çok büyük bir ölçüde arttığı görülmektedir. Ekipman sayısı çoğaldıkça T tarafının raunt kazanma sayıları da giderek düşmüştür. Bu durum yalnızca imha ekipmanının patlayıcıyı hızla imha edilmesine olanak tanınması kaynaklı bir avantaj değildir. Üzerinde bu ekipman bulunan bir oyuncu öldürüldüğünde ekipman yere düşmektedir ve diğer takım arkadaşları tarafından üzerlerine alınabilmektedir. Dolayısı ile imha ekipmanının bir veya iki oyuncuda olması genelde yeterli görülen bir durumdur. Ancak, takım ekonomisinin güçlü olduğu durumlarda her oyuncu bu ekipmanı edinme yoluna gidebilmektedir. Diğer bir deyişle bir rauntta bulunan imha ekipmanı ne kadar fazla ise CT tarafının ekonomisi o kadar güçlü ve raundu kazanma olasılığı buna paralel olarak fazla denilebilir. Şekil 6'da patlayıcının yerleştirilme durumuna göre raundu kazanan taraflar verilmiştir.





**Şekil 6.** Patlayıcının yerleştirilme durumuna göre raundu kazanan taraflar (Winners of the round based on explosive planting situation)

Patlayıcının yerleştirilmediği senaryoda, raunt süresi bitiminde en az bir CT tarafındaki oyuncunun hayatta

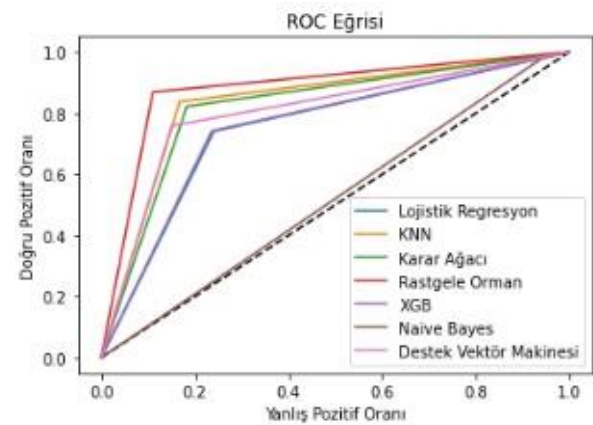
olması durumunda raundu CT'ler kazanmaktadır. T tarafı patlayıcıyı yerleştirme imkânı bulamıyorsa süre bitmeden önce raunttaki bütün CT oyuncularını ortadan kaldırma yoluna gitmelidir. Patlayıcının yerleştirildiği senaryoda ise süre CT tarafının aleyhine işlemektedir. Patlayıcı yerleştirildikten 40 saniye sonra patlamaktadır ve raunt bitmektedir. Patlayıcı yerleştirildikten sonra bütün T oyuncuları ortadan kaldırılsa dahi patlayıcının patlaması durumunda raundu T tarafı kazanmaktadır. Şekil 6 incelendiğinde, patlayıcının yerleştirilmediği senaryoda T tarafı raundu kazanma konusunda CT'lerin gerisinde kalmıştır. Başta bahsedilen durumdan ötürü raunt süresi azaldıkça T'lerin raundu kazanma ihtimali de giderek azalmıştır. Patlayıcının yerleştirildiği senaryoda ise tam tersi bir durum söz konusudur. Bu durumda T'ler raundu kazanma yönünden büyük bir avantaj elde etmekte ve patlayıcının patlamasına kalan süre azaldıkça T'lerin raundu kazanma ihtimalleri artmaktadır.

Çalışmada kullanılan sınıflandırma algoritmalarına göre veriler modellenerek tahminleme işlemleri gerçekleştirilmiştir. Bu işlemler sonucunda modellere ait doğruluk, kesinlik, duyarlılık, F-Skor ve AUC değerleri hesaplanmış ve Tablo 2'de verilmiştir.

