

T.C.
TRAKYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**ESPOR OYUNCULARININ OYUN İÇİ DAVRANIŞLARININ MAKİNE
ÖĞRENMESİ YÖNTEMLERİ İLE İNCELENMESİ**

TOLGA KOŞAR

YÜKSEK LİSANS

VERİ BİLİMİ VE ANALİTİĞİ

Tez Danışmanı: Dr. Öğr. Üyesi Gamze YILDIZ ERDURAN

EDİRNE-2025

TOLGA KOŞAR'ın hazırladığı “**ESPOR OYUNCULARININ OYUN İÇİ DAVRANIŞLARININ MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE İNCELENMESİ**” başlıklı bu tez, tarafımızca okunmuş, kapsam ve niteliği açısından Veri Bilimi ve Analitiği Anabilim Dalında bir **Yüksek lisans Tezi** olarak kabul edilmiştir.

Jüri Üyeleri (Ünvan, Ad, Soyad):

İmza

Dr. Öğr. Üyesi Gamze YILDIZ ERDURAN

.....

Prof. Dr. Mehmet Kenan TERZİOĞLU

.....

Prof. Dr. Güzin ÖZDAĞOĞLU

.....

Tez Savunma Tarihi:25/06/2025

Bu tezin Yüksek Lisans tezi olarak gerekli şartları sağladığını onaylarım.

İmza

Dr. Öğr. Üyesi Gamze YILDIZ ERDURAN
Tez Danışmanı

.....

Trakya Üniversitesi Fen Bilimleri Enstitüsü onayı

.....

Doç. Dr. Filiz UMAROĞULLARI

Fen Bilimleri Enstitüsü Müdürü

T.Ü.FEN BİLİMLERİ ENSTİTÜSÜ
VERİ BİLİMİ VE ANALİTİĞİ YÜKSEK LİSANS PROGRAMI
DOĞRULUK BEYANI

Trakya Üniversitesi Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmasında, tüm verilerin bilimsel ve akademik kurallar çerçevesinde elde edildiğini, kullanılan verilerde tahrifat yapılmadığını, tezin akademik ve etik kurallara uygun olarak yazıldığını, kullanılan tüm literatür bilgilerinin bilimsel normlara uygun bir şekilde kaynak gösterilerek ilgili tezde yer aldığını ve bu tezin tamamı ya da herhangi bir bölümünün daha önceden Trakya Üniversitesi ya da farklı bir üniversitede tez çalışması olarak sunulmadığını beyan ederim.

25/06/2025

Tolga KOŞAR

Yüksek Lisans Tezi

Espor Oyuncularının Oyun İçi Davranışlarının Makine Öğrenmesi Yöntemleri İle İncelenmesi

T.Ü. Fen Bilimleri Enstitüsü

Veri Bilimi ve Analitiği Anabilim Dalı

ÖZET

Bu tez çalışmasında, makine öğrenmesi metotları kullanarak farklı liglerdeki LoL oyuncularının belirli bir sezondaki verileri analiz edilmiş, bu oyuncuların profesyonel olma/olmama durumu makine öğrenmesi sınıflandırma algoritmaları ile tahmin edilmiş ve kullanılan algoritmaların performans ölçümleri kıyaslanmıştır. Çalışma Espor profesyonellerine oyun için davranışlarına göre hangi seviyede oyuncu olabileceği konusunda katkı sağlamayı amaçlamaktadır. Çalışmanın temelini, farklı liglerde yer alan oyuncuların oyun performansı, stratejik tercihleri, oyun içi kararları ve genel yeteneklerine ilişkin geniş bir veri seti oluşturmuştur. Makine öğrenmesi algoritmaları, bu kapsamlı veri setini işleyerek, oyuncuların gelecekteki potansiyellerini belirlemek için kullanılmıştır. Elde edilen sonuçlar, bu yaklaşımın profesyonel seviyede başarı gösterebilme olasılıklarını belirleme konusunda önemli bir başarı sağladığını göstermektedir. Bu çalışma, sadece LoL gibi rekabetçi oyunlarla sınırlı kalmayıp, genel olarak Espor alanında yetenek keşfi ve potansiyel profesyonel oyuncuların belirlenmesi konusunda da değerli bir katkı sağlamayı amaçlamaktadır. Sonuç olarak, makine öğrenme metotlarının Espor alanında kullanımının potansiyeli vurgulanmış ve bu alandaki gelecek araştırmalar için sağlam bir temel oluşturulmuştur. Bu çalışma, Espor endüstrisinde yetenek yönetimi ve gelecek vadeden oyuncuların keşfi için yeni bir yaklaşım sunmayı amaçlamıştır.

Bu çalışmanın öne çıkan yönü, makine öğrenme algoritmalarının esnekliği ve geniş veri setlerini etkili bir şekilde işleyebilme kabiliyetidir. Ligler arası ve sezonlar arası farklılıkları dikkate alarak, oyuncuların performansını ve potansiyelini belirleme sürecinde bu algoritmaların sağladığı adaptasyon yeteneği önemlidir. Ayrıca, çalışma kapsamında elde edilen bulgular, Espor yetenek yönetimi konusunda mevcut bilgiye önemli bir katkı sağlamakla birlikte, bu alanda daha fazla araştırma ve geliştirme gerektiğini de vurgulamaktadır.

Öte yandan, makine öğrenme metotlarının Espor endüstrisindeki uygulamalarının artmasıyla birlikte, etik ve gizlilik gibi konular da önem kazanmaktadır. Oyuncuların verilerinin doğru ve adil bir şekilde kullanılması, bu alandaki araştırmaların ve uygulamaların sürdürülebilirliği için hayati önem taşımaktadır.

Son olarak, bu tez çalışması Espor endüstrisindeki profesyonel yeteneklerin keşfi ve geliştirilmesi sürecine yeni bir bakış açısı sunarak, gelecekteki Espor oyuncularının yeteneklerini belirleme ve geliştirme süreçlerine değerli bir katkı sağlamayı hedeflemektedir. Bu çalışmanın bulgularının, Espor endüstrisinin daha da büyümesi ve gelişmesi için temel oluşturarak, gelecekteki araştırmalara ve uygulamalara katkı sağlaması amaçlanmıştır.

Yıl : 2025

Sayfa Sayısı : 109

Anahtar Kelimeler : Espor, Makine Öğrenmesi, Sınıflandırma Yöntemleri

Master Thesis

Review of In-Game Behavior of Esports Players with Machine Learning Methods

T.U. Institute of Natural and Applied Sciences

Department of Data Science and Analytics

ABSTRACT

In this thesis, machine learning methods were used to analyse the data of League of Legends players in different leagues during a specific season. The players' professional status was predicted using machine learning classification algorithms, and the performance metrics of the algorithms used were compared. The study aims to contribute to Esports professionals by helping them determine the level of players based on their behaviour in the game. The study is based on a comprehensive dataset regarding the game performance, strategic choices, in-game decisions, and overall skills of players in different leagues. Machine learning algorithms were used to process this extensive dataset to determine the future potential of players. The results obtained demonstrate that this approach has achieved significant success in determining the likelihood of success at the professional level. This study aims to make a valuable contribution not only to competitive games such as League of Legends but also to talent discovery and the identification of potential professional players in the field of Esports in general. As a result, the potential of machine learning methods in the field of Esports has been highlighted, and a solid foundation has been laid for future research in this area. This study aims to offer a new approach to talent management and the discovery of promising players in the Esports industry.

A notable aspect of this study is the flexibility of machine learning algorithms and their ability to effectively process large data sets. Considering the differences between leagues and seasons, the adaptability provided by these algorithms is important in determining players' performance and potential. In addition, the findings obtained in this

study contribute significantly to the existing knowledge on Esports talent management, while also emphasising the need for further research and development in this field.

On the other hand, with the increasing application of machine learning methods in the Esports industry, issues such as ethics and privacy are also gaining importance. The correct and fair use of players' data is vital for the sustainability of research and applications in this field.

Finally, this thesis aims to provide a new perspective on the process of discovering and developing professional talent in the Esports industry, thereby making a valuable contribution to the process of identifying and developing the talents of future Esports players. It is hoped that the findings of this study will serve as a foundation for the further growth and development of the Esports industry, contributing to future research and applications.

Year : 2025

Number of Pages : 109

Keywords : Esports, Machine Learning, Classification Methods

ÖNSÖZ

Çok kıymetli tez danışmanım Sayın Dr. Öğretim Üyesi Gamze YILDIZ ERDURAN, sizin sabrınız, bilgeliliğiniz ve rehberliğiniz, bu çalışmanın her aşamasında benim için büyük bir destek olmuştur. Sizin deneyimleriniz ve uzmanlığınız, teşvikleriniz ve yönlendirmeleriniz, benim daha derin düşünmemi ve daha nitelikli bir çalışma ortaya koymamı sağladı. Aynı zamanda, tezin bilimsel ve metodolojik yönlerini değerlendirmek için harcadığınız zaman ve enerji için de minnettarım.

Tolga KOŞAR

İÇİNDEKİLER

ÖZET	iv
ABSTRACT	vi
ÖNSÖZ	viii
İÇİNDEKİLER	ix
ÇİZELGELER DİZİNİ	xi
ŞEKİLLER DİZİNİ.....	xii
BÖLÜM 1	1
GİRİŞ	1
BÖLÜM 2.....	3
MAKİNE ÖĞRENMESİ.....	3
2.1. Makine Öğrenmesi Teknikleri İle Veri Analizi	4
2.1.1 Veri Ön İşleme	4
2.1.2. Model Kurma	6
2.1.3. Model Başarısı Değerlendirme	7
2.1.4. Model Doğrulama	9
2.1.5. Yeni Bir Gözlem İçin Tahminde Bulunma.....	12
2.2. Sınıflandırma Modelleri.....	13
2.2.1 Naive Bayes	13
2.2.2. Rastgele Orman.....	14
2.2.3. Karar Ağaçları	15
2.2.4. Lojistik Regresyon	16
2.2.5. K-En Yakın Komşu (KNN)	17
2.2.6. Destek Vektör Makineleri (SVM).....	19
2.2.7. XGBoost	20

2.2.8. Sınır Ağları.....	21
2.2.9. Gradient Boosting (GBoost)	22
BÖLÜM 3	24
ESPOR VE ESPOR OYUNLARI.....	24
3.1.1 Oyun Türleri: Rekabetin Farklı Yüzleri.....	27
3.1.2. Espor Oyuncuları	29
3.1.3. Espor Oyuncularının Özellikleri	33
3.1.4. Espor ve Geleneksel Sporlar Arasındaki Farklar	36
3.1.5. Espor Ekipmanları ve Teknolojik İlerlemeler.....	37
3.1.6. Espor Yayın Teknolojileri ve Canlı Yayınlar	38
3.1.7. Espor Yayınları ve İzleyici Etkileşimi: Bir Topluluğun Oluşumu.....	40
3.1.8. Espor'un Endüstriyel Büyüklüğü.....	42
3.1.9. Oyuncuların Kazançları ve Kariyer Olanakları.....	43
3.1.10. Esporun Etik ve Hukuki Boyutları.....	44
3.2. LoL Oyunu	45
3.3. Literatür Taraması.....	48
BÖLÜM 4	61
YÖNTEM.....	61
4.1. Araştırmanın Konusu, Amacı ve Önemi.....	61
4.2. Araştırmanın Kapsamı	62
4.3. Araştırmanın Kısıtları ve Varsayımları.....	62
4.4. Araştırma Verilerinin Elde Edilmesi ve Analizi	63
4.5. Araştırma Bulguları.....	70
BÖLÜM 5	74
SONUÇ ve ÖNERİLER.....	74
KAYNAKLAR	76
ÖZGEÇMİŞ	97

ÇİZELGELER DİZİNİ

Çizelge 2.1. Karmaşıklık Matrisi	8
Çizelge 3.1. Espor Tanımları	25
Çizelge 4.1. Araştırmanın Verileri	63
Çizelge 4.2. Araştırmada Kullanılan Hiperparametreler	68
Çizelge 4.3. Sınıflandırma Algoritmalarının Performans Ölçümleri.....	70
Çizelge 4.4. En İyi Hiperparametre Değerleri.....	72

ŞEKİLLER DİZİNİ

Şekil 4.1. ROC Eğrisi Değerleri.....	71
Şekil 4.2. Tüm Performans Ölçümlerine Göre Algoritmaların Karşılaştırılması.....	73



BÖLÜM 1

GİRİŞ

Bilgisayar oyunları, sürekli gelişen ve büyüyen oyun sektöründeki değişimler sayesinde toplumsal bir öğrenme aracı olarak önem kazanmıştır. Oyunlar, her zaman içinde bulundukları dönemin toplumsal, kültürel ve teknolojik atmosferini yansıtan birer ayna olmuştur (Yuzyk ve Seidner, 2022).

Elektronik spor (Espor), video oyunları kullanılarak yapılan bir spor müsabakası türüdür. Diğer oyun türlerinden farklı olan Espor, organize video oyunu yarışmaları ve bunların etrafında inşa edilen altyapıdır (Anderson vd., 2018). Her gün yüz milyonlarca kişi sanal ve rekabetçi Espor'a katılmaktadır. Espor hızla gelişen multidisipliner bir alandır. Espor oyunlarını oynayanlar veya sadece hayranı olan Espor tutkunları, dünya çapında çoğalmıştır. Espor dünyanın dört bir yanındaki ülkelerde hızla büyüyen bir eğlence unsurudur (DiFrancisco-Donoghue vd., 2019; Smerdov vd., 2019:1768). Bu büyüme, katılımcı topluluğun sadece güçlü bir ekonomik itici güç olmadığını, aynı zamanda daha kabul gören bir eğlence biçimi olduğunu göz önünde bulundurarak, araştırmacıların dikkatini çekmektedir. Ayrıca, bu büyüme sayesinde bilgisayar oyunları, kariyer ve yüksek öğrenime giren gençler için önemli bir hazırlık ekosistemi haline gelmiştir.

Günümüzde Espor sporcuları daha sıkı antrenman faaliyetleri ve artan psikolojik baskı ile karşı karşıya kalmaktadır (Anderson vd., 2018). Bu durum, Espor sporcularının performansının ölçülmesi ve değerlendirilmesi ile ilgili bazı sorunlara yol açmaktadır. Geleneksel olarak, koçlar takımın oynadığı oyunla ilgili öldürme ölüm oranı (Kill Death Ratio-KDR) gibi ölçütleri kullanmaktadır. Ancak, takım performansını artırmak için sadece oyun sonuçlarının analizini yapmak yeterli değildir. Bu nedenle, Espor alanındaki

arařtırmaların byk bir kısmı, yazarların Espor uzmanlarının davranıř kalıplarını anlamak iin istatistikleri ve elit oyuncularını neyin ayırdıđını anlamaya alıřmaktadır (Rambusch, 2011; Huang vd., 2017; Melentev vd., 2020). Ayrıca gnmzde Espor sporcuları, rekabetin giderek artmasıyla birlikte daha yođun antrenman programlarına katılmakta ve bu durum beraberinde artan psikolojik baskıyı getirmektedir. Bu, Esporun daha rekabeti bir dzeye evrilmesiyle birlikte sporcuların hem fiziksel hem de zihinsel olarak daha zorlu bir ortamda performans gstermesini gerektirmektedir (Anderson vd., 2018). Bu sorunlar, oyun ii verilere ek olarak fizyolojik veri toplanmasını sađlamak iin algılama teknolojilerine dayanarak veri toplama ve veri analizi alıřmalarını da ne ıkarmıřtır (Lebedev vd., 2017).

Bu tez alıřması, Espor oyuncularının oyun ii davranıřlarını makine đrenmesi yntemleri ile inceleyerek tahmin modelleri retmeyi amalamaktadır. Espor oyunlarından League of Legends (LoL) oyunu seilmiř ve veri seti bu erevede oluřturulmuřtur. alıřma Espor ve Espor oyunlarına dair kapsamlı bir arařtırma sunmaktadır. İkinci blmde makine đrenmesi, makine đrenmesi yntemlerinin ařamaları ve makine đrenmesi sınıflandırma algoritmaları aıklanmıřtır. nc blmde ise, Espor oyunlarının eřitleri, Espor oyuncularını, geleneksel sporlarla karřılařtırması, Espor ekipmanları ve teknolojik unsurları aıklanmıřtır. Ayrıca, Espor yayın teknolojileri, canlı yayınlar ve izleyici etkileřimi gibi nemli unsurlar da incelenmiřtir. Espor endstrisinin byklđ, oyuncuların kazanları ve kariyer olanakları gibi ekonomik ynleri ve Esporun etik ve hukuki boyutları detaylandırılmıřtır. LoL oyununun tarihi geliřimi, mekanikleri, stratejileri, poplerliđi ve teknolojik geliřmeleri zerinde durulmuřtur. Literatr taraması ile nceki alıřmalar gzden geirilmiř, arařtırma bořlukları ve gelecek iin arařtırma ihtiyaları belirlenmiřtir. Drdnc blmde arařtırma yntemi ve arařtırma bulguları aıklanmıřtır. Sonu ve nerilerle ise son blmde sunulmuřtur.

BÖLÜM 2

MAKİNE ÖĞRENMESİ

Makine öğrenmesi, verilerden öğrenebilen ve verilere dayalı tahminler yapabilen algoritma ve modellerin geliştirilmesine odaklanan bir alandır. Verilerden öğrenerek tahminde bulunmak için istatistiksel ve matematiksel yöntemlerin kullanılmasını içerir.

Makine öğrenmesi, sistemlerin verilerden öğrenmesini, kalıpları tanımasını ve en az insan müdahalesiyle kararlar almasını sağlayan hesaplamalı bir yöntemdir. Makine öğrenmesi, bilgisayarların deneyim yoluyla performanslarını otomatik olarak artırmalarına olanak tanıyan algoritmaların geliştirilmesine odaklanan yapay zekâ alt alanı olarak tanımlanmaktadır (Jordan ve Mitchell, 2015). Ayrıca makine öğrenmesi istatistik ve bilgisayar biliminin kesişiminde yer alan bir alan olarak da değerlendirilebilir (Jordan ve Mitchell, 2015). Bu çift yönlü bakış açısı, makine öğrenmesi modellerinde hem hesaplama verimliliğinin hem de istatistiksel sağlamlığın önemini vurgulamaktadır.

Makine öğrenmesi alanında başlıca üç öğrenme türü bulunmaktadır. Bunlar; denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenmedir.

Denetimli öğrenme, algoritmaların etiketli veri kümeleri üzerinde eğitilmesini içermektedir. Algoritma, yaptığı tahminler ile gerçek çıktılar arasındaki hatayı en aza indirerek girdileri uygun çıktılarla eşlemeyi öğrenir (Jordan ve Mitchell, 2015). Bu öğrenme biçimi, etiketli verilerin büyük miktarda bulunduğu görüntü sınıflandırma ve konuşma tanıma gibi uygulamalarda yaygın olarak kullanılmaktadır (Ghojogh ve Ghodsi, 2024). Denetimli öğrenmenin odak noktası, geçmiş verilere dayanarak gelecekteki sonuçları öngörebilmektir.

Buna karşılık denetimsiz öğrenme, etiketlenmemiş veri kümeleriyle çalışmaktadır. Bu yaklaşımın amacı, veri setini kategorize etmektir. Özellikle kümeleme,

anomali tespiti ve ilişkilendirme problemlerinde kullanılmaktadır. Denetimsiz öğrenme, önceden tanımlanmış etiketler olmadan desenleri veya grupları belirlemeye çalışmaktadır (Varshney ve Alemzadeh, 2016). Bu yöntem, büyük ve yapısal olmayan verileri etkili bir şekilde işleyebilme kapasitesi sayesinde çeşitli alanlarda önem kazanmıştır.

Pekiştirmeli öğrenme, bir ajanın bir ortamda hangi eylemleri gerçekleştirmesi gerektiğini deneme-yanılma yoluyla öğrenmesine odaklanmaktadır (Ghojogh ve Ghodsi, 2024). Ajanlar, çevreleriyle etkileşime girerek aldıkları eylemler sonucunda pozitif (ödül) ya da negatif (ceza) geri bildirim alırlar (Zhu, 2024). Bu çerçevede, özellikle robotik, oyun oynama ve gerçek zamanlı karar alma sistemleri gibi senaryolarda büyük önem taşımaktadır. Pekiştirmeli öğrenme algoritmalarının çoğu, ortamın durumlarını, eylemlerini ve ödülleri tanımlamak için kullanılan biçimsel bir yapı olan Markov karar süreci (MDP) temeli üzerine inşa edilmektedir (Ghojogh ve Ghodsi, 2024). Pekiştirmeli öğrenme, derin pekiştirmeli öğrenme gibi alt yöntemlere de ayrılabilir. Bu yaklaşım, karmaşık durum ve eylem uzaylarını işleyebilmek için derin öğrenme tekniklerinden faydalanır ve özellikle yüksek boyutlu ortamlarda etkili olmaktadır (Honda vd., 2022).

2.1. Makine Öğrenmesi Teknikleri İle Veri Analizi

2.1.1 Veri Ön İşleme

Veri ön işleme, makine öğrenmesi çalışmalarında model performansını önemli ölçüde etkileyen kritik bir aşamadır. Bu aşama, ham verilerin kalitesini ve kullanılabilirliğini iyileştirmek için verinin dönüştürülmesini ve temizlenmesini içerir. Veri ön işleme, etkili model eğitimi için bir temel oluşturmaktadır. Ön işlemenin önemi, bu adımın makine öğrenmesi iş akışına ayrılan toplam zamanın %60-%80 arasında büyük bir bölümü tüketebileceğini gösteren tahminlerle vurgulanmaktadır (Lopez vd., 2018). Uygun veri ön işleme olmadan modeller, artan hata oranları, aşırı öğrenme veya yetersiz öğrenme zorluklarıyla karşılaşabilmektedir. Sonuç olarak model performansın da düşmesine neden olabilmektedir.

Veri ön işlemenin temel işlevlerinden biri, gerçek dünya veri kümelerinde yaygın olan eksik değerler, aykırı değerler ve sınıf dengesizlikleri gibi veri kalitesi sorunlarını

ele almayı içermektedir (Chahid vd., 2023; Erol vd., 2022). Veri temizleme (eksik değerleri kaldırma veya yükleme), normalleştirme (özellikleri standart bir aralığa ölçekleme) ve dönüştürme (matematiksel ayarlamalar uygulama) gibi teknikler, verilerin modellemeyi amaçladığı temel olguyu temsil etmesini sağlamaya yardımcı olmaktadır (Alshdaifat vd., 2021). Araştırmalar, ilgili ön işleme tekniklerinin uygulanmasının, veri kalitesinin doğru teşhis ve tedavi planlaması için çok önemli olduğu sağlık hizmetleri de dahil olmak üzere çeşitli uygulama alanlarında sınıflandırma doğruluğunu önemli ölçüde artırabileceğini göstermektedir (Chahid vd., 2023; Sajjadnia vd., 2020).

Ön işleme tekniklerinin seçimi genellikle veri kümesinin özelliklerine ve seçilen modelleme algoritmalarına bağlı olmaktadır. Örneğin belirli çalışmalar, özellik seçimi ve boyut azaltma gibi yöntemlerin yüksek boyutlu verileri yönetmek ve model sağlamlığını iyileştirmek için hayati önem taşıdığını göstermektedir (Lopez-Miguel, 2021). Veri kümelerini en iyi şekilde temsil eden özelliklerin seçimi, daha yorumlanabilir modellere yol açabilmekte ve karmaşık makine öğrenmesi algoritmalarının eğitimiyle ilişkili hesaplama maliyetlerini önemli ölçüde azaltabilmektedir (Bouchiha vd., 2023).

Ön işleme metodolojilerindeki gelişmelerden biri de veri dizilerini hazırlamak için kayan pencereleri kullanan yöntemlerdir. Bu yöntemler, özellikle zaman serisi analizlerinde tercih edilmektedir (Kim ve Kim, 2024). Ön işleme stratejilerinin duruma göre uyarlanabilmesi, siber tehdit tespiti veya ağ izleme gibi sürekli değişen veri kümeleriyle çalışan alanlarda büyük önem taşımaktadır, çünkü bu alanlarda verilerin zamanında ve bağlama uygun şekilde dönüştürülmesi, sonraki makine öğrenmesi modellerinin başarısını önemli ölçüde etkileyebilmektedir. (Larriva-Novo vd., 2020; Larriva-Novo vd., 2021).

Veri ön işleme, ham verileri makine öğrenmesi uygulamaları için uygun temiz ve kullanılabilir bir biçime dönüştürmeyi amaçlayan bir dizi sistematik teknikten oluşmaktadır. Ham verilerdeki yaygın tuzakları ele alarak ve çeşitli ön işleme adımlarıyla kaliteyi artırarak, uygulayıcılar çeşitli sektörlerde daha doğru ve güvenilir makine öğrenmesi sonuçları için güçlü bir temel oluşturabilmektedirler.