**Tablo 2.** Sınıflandırma algoritmalarının performans değerleri (Performance values of classification algorithms)

Sınıflandırıcı	Doğruluk	Kesinlik	Duyarlılık	F-Skor	AUC
LR	0.75	0.76	0.74	0.75	0.84
KNN	0.83	0.84	0.84	0.83	0.91
KA	0.82	0.82	0.82	0.82	0.82
RO	0.88	0.89	0.87	0.88	0.95
XGBoost	0.75	0.77	0.74	0.75	0.89
NB	0.53	0.52	0.98	0.67	0.76
DVM	0.80	0.84	0.76	0.79	0.88

Tablo 2 incelendiğinde en yüksek doğruluk oranına sahip sınıflandırıcının %88 ile RO olduğu anlaşılmaktadır. Bunu %83 ile KNN ve KA algoritmaları takip etmektedir. En düşük doğruluk oranına sahip algoritma ise %53 ile NB'dir. Kesinlik metriği açısından bakıldığında en yüksek oran %89 ile RO algoritmasına aittir. NB doğruluk oranı en düşük algoritma olsa da duyarlılık değeri bakımından %98'lik bir değer ile en yüksek orana sahiptir. Duyarlılık ve kesinlik değerleri en dengeli algoritma RO algoritmasıdır (F-Skor = 88). AUC değerlerine bakıldığında %95 ile RO algoritması en yüksek değeri almıştır. Şekil 7'de, sınıflandırıcılara ait ROC eğrisi grafiği verilmiştir.



**Şekil 7.** Sınıflandırıcılara ait ROC eğrisi grafiği (ROC curve graph of classifiers)

ROC analizi sonucunda çizdirilen Şekil 7'deki grafik incelendiğinde en yüksek doğruluk veren kesim (cut-off) noktasına sahip algoritmanın RO olduğu, onun arkasında ise KNN algoritmasının yer aldığı görülmektedir.

## 5. Sonuçlar (Conclusions)

Bu araştırmada, günümüzde Esport karşılaşmalarının çok önemli bir bölümünü oluşturan CSGO oyunundaki rauntların kazanan taraflarının tahminlenmesi konusunda makine öğrenmesi tabanlı bir çalışma gerçekleştirilmiştir. Araştırmanın deneysel kısmında ilk olarak sıcaklık haritası ve korelasyon matrisine göre raundun kazanılması bağlamında etkili olduğu görülen parametreler Keşifsel Veri Analizleri (Exploratory Data Analysis – EDA) yoluyla görselleştirilmiştir. Buna göre, CSGO oyununda de\_nuke ve de\_train haritaları CT ağırlıklı haritalar iken de\_train2 haritası T tarafı ağırlıklıdır. Patlayıcı imha ekipmanları CT'lere raundu kazandırma konusunda ciddi bir işleve sahiptir. Patlayıcının yerleştirilmediği durumda CT tarafı T'ye göre avantajlı durumdadır ancak, patlayıcı yerleştirildikten itibaren T tarafı avantaj durumunu büyük ölçüde lehine çevirmektedir.