2.1.2. Model Kurma

Model oluřturma, girdi verilerine dayalı tahmini modellerin geliřtirilmesini ieren makine ğrenmesinin temel bir bileřenidir. Bu sure, eřitli alanlardaki makine ğrenmesi sistemlerinin performansını ve uygulanabilirliğini belirlediėi iin kritiktir. Model oluřturma ařaması genellikle veri hazırlama, algoritma seimi, eėitim, deėerlendirme ve iyileřtirme gibi birka ařamayı kapsamaktadır (Torra ve Navarro-Arribas, 2018; Tian vd., 2022).

Bařlangıta, modelin kalitesi byk lde verilerden etkilenmektedir. Uygun veri hazırlama, bir modeli eėitmek iin uygun olduėundan emin olmak iin veri setini temizlemeyi, normalleřtirmeyi ve potansiyel olarak artırmayı iermektedir. Yetersiz řekilde hazırlanmıř verilerin, optimum olmayan model performansına yol aabileceėi yaygın olarak kabul edilmektedir ve bu ilk adımın nemini gstermektedir (Jafari vd., 2021). Kim vd. (2019), ham verileri modele etkili bir řekilde iletebilen anlamlı deėiřkenlere dnřtrmek iin zellik ıkarma ve mhendisliėin gerekliliėini vurgulamıřtır. Bu n iřleme ařaması, modelin verilerden etkili bir řekilde ğrenebilmesini saėlamakta nem tařımaktadır.

Veri hazırlama ařamasının ardından bir sonraki kritik adım algoritma seimidir. Her biri, eldeki soruna ve verilerin zelliklerine baėlı olarak benzersiz avantajlara ve dezavantajlara sahip ok sayıda algoritma mevcuttur. rneėin Destek Vektr Regresyonu (SVR) gibi regresyon teknikleri ve doėrusal regresyon gibi geleneksel modeller genellikle ngrc analizler iin kullanılmaktadır (Kim vd., 2019). Buna karřılık karmařık desenler, tahmin doėruluėunu artırmak iin birden fazla modeli bir araya getiren karar aėaları veya topluluk yntemleri gibi algoritmalarından faydalanabilmektedir (Luo, 2018). Algoritma seimi, modelin etkinliėini nemli lde etkileyebilir.

Seilen modeli eėitmek, algoritmaya hazırlanan veri kmesini beslemeyi ieren sonraki adımdır. Bylece model, verilerdeki desenleri ve iliřkileri tanımlamayı ğrenebilmektedir. Bu ğrenme sreci genellikle tahmin hatasını en aza indirmek iin model parametrelerinin optimizasyonunu ierir ve genellikle gradyan iniři gibi yntemler kullanılmaktadır (Luo, 2017). Arařtırmalar, apraz doėrulama gibi tekniklerin kullanılmasının, modelin performansını deėerlendirmek ve ařırı uyumu nlemek iin eėitim ařamasında faydalı olabileceėini gstermektedir (Matsubara vd., 2023). Ařırı

öğrenme, bir modelin yalnızca temeldeki kalıpları değil, aynı zamanda eğitim verilerindeki gürültüyü de öğrenmesi ve görülmeyen verilerde zayıf genellemeye yol açması durumunda meydana gelmektedir (Pavlyshenko, 2018).

İyileştirme aşaması ise modelin performansını optimize etmek için, model parametrelerinin doğruluğu veya hızı artırmak için ayarlandığı hiperparametre ayarlamasını ve modelin güncellenmiş veya daha kapsamlı veri kümeleriyle yeniden eğitilmesini içermektedir (Liu vd., 2020). Yinelemeli model iyileştirmesi, performans ve sağlamlıkta önemli iyileştirmelere yol açabilir ve modelin gerçek dünya koşullarına daha iyi uyum sağlamasını sağlayabilmektedir (Friedman vd., 2010).

Makine öğrenmesinde model oluşturma, veri hazırlama, algoritma seçimi, eğitim, değerlendirme ve iyileştirmeyi içeren çok yönlü bir süreçtir. Her adım, iş analitiğinden sağlık uygulamalarına kadar çeşitli alanlarda temel önem taşıyan etkili tahmin modelleri geliştirmede önemli bir rol oynamaktadır. Bu aşamaların her birinde en iyi uygulamaları anlamak ve uygulamak, modelin faydasını ve performansını önemli ölçüde artırabilmektedir.

2.1.3. Model Başarısı Değerlendirme

Model performans değerlendirmesi, makine öğrenmesinin temel bir yönüdür ve bir modelin görülmeyen verilere ne kadar iyi genelleştirildiği ve belirli sorunları çözmedeki etkinliği hakkında kritik içgörüler sağlamaktadır. Bu değerlendirme aşaması, çeşitli performans ölçümlerinin değerlendirilmesini, model doğrulama tekniklerini ve daha fazla geliştirme ve optimizasyona rehberlik etmek için sonuçların yorumlanmasını kapsamaktadır. Etkili model performans değerlendirmesi, makine öğrenmesi modellerinin gerçek dünya uygulamalarında güvenilir ve eyleme geçirilebilir tahminler sağladığından emin olmak için önem arz etmektedir (Irie vd., 2024).

Model performans değerlendirmesindeki temel görevlerden biri, uygun performans ölçümlerinin seçilmesi ve hesaplanmasıdır. Model başarısının ölçülmesi için tahmin değeri ile gerçek değer arasındaki doğru ya da yanlış sınıf atamalarını ifade eden karmaşıklık matrisi kullanılır. Karmaşıklık matrisi, verilerin gerçek sınıfının doğru ve yanlış tahmin değerlerini içermektedir.

Çizelge 2.1. Karmaşıklık Matrisi

	Tahmin Pozitif Sınıfı	Tahmin Negatif Sınıfı
Gerçek Pozitif Sınıf	TP	FN
Gerçek Negatif Sınıf	FP	TN

Çizelge 2.1’de yer alan TP (True Pozitif) pozitif tahmin değerinin gerçekte de pozitif, FP (False Pozitif) pozitif tahmin değerinin gerçekte negatif olduğunu, FN (False Negatif) negatif tahmin değerinin gerçekte de pozitif olduğunu ve TN (True Negatif) negatif tahmin değerinin gerçekte de negatif olduğunu ifade eder.

Karmaşıklık matrisinde yer alan TP, FP, FN ve TN değerlerine göre sınıflandırma yöntemlerinin performans ölçüm değerleri hesaplanır. Bunlar; doğruluk (accuracy), duyarlılık (precision), kesinlik (recall), F1 puanı, işlem karakteristik eğrisi (ROC) ve ROC eğrisinin altındaki alan (AUC)’dır (Irie vd., 2024; Monareng vd., 2023).

Doğruluk, incelenen toplam örnek sayısının veri setindeki tüm örnek sayısına oranıdır. Denklem 2.1 şeklinde hesaplanır ve doğru sınıflandırma oranı olarak da kullanılır.

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \quad (2.1)$$

Duyarlılık pozitif tahminlerin doğruluğunu yansıtmaktadır. Doğru tahmin edilen pozitif örnek sayının, doğru tahmin edilen pozitif ve yanlış tahmin edilen negatif örnek sayısına oranıdır. Denklem 2.2’de verilmiştir.

$$\text{Duyarlılık} = \frac{TP}{TP+FN} \quad (2.2)$$

Kesinlik, pozitif sınıfın tahmin edilme oranıdır. Doğru tahmin edilen örnek sayısının, doğru tahmin edilen pozitif ve yanlış tahmin edilen pozitif örnek sayısına oranıdır. Denklem 2.3’te belirtilmiştir.

$$\text{Kesinlik} = \frac{TP}{TP+FP} \quad (2.3)$$

F1 skoru, duyarlılık ve kesinlik ölçümlerinden elde edilen bir performans ölçümüdür. Dengeli sınıf dağılımı olamayan veri setlerinde duyarlılık ve kesinlik değerlerinin ikisinin de etkisini göstermektedir. Duyarlılık, modelin tüm ilgili örnekleri belirleme yeteneğini gösterir ve F1 puanı, özellikle dengesiz veri kümeleri için gerekli olan kesinlik ve duyarlılık ölçümlerini tek bir ölçü haline getirmektedir (Os vd., 2018). Denklem 2.4 ile hesaplanmaktadır.

$$F1 = \frac{2 \times \text{Duyarlılık} \times \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} \quad (2.4)$$

ROC, ölçülen ikili sınıflandırma hatasının olası tüm kombinasyonları için sınıflandırıcı eşiğinin yanlış pozitif oranı ve yanlış negatif oranı ile oluşturulan eğridir. Eğrinin, x ekseninde Yanlış Pozitif (FP) oranları ve y ekseninde Doğru Pozitif (TP) oranları bulunur (Taşdemir, 2022: 231). Tüm olası sınıflandırma eşikleri için toplu bir performans ölçütüdür. AUC ise ROC eğrisinin altında kalan alandır.

Model performans değerlendirmesi, model etkinliğini değerlendirmek, geliştirmeye rehberlik etmek ve tahmin yeteneklerini optimize etmek için sistematik bir çerçeve sağlamaktadır. Uygun ölçümler, sağlam doğrulama stratejileri ve titiz karşılaştırmalı analizler kullanarak, makine öğrenmesi modellerinin çeşitli uygulamalarda güvenilir ve gerçeğe yakın öngörüler sağlaması mümkün olabilir.

2.1.4. Model Doğrulama

Model doğrulama, makine öğrenmesi iş akışında önemli bir aşamadır ve tahmine dayalı modellerin sağlamlığını ve genelleme yeteneğini değerlendirmeye odaklanmaktadır. Amaç, belirli bir veri kümesi üzerinde eğitilen bir modelin, görülmeyen veriler üzerinde ne kadar iyi performans gösterebileceğini belirlemek ve modelin gerçek dünya senaryolarında uygulandığında güvenilir sonuçlar vermesini sağlamaya yardımcı olmaktır (Granholm vd., 2012). Uygun doğrulama, bir modelin yeni girdilere etkili bir şekilde genelleme yapmak yerine eğitim verilerinin ayrıntılarını öğrendiği aşırı öğrenme gibi yaygın tuzaklardan kaçınmaya yardımcı olmaktadır (Gitto vd., 2024).

Model doğrulama teknikleri de performans değerlendirmesinin ayrılmaz bir parçasıdır. Yaygın stratejiler arasında tek bir doğrulama kümesi (hold out) doğrulaması, k katlı çapraz doğrulama ve birini dışarıda bırakma çapraz doğrulaması (Leave-One-Out

Cross-Validation) bulunmaktadır (Rahman ve Yogarajah, 2022). Özellikle k katlı çapraz doğrulama, veri kümesini k alt kümeye böler, modeli $k-1$ alt kümede eğitirken kalan alt kümede doğrulamaktadır. Bu işlem k kez tekrarlanır ve modelin genelleme yeteneğinin sağlam bir tahminine olanak tanır (He, 2022). Çeşitli doğrulama yöntemlerinin sonuç değerlendirmesini önemli ölçüde etkilediği ve veri özellikleri ve model hedefleriyle uyumlu bir doğrulama stratejisi seçmenin gerekliliğın vurguladığı belirtilmektedir (Rahman ve Yogarajah, 2022). Ayrıca çapraz doğrulama, bir modelin eğitim verilerinde iyi ancak görülmeyen örneklerde kötü performans gösterdiği aşırı öğrenme sorunlarını azaltmaya yardımcı olmaktadır (Wang ve Xu, 2020).

Aşırı öğrenme (overfitting) ve eksik öğrenme (underfitting) modelin performansını etkileyen ve kaçınılması gereken iki önemli sorundur. Aşırı öğrenme, modelin verinin tamamını gürültüsüyle birlikte ezberlemesidir. Dolayısıyla modelin eğitim setinde tam uyum sağlanır ancak model genelleme uygun olmaz (Uğuz, 2023, s. 80). Eksik öğrenme ise modelin veriyi öğrenememesidir. Eksik öğrenme, yüksek yanlılığı ifade eder. Bu iki önemli sorunu çözmek için model doğrulama ve hiperparametre ayarlama adımları uygulanır.

Model doğrulama için popüler ve yaygın olarak benimsenen bir teknik çapraz doğrulamadır. Bu yöntem, veri kümesini birden fazla alt kümeye veya katmana bölmeyi içermektedir. K katlı çapraz doğrulama olarak bilinen en yaygın biçim, veri kümesini k eşit büyüklükteki alt kümeye böler, modeli k kez eğitir, her seferinde doğrulama için bir alt kümeyi tutarken kalan $k-1$ alt küme üzerinde eğitim yapmaktadır (Mao vd., 2018). Bu strateji, her veri noktasının hem eğitim hem de doğrulama için kullanılmasına aracı olarak model performansının sağlam bir tahminini ve de böylece sonuç performans ölçümlerinin güvenilirliği sağlamaktadır (Towett vd., 2020). çapraz doğrulamanın çeşitli deneysel koşullar arasında sonuçların bütünlüğünü korumada özellikle etkili olduğu vurgulanmaktadır (Granholm vd., 2012; Peeken vd., 2021).

Tamamlayıcı çapraz doğrulama (Complementary Cross-Validation) diğer bir doğrulama tekniklerinden biridir. Örneğın, tutma doğrulaması veri setini rastgele bir eğitim seti ve bir test seti olarak böler ve model performansının hızlı bir şekilde değerlendirilmesine olanak tanımaktadır (Wu ve Zhou, 2021). Bu yöntem daha basit olsa da, değerlendirmede önyargıyı önlemek için bölünmenin rastgele olduğundan emin

olmak için kullanılmaktadır. Buna karşılık, önyükleme (Bootstrapping) gibi daha karmaşık yöntemler, orijinal veri setinden birden fazla eğitim seti oluşturmak için değiştirmeyeyle örneklemeyi içermektedir. Bu, model performans tahminlerinin değişkenliğini daha iyi anlamaya yardımcı olmaktadır (Buizza vd., 2021).

Doğrulama süreci, performansı en üst düzeye çıkaran en iyi model parametrelerini sistematik olarak aramayı içeren hiperparametre ayarlamasını da içermektedir (Gitto vd., 2021). Izgara araması ve rastgele arama gibi teknikler, aşırı öğrenmeyi önlerken optimum ayarları belirlemek için çapraz doğrulama çerçevelerine entegre edilebilmektedir (Oh vd., 2022).

Hiperparametre ayarı, model performansını iyileştirmede önemli bir unsur olarak ortaya çıkmaktadır. Izgara araması (Grid Search) ve Bayes optimizasyonu gibi teknikler, performans ölçümlerini en üst düzeye çıkaran optimum hiperparametre ayarlarını belirlemek için uygulanmaktadır. Titiz hiperparametre ayarının tahmin doğruluğu ve genellemede önemli iyileştirmelere yol açabileceği belirtilmektedir (Guan ve Fu, 2022; Wellner vd., 2017). Çeşitli yapılandırmaları sistematik olarak değerlendirerek, modeller geliştirilebilir ve yüksek performans değerlerine ulaşılabilir.

Şeffaflığı sağlamak ve hangi yaklaşımların üstün performans sağladığını anlamak için çeşitli modellerin istatistiksel karşılaştırmalarını yapmak da aynı derecede önemlidir. Karşılaştırmalı çalışmalar genellikle makine öğrenmesi yöntemlerinin lojistik regresyon gibi geleneksel istatistiksel tekniklere göre performans avantajını işaret etmektedir. Örneğin, sistematik bir inceleme, makine öğrenmesi algoritmalarının tahmin kalitesini geleneksel yöntemlere kıyasla iyileştirmesine rağmen, lojistik regresyonu tekdüze bir şekilde geride bırakmadığı vurgulanmaktadır (Christodoulou vd., 2019). Bu nedenle, makine öğrenmesi modelleri birçok senaryoda iyi performans sergilerken, geleneksel modellerin rekabetçi veya hatta üstün doğruluk sergilediği durumlar kalır ve bu da model seçiminde bağlamın önemini göstermektedir.

Model doğrulama, makine öğrenmesinde tahmin modellerinin güvenilirliğini ve etkinliğini garanti eden temel bir tekniktir. K katlı çapraz doğrulama, performans ölçümlerini değerlendirme ve hiperparametre ayarlama tekniklerini dahil etme gibi titiz doğrulama yöntemlerini kullanarak uygulayıcılar, modellerinin tahmin yeteneklerini güvenle değerlendirebilir ve geliştirebilmektedirler. Bu aşama, makine öğrenmesinin

teorik avantajlarını çeşitli sektörlerde pratik, etkili uygulamalara dönüştürmek için hayati önem taşımaktadır.

2.1.5. Yeni Bir Gözlem İçin Tahminde Bulunma

Yeni gözlemler için tahminlerde bulunmak, modellerin eğitim için kullanılan veri kümelerinin ötesine faydalarını genişletmesini sağlayan makine öğrenmesinde önemli bir tekniktir. Bu tahmin yeteneği, sağlık hizmetlerinden finansa kadar çeşitli alanlarda çok önemlidir ve eğitim verilerinden öğrenilen kalıpları, görülmemiş veriler hakkında tahminlerde bulunmak için uygulamayı içermektedir (Zhang vd., 2024). Bu tahminlerin etkinliği, model seçimi, veri ön işleme ve doğrulama teknikleri dahil olmak üzere birbiriyle ilişkili birkaç faktöre bağlı olmaktadır.

Tahminlerde bulunmanın temel yönlerinden biri, verilerdeki karmaşık ilişkileri tahmin edebilen sağlam makine öğrenmesi algoritmalarının kullanılmasıdır. Makine öğrenmesi algoritmaları, yeni veri noktalarındaki sonuçları tahmin etmek için eğitim sırasında öğrenilen kalıplardan yararlanmaktadır (Raita vd., 2019). Büyük ve iyi yapılandırılmış veri kümelerinin kullanımı öğrenme sürecini ve dolayısıyla model tarafından yapılan tahminlerin kalitesini önemli ölçüde etkileyebilmektedir.

Doğrulama teknikleri, uygulayıcıların modellerini etkili bir şekilde test etmelerine ve iyileştirmelerine olanak tanıyarak tahmin sürecinde önemli bir rol oynamaktadır. Bir modelin doğrulama veri kümesindeki sonuçları ne kadar iyi tahmin ettiğini değerlendirerek, modelin eğitim verilerinde mükemmel olduğunu ancak yeni gözlemlerde zayıf performans gösterdiğini belirleyebilmektedir (Hirano vd., 2021). Kapsamlı doğrulama, model güvenilirliğine ilişkin içgörüler sağlar ve değişen koşullar altında yapılan tahminlerin tutarlı ve güvenilir olmasını sağlamaktadır (Raita vd., 2019). Çapraz doğrulama gibi gelişmiş doğrulama yöntemleri, model performansının birden fazla tahminini sağlayarak bu süreci daha da kolaylaştırır ve böylece dağıtımdan önce en iyi modeli seçmeye yardımcı olmaktadır (Li vd., 2021).

Yeni gözlemler için tahminlerde bulunmak, sağlam algoritmik temellere, titiz veri ön işleme, kapsamlı doğrulama ve yorumlanabilirliğe dayanmaktadır. Modelleri görülmemiş verilere uygulama yeteneği, makine öğrenmesi metodolojilerinin çeşitli

sektörlerde pratik uygulamasını güçlendirmekte, anlamlı öngörüler sağlar ve doğruluğu yüksek karar almaya yardımcı olmaktadır.

2.2. Sınıflandırma Modelleri

2.2.1 Naive Bayes

Naive Bayes (NB) sınıflandırıcısı, makine öğrenmesinde yaygın olarak kullanılan bir sınıflandırma tekniğidir ve verilen özelliklere göre bir sınıf etiketinin olasılığını belirlemek için Bayes teoremini uygulamaktadır. Özelliklerin sınıf etiketi verildiğinde koşullu olarak bağımsız olduğu basitleştirici varsayımı altında çalışmaktadır. Bu basitleştirilmiş görüşe rağmen, NB sınıflandırıcıları, öncelikle büyük veri kümelerini işlemedeki hesaplama verimliliği ve etkinliği nedeniyle iyi performans göstermektedir (Wibawa vd., 2019; Wickramasinghe ve Kalutarage, 2020).

NB, koşullu olasılık ilkesine göre çalışır ve giriş özelliklerine göre her sınıfın olasılığını hesaplamasına olanak tanımaktadır. Model bir veri kümesi üzerinde eğitildikten sonra, her olası sınıf için sınıf üyeliği olasılığını hesaplayarak ve en yüksek olasılığa sahip sınıfı seçerek yeni gözlemleri sınıflandırabilmektedir (Pradana ve Sugiharti, 2023). Sınıflandırıcının eğitim süreci, sınıf etiketlerinin ön olasılıklarının yanı sıra her sınıftaki özellik oluşumlarının koşullu olasılıklarını tahmin etmeyi içermektedir.

NB'in önemli avantajlarından biri basitliğidir. Bağımsızlık varsayımı nedeniyle, diğer karmaşık algoritmalara kıyasla daha az eğitim verisi gerektirir ve bu da onu verilerin sınırlı olduğu senaryolarda özellikle yararlı hale getirmektedir (Subarkah vd., 2022). Basit uygulaması, özellikle spam tespiti ve duygu analizi gibi metin sınıflandırma görevlerinde hızlı geliştirme ve dağıtımına olanak tanımaktadır (Cahyani ve Mardiana, 2020; Wickramasinghe ve Kalutarage, 2020).

Birçok avantajına rağmen NB sınıflandırıcısı, öncelikle bağımsızlık varsayımından kaynaklanan sınırlamalarla karşı karşıyadır. Gerçek dünya uygulamalarında, özellikler genellikle tahminlerin doğruluğunu etkileyebilecek bağımlılıklar sergilemektedir (Wu vd., 2021). Sonuç olarak, NB'in performansını artırmak için özellik seçimi tekniklerini entegre etmek veya optimizasyon yöntemlerini dahil etmek gibi çeşitli geliştirmeler önerilmektedir. Laplace yumuşatma (Add-one smoothing) gibi diğer teknikler, sıfır olasılık senaryolarını ele almak için kullanılmakta

ve böylece test setinden bir özellik eğitim setinde mevcut olmadığında sorunlar önlenmektedir (Pradana ve Sugiharti, 2023).

NB sınıflandırıcısı makine öğrenmesi sınıflandırma görevlerinde temel bir teknik olarak öne çıkmaktadır. Çeşitli uygulamalardaki basitliği, verimliliği ve etkinliği onu veri bilimcileri için değerli bir araç haline getirmektedir. Bağımsızlık varsayımı belirli sınırlamalar getirirse de araştırmalar, algoritmanın yeteneklerini geliştirmeye ve iyileştirmeye devam etmektedir.

2.2.2. Rastgele Orman

Rastgele Orman (RF), çoğunlukla sınıflandırma ve regresyon görevleri için kullanılan çok yönlü ve güçlü bir makine öğrenmesi algoritmasıdır. Eğitim sırasında birden fazla bireysel karar ağacı oluşturarak çalışır ve sınıflandırma görevleri için tahminlerinin modunu veya regresyon görevleri için ortalama tahmini çıktı olarak vermektedir. Bu topluluk yaklaşımı, tahmin doğruluğunu ve aşırı uyumu kontrol etmek için torbalama ve rastgelelik ilkelerinden yararlanmaktadır. Ayrıca bu algoritma gürültülü verilere karşı dayanıklıdır (Fang vd., 2020; Lebedev vd., 2014).

RF, topluluk yapısı karar ağaçları üzerinden çalışan güçlü bir bagging yöntemidir. Her ağaç özellikler üzerinden rastgele seçilir böylece modeller arasında çeşitliliğin artması sağlanır. Topluluk yapısı, bireysel ağaçların hatalarını telafi edebilir ve genelleme performansını artırır.

Algoritmanın temel özelliklerinden biri, yüksek boyutlu verileri etkili bir şekilde işleyebilmesidir. Her karar ağacı, modelin varyansını azaltmaya yardımcı olan ve genelleme yeteneklerini artıran özelliklerin rastgele bir alt kümesi kullanılarak oluşturulmaktadır (Kulkarni ve Sinha, 2013). Bu yaklaşım, modelin bir veri kümesinde bulunan potansiyel gürültüyü ve yedeklilikleri görmezden gelmesini sağlayarak, özellikle özellikler arasındaki korelasyonların gerçek örüntüleri gizleyebildiği karmaşık veri kümelerinde gelişmiş performansa yol açmaktadır (Díaz-Uriarte ve Andrés, 2006).

RF algoritmasının yapısı, farklı ağaçlar için çeşitli eğitim kümeleri oluşturmak üzere orijinal veri kümesinden birden fazla rastgele örneğin çekildiği "önyükleme" kavramı üzerinde çalışmaktadır. Eğitim kümelerindeki bu farklılık, bireysel ağaçlar farklı

önyargılar sergileyebilse de birlikte çok çeşitli örüntüleri yakalayan kapsamlı bir model oluşturdıkları anlamına gelmektedir.

RF algoritmasının bir diğer önemli avantajı, özellik önemini yönetme yeteneğidir ve modelin tahminlerine hangi değişkenlerin en önemli şekilde katkıda bulunduğuna dair öngörüler sağlamaktadır. Bu özellik, çeşitli uygulamalarda özellik seçimi ve yorumlanması için yararlı olduğu belirtilmektedir (Díaz-Uriarte ve Andrés, 2006).

RF algoritmasının dezavantajları ise özellikle veri kümesinin karmaşıklığına göre az sayıda ağaçla dikkatli bir şekilde ayarlanmazsa aşırı öğrenmeye eğilimli olmasıdır (Rudiyanto vd., 2024). Ayrıca yüksek boyutlu sınıflandırma problemlerini etkili bir şekilde ele alırken, modelin karmaşıklığı, çoklu ağaç değerlendirmeleri gerektiren topluluk yapısı nedeniyle gerçek zamanlı uygulamalarda daha yavaş performans sergilemektedir (Fiesta, 2024).

Özetle RF algoritması, doğruluğu, sağlamlığı ve karmaşık veri kümelerini yönetme kapasitesiyle dikkat çeken makine öğrenmesi içinde oldukça etkili bir sınıflandırma tekniği olarak kabul edilmektedir. Topluluk öğrenme yaklaşımı, özellik önemine ilişkin öngörüler sağlama yeteneğiyle birleştiğinde, onu özellikle sağlık, finans ve çevre çalışmaları olmak üzere birden fazla alanda değerli bir araç haline getirmektedir.

2.2.3. Karar Ağaçları

Karar ağaçları (DT), makine öğrenmesinde netlikleri, yorumlama kolaylıkları ve hem kategorik hem de sayısal verileri işlemedeki verimlilikleri nedeniyle önem kazanmış temel bir sınıflandırma tekniğidir. DT yapısı, iç düğümlerin belirli niteliklere dayalı kararları temsil ettiği, dalların bu kararların sonuçlarını gösterdiği ve yaprak düğümlerin nihai sınıflandırma sonuçlarını belirttiği bir akış şemasına benzemektedir (Huang ve Hoa, 2009).

Bir karar ağacının oluşturulması, verilerin sınıfların en iyi şekilde ayrılmasını sağlayan niteliğe göre yinelemeli olarak segmentlere ayrıldığı yinelemeli bölümlendirme gibi yöntemleri içermektedir. En iyi bölünmeleri belirlemek için kullanılan yaygın ölçütler arasında, alt düğümlerin homojenliğini en üst düzeye çıkarmayı amaçlayan Gini kirliliği ve entropi bulunmaktadır (Huang ve Hoa, 2009).

DT ayrıca parametrik değildir, giriş verilerinin önceden tanımlanmış bir dağıtımını varsaymamaktadır. Bu özellik, sağlık, finans ve pazarlama gibi çeşitli alanlarda uygulanabilirliğini artırmaktadır (Last vd., 2002).

Avantajlarının yanında karar ağaçları, özellikle bir modelin çok karmaşık hale geldiği ve altta yatan örüntüler yerine verilerdeki gürültüyü yakaladığı aşırı öğrenme gibi zorluklar da sunmaktadır. Bu, özellikle aşırı ayrıntılı bölünmelerden kaynaklanan derin ağaçlarda belirgindir. Önemli tahmin gücü sağlamayan dalların çıkarılmasını içeren budama gibi teknikler, aşırı öğrenme azaltılmaya ve model genellemesini iyileştirmeye yardımcı olabilmektedir (Mirzamomen ve Kangavari, 2016). RF ve Boosted Trees gibi topluluk yöntemleri, birden fazla ağacı bir araya getirerek, genel doğruluğu artırırken bireysel ağaç varyanslarını yumuşatarak karar ağacı performansını daha da artırmaktadır (Zimmermann, 2008).

Yorumlanabilirlik açısından, DT diğer birçok makine öğrenmesi modeline göre bir avantaja sahiptir. Yapılarının netliği, kullanıcıların karar alma sürecini izlemelerine olanak tanımakta ve bu da onları özellikle kredi puanlaması veya kredi onayları gibi bir tahminin arkasındaki mantığı anlamamanın kritik olduğu bağlamlarda değerli hale getirmektedir (Last vd., 2002).

DT basitlikleri, yorumlanabilirlikleri ve geniş uygulanabilirlikleri ile dikkat çeken yüksek etkili bir sınıflandırma tekniğidir. Aşırı öğrenme gibi zorluklarla karşı karşıya kalsalar da, budama ve topluluk yöntemleriyle yapılan geliştirmeler, çeşitli sektörlerde öngörücü analitikte temel bir araç olarak konumlarını sağlamlaştırmaktadır.

2.2.4. Lojistik Regresyon

Lojistik regresyon (LR), ikili sınıflandırma için yaygın olarak kullanılan bir istatistiksel yöntemdir ve ikili bağımlı değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişkiyi modellemektedir. Temel amacı, bir olayın meydana gelme olasılığını tahmin etmektir ve bu, tahmin edici değişkenlere ilişkin log-oranlar aracılığıyla ifade edilmektedir. Bu yaklaşım, basitliği ve yorumlanabilirliği nedeniyle tıp, finans ve pazarlama dahil olmak üzere çeşitli disiplinlerde ilgi görmektedir (Hilbe, 2016; Markowska, 2017; Yan vd., 2020).

LR'nun temel avantajlarından biri, yorumlanabilir parametreler sağlarken ikili sonuçları ele alma becerisinde yatmaktadır. Özellikle, modelden tahmin edilen katsayılar, tahmin edici değişkendeki bir birimlik bir değişiklik için sonucun log-oranlarındaki değişiklik olarak yorumlanabilmektedir (Westreich vd., 2010).

LR'nun dezavantajı ise log-oranlarda doğrusallık varsayımına dayanması ve bu varsayım geçerli olmadığında etkinliğinin sınırlı olmasıdır. Ek olarak LR, modelin verilerdeki aşırı vakalarla veya zayıf temsil edilen sınıflarla ilişkili olasılıkları tahmin etme eğiliminde olması nedeniyle nadir olayları doğru bir şekilde tahmin etmekte zorlanabilmektedir (Genkin vd., 2007; Samawi vd., 2016). Ayrıca, tahmin edici değişkenler arasındaki yüksek çoklu doğrusallık, model tahminlerinin istikrarını ve yorumlanabilirliğini olumsuz etkileyebilmektedir (Zheng vd., 2019).

Son yıllarda, daha karmaşık makine öğrenme tekniklerinin ortaya çıkması, araştırmacıları bu yöntemleri geleneksel lojistik regresyonla karşılaştırmaya yöneltmektedir. LR basitliği nedeniyle sıklıkla bir temel olarak hizmet etse de, çalışmalar belirli senaryolarda, özellikle amaç netlik ve model açıklanabilirliği olduğunda, DT ve destek vektör makineleri (SVM) gibi daha karmaşık algoritmalarından daha iyi performans gösterebileceğini göstermektedir (Chen ve Zhang, 2024; Ye vd., 2020).

LR'nun işlevselliği, çoklu doğrusallığı yönetmeye ve daha az önemli öngörücüleri cezalandırarak öngörü performansını iyileştirmeye yardımcı olan Lasso ve Ridge regresyonu gibi düzenleme tekniklerinin uygulanmasıyla geliştirilmiştir (Liang vd., 2013). Bu nedenle, LR istatistiksel modelleme ve makine öğrenmesinde temel yöntemlerden biri olarak dururken, uygulayıcıların sınırlamalarının farkında olmaları ve aynı zamanda modelleme stratejilerini optimize etmek için son gelişmelerden yararlanmaktadırlar. Araştırmacılar basitlik ve karmaşıklık arasındaki dengeyi bulmaya çalışırken, LR hem güvenilir bir ölçüt hem de çeşitli alanlarda ikili sınıflandırma görevleri için pratik bir araç olarak hizmet etmeye devam etmektedir.

2.2.5. K-En Yakın Komşu

K-En Yakın Komşular (KNN), basitliği ve etkinliğiyle bilinen makine öğrenmesinde temel bir sınıflandırma tekniğidir. Benzer veri noktalarının özellik alanında birbirine yakın olması ilkesine göre çalışır ve bu da KNN'nin bir girdiyi en yakın k

komşusunun sınıflarını değerlendirerek sınıflandırmasına olanak tanımaktadır. k yapılandırması esasen yeni bir örneğin sınıfını belirlerken kaç tane komşu veri noktasının dikkate alındığını ifade etmektedir. Sınıflandırma kararı genellikle bu k en yakın noktadan gelen çoğunluk oyu temelinde verilmektedir. Bu teknik, açık bir model oluşturmadığı için bellek tabanlı veya örnek tabanlı bir öğrenme yöntemi olarak kategorize edilmektedir; sınıflandırma sırasında referans için eğitim veri setini korumaktadır (Maillo vd., 2017; Paramita, 2022).

KNN'nin tanımlayıcı özelliklerinden biri, parametrik olmayan yapısıdır. Örneğin altta yatan veriler için belirli bir dağıtım varsaymamakta ve bu da onu tıbbi teşhis, görüntü sınıflandırması ve müşteri memnuniyeti analizi dahil olmak üzere çeşitli uygulamalarda çok yönlü hale getirmektedir (Marlisa vd., 2024; Tembusai vd., 2021). KNN algoritması, iyi tanımlanmış ve örnek benzerliğinin doğrudan sınıf üyeliğiyle ilişkili olduğu veri kümeleriyle özellikle iyi performans göstermektedir. Ancak, özellikle yüksek boyutlu verilerde, veri noktaları arasındaki mesafelerin bu tür alanlarda daha az anlamlı hale geldiği "boyutluluk laneti" (Curse of Dimensionality) nedeniyle hatalar ortaya çıkabilmektedir (Tomašev vd, 2011).

KNN'nin basitliği, eğitim amaçları ve hızlı prototipleme için avantajlı olan uygulama ve yorumlama kolaylığına katkıda bulunmaktadır. KNN'ye yönelik hesaplama talebi, sınıflandırma aşamasında tüm eğitim veri kümesini işlediği için önemli olabilmektedir, bu nedenle ağaç yapıları ve sınıflandırma sürecinin doğruluğunu ve hızını artırabilen mesafe ağırlıklı yaklaşımlar gibi verimliliği artırmak için çeşitli stratejiler araştırılmaktadır (Prasanti vd, 2018).

KNN'nin performansını değerlendirmek genellikle doğruluk, kesinlik ve duyarlılık gibi çeşitli ölçümleri ve modelin görülmemiş verilere iyi genelleştirilmesini sağlamak için Çapraz Doğrulama gibi teknikleri içermektedir (Setiyorini ve Asmono, 2019). KNN algoritmasının sınıflandırma doğruluğunu artırmaya yönelik araştırmalar, özellik seçimi tekniklerinin entegrasyonu ve verilerin doğasını daha iyi yansıtan mesafe ölçümlerinin uyarlanması dahil olmak üzere çeşitli ilerlemelere de yol açmaktadır (Dananjaya vd., 2019).

KNN, kullanım kolaylığı ve uyarlanabilirliği nedeniyle makine öğrenmesi sınıflandırma ortamında baskın bir yöntemdir. Ancak performansı dikkatli parametre seçimi ve veri ön işleme çabalarına bağlı olabilmektedir.

2.2.6. Destek Vektör Makineleri

Destek Vektör Makineleri (SVM), hem sınıflandırma hem de regresyon görevlerinde mükemmellik göstererek, denetlenen makine öğrenmesi alanında temel bir araç olarak ortaya çıkmıştır. 1995 yılında Cortes ve Vapnik tarafından tanıtılan SVM'nin temel ilkesi, veri kümesindeki farklı sınıflar arasındaki marjı en üst düzeye çıkaran ve yüksek boyutlu veri alanlarının karmaşıklığını etkili bir şekilde ele alan optimum hiper düzlemi bulmaktır (Liu vd., 2022; Xiaokang vd., 2016). SVM'nin bu ikili işlevi, yalnızca doğrusal olarak ayrılabilir verileri sınıflandırmasına değil, aynı zamanda doğrusal olmayan sınıflandırma için çekirdek işlevlerini kullanmasına da olanak tanımakta ve esnekliğini ve çeşitli alanlardaki uygulamasını artırmaktadır (Ding ve Huang, 2014; Piccialli ve Sciandrone, 2022).

Pratik uygulamalarda, SVM ağırlıklı olarak metin sınıflandırması, tıbbi teşhis ve finansal tahmin gibi görevlerde kullanılmış ve sağlamlığını göstermektedir. Örneğin, diyabetik ayak ülseri tekrarını tahmin etmede ve otomotiv siber güvenlik senaryolarında normal ve anormal sürüş davranışları arasında ayırım yapmada etkili bir şekilde kullanılmaktadır (Hong vd., 2024; Mishra, 2024). Bu tür bir çok yönlülük, SVM'nin çeşitli veri kümeleri arasında kesin tahminler sağlayarak gerçek dünya sorunlarını ele almadaki etkinliğini vurgulamaktadır; bu, karar ağaçları ve sinir ağları gibi diğer sınıflandırıcılara kıyasla performansını vurgulayan çalışmalarla da doğrulanmıştır (Liu vd., 2010; Yuan vd., 2010).

SVM'nin teorik omurgası, görülmemiş test örnekleri için beklenen sınıflandırma hatasını en aza indirmeyi vurgulayan istatistiksel öğrenme teorisine dayanmaktadır. Bu, aşırı uyumu en aza indirmekte ve böylece SVM modellerinin yeni verilere iyi bir şekilde genelleştirilmesini sağlamaktadır (Ding ve Huang, 2014; Piccialli ve Sciandrone, 2022). "Marj" kavramı SVM'de önemli bir rol oynar; bu marjı en üst düzeye çıkarmak sınıflandırmaya yardımcı olmakta ve algoritmanın doğruluktan ödün vermeden verilerdeki hataları işleme kapasitesine önemli ölçüde katkıda bulunmaktadır (Thu ve

Xuan, 2018). SVM, makine öğrenmesi metodolojilerinde önemli bir ilerlemeyi temsil etmekte ve hem matematiksel olarak sağlam hem de çeşitli alanlarda pratik olarak etkili bir çerçeve sağlamaktadır.

2.2.7. XGBoost

Extreme Gradient Boosting (XGBoost), bir gradyan artırma çerçevesi aracılığıyla öngörücü modellemeyi geliştiren önemli bir makine öğrenme tekniğidir. Tahminlerin doğruluğunu artırmak için karar ağaçlarına dayanır. XGBoost, sağlık, finans ve çevre bilimi dahil olmak üzere birden fazla alanda çeşitli veri odaklı görevlerde özellikle değerli hale getirmektedir.

Chen ve Guestrin tarafından 2016 yılında geliştirilen XGBoost, geleneksel gradyan artırma algoritmalarının bir optimizasyonudur. Karar ağaçları gibi karmaşık modellerde yaygın bir sorun olan aşırı öğrenmeyi önlemek için düzenleme gibi teknikler sunmaktadır. XGBoost, algoritmanın verimliliğini artırmak için ikinci dereceden türevleri kullanır ve bu da onu büyük veri kümeleri için bile önemli ölçüde daha hızlı ve ölçeklenebilir hale getirmektedir (Chen ve Guestrin, 2016). Hızı ve ölçeklenebilirliği, çok sayıda özelliği ve eksik değeri işleme yeteneğiyle birleştiğinde, RF ve SVM gibi diğer modellere göre daha başarılıdır (Liu vd., 2023).

Birkaç zayıf öğreneni (genellikle sık karar ağaçları) birleştiren XGBoost'un topluluk yaklaşımı, model karmaşıklığına yenik düşmeden verilerdeki karmaşık ilişkileri yakalayan sağlam bir model üretir (Wang vd., 2020). Bu tür davranışlar, XGBoost'u çevresel olayları tahmin etmeye ve finansal tahminlere kadar uzanan uygulamalarla birden fazla disiplinde tercih edilen bir model haline getirmiştir (Cava vd., 2023; Gülsün ve Aydın, 2024; Jin vd., 2020). Topluluk yapısı; hız, doğruluk ve genelleme açısından verimli sonuçlar doğurur. Modeli, düzenlileştirme ve optimizasyon teknikleriyle güçlendirilir.

Hiperparametre ayarlaması açısından, XGBoost performansını artırmak için bir optimizasyon stratejisine ihtiyaç duyar. Bayes optimizasyonu gibi teknikler, bu parametreleri ayarlamak için başarıyla kullanılmış ve geliştirilmiş model çıktıları elde edilmiştir (Taninaga vd., 2019). Bu süreç, XGBoost kullanırken ince ayar yapmalarına

olanak tanır ve çeşitli uygulamalarda gelişmiş tahmin performansına daha fazla katkıda bulunur (Kollongei ve Onyango, 2024).

Genel olarak XGBoost, hesaplama açısından verimli ve ölçeklenebilir bir çerçeve aracılığıyla yüksek doğruluk sağlama konusundaki kapsamlı yeteneğiyle makine öğrenmesinde öne çıkmaktadır. Çok sayıda araştırma alanı ve pratik uygulamadaki etkinliği, uygulayıcılar arasında tahminsel modelleme zorlukları için önde gelen bir tercih olma statüsünü doğrulamaktadır.

2.2.8. Yapay Sinir Ağları

Yapay Sinir Ağları (ANNs), insan beyninin, özellikle nöronlarının ve sinapslarının yapısı ve işleyişinden esinlenerek, makine öğrenmesi algoritmalarının daha geniş yelpazesi içinde dönüştürücü bir yaklaşımı temsil etmektedir. Çeşitli alanlardaki karmaşık veri kümelerini işlemedeki etkinlikleri nedeniyle önemli ilgi görmüştür. ANNs, beyindeki biyolojik sinir ağlarının bilgiyi işleme biçimini taklit ederek çalışmaktadır. Bu, giriş verilerinden özellikleri öğrenmek için iş birliği içinde çalışan birbirine bağlı düğümlerin (nöronların) katmanlarını içermektedir.

ANNs tarafından öğrenilen temel mekanizmalardan biri, geri yayılım olarak bilinen bir eğitim süreci sırasında ağırlıklarını ayarlamaktır. Bu eğitim, üretilen çıktıya göre ağırlık parametrelerini yinelemeli olarak güncelleyerek tahminlerdeki hatayı en aza indirmek için büyük veri kümelerini kullanır. ANNs, özellikle çok katmanlı algılayıcılar ve derin sinir ağları, özellik çıkarma ve sınıflandırma görevlerinde mükemmeldir ve genellikle geleneksel makine öğrenmesi yaklaşımlarını geride bırakır (Dash vd., 2020; Du, 2024). Örneğin, derin öğrenme mimarilerinin tanıtımı, yüksek boyutlu alanlarda karmaşık işlevleri yaklaşık olarak hesaplama yeteneğini önemli ölçüde geliştirerek görüntü ve konuşma tanıma alanındaki uygulamaları önemli ölçüde iyileştirmiştir (Gu vd., 2018; Mnih vd., 2015).

ANNs mimarisi, basit ileri beslemeli ağlardan, evrişimli sinir ağları (CNN'ler) ve yinelemeli sinir ağları (RNN'ler) gibi daha karmaşık yapılandırmalara kadar geniş bir yelpazede değişebilir. Her mimari farklı amaçlara hizmet eder; örneğin, CNN'ler görüntü verilerine göre uyarlanmıştır ve görüntülerdeki uzamsal hiyerarşileri algılayabilen katmanları kullanırken, RNN'ler ardışık bilgileri işlemede ustadır ve bu da onları doğal

dil işleme görevleri için uygun hale getirir (Du, 2024; Gu vd., 2018). ANNs mimarilerinin uyarlanabilirliği, belirli uygulama gereksinimlerini karşılamak için evrimleşmelerine olanak tanır ve sağlık hizmetlerinden otonom sürüşe kadar uzanan alanlarda dikkate değer ilerlemelere yol açmaktadır (Sharma vd., 2020; Wu vd., 2018).

Avantajlarına rağmen ANNs, aşırı öğrenme ve etkili eğitim için kapsamlı veri ihtiyacı gibi zorluklarla da karşı karşıyadır. Bu tür sorunları azaltmak için bırakma, düzenleme ve veri artırma gibi teknikler önerilmektedir (Du, 2024; Serwa, 2022). Ayrıca derin ağların eğitimiyle ilişkili hesaplama yoğunluğu, donanım yeteneklerinde ve eğitim algoritmalarında ilerlemeler gerektirir. Paralel hesaplama ve bulut kaynaklarının kullanımındaki son gelişmeler, bu hesaplama kısıtlamalarını ele almak için ortaya çıkmış ve büyük ölçekli modellerin daha verimli bir şekilde eğitilmesini sağlamıştır (Wu vd., 2018).

ANNs modern makine öğrenmesinin temel bir ayağı olarak hizmet eder ve verilerden karmaşık gösterimleri öğrenme yeteneği özellikleri ile öne çıkar. Devam eden evrimleri muhtemelen daha da büyük yetenekler ve uygulama potansiyelleri ortaya çıkaracak ve bu da YSA'nı alanda devam eden araştırma ve geliştirme konusu yapacaktır.

2.2.9. Gradient Boosting

Gradient Boosting'in (GBoost) temel özelliklerinden biri, modele yeni öğrenciler eklenmesi sürecinde yapılan hataların artıklarına (Residual Errors) odaklanarak öğrenmeyi kademeli biçimde ilerletmesidir. Bu birikimli öğrenme süreci, genel tahmin doğruluğunun artırılmasında kritik bir rol oynamaktadır (Mienye ve Sun, 2022). GBoost'un temel ilkelerini optimize etmek ve model performansını artırmak amacıyla geliştirilmiş çeşitli uygulamaları bulunmaktadır. Bunlar arasında XGBoost, LightGBM ve CatBoost gibi popüler yöntemler yer almaktadır (Nguyen vd., 2021; Luo ve Chen, 2020; Rathnayake vd., 2023). GB, birçok zayıf karar ağacının ardışık olarak eğitildiği bir topluluk modelidir. Her ağaç, önceki modelin hatasını azaltmayı hedefler. Her model ile topluluk, yüksek doğrulukta sınıflandırmalar yapabilir.

Gradyan artırma algoritmalarının başarısı, finans sektöründen çevre bilimlerine kadar pek çok alanda yapılan uygulamalarla kanıtlanmıştır. Örneğin balık türlerinin dağılımının tahmini (Khiari ve Olaverri-Monreal, 2020), dengesiz veri kümelerinde yetim

genlerin (orphan genes) tanımlanması (Pittman ve Brown, 2011) ve güneş radyasyonu tahmini (Gao vd., 2020) gibi karmaşık görevlerde gradyan artırma tekniklerini içeren topluluk yöntemlerinin üstün performans sergilediği gösterilmiştir. XGBoost gibi özel varyantlar, paralel işlem, düzenlileştirme (regularization) ve ağaç budama gibi gelişmiş özellikler sunarak verimliliği ve tahmin gücünü daha da artırmaktadır (Solano vd., 2022).

Gradyan artırma yöntemleri, hedef değişkenin istatistiksel özelliklerinin zamanla değiştiği "kavram kayması" (concept drift) gibi veri koşullarına da uyum sağlayabilmektedir (Toghani, 2020). Bu tür uyarlanabilirlik, GBoost türlerinin değişen veri yapıları karşısında yüksek performanslarını koruyabildiklerini ve topluluk öğrenme tekniklerindeki en son gelişmeleri temsil ettiklerini göstermektedir.

GBoost modellerinin etkinliğini en üst düzeye çıkarmada hiperparametre ayarlaması da büyük önem taşımaktadır. Araştırmalar parametrelerin dikkatli bir şekilde düzenlenmesinin modellerin genelleme yeteneklerini önemli ölçüde etkileyebileceğini ve doğruluk ile ROC eğrisi altındaki alan (AUC) gibi performans ölçütlerini iyileştirdiğini ortaya koymaktadır (Li ve Chen, 2020; Vassallo vd., 2021).

BÖLÜM 3

ESPOR VE ESPOR OYUNLARI

Espor yeni bir olgu değildir, bilişimle birlikte ortaya çıkmış ve gelişmiştir. Espor teriminin geçmişi doksanlı yılların sonlarına kadar uzanmaktadır (Scholz vd., 2019). Espor endüstrisi 2020 yılından bu yana artan sayıda kullanıcı, izleyici ve teknoloji gelişimi nedeniyle önemli bir büyüme göstermiştir. Küresel Espor pazarı 1,08 milyar ABD doları değerinde olup yıllık %14,5'lik bir artış göstermektedir. Bu büyümeye katkıda bulunan faktörler arasında teknoloji patlaması ve COVID-19'un neden olduğu sosyal mesafe de yer almaktadır (Jordan-Vallverdú vd., 2024).