Çalışmada sınıflandırma algoritmalarından Lojistik Regresyon, K-En Yakın Komşu, Karar Ağaçları, Rastgele Orman, XGBoost, Naive Bayes ve Destek Vektör Makinesi olmak üzere yedi algoritma kullanılmıştır. Kurulan modellerin etkili bir sınıflandırma yaptığıının anlaşılması açısından performans değerlerinin 1'e yakın değerler üretmesi gerekmektedir. Kesinlik, sınıflandırıcıların pozitif olarak tayin ettiği örneklerin gerçekte kaç tanesinin pozitif olduğunu hesaplayan bir metriktir. Duyarlılık, toplam pozitif durumların ne kadarlık bir bölümünün başarılı tahmin edildiğini hesaplamaktadır. Kesinlik ve duyarlılık arasındaki denge ise F-Skor metriğiyle ifade edilmektedir. Bunlara ek olarak ROC analizi, iki ya da daha fazla sınıflandırıcı algoritmanın tahminleme güvenilirliklerini karşılaştırmak amacıyla kullanılmaktadır. AUC değeri ise model performansının bir özeti niteliğinde olup, algoritmaların tahminlemede ne kadar başarılı olduğunu sunmaktadır. Bu bilgilerin ve araştırmanın bulguları ışığında CSGO'da rauntların kazananını tahminlemede en başarılı algoritma Rastgele Orman olmuştur ve %88 doğruluk değerine sahiptir. Alanyazın incelendiğinde, aynı veri seti ile çalışan Huang ve diğerleri (2022), kullandıkları sınıflandırıcılar arasında XGBoost ile en yüksek %79'luk doğruluk değerine ulaşmışlardır. Araştırmacıların elde ettiği sonuç ile bu araştırmanın sonuçları arasındaki farkın temelinde araştırmacıların modellerini oluştururken öznitelik seçimleri sırasında toplamda 97 olan öznitelik sayısını 26'ya indirgemeleri olduğu düşünülmektedir. Bunun yanı sıra verilerin normalizasyon işlemleri, kullanılan algoritmalar ve algoritmalara ait parametre seçimleri bu farkın oluşmasında önemli etmenler arasındadır. CSGO üzerinde rauntların veya takımların kazananlarını tahminlemeye yönelik alanyazındaki diğer çalışmalara bakıldığında Makarov ve diğerleri %62'lik, Xenopoulos ve diğerleri ise %79.1'lik doğruluk oranları elde etmişlerdir. Farklı veri setleriyle çalışılmış olsa da bu araştırma kapsamında yapılan

modellemeler, bahsedilen iki çalışmadan önemli ölçüde ayrılarak daha doğru bir tahminleme yapmaktadır.

Araştırma, CSGO oyununda raundu kazanan tarafların tahminleme başarısı açısından Esport sektörüne yönelik önemli çıktılar sunmaktadır. Araştırma kapsamında gerçekleştirilen modellerin canlı maçlarla bütünleştirilmesi durumunda izleyenlere sunulacak anlık bir tahmin bilgisi seyir zevkinin artmasına yol açabilir. Bunun yanı sıra takımlar; harita seçimi, oyun içi ekipman alımları, oyun içi senaryolarda uygulayacakları taktikler yönlerinden araştırmadan elde edilen bulguları kullanabilirler. Çalışmanın ayrıca, makine öğrenmesi sınıflandırıcılarının video oyunlarında nasıl performans gösterdiğinin karşılaştırılması, makine öğrenmesinin Esport sektöründe hangi çıktılara olanak tanıyabileceğini ortaya koyması açısından önemli bulguları bulunmaktadır.

## Kaynaklar (References)

- Ali, P. J. M., Faraj, R. H., Koya, E., Ali, P. J. M., & Faraj, R. H. (2014). Data normalization and standardization: a technical report. *Mach Learn Tech Rep*, 1(1), 1-6.
- Bengio, Y., Courville, A. C., & Vincent, P. (2012). Unsupervised feature learning and deep learning: A review and new perspectives. *CoRR*, 1(2665), 2012.
- Biau, G., & Scornet, E. (2016). A random forest guided tour. *Test*, 25(2), 197-227.
- Boyd, K., Eng, K. H., & Page, C. D. (2013, September). Area under the precision-recall curve: point estimates and confidence intervals. In *Joint European conference on machine learning and knowledge discovery in databases* (pp. 451-466). Springer.
- Böhning, D. (1992). Multinomial logistic regression algorithm. *Annals of the institute of Statistical Mathematics*, 44(1), 197-200.
- Chen, T., He, T., Benesty, M., Khotilovich, V., Tang, Y., Cho, H., & Chen, K. (2015). Xgboost: extreme gradient boosting. *R package version 0.4-2*, 1(4), 1-4.
- Cunningham, P., & Delany, S. J. (2021). K-nearest neighbour classifiers-a tutorial. *ACM Computing Surveys (CSUR)*, 54(6), 1-25.
- Davis, W. (2021). As esports grows, so too do its sponsorships. URL <https://win.gg/news/as-esports-grows-so-too-do-its-sponsorships> (Erişim tarihi: 28.12.2022)
- Gök, M., 2017. Makine öğrenmesi yöntemleri ile akademik başarının tahmin edilmesi. *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji*, 5(3), 139-148.
- Hamari, J. & Sjöblom, M. (2017). What is eSports and why do people watch it? *Internet Research*, 27(2), 211-232. <https://doi.org/10.1108/IntR-04-2016-0085>
- Hodge, V. J., Devlin, S., Sephton, N., Block, F., Cowling, P. I., & Drachen, A. (2019). Win prediction in multiplayer esports: Live professional match prediction. *IEEE Transactions on Games*, 13(4), 368-379.
- Huang, W. X., Wang, J., & Xu, Y. (2022, April). Predicting round result in Counter-Strike: Global Offensive using machine learning. In *2022 7th International Conference on Intelligent Computing and Signal Processing (ICSP)* (pp. 1685-1691). IEEE.