Espor'un tanımlanmasına ilişkin fikir birliği eksikliği, araştırma ve geliştirmede sorunlara yol açmıştır. Farklı Espor araştırmaları arasında bulguların genelleştirilmesi, Espor'un tanımlanması konusunda fikir birliği olmaması nedeniyle engellenmektedir. Espor kavramının ve ilgili kavramlarla ilişkisinin netleştirilmesi, gelecekteki araştırmalar ve Espor konusunda kamu bilincinin geliştirilmesi ve sektörün gelişiminin teşvik edilmesi için çok önemlidir. Mobil oyunlar ve hareket algılayıcı oyunlar gibi yeni oyunlar 2016'dan bu yana uluslararası Espor yarışmasında yer aldığından, 2022 Asya Oyunları'ndaki resmi rekabet, Espor'un nasıl tanımlandığına dair yeni bilgiler sunmaktadır. Bu nedenle Espor tanımlarının endüstri eğilimleri bağlamında yeniden gözden geçirilmesi ve anlaşılması gerekmektedir (Tang vd., 2023).

Espor, bir spor türü olarak güçlü bilişsel yetenekler gerektirmektedir. Bireysel veya takımlar halinde oynanabilen bir spor olan Espor, önemli takipçi ve katılımcı tabanı nedeniyle uluslararası bir fenomen haline gelmiştir (Mancı vd., 2024).

İnsanların oyun oynama ve oyunu izleme motivasyonunun ötesinde Espor, diğer geleneksel sporlar gibi, büyük bir iştir. Ancak Espor, Amerikan ya da Avrupa futbolu gibi

sporlarla karşılaştırılamamalıdır, çünkü Espor daha çok rekabetçi bir şekilde oynanabilen herhangi bir video oyunu için kullanılan bir kapsayıcı terimdir. Espor'un öne çıkan bir tanımı Wagner (2006), “*Esporum, insanların bilgi ve iletişim teknolojilerini kullanarak zihinsel veya fiziksel yeteneklerini geliştirdikleri ve eğittikleri bir spor faaliyeti alanı olduğu*” belirtilmektedir (parag.21).

Çizelge 3.1. Espor Tanımları

Yazar/yıl	Tanımlar
Jin (2010)	Espor başlangıçta ağ oyunları aracılığıyla yarışan elektronik spor ligleri için dar bir tanım olarak kullanılmıştır. Çevrimiçi oyunların büyümesiyle birlikte, Espor kavramı yalnızca ağ oyunları aracılığıyla rekabeti değil, aynı zamanda ağ oyunları ile ilgili kültürel ve endüstriyel faaliyetleri de içerecek şekilde genişlemiştir.
Jonasson & Thilborg, (2010)	Espor, rekabetçi bilgisayar oyunları olarak tanımlanmaktadır.
Jenny vd., (2017)	Espor, “ <i>organize video oyunu müsabakalarıdır</i> ”.
Hamari & Sjöblom, (2017)	Espor, “ <i>sporun birincil yönlerinin elektronik sistemler tarafından kolaylaştırıldığı bir spor biçimidir; oyuncuların ve takımların girdilerinin yanı sıra Espor sisteminin çıktısına insan-bilgisayar arayüzleri aracılık etmektedir</i> ”.
Baltezarević & Baltezarević, (2018)	Espor sanal alanda gerçekleşmekte ve geleneksel spor anlayışında olduğu gibi sadece katılımcının fiziksel varlığına değil, insan ve bilgisayar arasındaki etkileşime dayanmaktadır.
Anderson vd., (2018)	Espor, organize video oyunu müsabakaları ve bunların etrafında inşa edilen altyapıdır.
Ruvalcaba vd. (2018)	Espor, video oyunlarının halka açık ortamlarda rekabetçi bir şekilde oynanması olarak tanımlanmaktadır (örneğin, çevrimiçi ortamlarda veya seyirciler için video oyunlarının yayınlanması)
Scholz vd., (2019).	Espor, bir ödül için tek başına veya takımlar halinde, yerel, ulusal veya küresel olarak bir video oyununda rekabet etmektir
Gawrysiak vd., (2020)	Espor, geleneksel olmayan bir spor modeli olarak hizmet veren, ticarileştirilmiş bir eğlence girişimi olarak kendini kabul ettiren ve özellikle son beş yılda yüz milyonlarca dolar gelir elde eden organize video oyunu yarışmalarını ifade etmektedir.
Pedraza-Ramirez, (2020)	Espor, oyuncuya profesyonel ve/veya kişisel gelişim sağlayan belirli video oyunlarını oynamanın gündelik veya organize rekabetçi faaliyetidir. Bu uygulama, takımların ve bireysel oyuncuların profesyonel veya amatör düzeyde çevrimiçi ve/veya yerel alan ağı turnuvalarında pratik yaptığı ve rekabet ettiği bilgisayarlar, konsollar, tabletler veya cep telefonları gibi elektronik sistemler tarafından sağlanmaktadır. Oyunlar sıralama sistemleri ve yarışmalarla belirlenir ve resmi ligler tarafından düzenlenmektedir. Bu yapı, oyunculara bir topluluğun parçası olma hissi verir ve özellikle yüksek performans seviyelerinde ince motor koordinasyonu ve algısal-bilişsel becerilerde uzmanlık kazanmayı kolaylaştırmaktadır.
Jordan-Vallverdú vd., (2024)	Espor terimi, çevrimiçi veya yüz yüze, bireysel ve profesyonel oyuncuların “ <i>bilgisayar oyunlarına yönelik organize ve rekabetçi bir yaklaşımla</i> ” yarıştığı bölgesel ve uluslararası oyun etkinliklerini ifade etmektedir.

Teknolojik gelişme, Espor oyun tutkusunun dijital dünyaya yayılmasını ve video oyunlarının ortaya çıkmasını sağlamıştır. İlk oyunların rekabetçi yöne odaklandığını ve daha da önemlisi insanların rakiplerini izleyebilecekleri bir ortam yarattığını vurgulamak önemlidir. Eğlence amaçlı ilk oyun 1958 yılında William Higinbotham tarafından yazılan Tennis for Two (İki Kişilik Tenis) adlı oyundur. Bu oyun rekabetçi bir yöne sahip olmasının yanı sıra başkalarının oyunu izlemesine olanak tanıyan bir potansiyele de sahiptir (Wolf, 2012).

Tennis for Two ve diğer oyunlar o dönemde başarılı bir Espor oyununun tüm unsurlarına sahip olabilmıştır. Ancak iş perspektifinden bakıldığında bir video oyunu endüstrisi yaratmak mümkün olmamıştır. Bilgisayarlar maliyetli olduğundan, eğlence amaçlı video oyunları için bir pazar oluşturulamamıştır. 1970'lere kadar insanların sadece küçük bir kısmının bilgisayarlara erişimi olmuştur ve bu bilgisayarlar da çoğunlukla işyerlerinde kullanılmıştır. Bu durum bilgisayarların fiyatlarının azalması ve atari oyunlarının ve oyun konsollarının yaygınlaşmasıyla değişmiştir. Magnavox, Atari ve Vectorbeam gibi şirketler ilk ürünlerini 1972 yıllarında piyasaya sürmüştür ve ilk Espor turnuvası o yılın Ekim ayında Stanford'da gerçekleşmiştir. Galaksilerarası Uzay Savaşı Olimpiyatları (The Intergalactic Spacewar Olympics)'nın ödülü Rolling Stone dergisine bir yıllık abonelik olmuş ve video oyunlarına rekabetçi bir turnuva bakış açısının başlangıcını işaret etmiştir (Taylor, 2012). Sonraki yıllarda video oyunları pazarı büyümüş, konsolların ve oyun salonlarının sayısı katlanarak artmıştır. Ancak Esporun bu ilk aşamalarında yer alan birçok şirket ürünlerinden yeterince para kazanmakta zorlanmıştır (Scholz, 2019).

Espor terimini kullanan en eski güvenilir kaynaklardan biri, 1999 yılında Online Gamers Association'ın (OGA) lansmanında Eurogamer evangelisti Mat Bettington'ın Espor'u geleneksel sporlarla karşılaştırdığı basın açıklamasıdır. Bettington, Esporun gelecekte geleneksel sporlarla aynı şekilde sanal olarak yer alacağını öngörmektedir (The OGA, 1999).

Espor'un gençlik kültüründe bir iş faktörü olarak ortaya çıkışı dünya çapında öneme sahiptir ve kültürel bir fenomen olarak tanımlanmaktadır. Ancak gerçekte doğu ve batı değer sistemleriyle ayrılmış iki farklı oyun kültürü görülmektedir. Amerika Birleşik Devletleri ve Avrupa'da rekabetçi oyunların tarihi genellikle ağ üzerinden oynanan

birinci şahıs atış oyunlarının, özellikle de id Software tarafından 1993'te piyasaya sürülen "Doom" ve 1996'daki devam oyunu "Quake"ın piyasaya sürülmesiyle ilişkilendirilmektedir. Bu süre zarfında "Klanlar" olarak da adlandırılan çevrimiçi oyuncu takımları, çevrimiçi turnuvalarda yarışmaya başlamıştır. 1997 yılına gelindiğinde birkaç profesyonel ve yarı profesyonel çevrimiçi oyun ligi kurulmuş, en dikkat çekenini de hala etkili olan ve iş konsepti Amerika Birleşik Devletleri'ndeki büyük profesyonel spor liglerini örnek alan "Cyberathlete Professional League (CPL)" olmuştur (Welch, 2002). Canlı izleyiciler önünde düzenlenen ilk CPL turnuva etkinlikleri arasında 1997 yılında "The Frag" olarak da bilinen "The Foremost Roundup of Advanced Gamers" yer almıştır. CPL'nin felsefesine göre, profesyonel bilgisayar oyunculuğu artık gelişmekte olan bir seyirci sporu olarak kabul edilmiştir. 1999 yılında oyun geliştirme şirketi Valve, birinci şahıs nişancı oyunu (FPS) "Half-Life"ın bir modifikasyonu olarak "Counter-Strike" oyununu piyasaya sürmüştür. Oyun, rekabetçi oyunlarda popülerlik açısından hızla Quake'in yerini almış ve o zamandan beri batı Espor etkinliklerinde merkezi unsur olarak devam etmektedir (Wagner, 2006).

3.1.1. Oyun Türleri: Rekabetin Farklı Yüzleri

Teknolojik gelişmeler oyun ve oyuncu deneyimleri için yeni fırsatlar yaratmıştır. Özellikle daha iyi ve daha hızlı internet bağlantısındaki gelişmeler, genellikle klan olarak adlandırılan küçük oyun topluluklarının çok oyunculu bilgisayar oyunlarında (MCG) birbirleriyle rekabet etmek için cihazlar arasında Yerel Alan Ağı (LAN) bağlantıları oluşturmalarını sağlamıştır (Smed vd., 2002; Wagner, 2006). Bu durum, oyuncuya karşı makine oyunlarından oyuncuya karşı oyuncu oyunlarına doğru bir hareketi teşvik etmiştir (Sjöblom vd., 2019). Bunun bir başlangıç olduğu ve video oyunları ağ yeteneklerini ve hem şahsen hem de dünya çapında başkalarına karşı oynama yeteneğini içermeye başladığında Espor'un doğal olarak başladığı belirtilmektedir (Filchenko, 2018). 1999'dan bu yana teknolojiler artık oyuncuların ortak oyun oturumlarında iletişim kurmasını ve işbirliği yapmasını sağladığından (Manninen, 2003), MCG'nın popülaritesi artmaya devam etmiştir (Smed vd., 2002; Wagner, 2006). Akış ve mobil teknolojilerdeki gelişmeler o zamandan beri yeni video oyunları biçimleri yaratarak oyun alanının yapısını temelden değiştirmiştir (Burroughs ve Rama, 2015). MCG, oyuncuların birbirlerine karşı rekabet ederek işbirliği yapmaları ve iletişim kurmaları için fırsatlar sunmaktadır. Dövüş

(örneğin Street Fighter IV), gerçek zamanlı strateji oyunları (örneğin StarCraft II) ve spor tabanlı oyunlar (örneğin FIFA 17) gibi çok sayıda türü kapsayan birçok popüler Espor oyunu vardır (Funk vd., 2018). Ayrıca LoL gibi bireysel ve takım tabanlı oyunlar da mevcuttur. (Funk vd., 2018).

Takım oyunları ile birlikte Espor belirli sayıda kişinin yer aldığı MCG'dan çok oyunculu oyunlara ve dünyanın her yerinden binlerce kişinin katılımına olanak tanıyan devasa çok oyunculu çevrimiçi oyunlara (MMOG) doğru genişlemiştir. MMOG milyonlarca oyuncunun ilgisini çekmekte ve sonuç olarak daha fazla kültürel, sosyal ve ekonomik önem kazanmaktadır (Duchenaud vd., 2006). MMOG tarzındaki oyunların sosyal doğasının, popülerliklerinin bir nedeni olduğu ve bağımlılık yapanın oyun değil insanlar olduğu öne sürülmektedir (Lazzaro, 2004). MMOG'ın paylaşım ve paylaşılan deneyimleri, tek kişilik veya MCG deneyimlerine göre ana fark olarak kabul edilmektedir. Genellikle tek oyunculu oyunlar aynı etkinlikleri ve özellikleri içerir, ancak MMOG, paylaşılan, işbirliğine dayalı deneyimler sunar ve oyuncular çevrimiçi oyun topluluğu içinde itibar kazanabilmektedir (Delwiche, 2006; Hilvert-Bruce vd., 2018). MMOG'lar, oyuncuların, hedeflerine ulaşmak için bir araya gelerek hem yönlendirilmiş hem de kendi belirledikleri stratejilere dayalı geçici ve kalıcı ittifaklar kurmalarını sağlamaktadır. Bu işbirlikleri, genellikle metin ve sesli sohbet gibi iletişim araçlarıyla kolaylaştırılan işlevsel ittifaklar olup, zamanla daha derin sosyal ilişkilere dönüşebilmektedir (O'Connor vd., 2015). Bu şekilde Espor oyunu, boş zaman geçirmenin değerli bir yolu ve bireylerin kendilerini ifade etmeleri, ilişkiler kurmaları ve aidiyet duygusu oluşturmaları için bir yol olarak ortaya çıkmaktadır (Martonçik, 2015). Espor "karmaşık bir fenomen" olarak tanımlanmış, oyun oynamanın yanı sıra Esporun bilgisayar oyunlarını rekabetçi bir şekilde oynayarak ve Espor etkinliklerine katılarak, Espor uygulamaları hakkında bilgi edinebilecekleri ve Espor medyasını izleyerek Espor deneyimlerinin güçlendirilebileceği öne sürülmüştür (Seo, 2013). Bu çalışmalar MMOG'lerin eleştirel düşünme, iletişim ve işbirliği gibi becerileri geliştirmedeki olumlu etkisini göstermektedir.

Pek çok araştırma insanların ortak bir ilgi alanını paylaştıkları bir grubun, bu durumda Esporun parçası olmaktan elde ettikleri psikolojik topluluk duygusunu incelemiştir (Hamari ve Sjöblom, 2017; Hilvert-Bruce vd., 2018). Birçok MMOG, ortamda sosyalliği, iletişimi ve işbirliğini teşvik etmek üzere tasarlanmıştır (Sourmelis

vd., 2017) ve temelde yatan birliktelik temasıyla eş anlamlıdır (Manninen, 2003). Canlı yayın izleyicileri için sosyal motivasyonun, yeni insanlarla tanışma, sosyal etkileşim ve topluluk duygusu gibi önemli faktörler olduğu belirtilmektedir (Hilvert-Bruce vd., 2018). World of Warcraft'ın en önemli yönlerinden birinin daha çeşitli ilişkilerin gelişmesine olanak tanıyan geleneksel sosyal ve coğrafi sınırların yıkılması olduğu belirtilmektedir (O'Connor vd., 2015). Oyuncuların bir topluluk hissi, aidiyet, farklı sosyal kimlikler ve diğer oyuncularla olan ilişkilerinden sosyal destek kazandıklarını ve genellikle oyun toplulukları oluşturduklarını tespit edilmiştir. Oyuncular ayrıca topluluk içinde desteğe eriştiklerini ve destek sağladıklarını ve duygusal destek verdiklerini veya aldıklarını bildirmişlerdir (Hilvert-Bruce vd., 2018; O'Connor vd., 2015). İzleyiciliğin ve Espor oyununun, oyunun ötesine geçtiği, oyun takımlarına (klanlara) üyelik ve LAN partilerine katılım yoluyla dostane ilişkiler kurarak ait olma ihtiyacı veya bir oyun takımı liderinin konumunu koruyarak ve hareket tarzını belirleyerek liderlik arzusunu tatmin etme gibi çeşitli ihtiyaçları karşılama aracı olarak da hizmet edebileceğini belirtilmektedir (Martončík, 2015). Araştırmalar ayrıca MMOG'lerin eğitimsel faydalarını da tanımlamaktadır. Espor oyuncularının gelişmiş okuryazarlık, dikkat, tepki süresi ve üst düzey düşünme geliştirdikleri belirtilmektedir (Delwiche, 2006). Squire (2006) en yoğun sosyal öğrenmenin, oyuncuların internet üzerinden gerçek zamanlı olarak binlerce diğer oyuncuyla etkileşime girdiği devasa çok oyunculu oyunlarda bulunduğunu belirtmektedir (Squire, 2006). Birçok MMOG oyuncuların bilgiyi sentezlemesini, analiz etmesini ve değerlendirmesini, eleştirel düşünmeyi uygulamasını ve problem çözmesini gerektirmektedir. Bu nedenle oyuncuların 21. yüzyıl becerileri olarak adlandırılan ve potansiyel olarak gerçek hayata aktarılabilecek becerileri kazanmalarını destekleyen öğrenme ortamları olarak değerlendirilebilmektedir (Dickey, 2007; Susaeta vd., 2010).

3.1.2. Espor Oyuncuları

Son yirmi yılda video oyunu oynamak, dünya çapında giderek daha popüler bir eğlence aktivitesi haline gelmiştir (Bányai vd., 2019). Bununla birlikte video oyunları oynama faaliyeti sadece eğlence amaçlı bir uğraş olarak nitelendirilemez. Oyuncuların küçük bir kısmı artık profesyonel olarak oyun oynamakta ve becerilerinde ustalaşmak için her gün saatlerini harcamaktadır (Hemphill, 2005).

Espor, oyuncuların oyun tabanlı bilgi-iletiřim teknolojisini kullanırken zihinsel becerilerini ve el-göz koordinasyon becerilerini geliřtirdikleri ve eđittikleri ve oyuncuların dijital bir spor dűnyasında, sanal olarak temsil edildiđi bir tűr spor etkinliđi olarak tanımlanmıřtır (Hemphill, 2005; Wagner, 2006).

Espor, taraftarların canlı oyun műsabakaları sırasında profesyonel oyuncuları izleyebildiđi, geleneksel sporların özelliklerini takip eden rekabetçi oyun etkinliklerini ifade etmektedir (Robertson, 2021). Popűler bir faaliyet olan Espor, bireylerin profesyonel oyuncular olmalarına ve bir meslek olarak rekabetçi oyunlarda kariyer geliřtirmelerine olanak tanıyarak bu tűr bireylerin sahip olabileceđi genel oyun becerilerine katkıda bulunmaktadır (Rosell, 2017).

Espor oyunlarının oyuncuları genellikle iki kategoriye ayrılmaktadır. Bunlar gűndelik oyuncular ve rekabetçi oyunculardır (Zarrabi ve Jerkrot, 2016). Oyuncu, oyunu diđerleri arasında (örneđin filmler, spor, okuma gibi) sadece bir etkinlik olarak algıladıđında oyun gűndeliktir (Kuittinen vd., 2017). Dolayısıyla sıradan bir oyuncu, oyunları sıradan bir řekilde oynayan veya oyun oynamaya karřı sıradan bir tutuma sahip olan kiřidir. Rekabetçi bir oyuncu ise oyun oynamaya önemli miktarda zaman ayıran ve rahatlamaktan ziyade rekabet iin oynayan kiřidir (Banyai Vd., 2018). Genel olarak video oyunu oyuncuları űzerine ok sayıda psikolojik arařtırma yapılmıřtır. Arařtırmacılar yıllar boyunca farklı teorik ereveler kullanmıř ve farklı video oyunu tűrlerini incelemiř olsa da, oyuncular arasında bazı ortak motivasyon kalıpları bulunmuřtur. Etkileřim, iletiřim, iřbirliđi ve rekabetin video oyunları oynamak iin en yaygın motivasyon olduđu belirtilmektedir (Vorderer 2000; Vorderer vd., 2003). Ayrıca meydan okuma, sosyal etkileřim, uyarılma ve dikkat dađıtmanın insanları video oyunları oynamaya motive ettiđini gűsterilmektedir (Sherry vd., 2006). Video oyunları oynamanın altında yatan ű ihtiya keřfedilmiřtir. Bunlar, dalma arayıřı (keřif, rol yapma, űzelleřtirme, kaıř), bařarı arzusu (ilerleme, mekanik, rekabet) ve sosyal faktűrlerdir (sosyalleşme, iliřki, takım alıřması) (Yee, 2006). Benzer řekilde bařarı, sosyalleşme, keřif ve ayrıřmanın video oyunları oynamak iin önemli motivasyonlar olduđu belirtilmektedir (Fuster vd., 2014). Yapılan diđer bir alıřmada da altı tűr oyuncu motivasyonu tanımlamıřtır. Bunlar; sosyalleşenler (sosyal iliřkiler kurma ve sűrdűrmeye ilgi duyanlar), tamamlayıcılar (oyunu műmkűn olan en geniř űlűde keřfetmeye ilgi duyanlar), yarıřmacılar (oyun kazanmaya ve zafere katkıda bulunacak řekilde oynamaya ilgi duyanlar), kaıř

(gerçeklikten kaçmaya ilgi duyanlar), hikaye odaklılar (karakterlerin geçmişlerine ve oyunun konusuna ilgi duyanlar) ve çokbilmişlerdir (zihinsel kapasiteyi güçlendirmeye ilgi duyanlar) (Kahn vd., 2015).

Bazı araştırmalar oyun motivasyonları ve kişilik arasındaki bağlantıyı incelemişlerdir. Jeng ve Teng (2008) oyuncu motivasyonları ve kişilik arasındaki bağlantıyı araştırmak için Yee'nin (2006) motivasyonel boyutlarının (yani keşif, rol yapma, takım çalışması, ilerleme ve kaçış) alt ölçeklerinde büyük beş kişilik özelliğini (dışadönüklük, uyumluluk, vicdanlılık, nevrotiklik ve açıklık) kullanmıştır (Jeng ve Teng, 2008). Dışadönüklük ve duygusal dengeden yüksek puan alan oyuncuların takım çalışmasıyla olumlu yönde bağlantılı olduğu görülmüştür. Uyumluluk kişilik özelliği ilerlemeye, açıklık kişilik özelliği ise keşif ve rol yapma ile pozitif yönde ilişkilendirilmiştir. Çevrimiçi oyun oynama motivasyonları ile kişilik özellikleri arasında bağlantılar olduğu belirtilmektedir (Park vd., 2011). Oyuncu motivasyonları beş büyük kişilik özelliğinden yalnızca ikisiyle ilişkilendirilmiştir. Bunlar dışadönüklük ve uyumluluktur. Dışadönüklükten yüksek puan alan oyuncular başarı, macera, kaçış ve rahatlama ile motive olmuşlardır. Uyumluluk puanı yüksek olan oyuncular başarı, macera ve kaçış ile motive olurken rahatlama ile motive olmamışlardır. Kişilik özelliklerinin oyun türü tercihi veya oyun oynama süresi üzerinde bir etkisi olmamıştır (Park vd., 2011). Devasa çok oyunculu çevrimiçi rol yapma oyunu (MMORPG) World of Warcraft'ı oynama motivasyonları ile kişilik özellikleri arasındaki bağlantılar incelemiştir. Oyuncu motivasyonları ve kişilik özellikleri arasında çeşitli bağlantılar bulunmuştur. Beklendiği gibi sosyalleşmeyle motive olan oyuncuların dışadönüklük puanları daha yüksektir, ancak ilginç bir şekilde uyumluluk, nevrotiklik ve açıklık puanları da nispeten daha yüksektir. Başarı ile motive olan oyuncular dışadönüklük ve nevrotiklikte daha yüksek puanlar göstermiştir. Sürükleyici faktörler tarafından motive edilenler, nevrotiklik ve uyumluluk ile pozitif olarak ilişkilendirilmiştir. Liderlik nedeniyle oynayan bireyler açık, dışa dönük ve vicdanlı olma eğiliminde olmuştur. Bağımsızlık güdüsüyle oynayanlar açıklık ile pozitif ilişkilidir (Graham ve Gosling, 2013).

Video oyunu oyuncuları üzerine çok sayıda çalışma yapılmış olmasına rağmen, sadece az sayıda çalışma Espor oyuncularının psikolojik profilini araştırmıştır. Bu çalışmalar temel olarak Espor oyuncusu olma (sıradan bir oyuncudan Espor oyuncusuna dönüşme süreci) ve bir Espor oyuncusunun özellikleri (zihinsel beceriler, motivasyonlar,

ihtiyalar) olmak zere iki konuya odaklanmıřtır. Bir Espor oyuncusu, eęlence ve/veya rahatlatma yerine rekabet iin oynayan ve oyun oynamayı iři olarak tanımlayan profesyonel bir oyuncu olarak tanımlanmaktadırlar (Banyai vd., 2018). Dięer bir alıřmada da Espor'un farklı ynlerini incelenmiř ve zellikle  unsura yanıt verilmesi amalanmıřtır (Seo, 2016). Bunlar Espor tketimini oyuncular iin cazip bir kariyer seeneęi haline getiren unsurlar, oyuncuların profesyonel Espor oyuncusu olarak kariyer yapmak istemelerinin nedeni ve oyuncuların sıradan oyunculardan Espor oyuncusuna nasıl dnřtę srecidir. Seo (2016) bu alıřmasında Espor oyuncuları kendilerini Esporda kariyer yapmaya eken ana unsurların kiřisel geliřim ihtiyaı, becerilerin ustalıęının kutlanması ve evrimii ve LAN (Yerel Alan Aęı) turnuvalarında adalet ve karřılıklı saygının nemi olduęunu belirtmiřtir. Ayrıca Espor oyuncuları kendilerini profesyonel oyuncular haline getiren bu yolculuęun z saygılarını artırdıęını ve kendilerine bařarı ve sosyal tanınma saęladıęını dřnmektedir. Espor'un doęası rekabeti olsa da, oyuncular bunu eęlenceli ve kendi kendilerini motive edici olarak deęerlendirmiřtir. Ayrıca Espor oyuncusu olmanın zihinsel dnřmn inceleyen Seo (2016), Campbell'in (1995) "*kahraman yolculuęu monomiti*"ni teorik bir temel olarak kullanarak  farklı ařama belirlemiřtir (Seo, 2016). İlk ařama olan "*maceraya aęrı*" ařamasında oyuncular eęlenmek iin video oyunları oynamakta ancak Espor dnyasında ilk algılarını ve iliřkilerini oluřturmaya bařlamaktadır. İkinci ařama olan "*denemeler yolu*"nda oyuncular, bir Espor oyuncusu olmak iin kiřisel dnřme bařlamaktadır. Oyun oynamaya karřı tutumları deęiřir, becerilerini ve oyun mekanięi bilgilerini uygulamaya ve uzmanlařmaya bařlamaktadırlar. Son ařama olan "*iki dnyanın efendisi*" ařamasında, oyuncular yeni bir Espor oyuncusu kimlięi edinmektedir. Bu basite kendilerini Espor oyuncusu olarak grdkleri ve insanların onları Espor oyuncusu olarak tanımasını istedikleri anlamına gelmektedir. Espor, kimliklerinin nemli bir parası haline gelmektedir ve bunu hayatlarının dięer nemli kısımlarıyla birlikte ynetmeye alıřmaktadırlar (Seo, 2016). Benzer řekilde aktivite teorisi kullanılarak sıradan bir oyuncunun bir Espor oyuncusuna nasıl dnřtęn incelenmiřtir (Kim ve Thomas, 2015). Oyuncuların Espor oyuncusu olurken motivasyonlarını, hedeflerini ve ęrenme stillerini tanımlamak iin bir model geliřtirilmiřtir. Esporu tanımlarken oyuncular, taraftarlar, sponsorlar, takımlar vb. dahil olmak zere olguyu tm perspektiflerden incelemenin nemli olduęu savunulmaktadır. Bu bakıř aısıyla Kim ve Thomas (2015),

Espor oyuncularını, antrenörleri, takım yöneticileri ve bir Espor psikoloğu ile görüşerek bir teori modeli geliştirmişlerdir. Sonuç olarak oyuncuların tutum, motivasyon ve performanslarının farklılık gösterebileceği beş farklı aşama geliştirilmiştir. İlk olarak, oyuncular deneyimsizdir ve aşına olmadıkları görevleri çözmeleri gerekmektedir. Daha sonra, oyuncular bir takımda başlangıç oyuncusu olarak seçilmek için rekabet etmeli ve diğerlerinden takdir almak için mücadele etmelidir. Bu nedenle içsel motivasyonlarını ve video oyunları oynamanın eğlence faktörünü (mücadele aşaması) kaybetmektedirler. Oyuncular bir takımdaki yerlerini güvence altına aldıklarında, takım arkadaşlarının güvenini kazanırlar ve oyunu fazla stres veya endişe hissetmeden oynamaktadırlar. Maalesef birçok oyuncu başarı aşamasındaki yerini koruyamıyor ve artık profesyonel Espor maçları oynayamamaktadır. Mücadele aşamasındakine benzer bir süreçten geçerler. Uyum sağlamaları, yeni beceriler öğrenmeleri ve tekrar başlangıç kadrosunun bir parçası olmak için rekabet etmeleri gerekmektedir. Bu nedenle daha önce yaşadıkları memnuniyeti sürdürmekte zorlanırlar ve düşüş aşamasına geçmektedirler. Bazı oyuncular düşüş aşamasından kurtulup tekrar profesyonel oyuncular haline gelebilmektedir (toparlanma aşaması). Bununla birlikte birçoğu bunu yapacak yetkinliğe sahip değildir ve bazıları Espor içindeki kariyer yollarını takım koçu, analist, yorumcu veya oyunlarda başka bir pozisyon olmak için değiştirmek istemektedir. Artık profesyonel Espor oyuncusu olmasalar da, yeni kariyer yollarında oyuncu olarak edindikleri deneyimlerden faydalanmaktadırlar. Beş aşamalı modelde Espor oyuncularının video oyunları hakkında sıradan oyunculardan farklı düşündüklerini vurgulanmaktadır. Teori modelinin üst aşamalarında, video oyunları oynamak Espor oyuncuları için her zaman bir iş olarak görülürken, sıradan oyuncular bunu her zaman bir boş zaman aktivitesi olarak görmektedir (Kim ve Thomas, 2015).

3.1.3. Espor Oyuncularının Özellikleri

Espor'da başarının arkasındaki faktörleri ve iyi bir performans sergilemenin önündeki engelleri incelenmiştir (Himmelstein vd., 2017). Araştırmacılar, başarılı bir performans sergilemek için bir Espor oyuncusunun;

1. Oyundaki mekanikler hakkında büyük bilgiye sahip olması,
2. Stratejik düşünmesi ve hızlı ve akıllı kararlar verebilmesi,
3. Kişisel hayatı performanstan ayırması,

4. İlerlemek ve geçmiş performansları unutmak için motive olması,
5. Odaklanması ve dikkatinin dağılmaması,
6. Büyüme zihniyetini sürdürmesi ve
7. Performans öncesinde zihinsel ve fiziksel olarak ısınması gerektiğini ortaya koymuştur.

Oyuncuların stratejik olarak rakiplerinin oyun tarzına uyum sağlayabilmeleri, takım arkadaşlarıyla etkili iletişim kurabilmeleri, kendilerini ve takımlarını geliştirebilmeleri ve hem kısa hem de uzun vadeli hedefler belirleyebilmeleri gerektiği vurgulanmıştır. En iyi performans göstermenin zihinsel faktörlerine ek olarak, iyi performansın önündeki engeller de belirlenmiştir. Bu engeller düşük özgüven, kaygıyla başa çıkma stratejilerinin yetersizliği, geçmiş başarıları veya hataları düşünme, taciz, bireysel veya takım olarak gelişememe (örneğin, düşük bireysel beceriler, zayıf takım dinamiği, etkisiz takım iletişimi, oyun hakkında yeterli bilgi sahibi olmama) ve günlük hayatı oyundan ayıramama sorunlarıdır (Himmelstein vd., 2017). Birkaç çalışma Espor oyuncularının motivasyonlarına odaklanmıştır. İlk olarak kullanımlar ve hazlar teorisinin teorik çerçevesini kullanarak Espor ve geleneksel spor tüketim motivasyonlarını karşılaştırılmıştır (Lee ve Schoendstedt, 2011). Daha önceki video oyunu kullanımları ve hazları araştırmasına dayanarak, video oyunları ile ilgili şu motivasyonları değerlendirilmiştir (Lee vd., 2010). Bunlar rekabet, beceri geliştirme, akran baskısı (kişinin akran grubunun üyelerinden etkilenmesi), sosyal etkileşim, fantezi, dikkat dağıtma, kalıcılık, uyarılma, tasarım/grafikler, sporla özdeşleşme, spor bilgisi uygulaması, zaman geçirme, kontrol ve eğlencedir. Bulgular, rekabet, akran baskısı ve gerçek spor yapmak için beceri geliştirmenin, oyuncuların Espor'u tüketme motivasyonları üzerinde etkili olduğunu göstermiştir. Diğer bir çalışmada Espor oyuncularının ihtiyaçlarını incelemek için kullanımlar ve doyumlar teorisi kullanılmıştır (Weiss ve Schiele, 2013). Ancak Weiss ve Schiele (2013) tarafından değerlendirilen ihtiyaç tatminleri, Lee ve Schoendstedt (2011) tarafından seçilenlerden çoğunlukla farklı olmuştur. Weiss ve Schiele (2013), sanal dünyalarda daha önce yapılan kullanımlar ve hazlar çalışmalarına dayanarak, daha yakından incelenmek üzere beş rekabetçi ihtiyaç hazzı (rekabet, başarı, meydan okuma, itibar ve ödüller) ve beş hedonik ihtiyaç hazzı (sosyal ilişki, kaçış, kendini gerçekleştirme, eğlence ve sanal kimlik) seçmiştir. On sektör uzmanıyla yarı yapılandırılmış derinlemesine görüşmeler yapıldıktan

sonra on ihtiyaç tatmininden beşinin Espor'la ilgili olduğu belirlendi. Seçilen beş ihtiyaç, sosyal ilişki, rekabet, meydan okuma, eğlence ve kaçıştır. Bu tatminler Espor oyuncularıyla yapılan bir takip ankete dahil edilmiştir. Anket sonuçları kaçış, rekabet ve mücadelenin oyuncuların video oyunlarını rekabetçi bir şekilde oynama motivasyonları üzerinde olumlu bir etkisi olduğunu göstermiştir.

Diğer bir araştırma sıradan oyuncular ile Espor oyuncuları arasındaki oyun motivasyonları ve yaşam amaçlarındaki farklılıkları keşfetmeyi amaçlamıştır (Martoncik, 2015). Oyunculara altı ana kategoriden yaşam amaçlarını içeren bir anket sunulmuştur. Bu amaçlar, yakınlık, bağlılık, özgecilik, güç, başarı ve oyalanmadır. İki oyuncu tipi arasındaki tek anlamlı fark, bağlılık (başkalarıyla yoğun etkileşim ve başkalarına yardım etme ihtiyacı) ve saptırma (yeni deneyimler, gerilim ve heyecan ihtiyacı) değişkenlerinde bulunmuştur. Espor oyuncuları her iki değişkende de daha yüksek puanlar vermiştir. Espor oyuncuları arasındaki bağlılık puanının daha yüksek olması, Espor oyuncularının takım üyelikleri yoluyla daha dostane ilişkiler geliştirmeleriyle açıklanabilmektedir. Espor oyuncuları için önemli bir motivasyonun sadece rekabet değil, aynı zamanda video oyunları oynamanın sosyal doğası olduğunu göstermektedir. Oyuncular sanal bir ortamda birbirleriyle etkileşime girebilir, birlikte antrenman yapabilir ve turnuvalarda ve liglerde rekabet edebilirler. Espor oyuncuları genellikle gerçek hayatta LAN partilerinde buluşur ve burada birlikte video oyunları oynamaktadırlar. LAN partileri, rekabet etmekten çok çevrimiçi arkadaşlarla tanışmakla ilgilidir. Espor oyuncuları arasında dikkat dağınıklığı puanının daha yüksek olması, müsabakaların heyecanı ve bu müsabakalara dahil olan her şeyle örneğin antrenman yapmak, oyunu çalışmak ve strateji geliştirmekle açıklanabilmektedir. Takımlarında lider olan Espor oyuncularının, diğerlerini kontrol ederek ve yönlendirerek güç ihtiyaçlarını tatmin ettiklerini ve sanal ortamda daha yüksek bir statü elde ettiklerini vurgulanmaktadır (Martoncik, 2015).

Amatör ve yarı profesyonel Espor oyuncuları üzerinde yaş, oyun saatleri, motivasyonlar ve tutku dahil olmak üzere çeşitli değişkenleri araştırılmıştır (Chamarro ve Lanzo, 2018). En yaygın üç motivasyon faktörü, sosyal ilişkiler kurma ve sürdürme ilgisi, oyundaki unsurları keşfetme ve diğer oyunculara karşı rekabet etme tutkusu olduğu belirtilmiştir. Yarı profesyonel oyuncuların daha genç olma eğiliminde oldukları, oyuna daha fazla zaman ayırdıkları ve zihinsel kapasitelerini geliştirmeye daha fazla ilgi duydukları belirtilmektedir. Aksine amatörler, motivasyonlarında daha çok hikaye odaklı

(karakterlerin geçmişi ve oyunun konusu ile ilgilenen) olma eğilimindedir. Ancak “*tutku*” değişkeni, amatörler ve yarı profesyonel oyuncular arasındaki ayrımı açıklamaya katkıda bulunmamıştır. Video oyunlarında iki tür tutku, uyumlu tutku ve saplantılı tutku, arasında bir ayrım yapmak mümkündür. Bir kişi uyumlu bir tutku yaşadığında, kimliğinde önemli bir rol oynar, ancak kimliğin diğer yönlerini rahatsız etmez ve kişinin hayatının diğer bölümleriyle uyumlu bir şekilde çalışabilmektedir (Chamarro ve Lanzo, 2018). Öte yandan bir kişi saplantılı tutku yaşadığında, faaliyet kendi kontrolü altında değildir. Bu nedenle faaliyete yönelik tutku, yavaş yavaş kişinin kimliğinin önemli bir bölümünü işgal eder ve sonunda kişinin hayatının diğer bölümlerini rahatsız etmektedir (Curran vd., 2015). Chamarro ve Lanzo’nun (2018) çalışmasındaki bulgular, hem amatör hem de yarı profesyonel Espor oyuncularının oyun oynarken uyumlu bir tutku yaşama eğiliminde olduğunu göstermektedir.

3.1.4. Espor ve Geleneksel Sporlar Arasındaki Farklar

Espor’un birleşik bir tanımını çevreleyen karışıklığa katkıda bulunan ana nedenlerden biri ona yaklaşılan farklı bakış açılarıdır. Espor’un kültür, teknoloji, spor ve iş dünyasının birleşimi olması ve geleneksel sporların aksine, Espor’un oyunla eşanlamlı birden fazla platformun (bilgisayar, medya vb.) birbirine bağlanması karmaşıklığı artırmaktadır (Jin vd., 2010). Espor’un geleneksel sporlardan daha karmaşık bir yapıya sahip olduğu, çünkü aktörlerin birden fazla rol üstlenebileceğini ve bu şekilde Espor ve spor oyununun tamamlayıcı olarak görülmesi gerektiği, ayrıca Espor endüstrisinin spor endüstrisinde yeni bir çağ açtığı belirtilmektedir (Chikish vd., 2019). Bununla birlikte, Asya Olimpiyat Konseyi’ne (2017) göre gençler arasında bu yeni spor katılım biçiminin hızlı gelişimi ve popüleritesi, Espor’un gelecekte bir spor olarak tanınması için katalizör olabilmektedir (Asya Olimpiyat Konseyi, 2017).

Espor’un spor olup olmadığının önemli olmayabileceğini belirtilirken, Espor’u geleneksel sporlarla karşılaştırmanın aslında Espor’un tanınmasını ve ilerlemesini engellediği belirtilmektedir, çünkü şu anda geleneksel sporlardan anlaşılanın ötesinde benzersiz fırsatlar ve potansiyel barındırmaktadır (Funk vd., 2018). Aslında Espor, yeni küresel kitlelere ulaşarak yeni oyun, katılım ve seyirci deneyimleri yaratmak için gelişmekte olan teknolojileri birleştirme ve kullanma potansiyeli gibi geleneksel sporlar

hakkında zaten bildiklerimizi ve bildiğimizi düşündüklerimizi genişletmek için yeni fırsatlar sunmaktadır (Cranmer vd., 2021).

3.1.5. Espor Ekipmanları ve Teknolojik İlerlemeler

Espor ekipmanları ve teknolojik gelişmelerin manzarası, son yıllarda hem donanım hem de yazılım alanındaki yeniliklerle önemli bir dönüşüm geçirmiştir. Bu evrim, Esportun çağdaş eğlencenin önemli bir bileşeni haline gelmesini sağlamış, rekabetçi oyun deneyimi dünya genelinde milyonlarca izleyiciyi cezbeden bir olguya dönüşmüştür. Bu alandaki temel gelişmeler, canlı yayın teknolojileri, özel tasarlanmış oyun ekipmanları, erişilebilirlik özellikleri ve analiz ile veri biliminin entegrasyonu olmak üzere dört başlık altında incelenebilir.

Canlı yayın teknolojilerindeki ilerlemeler Esportun tüketim biçimini kökten değiştirmiştir. Twitch ve YouTube Gaming gibi platformların ortaya çıkışı, oyuncuların oyun oynayımlarını yayınlamasını kolaylaştırırken, izleyiciler için de etkileşimli bir ortam sunmuştur. Bu durum özellikle, geleneksel sporlardan ziyade Esport izlemeyi tercih eden milenyum kuşağıyla güçlü bir şekilde örtüşmektedir (Jang vd., 2020). Yüksek çözünürlüklü kameralar, çoklu açı görünümüleri ve uzman yorumlarının yayına entegre edilmesi, izleyici deneyimini daha sürükleyici ve ilgi çekici hâle getirmektedir (Jang vd., 2020).

Bunun yanı sıra Esport odaklı özel ekipmanlar da giderek daha sofistike bir hâl almıştır ve rekabetçi oyun ortamının özgün gereksinimlerine cevap vermektedir. Yüksek performanslı oyun bilgisayarları ve konsolları, oyun faresi, klavye ve kulaklık gibi çevre birimleri, tepki süresi ve dayanıklılık açısından optimize edilmiştir. Bu teknolojiler yalnızca profesyonel oyuncuların deneyimini geliştirmekle kalmayıp, aynı zamanda turnuvalarda performans standartlarının belirlenmesine de katkı sunmaktadır. En son grafik teknolojileri ve yüksek kare hızlarının entegrasyonu, oyunculara daha sürükleyici bir deneyim sunmakta ve bu, rekabetin yoğun olduğu bir ortamda kritik bir avantaj sağlamaktadır (Cranmer vd., 2021; Rahman vd., 2023).

Performans artırıcı teknolojilere ek olarak Esport ekosisteminde erişilebilirliğe yönelik artan bir ilgi olduğu belirtilmektedir. Fiziksel engeli olan bireylerin oyunlara katılımını kolaylaştıran çeşitli teknolojik yenilikler, daha kapsayıcı bir ortam yaratmayı

hedeflemektedir. Araştırmalar, Espor alanındaki erişilebilirlik teknolojilerinin bu bireylerin yaşam kalitesini önemli ölçüde artırdığını, oyun topluluklarına katılımlarını kolaylaştırdığını ve sosyal etkileşimlerini geliştirdiğini göstermektedir (Kartal, 2023). Bu tür kapsayıcılık odaklı yenilikler, teknolojinin Esporun demografik yelpazesini genişletmedeki rolünü vurgulamakta ve Esporun toplumun farklı kesimlerini yansıtmasına katkı sunmaktadır (Cestino vd., 2023).

Espor endüstrisinin olgunlaşmaya devam etmesiyle birlikte, veri analitiği ve yapay zekâ entegrasyonu giderek daha fazla önem kazanmaktadır. Bu teknolojiler, oyuncu performansı, izleyici etkileşimi ve pazar eğilimleri gibi konularda değerli içgörüler sağlayarak, Espor organizasyonlarında daha bilinçli karar alma süreçlerini mümkün kılmaktadır (Xu, 2024). Örneğin yapay zekâ destekli analiz sistemleri, koçların oyunculara özel antrenman programları geliştirmesine yardımcı olabilir ve bu da strateji ve performans üzerinde doğrudan olumlu etki yaratabilmektedir (Pluss vd., 2019).

Espor sektörü büyümeye devam ettikçe teknoloji ve pazarlama gibi çeşitli sektörlerden yatırım çekmektedir. Esporla ilişkili iş alanlarındaki iş ilanlarının önümüzdeki yıllarda iki katına çıkması beklenmekte olup, bu durum Esporun meşru bir kariyer yolu olarak giderek daha fazla kabul gördüğünü göstermektedir (Said vd., 2023). Espora yapılan yatırımlar yalnızca finansal kazanç amacı taşımamakta, aynı zamanda oyun alanında inovasyonu teşvik eden bir ortamın gelişimini de desteklemektedir.

3.1.6. Espor Yayın Teknolojileri ve Canlı Yayınlar

Espor yayıncılık teknolojileri, özellikle oyuncular ile izleyiciler arasında gerçek zamanlı etkileşimi mümkün kılan canlı yayınlar aracılığıyla dijital eğlence alanının çehresini köklü biçimde değiştirmiştir. 2020 yılında küresel ölçekte yaklaşık 500 milyon izleyiciye ulaşan Esporun büyümesi, canlı yayın platformları ile izleyici etkileşimi arasındaki karmaşık ilişkinin altını çizmektedir (Ryu vd., 2023). Geleneksel yayıncılık yöntemlerinden Twitch ve YouTube gibi çağdaş sosyal canlı yayın hizmetlerine (Social Live-Streaming Services - SLSS) geçiş, bu büyümeyi tetiklemiş, hayranların rekabetçi oyunları, geleneksel spor etkinliklerinden farklı olarak etkileşimli bir ortamda deneyimlemelerine olanak tanımıştır.

Espor yayıncılığının temelinde, oyun ve etkinliklerin izleyicilere anında aktarılmasını mümkün kılan gerçek zamanlı yayın teknolojileri yer almaktadır. Profesyonel yayıncıların genellikle yetenekli oyuncu ya da atlet geçmişine sahip olduklarını ve izleyicilerle yüksek derecede etkileşimli bir formatta becerilerini sergileyerek etkileşim kurdukları belirtilmektedir (Tang vd., 2023). Espor yayıncılığındaki bu özgün dinamik, genellikle izleyici katılımının ve etkileşiminin daha düşük olduğu geleneksel spor medyasından belirgin şekilde ayrılmaktadır (Ryu vd., 2023). Twitch gibi platformlar yalnızca oyun yayınlarına ev sahipliği yapmakla kalmayıp aynı zamanda yorumların yapıldığı, toplulukların inşa edildiği ve tartışmaların gerçekleştiği sosyal bir deneyimi de içinde barındırmaktadır (Foxman vd., 2021).

İzleyicilerin Espor yayınlarına neden ilgi gösterdiğine ilişkin güdüler de, izleme deneyimini şekillendiren önemli bir unsur olarak öne çıkmaktadır. Araştırmalar, yayıncı güvenilirliği, kullanıcı etkileşimi ve izleyici motivasyonları gibi faktörlerin Espor ortamlarında gözlemlenen medya tüketim davranışlarını önemli ölçüde etkilediğini göstermektedir (Hua vd., 2023). Planlanmış Davranış Teorisi (TPB), izleyicilerin yayıncılara duyduğu duygusal bağlılıkların, canlı içeriğe sürekli olarak katılım sağlama güdülerini doğrudan etkilediğini ortaya koymak için kullanılmaktadır (Jang vd., 2024). İzleyicilerin canlı sohbetler yoluyla iki yönlü iletişime katılabilmelerinin, bu seyir deneyimini daha da zenginleştirmekte olduğu ve canlı yayınların da yalnızca pasif bir gözlem biçimi olmaktan çıkıp, aktif bir eğlence formatına dönüştüğü belirtilmektedir (Ma vd., 2021).

Oyun oynama deneyiminin izleyici tercihleri üzerindeki etkisi de vurgulanmıştır. Eğlence amaçlı oyun oynama ile yayın formatlarının cazibesi arasında doğrudan bir ilişki olduğu gösterilmiştir. Espor oyunlarını oynama niyeti ile canlı Espor içeriklerini izleme arasında anlamlı bir korelasyon tespit edilmiş ve bu durumun bireylerin medya tüketim alışkanlıklarını şekillendirdiği ifade edilmiştir (Jang vd., 2021). Bu bulgular farklı ilgi alanlarına hitap eden yayın formatlarının izleyici memnuniyetini artırabileceği, buna bağlı olarak izleyici bağlılığı, ürün satışları ve etkinlik katılımı gibi alanlarda gelir fırsatlarını da artırabileceği ortaya koyulmaktadır (Xu vd., 2024).