- Lillelund, C. (2020). CS:GO round winner classification. URL <https://www.kaggle.com/datasets/christianlillelund/csgo-round-winner-classification> (Erişim tarihi: 08.12.2022)
- Makarov, I., Savostyanov, D., Litvyakov, B., & Ignatov, D. I. (2018). Predicting winning team and probabilistic ratings in “Dota 2” and “Counter-Strike: Global Offensive” video games. In International Conference on Analysis of Images, Social Networks and Texts (pp. 183-196). Springer, Cham.
- Minka, T.P., Cleven, R., & Zaykov, Y. (2018). TrueSkill 2: An improved Bayesian skill rating system. Technical Report. <https://www.microsoft.com/en-us/research/uploads/prod/2018/03/trueskill2.pdf>
- Noble, W. S. (2006). What is a support vector machine?. *Nature Biotechnology*, 24(12), 1565-1567.
- Priyam, A., Abhijeeta, G. R., Rathee, A., & Srivastava, S. (2013). Comparative analysis of decision tree classification algorithms. *International Journal of current engineering and technology*, 3(2), 334-337.
- Ray, S. (2019, February). A quick review of machine learning algorithms. In 2019 International conference on machine learning, big data, cloud and parallel computing (COMITCon) (pp. 35-39). IEEE.
- Sevli, O. (2022). Farklı sınıflandırıcılar ve yeniden örnekleme teknikleri kullanılarak kalp hastalığı teşhisine yönelik karşılaştırmalı bir çalışma. *Journal of Intelligent Systems: Theory and Applications*, 5(2), 92-105.
- Shen, Q. (2022, February). A machine learning approach to predict the result of League of Legends. In 2022 International Conference on Machine Learning and Knowledge Engineering (MLKE) (pp. 38-45). IEEE.
- Statista. (2023). eSports market size worldwide in 2021, with a forecast for 2022 and 2029. URL <https://www.statista.com/statistics/1256162/global-esports-market-size/> (Erişim tarihi: 04.01.2023)
- UOK. (2023). IOC confirms Singapore as host of first Olympic Esports Week in June 2023. URL <https://olympics.com/en/news/ioc-confirms-singapore-host-first-olympic-esports-week-june-2023> (Erişim tarihi: 08.01.2023)
- Xenopoulos, P., Coelho, B., & Silva, C. (2021). Optimal Team Economic Decisions in Counter-Strike. arXiv preprint arXiv, abs/2109.12990.
- Xenopoulos, P., Doraiswamy, H., & Silva, C. (2020, December). Valuing player actions in counter-strike: Global offensive. In 2020 IEEE International Conference on Big Data (Big Data) (pp. 1283-1292). IEEE.
- Yang, B. (2018). Predicting e-sports winners with machine learning. URL <https://blog.insightdatascience.com/hero2vec-d42d6838c941> (Erişim tarihi: 22.12.2022)
- Zhang, H., & Li, D. (2007, November). Naïve Bayes text classifier. In 2007 IEEE international conference on granular computing (GRC 2007) (pp. 708-708). IEEE.
- Zhang, Z. (2016). Introduction to machine learning: k-nearest neighbors. *Annals of Translational Medicine*, 4(11), 218.
- Zhu, X., & Goldberg, A. B. (2009). Introduction to semi-supervised learning. *Synthesis lectures on artificial intelligence and machine learning*, 3(1), 1-130.