Teknolojilerin gelişimiyle birlikte, Espor yayıncılığının geleceği giderek daha da sürükleyici deneyimlere yönelmektedir. Gerçek zamanlı analizler, artırılmış gerçeklik

(AR) ve sanal gerçeklik (VR) teknolojilerindeki gelişmeler bu süreci şekillendirmektedir (Burroughs ve Rama, 2015). Bu eğilim söz konusu teknolojilerin izleyici deneyimini nasıl daha da zenginleştirebileceğine yönelik araştırmaların devam etmesi gerekliliğini vurgulamaktadır. Canlı yayınların sadece etkileşim yaratmakla kalmayıp, Espor karşılaşmalarının küresel ölçekte deneyimlenme biçimini de yenilikçi bir şekilde dönüştürebileceğini göstermektedir.

Sonuç olarak Espor yayıncılık teknolojileri ve canlı yayınlar, oyuncular ile izleyiciler arasındaki etkileşimi yeniden tanımlayarak, teknolojinin, topluluk katılımının ve izleyici motivasyonlarının ön planda olduğu özgün bir ekosistem yaratmaktadır.

3.1.7. Espor Yayınları ve İzleyici Etkileşimi: Bir Topluluğun Oluşumu

Espor yayıncılığı oyun izleyiciliğine ilişkin geleneksel anlayışları köklü biçimde dönüştürerek, pasif gözlemci canlı ve etkileşimli topluluklar içinde aktif katılıma evrilmiştir. Güncel çalışmalar izleyici katılımının çok katmanlı doğasını ortaya koymaktadır ve izleyici etkileşimi, yayıncı güvenilirliği ve canlı yayın ortamlarının sosyal atmosferi gibi unsurların Espor hayranları arasında güçlü bir topluluk oluşumuna katkı sunduğunu vurgulamaktadır.

İzleyici katılımının temel itici güçlerinden biri Twitch ve YouTube gibi yayın platformları aracılığıyla sağlanan etkileşim olanaklarıdır. Bu platformlarda yer alan sohbet özellikleri sayesinde izleyiciler, anlık iletişim kurarak deneyimlerini paylaşmakta ve bir topluluk hissi geliştirmektedir. Bu etkileşim biçiminin izleyicilerin içerikle duygusal bağ kurmasını artırdığını belirtilmektedir (Jang vd., 2021). Espor bağlamında sosyal etkileşimlerin önemine dikkat çekmiş, yayınların ortak izlenmesinin izleyici memnuniyeti ve sadakati açısından kritik bir rol oynadığı ortaya koyulmuştur (Hamari ve Sjöblom, 2017). Bir yayın sırasında aynı anda etkin olan izleyici sayısı, yani sosyal yoğunluğun yüksek olmasının, izleyicilerin duygusal tepkilerini olumlu yönde etkilediği belirtilmektedir (Jang vd., 2020).

Yayıncıların bireysel özellikleri de izleyici etkileşimi açısından belirleyici bir rol oynamaktadır. Yayıncı güvenilirliğinin izleyicilerin satın alma niyetleri ve katılım düzeyleri üzerinde etkili olduğu; izleyicilerin geleneksel ünlüler yerine yayıncılara daha fazla güvendiği belirtilmektedir (Xu vd., 2024). Bu güvenin, yayıncıların tutarlı

etkileşimleri ve samimi yaklaşımları sayesinde inşa edildiği ve yayıncılık, oyun oynama ve finansal destek arasında karşılıklı fayda sağlayan bir ilişki kurduğu belirtilmektedir (Wohn ve Freeman, 2019). Yayıncıların eğlenceli yorumları ve ilgi çekici kişilik özellikleri gibi nitelikleri, izleyici tercihlerini anlamlı biçimde şekillendirmektedir (Rietz ve Hallmann, 2022).

İzleyici motivasyonları ise yayınlanan oyun türlerine göre çeşitlilik göstermektedir. Farklı oyun türlerinin ve yayın formatlarının izleyici güdüleriyile nasıl etkileştiği incelenmiş, Esporun geniş ve çeşitli izleyici kitlesiyle farklı ilgi alanlarına hitap ettiği ortaya koyulmuştur (Ma vd., 2021). Bu durum içerik üreticileri ile markaların stratejilerini izleyici beklentilerine ve yayın formatlarına uygun biçimde uyarlamalarını gerekli kılmakta ve izleme deneyimi bütüncül biçimde zenginleştirmektedir.

Espor yayıncılığının yapısal yönleri de topluluk oluşumunu etkileyen önemli unsurlar arasında yer almaktadır. Oyuncuların içerik üreticileri ve izleyiciler gibi farklı paydaşların sahip olduğu özgün rollerin, Espor yayıncılığında karmaşık bir ekosistem yarattığı belirtilmiştir (Felczak, 2022). Ancak bu yapı aynı zamanda topluluklar içinde toksik davranışların ortaya çıkmasına da zemin hazırlayabilmekte ve yapıcı katılımı zedeleyebilmekle birlikte, sağlıklı bir topluluk atmosferi oluşturmak amacıyla çeşitli müdahaleleri de beraberinde getirmektedir.

Canlı yayınların dönüştürücü potansiyeli vurgulanmış Xu vd. (2024), Esporun yeni turizm olanakları yarattığı, sadık izleyicilerin zamanla fiziksel etkinliklere katılım göstermeye başlamasıyla sanal ve fiziksel katılım arasındaki sınırların bulanıklaştığı belirtilmiştir (Xu vd., 2024). Bu durum Espor yayıncılığının yalnızca bir eğlence biçimi olmanın ötesinde; izleyiciler arasında bağlar kuran ve onları Espor ekosistemine daha derinlemesine entegre eden dinamik bir topluluk platformu olduğunu göstermektedir (Xu vd., 2024).

Sonuç olarak Espor yayıncılığı, çok katmanlı, etkileşimli bir medya biçimi olarak, izleyicileri birden çok düzlemde harekete geçiren bir yapıya sahiptir. Yayın platformlarının sunduğu topluluk temelli etkileşim, yayıncıların güvenilirliği ve katılımcı doğalarıyla birleştiğinde, izleyiciler arasında güçlü bağların kurulmasını teşvik etmektedir. Teknolojik gelişmelerle birlikte evrilmeye devam eden bu ekosistem, Espor taraftarlığının kültürünü ve pratiklerini şekillendirmede belirleyici olmaktadır.

3.1.8. Espor'un Endüstriyel Büyüklüğü

Espor, son zamanlarda akademide ilgi odağı olmaya başlayan kazançlı bir eğlence endüstrisidir. 2020 League of Legends Dünya Şampiyonası'nda dakika başına ortalama izleyici sayısı 23,4 milyon olmuştur. Bu endüstri, medya teknolojisine ayak uydururken profesyonel sporları kıyaslayan benzersiz bir ekosisteme sahip olduğu için video oyunlarının ötesine geçmiştir (Vera, 2019).

Espor karmaşıktır ve etrafında dönen araştırmalar birden fazla disiplinin bir sentezidir. Espor araştırmaları en az yedi farklı akademik alanda yürütülmektedir. Bunlar; medya çalışmaları, bilişim, işletme, spor bilimi, sosyoloji, hukuk ve bilişsel bilimdir (Reitman, 2020). Bazı akademisyenler Espor ile geleneksel sporlar arasındaki benzerlik ve farklılıkları incelerken diğerleri üniversiteler arası bir perspektiften, kumar perspektifinden veya tüketici davranışı perspektifinden incelemektedir (Funk vd., 2018; Keiper, 2017; Skubida, 2016). Bu karmaşıklık nedeniyle, Espor'un tek bir tanımı yoktur. Bazı akademisyenler ise Espor'u geleneksel sporların bir uzantısı olarak görürken, diğerleri bunu bir kültür ve endüstri olarak görmektedir (Cranmer, 2021; Gawrysiak, 2020; Macey ve Hamari, 2018).

Espor araştırmaları birbiriyle ilişkili üç zorlukla karşı karşıyadır (Cranmer, 2021; Pizzo vd., 2022):

- Espor'u incelemeye yönelik çeşitli bakış açıları Espor'un ne anlama geldiğini belirsizleştirmektedir.
- Espor'un tek tip bir tanımının olmaması bilimsel bilgi birikimini engellemektedir.
- Espor araştırmalarının incelenmesi genellikle nitel bir yaklaşım benimsemektedir ve bulguları ilişkilendirmek için farklı bir yaklaşımın kullanılması faydalı olabilmektedir.

Geleneksel sporlar, örneğin Taekwondo, hentbol, kriket ve futbol, dünya çapında popüler ve iyi bilinen sporlardır. Son yıllarda yeni bir fenomen ortaya çıkmıştır. Bunlar, “*Spor*” kelimesinin anlamını yeniden tanımlayabilecek elektronik spor veya Espordur. Espor, bilgisayar oyunlarının seyirci kitlesi için profesyonel ve rekabetçi bir şekilde oynanmasıdır. Son yıllarda hem artan katılım hem de artan izlenme oranıyla birlikte

Espor'un popülaritesi giderek artmaktadır ve muhtemelen geleneksel sporlarla aynı toplumsal ve kültürel etkilere sahiptir.

Espor endüstrisinin büyüklüğünün araştırılması, potansiyel ekonomik etkinin gözlemlenmesine olanak sağlamaktadır. Espor'un izleyici dostu olma özelliğinin incelenmesi, izleyicilerin ilgisini daha iyi anlamaya yardımcı olmaktadır. Oyun rekabetçiliğinin analizi, izleyicilerin potansiyel katılımını gösterebilmektedir (Campbell vd., 2021).

3.1.9. Oyuncuların Kazançları ve Kariyer Olanakları

Son zamanlarda Espor, yakın gelecekte birçok kişi tarafından öngörülen istikrarlı bir yükseliş eğilimi ile gelişen bir endüstri olduğunu göstermektedir. Küresel Espor gelirinin 2016 yılında 800 milyon dolara ulaştığı ve 2019 yılına kadar öncelikle reklam ve sponsorluk yoluyla 1,23 milyar dolara ulaşmasının beklendiği bildirilmektedir (Bitkraft, 2017). Espor'un 2019'daki nihai geliri, 1,2 milyar doların hemen altındaki projeksiyona yakın gerçekleşmiştir (Gough, 2019). Benzer şekilde küresel Espor gelirinin 2017'deki 1,23 milyar dolardan 2022'de 2,3 milyar dolara çıkması ve izleyici sayısında öngörülen yıllık %12'lik artışa denk gelmesi beklenmektedir (SuperData, 2017). Ayrıca Espor izleyicilerinin 2019 yılında 214 milyondan 303 milyonun üzerine çıkacağı tahmin edilmektedir (Minotti, 2016). Sadece Ekim 2017'de LoL video oyunu Twitch.tv üzerinden 286 milyon tekil izleyici tarafından izlenmiştir (SuperData, 2017). Dünya genelinde 4.000 kişiyle yapılan bir anket 18-25 yaş arasındaki erkeklerin geleneksel sporlardan daha fazla çevrimiçi video oyunu ve Espor izlediğini ortaya koymaktadır (Limelight Networks, 2017). Bu büyüme üniversiteler arası sporlarda ve Olimpiyat Oyunlarında da görülmektedir. Örneğin 2016 yılında yedi üniversite Espor takımıyla başlayan Ulusal Kolej Esporları Birliği (NACE, 2018), 2018 yılına kadar 90 üye kuruma ulaşmıştır ve bunların çoğu Espor bursları sunmakta ve spor departmanları tarafından desteklenmektedir. 2019 itibarıyla resmi bir Olimpiyat sporu olmasa da Espor, Çin'in Hangzhou kentinde düzenlenen 2022 Asya Olimpiyatları'nda bir madalya müsabakası olarak yer almaktadır (Graham, 2017).

Esporun toplumsal ve ekonomik önemi son yıllarda büyük ölçüde artmıştır. Sektör 2021'de bir milyar ABD dolarını aşan pazarlama geliri elde etmiştir (Newzoo, 2022, s.

34), düzenli olarak yeni finansal ve seyirci rekorları kaydedilmekte ve neredeyse her gün büyük yeni sponsorluk anlaşmaları bildirilmektedir (Mariot ve Nufer, 2020, s. 5-6). Fiyat havuzları hızla yükselmekte ve profesyonel sportlardaki tanınmış uluslararası etkinliklerin fiyatlarına ulaşmaktadır. Örneğin 2021’de tek bir Espor etkinliği için en yüksek fiyat havuzu The International 2021 için 40 milyon doların üzerinde gerçekleşmiştir. Farklı Espor ligleri 10 milyon doların üzerinde fiyat havuzları ödüllendirmiştir. Ayrıca, popüler Espor etkinlikleri izleyici oranları açısından kitlesel etkinlikler haline gelmiştir (Llorens, 2017) ve Madison Square Garden gibi büyük spor stadyumlarının biletleri tükenebilmektedir (Rapaport, 2017). Bununla birlikte sahadaki izleyici rakamları internet üzerinden elde edilenlere kıyasla küçüktür. Örneğin 2018 LoL şampiyonası aynı yıl içinde NFL Super Bowl’un iki katından daha fazla toplam izleyiciye sahip olmuştur (de Zoeten & Könecke, 2024).

3.1.10. Esporun Etik ve Hukuki Boyutları

Esporun çağdaş atletik kültürün önemli bir boyutu olarak ortaya çıkışı, çeşitli etik ve hukuki soruları da beraberinde getirmektedir. Elektronik sistemler aracılığıyla gerçekleştirilen rekabetçi video oyunları olarak tanımlanan Espor, geleneksel sportlardan farklı, kendine özgü zorluklar içermektedir. Esporun etik boyutları, adalet, profesyonellik ve teknolojinin etkileri gibi, spor alanında yaygın olarak tartışılan temel konularla paralellik göstermektedir.

Esporun meşru bir spor dalı olarak tanınıp tanınmaması üzerine temel bir tartışma söz konusudur. Espor, rekabet, beceri geliştirme ve topluluk katılımı gibi geleneksel sportların temel ölçütlerini karşılamaktadır (Hamari ve Sjöblom, 2017; Sabillah ve Annasai, 2021). Ancak bu sınıflandırma Espor oyuncularının maruz kaldığı performans baskısı ve zihinsel sağlık sorunları gibi geleneksel sportcularla benzer koşulları içeren etik sonuçların titizlikle değerlendirilmesini zorunlu kılmaktadır (Milić ve Djamel, 2020). Esporda teknolojinin rolü tıpkı geleneksel sportlarda olduğu gibi rekabetin eşitliği ve adil olması açısından etik soruları gündeme getirmektedir. Gelişmiş oyun ekipmanları gibi yenilikler oyuncular arasında algılanan ya da gerçek farklılıklara neden olabilmektedir. Bu durum ise adil rekabetin sağlanabilmesi için düzenleyici bir çerçeve oluşturulmasını gerekli kılmaktadır (Dyer, 2020; Whysall, 2014).

Ayrıca Esporda etik dışı uygulamaların (hile yapma, maç ayarlama ve doping gibi) potansiyel olarak varlığı söz konusudur. Espor yarışmalarının bütünlüğüne yönelik bu kaygılar, tarihsel olarak geleneksel sporları etkileyen yolsuzluk ve etik ihlallerle paralellik göstermektedir (Burton ve Peachey, 2014; Constantin vd., 2021). Bu tür riskleri azaltmak adına etik liderlik büyük önem taşımaktadır. Oyun geliştiricilerin, organizatörler ve profesyonel ligler gibi paydaşların, dürüstlük ve hesap verebilirlik ilkelerini önceleyen ortamları oluşturmaları gerektiği belirtilmektedir (Constandt vd., 2020; Meeuwsen ve Kreft, 2022). Esporun ticarileşmesi ve profesyonelleşmesiyle birlikte ortaya çıkan etik ikilemler bu alanı daha da karmaşık hâle getirmektedir. Sektör büyüdükçe, Espor giderek geleneksel sporların neoliberal gerçeklerini yansıtan bir yapıya bürünmekte ve bu süreçte kar odaklılık, etik ilkelerin göz ardı edilmesine yol açabilmektedir (Whysall, 2014).

Hukuki açıdan bakıldığında Esporun tanınması, fikri mülkiyet hakları, sözleşme hukuku ve adil oyunun teşvik edilmesine yönelik paydaş yükümlülükleri gibi önemli soruları gündeme getirmektedir. Teknolojinin kullanımı ya da kötüye kullanımı, Esporun temel bileşenlerinden biri olarak genellikle rekabetin adilliği ve oyuncu haklarıyla ilgili hukuki meselelerle kesişmektedir (Evans vd., 2016). Esporun son yıllarda geçirdiği evrim, bu hukuki karmaşıklıkları ele alacak güçlü yönetim yapılarının oluşturulmasının ve etik standartların korunmasının ne denli gerekli olduğunu ortaya koymaktadır (Navarro vd., 2024).

3.2. LoL Oyunu

LoL, Riot Games tarafından geliştirilen ve yayınlanan bir çok oyunculu çevrimiçi savaş arenası (MOBA) oyunudur. LoL, beş kişilik takımlar halinde oynanan rekabetçi bir Espor oyunudur. LoL’de her oyuncu bir şampiyonu kontrol eder ve başka bir oyuncu takımıyla rekabet etmektedir. Amaç, rakip takımın üssünün ortasındaki bir yapı olan “nexus”u devirmektir.

En yüksek oyuncu tabanına ve en geniş izleyici kitlesine sahip olan LoL, profesyonel oyuncuların en görünür ve dikkate değer sahnesine sahiptir. Espor’un popülaritesindeki artış LoL’a bağlamaktadır (Bornemark, 2013). Çoğu zaman Espor oyuncularının yaptığı iş, diğer oyuncular ve taraftarlar tarafından sadece eğlenmek için

oyun oynamak olarak yanlış anlaşılmaktadır. Bunu ele almak için ve LoL'in önde gelen bir Espor olduğu göz önünde bulundurulduğunda oyuncuların statülerini ve çalışmalarını göz önünde bulundurmak için çalışmaları araştırılması gerektiği belirtilmiştir. Bir bütün olarak oyun birçok insanın hayatının büyük bir parçası haline gelmektedir (Taylor, 2012). Bu nedenle oyun ve oynanan oyunlar, geçmişin tanınmayan bir alt kültürü olmaktan uzaklaşarak toplumun bir parçası haline gelmekte ve bu oyunları oynayanları günlük olarak etkilemektedir. Çok sayıda çalışma bu faktörleri ve diğerlerini dikkate almakta, ancak hiçbirisi yalnızca LoL Espor oyuncularını ele almamaktadır. Kısa röportajlar ve yorumlar aracılığıyla LoL Espor oyuncuları genellikle profesyonel sahnenin arkasındaki gerçeklere işaret etmektedir. Oyuncular, oyun oynarken ve takımlarının işverenlerinin evlerinde yaşarken okul işlerini, ilişkilerini ve diğer faktörleri yönettiklerini anlatmaktadırlar (Agha, 2015).

Kuzey Amerika Lig Şampiyonası Serisi (NA LCS), Avrupa Lig Şampiyonası Serisi (EU LCS), Çin League of Legends Profesyonel Ligi (LPL), Güney Kore League of Legends Şampiyonlar Ligi (LCK), League of Legends Usta Serisi (LMS) ve diğer çeşitli bölgelerde büyük bölgesel rekabetler mevcuttur. Kendi bölgelerinde kazanan takımlar her yıl düzenlenen Dünya Şampiyonasında yarışma şansı elde etmektedir. 2018 Dünya Şampiyonası 99,6 milyon tekil izleyiciye ve 6,45 milyon ABD dolarının üzerinde bir toplam ödül havuzuna sahip olmuştur (Riot Games, 2018). Espor ilerledikçe oyun stratejilerini analiz etme ihtiyacı ortaya çıkmaktadır. Günümüzde çoğu profesyonel oyun takımı, rakiplerini analiz etmeleri, stratejilerini belirlemeleri ve karşı stratejiler geliştirmeleri için analistleri işe almaktadır. Analistler analizlerini turnuvalar ve maçlar sırasında raporlamaktadır. Günümüzde Espor oyuncuları takım koçları, yöneticileri ve stratejistleri ile birlikte çalışmaktadır. Hızla artan rekabet seviyesiyle birlikte, oyuncuların performansını artıracak stratejilere duyulan ihtiyaç da artmaktadır. LoL'de takım performansını tahmin etmek için kolektif zeka kullanıldığı belirtilmektedir (Kim vd., 2017). Kolektif zekanın, oyuncuların zımni koordinasyonuna dayalı olarak takım performansını tahmin edebildiğini göstermişlerdir. Takımların performansını çeşitli gruplara ayırmıştır (Nascimento Jr vd., 2017). Makine öğrenmesi ve istatistiksel analiz uygulayarak bu özelliklerin LoL'deki sonuçları nasıl etkilediğini bulmak için her gruptaki özellikleri değerlendirmişlerdir. Diğer bir çalışmada savaş taktikleri grafiklerde modellenmiş ve MOBA oyununun sonuçlarını tahmin eden bir karar ağacı oluşturmak

için grafiklerden özellikler çıkarılmıştır (Yang vd., 2014). Oyuncuların davranışları hakkında yeterli veri toplandıktan sonra bir MOBA oyununun sonucunu tahmin etmeyi sağlayan bir oyuncu davranış modeli önerilmiştir. Oyuncu davranışı varyasyonunun özellikleri arasındaki etkileşimi işlemek ve bir oyunun sonucunu tahmin etmek için tekrarlayan sinir ağı kullanıldığı belirtilmektedir (Lan vd., 2018). Oyun ilerledikçe toplanan kısmi oyun verilerinin, makine öğrenmesi tekniklerinin uygulanmasıyla devam eden bir Defense of the Ancients 2 (Dota 2) oyununun sonuçlarını gerçek zamanlı olarak doğru bir şekilde tahmin etmek için kullanılabileceği gösterilmektedir (Johansson ve Wikström, 2015). Kahraman taslak verilerine dayanarak Dota 2 oyun sonucunu tahmin etmek için çok katmanlı ileri beslemeli sinir ağları kullanıldığı belirtilmektedir (Kho vd., 2020). Tüm bu çalışmalar, oyunun ana amacı kazanmak için oyundaki kuleler gibi hedefleri alt etmek iken, oyun oynanışlarını veya oyundaki hedefleri dikkate almamıştır (Wang, 2016).

Bir bilgisayar oyunu olan LoL, geleneksel spor tarihi metodolojisi ve iletişim ve retorik gibi diğer disiplinlerden gelen teoriler kullanılarak incelenebilmektedir. Beyzbol tarihçisi Jules Tygiel (2000), oyunun toplumdaki daha geniş çaplı değişimleri yansıttığını ve Amerikan kültüründe özel bir yeri olduğunu savunmaktadır.

Riot Games tarafından geliştirilen ve 2009 yılında piyasaya sürülen LoL, özellikle MOBA türünde, oyun endüstrisindeki modern popülerite artışını simgelemektedir. Bu oyun 100 milyondan fazla aylık aktif kullanıcıya ulaşması gibi kayda değer başarılar elde etmiş ve sadece bir oyun olmanın ötesinde, topluluk etkileşimi ve eğlence anlayışını yeniden şekillendiren kültürel bir fenomen haline geldiği belirtilmektedir (Liu, 2023). Ücretsiz oynanabilen bir model üzerinden erişilebilir olması, oyuncu kitlesinin büyümesini daha da destekleyerek, kullanıcıların ön maliyet olmaksızın oyuna katılımını sağlamıştır. LoL'in, Riot Games'in kazanmanın para ile satın alınmadığı bir sistem olduğu adil bir oyun deneyimi sunma taahhüdü, rekabetçi bütünlüğü teşvik etmiş ve gelecekteki çevrimiçi oyunlar için bir standart oluşturmuştur (Jarrett, 2021).

Oyunun tasarım unsurları, oyuncuların çeşitli psikolojik ihtiyaçlarına hitap etmektedir. Oyun içi yapılar ve topluluk kültürü aracılığıyla kimlik ve aidiyet duygusu oluşturarak, LoL kullanıcıları psikolojik düzeyde etkin biçimde bağlayarak, oyuncu bağlılığı ve sadakatini artırmaktadır (Liu, 2025). LCK ve LoL Avrupa Şampiyonası

(LEC) gibi profesyonel liglerin kurulması ile iyi organize edilmiş uluslararası turnuvalar, oyunun rekabetçi sahnesini küresel ölçekte ön plana çıkarmış ve dünya çapında izleyicileri büyüleyen dinamik bir Espor ortamı yarattığı belirtilmiştir (Horbiński ve Zagata, 2023).

Riot Games, LoL fikri mülkiyetini geleneksel oyun platformlarının ötesine genişletme konusunda da akıllıca adımlar atmıştır. Mobil cihazlar için geliştirilen League of Legends: Wild Rift, büyüyen mobil oyun pazarını hedefleyen stratejik bir hamle olarak oyunun değişen oyun ortamında güncelliğini korumasını sağlamaktadır (Li, 2024). Bu mobil platformlara genişleme ve “Arcane” gibi ilgili medya aracılığıyla platformlarda yayınlanan animasyon serileri, LoL evreninin hikaye derinliğini ve oyuncu katılımını artırmış, böylece daha geniş bir demografik çekicilik sağlarken mevcut hayran kitlesini de muhafaza etmiştir (Cai, 2024).

Oyunun yayın platformlarına entegrasyonu, LoL’ı bir seyir sporuna dönüştürmüş ve popülerliğine önemli katkılar sağlamıştır. Bu eğilim, izleyicilerin oyun deneyimine sadece katılımcı olarak değil, aynı zamanda gözlemci olarak da dahil olduğu yeni bir eğlence tüketim biçimini beraberinde getirerek oyunun popüler kültürdeki konumunu yükseltmiş ve etkinlikler için önemli medya iş birlikleri ile sponsorlukların çekilmesini sağlamıştır (Jarrett, 2021; Liu, 2023).

3.3. Espor ve Oyuncu Performansları: Literatürdeki Eğilimler

Cao (2024), mobil Espor oyuncu davranışlarını analiz ederek oyuncuların demografik özellikleri, oyun süreleri, harcama alışkanlıkları ve oyun zamanlamaları gibi önemli faktörler hakkında veriler sunmak ve bu veriler üzerinden Espor şirketlerinin stratejilerini geliştirmelerine yardımcı olmak amaçlanmıştır. Çalışma 623 oyuncu profilinden alınan verilerle gerçekleştirilmiştir. Oyuncuların yaş dağılımına bakıldığında, 18-22 yaş arası oyuncular %31,94 ile en büyük grubu oluştururken, 23-27 yaş arası oyuncular %25,67, 28-32 yaş arası oyuncular %23,19, 38 yaş ve üzeri oyuncular ise yalnızca %7,54 oranında yer almaktadır. Bu veriler, genç oyuncuların mobil Espor oyunlarına daha fazla ilgi gösterdiğini ve yaş ilerledikçe oyuncu sayısının azaldığını göstermektedir.

Oyuncuların eğitim seviyesiyle ilgili olarak, üniversite diplomasına sahip oyuncular toplam oyuncu sayısının %38,2'sini oluştururken, lisans mezunları %23,43, yüksek lisans mezunları ise %5,46 oranında yer almaktadır. Bu veriler, daha yüksek eğitim seviyesindeki bireylerin, oyun oynamaya daha az vakit ayırdığını ve bu kişilerin oyunları eğlence amaçlı değil, boş zamanlarını değerlendirmek amacıyla daha az tercih ettiklerini göstermektedir. Oyun süresi ve harcama alışkanlıklarına ilişkin veriler, bir çok oyuncunun oyun içi harcama yaptığı ve özellikle öğrencilerin daha yüksek harcama yapma eğiliminde olduğunu göstermektedir. Çalışma; yaş gruplarına, eğitim seviyelerine ve harcama alışkanlıklarına göre mobil Espor oyuncularının davranışlarını ortaya koymuş ve şirketler için önemli stratejik çıkarımlar yapılmasına olanak sağlamıştır.

Minami vd.(2024) çalışmasında elektroensefalogram (EEG) verisi ile maç sonuçlarını tahmin etme süreci ele alınmış ve farklı makine öğrenmesi modelleri ile bu tahminlerin doğruluğu ölçülmüştür. LightGBM modeli EEG verisi ile yapılan tahminlerde en yüksek doğruluğu sağlayan model olarak öne çıkmaktadır. LightGBM modelinin doğruluk oranı %80 olarak belirlenmiştir. Model, kazanma ve kaybetme tahminlerinde, dengesiz veri dağılımına karşı sağlam bir performans sergileyerek, %79,6 doğruluk oranı, %79,5 makro-precision ve %0,589 MCC (Matthews Correlation Coefficient) gibi metriklerde de yüksek sonuçlar elde edilmiştir. EEG verilerinin maç sonuçlarını tahmin etme konusunda etkili bir araç olduğunu ortaya koymaktadır. EEG verisi ile geleneksel verilerin birleştirilmesi durumunda, LightGBM modelinin doğruluk oranının %62,5 olduğu geleneksel veri seti ile yapılan tahminlerin doğruluk oranından önemli ölçüde yüksek olduğu gözlemlenmiştir. Geleneksel veri seti, maç sonuçlarını tahmin etme açısından sınırlı kalmış, ancak EEG verisinin eklenmesiyle doğruluk oranında kayda değer bir artış sağlanmıştır. Ayrıca, LightGBM ve KNN gibi diğer modeller, özellikle kaybetme durumlarını tahmin etmede zayıf kalmış, LightGBM modelinin bu dengesizliği stabil bir şekilde yönetebildiği belirtilmiştir.

Yu vd.(2024), Espor oyunlarının oyuncu geri bildirimlerini analiz etmek için konu modelleme ve duygu analizi yaklaşımlarını birleştiren bir yöntem geliştirmişlerdir. Dört popüler Espor oyununun oyuncu yorumlarını inceleyerek önemli veriler sunmaktadır. Bu oyunlar; TEKKEN 7, Dota 2, PUBG ve CS:GO'dur. Her bir oyun için 15 ila 16 konu başlığı tespit etmiş ve bu başlıkları oyun içindeki önemli unsurlar olarak kategorize etmiştir. Örneğin, TEKKEN 7'de 16 konu başlığı, Dota 2'de 16, PUBG'de 15 ve CS:GO'da

ise 16 konu başlığı belirlenmiştir. Latent Dirichlet Allocation (LDA) algoritması kullanılarak yapılan konu modelleme, her bir oyunun oyuncu geri bildirimlerinin daha iyi anlaşılmasına olanak sağlamaktadır.

Yayınlanan ısı haritasına göre, her bir oyunda öne çıkan konular grafikler, oyun içi oynanış ve karakter tasarımı gibi temel unsurlardır. PUBG oyuncularının yaklaşık %20'si "hile yapma" ve "sunucu gecikmesi" konularına odaklanırken, TEKKEN 7 oyuncularının %18'i "beceri" ve "karakter tasarımı" ile ilgili geri bildirimde bulunmuştur. PUBG'nin "optimizasyon" konusu %30 oranında olumsuz yorum alırken, CS:GO oyuncuları "derecelendirme" ve "hile" gibi konularda daha fazla olumsuz geri bildirimde bulunmuşlardır. BERT tabanlı bir model kullanılarak yapılan duygu analizi sonuçları da çalışmanın önemli bulguları arasındadır. Araştırmacılar duygu analizi için E2E-ABSA (End-to-End Aspect-Based Sentiment Analysis) yöntemini kullanarak oyuncu geri bildirimlerinden Mikro F1 ve Makro F1 puanları hesaplamışlardır. Modelin performansı Mikro F1 skoru %75,48 ve Makro F1 skoru ise %60,46 olarak belirlenmiştir. Bu sonuçlar, modelin duygu analizi açısından oldukça başarılı olduğunu göstermektedir. Duygusal analizde, oyuncuların geri bildirimleri genellikle "hile yapma" ve "sunucu sorunları" gibi konularda olumsuz eğilimler göstermektedir (Yu vd., 2024).

Xenopoulos (2023), CS:GO (Counter-Strike: Global Offensive) gibi Esport oyunlarında maç sonuçlarını tahmin etmek için çeşitli makine öğrenmesi teknikleri kullanmışlardır. Özellikle oyuncu hareketlerinin ve oyun içindeki etkileşimlerin modellenmesi üzerine yapılan analizler, oyun tahminlerinin doğruluğunu artırmaya yönelik önemli bulgular sunmaktadır. Örneğin, CS:GO oyunları üzerindeki tahmin modellerinde, logaritmik kayıp (logarithmic loss, LL), ortalama kare hatası (MSE) ve ortalama mutlak hata (MAE) gibi metrikler kullanılarak modelin başarısı ölçülmüştür. Modelin kalibrasyonu da önemli bir değerlendirme kriteri olarak ele alınmış ve beklenen kalibrasyon hatası (ECE) gibi metriklerle modelin doğruluğu görsel olarak analiz edilmiştir.

Kullanılan veriler, özellikle ESTA veritabanı üzerinden elde edilmiştir ve 2021-2022 yıllarında gerçekleştirilen CS:GO turnuvalarına ait 1,558 demo dosyasından toplanan 8.6 milyon eylem, 417 bin oyuncu yolu ve 7.9 milyon kareyi içermektedir. Bu veriler, oyuncu hareketlerini ve oyun içindeki etkileşimleri ayrıntılı bir şekilde sunarak,

modelleme süreçlerine katkı sağlaması amaçlanmıştır. Örneğin, bu verilerde oyuncu eylemleri arasında silah ateşleri %68, hasar %13, grenat atışı %10, flash kullanımı %6, öldürmeler %3 ve bomba olayları %1'lik bir dağılıma sahiptir. Bu dağılımlar, oyunun her anını anlamada ve oyuncu davranışlarını tahmin etmede kullanılmıştır.

DeepSets modeli gibi derin öğrenme yaklaşımları kullanılarak oyuncu verilerinin etkisi incelenmiştir. Özellikle oyuncu koordinatları (X/Y/Z) kullanılarak yapılan öldürme olasılığı (kill probability) tahminlerinde yaklaşık %20'lik bir iyileşme sağlanmıştır. Bu bulgu, oyuncu pozisyonlarının öldürme tahminlerinde önemli bir faktör olduğunu ortaya koymaktadır. Ancak aynı yaklaşım galibiyet olasılığı (win probability) tahminlerinde belirgin bir iyileşme sağlamamıştır. Maçın sonucunu tahmin etmenin sadece oyuncu koordinatlarına dayalı olmadığı, diğer faktörlerin de önemli olduğu anlamına geldiği belirtilmiştir. Çalışmada, Espor oyunlarında kullanılan veri setlerinin ve oyuncu özelliklerinin model performansı üzerinde etkisi olduğunu ortaya koymaktadır. Özellikle, oyuncu koordinatlarının öldürme olasılığı (kill probability) tahminlerinde sağladığı iyileşme, oyuncu pozisyonlarının önemini vurgulamaktadır. Ayrıca, galibiyet tahminlerinde oyuncu koordinatlarının eklenmesinin sınırlı bir etki yarattığı, bunun yerine takım stratejileri ve diğer oyun içi faktörlerin daha belirleyici olduğu gözlemlenmiştir. Bu bulgular, yalnızca maç sonuçlarını tahmin etmek için değil, aynı zamanda oyuncu stratejilerini analiz etmek, oyun içi olayları daha iyi anlamak ve canlı bahis uygulamalarına yön vermek için de önemli bir katkı sağlamaktadır.

Sinap (2023), Counter-Strike: Global Offensive (CS:GO) oyunundaki rauntların kazanan taraflarının tahmin edilmesi amaçlamışlardır. Kaggle platformunda bulunan “CS:GO Round Winner Classification” veri seti kullanılmıştır. Bu veri seti, 2019 ve 2020 yıllarında düzenlenen üst düzey turnuva oyunlarından alınan 700 demo kaydından oluşturulmuştur. Toplamda 122.410 örnek ve 97 öznitelik içeren bu veri setinde, her bir rauntun kazananını ifade eden kategorik bir sınıf değeri bulunmaktadır. Örneklerin 62.406'sında T takımı, 60.004'ünde ise CT takımı raundu kazanmıştır. Verinin hazırlık aşamasında, kayıp veriler çıkarılmış ve öznitelikler sayısal değerlere dönüştürülerek standartlaştırma işlemi uygulanmıştır. Bu standartlaştırma, her bir öznitelik için ortalama ve standart sapma değerleri hesaplanarak gerçekleştirilmiştir. Kullanılan yedi farklı denetimli sınıflandırma algoritmasından LR, DT, RF, XGBoost, NB, KNN ve SVM ile modelleme yapılmıştır. En başarılı algoritma olarak RF seçilmiştir ve bu model %88

doğruluk oranına ulaşmıştır. Bu, çalışmanın en yüksek doğruluk oranıdır. Diğer algoritmalar arasında, XGBoost ile %79 doğruluk oranına ulaşılmıştır. NB ve KNN algoritmaları ise sırasıyla %70 ve %72 doğruluk oranları elde etmiştir.

Brewer vd.(2022), dinamik kazanan tahmin modellerinin oluşturulmasına odaklanmışlardır. Bu tür modeller, bir spor veya Espor maçının değişen durumunu analiz ederek her potansiyel maç sonucunun olasılığını düzenli olarak güncellemesi amaçlanmıştır. Kazanan tahmini ile ilgili çalışmalarının çoğunda, en olası sonucun doğru bir şekilde tanımlanmasına odaklanırken, bu çalışma her potansiyel maç sonucuna atanan olasılık değerlerinin değerlendirilip optimize edilmesinin daha iyi bir çıktı sağladığını göstermektedir. Altı farklı makine öğrenmesi yöntemi değerlendirilmiş ve her birinin Brier skorunu minimize etmek için optimize edilmiştir. Yapay Sinir Ağı (ANN) yöntemi ile en iyi genel sonuçları elde etmiştir. Test setinden örnek maçlar analiz edildiğinde, CS:GO modelinin dinamik tahminlerinin maç durumundaki değişikliklere (örneğin, kazanan turlarda veya takım ekonomisinin değişmesi) oldukça iyi tepki verdiği, maç sırasında güç dengelerinin nasıl değiştiğini gösteren mantıklı tahmin geçmişi grafikleri oluşturduğu görülmüştür.

Kuzmenko vd.(2021), Espor karşılaşmalarının sonuçlarını öngörebilecek yüksek kaliteli bir model oluşturmayı amaçlamışlardır. Bu amaçla karar ağaçları, lojistik regresyon ve yapay sinir ağı gibi yaygın veri madenciliği teknolojileri kullanılarak çeşitli tahminleme modelleri geliştirilmiştir. Kaggle veri setinden elde edilen LoL oyununa ait 7620 profesyonel maç verisi analiz edilmiştir. Her maçta iki takım (mavi ve kırmızı) arasında gerçekleşen mücadeleye ait toplam 14 adet sayısal değişkeni ve bir hedef değişken (kazanan takım: 1=mavi, 2=kırmızı) kullanılmıştır.

Giriş değişkenleri arasında; takım başına kazanılan altın miktarı (blue_end_gold, red_end_gold), öldürülen rakip sayısı (blue_kills, red_kills), yıkılan kule sayısı (blue_towers, red_towers), imha edilen inhibitörler (blue_inhibs, red_inhibs), öldürülen güçlü yaratıklar (dragon, baron, herald) gibi oyun içi başarı göstergeleri yer almaktadır. Sonuçlara göre, en iyi tahminleme performansı sinir ağı modeli tarafından sağlanmış; onu lojistik regresyon, en sonda ise karar ağacı modeli takip etmiştir. Özellikle sinir ağı modelinde, aktivasyon fonksiyonu olarak hiperbolik tanjant kullanılmış ve tek gizli katmanlı bir yapı tercih edilmiştir. Ayrıca bu modellerin oyunculara gerçek zamanlı

strateji deęişiklikleri önermek için kullanılabileceęi ve Espor alanında yapay zekâ destekli karar sistemlerinin geliştirilmesinde önemli bir potansiyel sunduęu sonucuna varılmıřtır.

Hodge vd.(2021), profesyonel Espor oyuncularının davranıřlarını tahmin etmek için veri madencilięi tekniklerini kullanmıřtır. Özellikle Dota 2 oyunu üzerinden profesyonel maların kazananlarını tahmin etmeyi amalayan bir modelin geliştirilmesini ele almaktadır. Bu model, malar ilerledike gerek zamanlı tahminler üretmekte ve izleyicilerin maı daha anlaşılır bir řekilde takip etmelerini saęlamayı amalamaktadır. 28 profesyonel ma üzerinden toplanan veriler kullanılmaktadır. 5. dakikadan itibaren her ma için dakika bazında kazanan takım ve güven seviyeleri tahmin edilmiřtir. Tahmin doęruluęu, maların farklı sürelerinde deęişiklik göstermektedir. 5-20. dakikalar arasında doęruluk %70-%80 aralıęında, 20-30. dakikalarda ise %80-%90 aralıęında olmuřtur. 5. dakikadaki ilk tahmin, %85 doęruluk oranına ulařmıřtır. Ayrıca, 2017 ESL One Hamburg turnuvası gibi büyük turnuvalarda kullanılan canlı veri ile yapılan testler de yer almaktadır. Bu testlerde, toplamda 28 ma için gerek zamanlı tahminler yapılmıřtır ve bu malar 25 milyon izleyiciye ulařmıřtır. Profesyonel maların daha zor tahmin edilebilir olduęunu ve metagame deęişikliklerinin tahmin doęruluęunu etkileyebileceęini belirtmiřtir. Özellikle yeni yamanın etkisiyle deęişen stratejiler, tahmin doęruluęunda iniř ıkıřlara neden olmuřtur. Algoritma seimi ve parametre optimizasyonu doęruluk oranlarını artırmada kritik bir rol oynamıřtır. Özellikle RF ve LR algoritmaları, %74,59 doęruluk oranına kadar ıkabilmiřtir. Yang ve Johansson'un (2016;2021) alıřmalarına atıfta bulunarak, malar ilerledike tahmin doęruluęunun deęiřtięi ve son ařamalarda tahminlerin daha güvenilir olduęu belirtilmiřtir. 35. dakikaya kadar doęruluk oranı yükselmiř, ardından %45 dakikasında bir düşüř gözlemlenmiřtir. İzleyicilerin tahminlere olan güveni, doęruluk oranlarına baęlı olduęu gözlemlenmiřtir. %100 doęruluk oranı ile yapılan tahminler maın heyecanını azaltabilirken, %70-%80 arası doęruluk oranları daha tutarlı ve eęlenceli sonuçlar ürettięi görülmüřtür. Profesyonel oyun verileri nadir ve az sayıda olduęundan, bu verilerle yapılan tahminlerin her zaman sınırlı olduęunu ifade etmektedir. Ancak, profesyonel ve amatör oyun verilerinin karıřtırılması, modelin doęruluęunu artırmakta etkili olmuřtur.

Yang vd.(2022) Honor of Kings (HoK) gibi MOBA oyunları için kazanma tahminlerini doęru ve yorumlanabilir bir řekilde yapmak amacıyla geliştirilen bir model

sunmuşlardır. Model, Two-Stage Spatial-Temporal Network (TSSTN) adını taşımaktadır ve hem güvenilir sonuçlar sunmakta hem de tahminlerin hangi özelliklerin etkisiyle elde edildiğini yorumlanabilir hale getirmektedir. Kullanılan veri seti, 174.362 HoK oyununu içermektedir ve bu veriler, gerçek zamanlı oyun kayıtlarından alınmıştır. Çalışmanın sonuçlarına göre, TSSTN modelinin doğruluğu, %50 doğruluk oranına sahip Heuristic modeline göre daha yüksektir, ancak Fully-Connected Network ve LSTM gibi diğer modellerden biraz daha düşüktür. TSSTN modelinin doğruluğu, örneğin, 0.0 dakikada %50, 17.5 dakikada %54,4, 20.0 dakikada ise %56,2'ye çıkmıştır. Bu doğruluk oranları, modelin oyun sırasında dinamik olarak gelişen özelliklere tepki verebildiğini göstermektedir. Sonuçlar, TSSTN modelinin zaman ilerledikçe farklı özellik gruplarının doğruluğunu nasıl etkilediğini ortaya koymuştur. Başlangıçta "Heroes" özelliği yüksek doğruluk oranlarıyla öne çıkarken, zamanla "Gold" özelliği doğruluk açısından önemli bir rol oynamıştır. Ancak 12. dakikadan sonra, altın miktarındaki artışın etkisi azalmış ve "Soldier" özelliği daha belirgin hale gelmiştir. Bu, modelin oyun dinamiklerine göre esnek bir şekilde adaptasyon gösterebildiğini ortaya koymaktadır. Ayrıca, insan uzmanlarının tahminleriyle karşılaştırıldığında, TSSTN modeli daha başarılı olmuştur. TSSTN modelinin yorumlanabilirlik özelliği, özellikle gerçek zamanlı AI yorumlayıcı sistemler için büyük önem taşımaktadır. Model, 2020 yılından itibaren HoK oyunlarında bir AI yorumlayıcıda başarıyla kullanılmaktadır. Bu sistem, her oyunda ortalama 157,2 yorum üreterek, izleyicilere kazananı tahmin etmenin yanı sıra bu tahminlerin hangi özelliklere dayandığını da açıklar. Bu özellik, izleyicilere geleneksel sistemlere göre çok daha etkileşimli ve bilgi dolu bir deneyim sunmaktadır.

Kim vd.(2020), LoL oyununda maç sonucunu tahmin etmek amacıyla Platt ölçekleme yöntemlerinden Sıcaklık Ölçekleme, Matris Ölçekleme ve Vektör (Temperature Scaling, Matrix Scaling ve Vector Scaling) karşılaştırılmıştır. Platt ölçekleme yöntemlerinin yalnızca logits değerlerine dayalı olması, farklı girdiler için aynı logits değeri üretildiğinde aynı güven çıktısı oluşturmaya neden olmakta ve bu durum belirsizliğin yüksek olduğu MOBA veri setlerinde yetersiz kalmaktadır. Bu sınırlamayı aşmak amacıyla geliştirilen yeni yöntem, girdiye bağlı belirsizliği doğrudan dikkate alarak gerçekleştirmektedir. Elde edilen sonuçlar, doğruluk oranı %72,95 olarak ölçülürken, en iyi sonucu veren Platt ölçekleme yöntemi olan Matrix Scaling %73,05

doğruluk sağlamıştır. Önerilen yöntem ise %73,81 doğruluk oranına ulaşarak tüm yöntemler arasında en yüksek başarıyı göstermiştir.

Leathart vd.(2020) sıralı veriler için olasılık kalibrasyonunu incelemiştir. Özellikle sıralı bir verinin sınıflandırılması esnasında yapılan tahminlerin zamanla nasıl değiştiği ve kalibrasyonunun nasıl yapılabileceği incelenmiştir. Sırasıyla, sürekli sıralar için üssel olarak azalan sıcaklık kalibrasyonu ve ayırık sıralar için zaman adımı bazında gruplama önererek her iki yöntemle ilgili iyileşmeleri test edilmiştir. Her iki kalibrasyon yönteminin, uygulama alanlarında Ortalama Log Likelihood (NLL) ve Empirik Kalibrasyon Hatası (ECE) üzerinde önemli iyileşmeler sağladığını ortaya koymuştur.

Xenopoulos vd.(2020), CS:GO gibi Espor oyunlarında oyuncu performansını değerlendirmek amacıyla geliştirilmiş yeni bir “Kazanma Olasılığı Değerlendirmesi” (Win Probability Assessment; WPA) çerçevesini tanıtlmaktadır. WPA, oyuncuların eylemlerini değerlendiren ve her bir eyleme bir değer atayan bir modeldir. Modelin amacı, oyuncu becerisini ve takım stratejilerini daha doğru bir şekilde ölçmek ve analiz etmektir. Oyuncu değerlendirmelerinde yalnızca hasar olaylarının dikkate alınmasının sınırlayıcı bir faktör olduğunu ve bunun yerine oyun içindeki diğer önemli aksiyonların da göz önünde bulundurulması gerektiğini vurgulamaktadır.

Ruseti vd.(2020) kullanıcı yorumlarına dayalı duygu analizi gerçekleştirmek amacıyla Metacritic platformunu kullanmışlardır. Metacritic’ten Crawler4j aracı ile 3000’den fazla oyuna ait toplam 201.552 kullanıcı incelemesi toplanmıştır. Araştırmacılar, genel amaçlı bir sınıflandırma yerine, oyun sektörü gibi belirli bir alan için uyarlanmış, modüler bir analiz hattı geliştirmeyi hedeflemiştir. Sonuçlar derin sinir ağı modellerinin diğer yöntemlere göre daha yüksek doğruluk sağladığını göstermiştir. Ancak bu fark anlamlı düzeyde yüksek değildir. Ayrıca, kullanıcı yorumlarında sıkça karşılaşılan yazım hatalarının modellerin doğruluğunu olumsuz etkilediği gözlemlenmiştir. Bu nedenle, veri ön işleme sürecine otomatik yazım denetimi eklenecektir.

Santos vd.(2019) uzmanlar ile amatörlerin video oyunu değerlendirme davranışlarını büyük ölçekli veriler üzerinden karşılaştırmak ve bu farklılıkları kullanarak video oyununun kısa ve uzun vadeli itibarı üzerine tahminlerde bulunabilecek modeller geliştirmeyi hedeflemiştir. Metacritic platformundan alınan 1.167.553 inceleme verisi

kullanılmıştır. Bu incelemeler hem metin içeriği hem de puanlama eğilimleri açısından analiz edilmiştir. Elde edilen bulgulara göre uzman yorumları daha tutarlı ve zaman içinde istikrarlıyken, amatör yorumlar daha duygusal ve uç değerlere eğilimlidir. Bununla birlikte, amatörlerin erken dönemde yaptığı yorumların oyunun uzun vadeli itibarı hakkında önemli ipuçları verdiği anlaşılmıştır. Bu nedenle, geliştiricilerin oyun yayımlandıktan sonraki ilk haftalarda gelen amatör tepkileri dikkatle izlemeleri gerektiği ortaya konmuştur. Uzman yorumları ise özellikle uzun vadeli başarı öngörülerinde etkili bulunmuştur.

Hodge vd.(2018) iki popüler rekabetçi Espor oyunu olan Dota 2 ve CS:GO için takım galibiyetini tahmin edebilecek bir makine öğrenmesi modeli geliştirmeyi amaçlamışlardır. Çalışmanın temel amacı, oyuncu rollerinin galibiyete olan etkisini modelleyerek, oyun içi parametrelere dayalı olarak maç sonuçlarını tahmin etmektir. Kullanılan temel yöntem, lojistik regresyon modeliyle her oyuncunun oynadığı rolün galibiyete katkısının tahmin edilmesidir. Yapılan tahminlerin doğruluğu TrueSkill modeli ile 0,68 olarak bulunmuştur. Bu sonuçlar, oyun içi verilerin doğru şekilde işlenmesiyle, takım galibiyet tahminlerinin önemli ölçüde daha doğru yapılabileceğini göstermektedir.

Baumann vd.(2018)'ın Steam platformundaki 100 milyondan fazla kullanıcıdan elde edilen verilerle hardcore oyuncu profillerinin analizini sunmaktadır. Çalışma, özellikle haftada 20 saatten fazla oyun oynayan 700.000'den fazla hardcore oyuncuyu inceleyerek, 3.300'ün üzerinde oyunun verilerini kullanmıştır. Oyuncu davranışlarını belirlemek için denetimsiz öğrenme yöntemlerinden K-means kümeleme algoritması kullanılmıştır. Sonuçlar, hardcore oyuncuların farklı oyun türlerine göre altı ana grupta kümelendiğini göstermektedir. Bunlar; Birinci Şahıs Nişancı oyuncular, Team Fortress 2 oyuncular, Aksiyon oyunları oyuncular, Dota 2 oyuncular, Strateji ve aksiyon kombinasyonu oyuncular ve Tür değiştirici oyunculardır. Bulgular hardcore oyuncuların oyun türlerine olan ilgilerini ve davranışlarını yansıtan profiller oluşturulmasına olanak sağlamaktadır. Örneğin, Birinci Şahıs Nişancı (FPS) oyuncular, zamanlarının büyük kısmını Counter-Strike ve Call of Duty gibi oyunlara ayırırken, Team Fortress 2 oyuncular daha çok ücretsiz oyunlara yönelmektedir. Ayrıca, Dota 2 oyuncular, büyük bir oyun saatine sahip olan ve bu oyunda yoğunlaşan bir oyuncu grubu olarak dikkat çekmektedir. Strateji ve aksiyon kombinasyonu oyuncular, Civilization V gibi strateji oyunları ile aksiyon unsurlarını harmanlayan oyunlara ilgi göstermektedir.

Yang vd.(2016), Dota 2’de bir maın kazanan takımını hem ma ncesi hem de ma anındaki bilgilerle tahmin edebilen modeller geliřtirmiřtir. Genellikle alıřmalarda gz ardı edilen eřitli ncl (ma ncesi) ve eřzamanlı (ma sırasındaki) zellikler dikkate alınarak, tahmin doėruluėunu artıracak yntemler denenmiřtir. alıřmada, 19.790 farklı oyuncunun katıldıėı toplam 78.362 matan elde edilen veri seti kullanılmıřtır. Modelleme srecinde, lojistik regresyon (LR), nerilen znelik Sıra Modeli (Attribute Sequence Model - ASM) ve bu modellerin kombinasyonları kullanılmıřtır. Yapılan deneylerde, yalnızca kahraman seimlerine dayalı tahmin %58,69 doėruluk saėlarken; oyuncu ve kahraman bilgileri ile birlikte oluřturulan tam ncl zellik kmesiyle doėruluk %71,49’a ykselmiřtir. zellikle oyuncu-kahraman kombinasyonlarının tek bařına %69,90 doėruluk saėlaması, bireysel oyuncu deneyiminin ve tercihlerinin ma sonucuna etkisini gstermektedir.

Wattanaburanon vd.(2016), oyun kullanılabilirlik kaliteleri ve problemlerini sınıflandırmak amacıyla metin madenciliėi teknikleri ve duygu analizi yntemleri kullanmıřlardır. alıřma, oyun kullanılabilirlik kaliteleri ve problemleri kategorilerinin belirlenmesi ve oyun incelemelerinin toplanıp analiz edilerek sınıflandırılması ařamalarını iermektedir. Oyun kullanılabilirlik kaliteleri ve problemleri iin anahtar kelimelerle desteklenen kategorilerin belirlenmesidir. Oyun kullanılabilirlik kaliteleri  ana kategoriye ayrılmıřtır: Gameplay, Game sensation ve Game usability. Bu ana kategorilerde alt kategoriler de oluřturulmuřtur. Oyun problemleri ise  ana kategoriye ayrılmıřtır: Hack ve chat (Hacking and cheating), oyun hatası (Game error) ve fiyatlandırma (Pricing). Bu kategorilerde yer alan anahtar kelimeler belirlenmiř ve her bir kategori iin zel bir kelime kmesi oluřturulmuřtur. Sınıflandırma ařamasında kullanılan Anahtar Kelime Eřleřtirme (Keyword Matching) tekniėi, her cmleyi belirli bir kategoriye ifade eden anahtar kelimelerle eřleřtirmeye dayalıdır. Bu yntem, her cmlenin hangi kategoriye ait olduėunu belirlemek iin kullanılmıřtır. Ayrıca, duygu analizi ařamasında, Hu ve Liu’nun (2004) geliřtirdiėi pozitif ve negatif kelimeler listesi kullanılarak, cmlelerin duygu tonları sınıflandırılmıřtır. Bu duygu analizi, her cmlenin ierdiėi duygusal yn belirlemek iin kullanılmıřtır. Uzman deėerlendirmesi referans alınarak yapılan sınıflandırma, %80 doėruluk oranına ulařmıřtır. Bu alıřma, oyun kullanılabilirlik kaliteleri ve problemlerinin sınıflandırılmasında kullanılan metin madenciliėi yntemlerinin etkili olduėunu gstermektedir.

Schubert vd.(2016), Dota oyununda, karşılaşmaların sonuçlarını tahmin etmek ve bu sonuçların maç sonuçları üzerindeki etkisini analiz etmek amacıyla yapılmıştır. Çalışmanın temel amacı, karşılaşma tabanlı analiz yöntemiyle, oyunun dinamiklerini daha küçük parçalara ayırarak oyuncu ve takım performanslarını değerlendirmek ve bu bilgileri kullanarak maç sonuçlarını tahmin etmektir. Bu çalışma, oyuncu ve takım seviyesindeki stratejilerin, kaynak kazanımlarının ve öldürme farklarının, maçın sonunda kimin galip geleceğini tahmin etmede nasıl bir rol oynadığını incelemeyi hedeflemiştir. Karşılaşmalar, oyuncuların kaynak kazanımları ve öldürme farkları gibi kriterlere göre tanımlanmış ve bu metrikler kullanılarak, her karşılaşmanın sonunda kimin galip geleceği tahmin edilmeye çalışılmıştır. LR, her karşılaşma için kullanılan bir sınıflandırma yöntemidir ve her karşılaşma sonucunun kazananını tahmin etmek için kullanılmak üzere XP, Altın ve öldürme farkı gibi metrikler üzerinden modellenmiştir. Tahmin doğruluğu, her karşılaşmanın ilk birkaç anında yüksekken, maçın ilerleyen dönemlerinde doğruluğun azaldığı gözlemlenmiştir. Ayrıca, XP kazanımının tahmin için en zayıf metrik olduğu, çünkü maç başlarında XP kazanımının daha çok yapay zeka (AI) kontrolündeki birimleri öldürmekten elde edilmesinin daha fazla katkı sağladığı sonucuna varılmıştır. Altın kazanımı ve öldürme farkı gibi metriklerin ise tahmin doğruluğu üzerinde daha büyük etkiler yarattığı ve daha iyi sonuçlar verdiği bulunmuştur.

Rioutl vd.(2014), video oyunlarının gelişimi ve profesyonelleşmesi için oyuncuların ve takımların oyun içindeki strateji ve taktiklerini analiz etmeye yönelik araçlar geliştirmeyi amaçladığı belirtilmiştir. Çalışmada, Dota oyunu verileri kullanılmıştır. Bu oyun, iki takımın rugby ya da Amerikan futboluna benzer şekilde mücadele ettiği bir yapıya sahiptir. Çalışma, bu oyunun oynanışına dair topolojik ölçümler kullanarak, oyunun sonucunun tahmin edilmesini amaçlamıştır. Çalışma, topolojik verilerin yalnızca MOBA maçlarının sonucunu tahmin etmek için değil, aynı zamanda takım oyunu stratejilerinin analiz edilmesinde de önemli bir araç olduğu doğrulanmıştır. Çalışma, oyunların sonuçlarını tahmin etmek için kullanılan bu düşük seviyeli verilerin, oyun oynanışı hakkında derinlemesine analizler yapabilmeyi mümkün kıldığını göstermiştir. Aynı zamanda bu tür analizlerin profesyonel Espor stratejilerinin geliştirilmesine nasıl katkı sağlayabileceğini de vurgulamaktadır.

Drachen vd.(2014), Dota 2 oyununda mekansal-zamansal (spatio-temporal) takım davranışlarını incelemeyi amaçlamışlardır. Çalışma, dört farklı beceri seviyesindeki

oyuncuların davranışlarını karşılaştırarak, oyun içindeki hareketliliklerini ve takım etkileşimlerini anlamaya yönelik bir veri analizi sunmaktadır. Çalışmada kullanılan üç temel analiz, oyun haritasındaki bölgesel hareket (zon değişimleri), takım üyelerinin dağılımı ve zaman serisi kümeleme analizidir. Bu analizlerde, bölge değişimleri (zone changes), takım üyelerinin harita üzerindeki hareketliliğini ölçerken, takım mesafesi (team distance), takım içindeki oyuncular arasındaki ortalama mesafeyi incelemektedir. Çalışma, MOBA oyunlarında takım davranışlarının beceri seviyesine göre nasıl değiştiğini ve bu davranışların galibiyetle nasıl ilişkilendiğini göstermektedir. Profesyonel oyuncular, daha fazla koordinasyon ve daha yakın takım içi mesafelerle galibiyet kazanırken, daha düşük seviyedeki oyuncular daha dağınık hareket etmekte ve stratejik olarak daha az koordine olduklarını göstermiştir.

Conley ve Perry(2013), Dota 2 oyununda kahraman seçiminin maç sonuçlarını ne ölçüde etkilediğini anlamak ve bu doğrultuda bir kahraman öneri sistemi geliştirmek amaçlamışlardır. Oyuncu davranışlarından bağımsız olarak yalnızca kahraman kompozisyonuna odaklanılmıştır. Yazarlar, öneri motoru ve maç sonucu tahmini yapmak için LR ve KNN algoritmalarını karşılaştırmalı olarak kullanmışlardır. Çalışmanın sonuçları kahraman seçiminin maç sonucunu önemli ölçüde etkileyebildiğini göstermiştir. Ancak bu etkiler, kahramanlar arası etkileşimleri hesaba katan daha gelişmiş yöntemlerle daha iyi modellenebilir. LR modeli basit ve hızlı olmasına rağmen sınırlı temsil gücüne sahiptir. Buna karşılık KNN modeli daha güçlü öngörüler sunabilmektedir ancak yüksek hesaplama maliyetine sahiptir.

(Kamal, Mansor, Truna, Shaipullah ve Sultan, 2025, s. 780-781), MOBA oyunlarının verilerinin çeşitli çalışmalarda sınıflandırma algoritmalarıyla karşılaştırmasını içeren çalışmaları incelemiştir. Araştırma sonuçları makine öğrenmesi performans metrikleri açısından değerlendirildiğinde yüksek doğruluk oranları, özellikle RF, Deep Neural Networks (DNN) ve XGBoost gibi güçlü modellerde ortaya çıkmaktadır. Bahrololloomi vd. (2023) çalışmasında doğruluk %92.78'e ulaşırken, Stanlly vd. (2022) RF ve XGBoost ile sırasıyla %91 ve %93 doğruluk elde etmişlerdir. Benzer şekilde Luo vd. (2019), öğretici-öğrenci modelinde %99.8 gibi yüksek bir doğruluk oranı bildirmiştir.

Ancak tüm çalışmalar bu kadar başarılı sonuçlar göstermemektedir. Bisberg ve Ferrara (2022) gibi bazı çalışmalar daha düşük doğruluk oranları (GCN-Cheby %61.9, RF %57.8) rapor etmişlerdir. Ayrıca Lyu vd. (2022) çalışmasında regresyon metrikleri (RMSE ve R^2) oldukça düşük performansa işaret etmektedir (örneğin R^2 değeri yalnızca 0.01). Bu da bazı yöntemlerin veri türüne veya probleme yeterince iyi uymadığını göstermektedir.

Bazı araştırmalar ise özellikle kullanıcı deneyimi, öneri sistemleri veya oyun stratejisi gibi farklı açılara odaklanmıştır. Örneğin Do vd. (2020) sistem önerileri, rastgele önerilere göre anlamlı şekilde daha yüksek değerlendirme elde etmişlerdir ($p = 0.01257$). Mohammed vd. (2022) ve Ye vd. (2022) ise öneri ve strateji sistemlerinde yüksek başarı elde etmiş ve hatta insan oyunculara karşı başarı sağlanmıştır.

Bu sonuçlar bazı algoritmaların belirli veri türleri ve problemler için daha uygun olduğunu göstermektedir. Örneğin RF ve DNN gibi modeller genellikle yüksek doğruluk sağlarken, bazı grafik tabanlı veya basit modeller daha düşük performans sergilemişlerdir. Ayrıca modellerin başarısı yalnızca doğrulukla değil, AUC, F1-skoru, kullanıcı geri bildirimi ve oyunun bağlamına göre de değerlendirilmelidir. Bu çeşitlilik, problem tanımı ve veri yapısının, algoritma seçimi kadar önemli olduğunu ortaya koymaktadır.

BÖLÜM 4

YÖNTEM

Bu çalışmada makine öğrenmesi denetimli öğrenme sınıflandırma analizi algoritmalarından RF, SVM, KNN, LR, XGBoost, NB, DT, ANNs ve GBoost kullanılmıştır.

4.1. Araştırmanın Konusu, Amacı ve Önemi

Bu araştırmanın temel konusu, makine öğrenmesi yöntemlerinden biri olan sınıflandırma algoritmalarını kullanarak rekabetçi bir Espor oyunu olan LoL’da, oyuncu davranış verilerden oyuncuların oyundaki seviyesini tahmin etmektir. LoL; strateji, refleks ve takım işbirliği gerektiren dinamik bir oyundur. Bu bağlamda oyuncuların oyun içi metrikleri, karar alma yetenekleri, stratejik hareketleri ve diğer performans göstergeleri onların profesyonel seviyede başarı gösterebilme potansiyellerini etkileyebilir.

Araştırmanın amacı, oyuncuların oyundaki performans verilerini inceleyerek oyuncuların başarı potansiyellerini tahmin etmektir. Bu şekilde, yetenekli oyuncuların keşfedilmesi ve onların eğitim süreçlerinin optimize edilmesi amaçlanmaktadır.

Bu çalışma, LoL gibi rekabetçi Espor oyunlarında yapılan çalışmalar ile spor biliminin ve veri analitiğinin sınırlarını genişletmek ve Espor dünyasında stratejik karar alma süreçlerini desteklemeyi hedeflemektedir. Bu alanda yapılan çalışmalar takımların yetenek avcılığı süreçleri ve oyuncu gelişim stratejilerini önemli ölçüde iyileştirilebilmesi sağlamaktadır. Ayrıca oyuncuların potansiyellerini maksimize etmelerini ve rekabetçi arenada daha üst düzey performans sergilemeleri sağlanabilmesi adına önem arz etmektedir.

4.2. Araştırmanın Kapsamı

Bu çalışma, oyuncuların oyun içi performans verilerini içeren kapsamlı bir veri seti üzerinde yürütülmektedir. Veri seti, oyuncuların her biri için toplanan çeşitli özellikleri içermekte olup, bunlar arasında şampiyon seçimleri, oyun sonu istatistikleri, kazanılan maçlar, kaybedilen maçlar, elde edilen başarılar ve oyun içi etkileşimler yer almaktadır.

Oyun içi metrikler arasında oyuncu seviyesi, toplam galibiyet ve mağlubiyet sayıları, üst üste galibiyetler, ilk kan kazanma, belirli bir şampiyonu sıkça seçip seçmemek gibi faktörler bulunmaktadır. Ayrıca, oyuncuların toplam öldürme, öldürülme, asist sayıları, kazanılan altın miktarı, kesilen minyon sayısı, yok edilen kuleler, kesilen orman canlıları gibi istatistikler de önemlidir. Bunların yanı sıra, oyuncuların bir maçta maksimum kill(ölüm) skoru, ölmeden üst üste alınan max kill (ölüm) sayısı, en yüksek kritik vuruş, kulelere ve rakip şampiyonlara verilen toplam hasarlar gibi detaylar da performansı doğrudan etkileyen unsurlardır.

Çalışma, LoL oyuncularının performanslarını analiz ederek rekabetçi oyun ortamında Espor oyuncularının başarılarını artırmak için veri odaklı bir yaklaşım sunmayı hedeflemektedir. Oyuncu verilerinin kapsamlı analizi, oyun endüstrisindeki profesyoneller, araştırmacılar ve oyuncular için değerli bilgiler sunmaktadır.

4.3. Araştırmanın Kısıtları ve Varsayımları

LoL oyuncularının bir sezondaki verilerini içeren bu araştırma için verilerin belirli bir tarihte çekilmiş olması araştırmanın temel kısıtlarından biridir. Verilerin belirli bir zaman diliminde toplanması, araştırmanın güncelliği ve zaman hassasiyeti açısından kritik bir faktördür. Oyun verileri sürekli olarak değişebilir ve güncellemelerle oyun mekaniği, karakter dengeleri ve istatistikler üzerinde önemli değişiklikler yapılabilir. Dolayısıyla verilerin belirli bir tarihte alınmış olması çalışmanın sonuçlarına etki etmektedir.

LoL gibi dinamik oyunlarda, sürekli olarak güncellemeler yapılmaktadır. Bu süreçte, oyuna yeni şampiyonlar eklenebilir, mevcut şampiyonların yetenekleri ve özellikleri de değişebilmektedir. Bu durum, oyuncuların tercihlerini ve oyun stratejilerini

doğrudan etkileyebilir ve dolayısıyla oyun verilerinin zaman içinde sürekli değişen bir yapıya sahip olmasına yol açabilmektedir.

Belirli veri başlıklarının eksik veya sınırlı olması araştırmanın kapsamını etkileyebilmektedir. Örneğin, bazı şampiyonların yetenekleri veya oyun içi mekaniklerdeki değişiklikler nedeniyle yeni istatistikler eklenmiş olabilir veya bazı istatistikler zamanla kaldırılmış olabilmektedir. Bu durum, veri toplama zamanlaması ve hangi başlıkların inceleneceği konusunda araştırmayı yönlendiren bir faktör olabilmektedir.

4.4. Araştırma Verilerinin Elde Edilmesi ve Analizi

Bu çalışmada kamuya açık erişim sağlanabilen OPGG (<https://op.gg/tr>) sitesi üzerinden yayınlanan LoL oyununa ait veri seti 22.02.2024 tarihinde elde edilmiştir. Veri setinde 41 tane özellik (feature) yer almaktadır. Özelliklerin tamamı sayısal değerlerden oluşmaktadır. Çalışmanın ön işleme aşamasında “user id”, “şampiyon adı” gibi eşsiz özellikler analizden çıkarılmıştır.

Çizelge 4.1. Araştırma Verileri

Özellik Adı	Tanımı	Ortalama	Standart Sapma	Min-Maks Değer
Toplam Galibiyet	Bir oyuncunun tüm şampiyonlarla elde ettiği toplam galibiyet sayısıdır. Bu değer, oyuncunun genel başarısını gösterir.	75,04	44,70	8-295
Toplam Mağlubiyet	Bir oyuncunun tüm şampiyonlarla aldığı toplam mağlubiyet sayısıdır. Bu değer, oyuncunun karşılaştığı zorlukları ve başarısızlıkları gösterir.	65	43,77	1-326
Maç Sayısı (Şampiyon Başına)	Her bir şampiyonla yapılan toplam maç sayısıdır. Bu, şampiyonların ne kadar sık oynandığını gösterir.	25,56	27,64	1-561
Galibiyet Sayısı (Şampiyon Başına)	Her bir şampiyonla kazanılan maç sayısıdır. Şampiyonların ne kadar başarılı olduğunu gösterir.	15,05	16,36	0-275
Mağlubiyet Sayısı (Şampiyon Başına)	Her bir şampiyonla kaybedilen maç sayısıdır. Şampiyonların ne kadar başarısız olduğunu gösterir.	10,51	11,95	0-286
Toplam Kill (Şampiyon Başına)	Her bir şampiyonla elde edilen toplam kill sayısıdır. Oyuncunun atak gücünü gösterir.	191,17	242,71	0-2.817

Çizelge 4.1. Devamı

Toplam Asist (Şampiyon Başına)	Her bir şampiyonla yapılan toplam asist sayısıdır. Oyuncunun takım arkadaşlarına ne kadar destek olduğunu gösterir.	224,37	271,26	0-3.718
Kazanılan Altın	Oyuncunun oyun içinde kazandığı toplam altın miktarıdır. Oyuncunun ekonomik olarak ne kadar başarılı olduğunu gösterir.	312.215	345.962,7	486.800-6.468.690
Kesilen Minyon	Oyuncunun öldürdüğü toplam minyon sayısıdır. Oyuncunun ne kadar farm yaptığını gösterir.	3.207,75	4.436,75	9-93.697
Yok Edilen Kuleler	Oyuncunun yıktığı toplam kule sayısıdır. Oyuncunun hedeflere ne kadar odaklandığını gösterir.	33,01	46,59	0-1.038
Kesilen Orman Canlıları	Oyuncunun öldürdüğü toplam orman canavarı sayısıdır. Ormancı rolündeki oyuncuların etkinliğini gösterir.	899,57	2.334,71	0-34.139
Verilen Toplam Hasar	Oyuncunun karşı takıma, orman canlılarına ve kulelere verdiği toplam hasar miktarıdır. Oyuncunun atak gücünü gösterir.	383.339	482.756	146.6000-77.442.380
Alınan Toplam Hasar	Oyuncunun aldığı toplam hasar miktarıdır. Oyuncunun ne kadar hasar aldığını ve defansif yeteneklerini gösterir.	674.904	781.052	3.965-13.037.800
Verilen Fiziksel Hasar	Oyuncunun verdiği toplam fiziksel hasar miktarıdır. Fiziksel hasar veren şampiyonlarla olan etkinliği gösterir.	2.104.288	3.605.118	2.470-44.477.330
Verilen Büyü Hasarı	Oyuncunun verdiği toplam büyü hasarı miktarıdır. Büyü hasarı veren şampiyonlarla olan etkinliği gösterir.	1.270.864	2.375.469	0-60.821.550
Bir Maçtaki Maksimum Kill Skoru	Bir maçta ulaşılan en yüksek kill sayısıdır. Oyuncunun bireysel olarak ne kadar başarılı olduğunu gösterir.	15,28	7,18	0-42
Bir Maçtaki Maksimum Ölüm Skoru	Bir maçta alınan en yüksek ölüm sayısıdır. Oyuncunun ne kadar sık öldüğünü gösterir.	11,46	2,8	0-27
Bir Maçtaki Üst Üste İki Kill	Bir maçta üst üste iki kill alma sayısıdır. Oyuncunun çatışmalardaki etkinliğini gösterir.	20,14	31,09	0-484
Bir Maçtaki Üst Üste Üç Kill	Bir maçta üst üste üç kill alma sayısıdır. Oyuncunun ne kadar baskın oynadığını gösterir.	2,91	6,08	0-127
Bir Maçtaki Üst Üste Dört Kill	Bir maçta üst üste dört kill alma sayısıdır. Oyuncunun ne kadar baskın oynadığını gösterir.	0,43	1,3	0-30
Bir Maçtaki Üst Üste Beş Kill	Bir maçta üst üste beş kill alma sayısıdır. Oyuncunun ne kadar baskın oynadığını gösterir.	0,07	0,36	0-9

Çizelge 4.1. Devamı

Toplam Maç Süresi	Oyuncunun maçlarının toplamda ne kadar sürede bittiğini belirtir.	43.326	46.968	660-1.000.089
Yok Edilen İnhibitörler	Bir maçta kazanmaya ne kadar yakın olduğunu belirtir.	5,5	7,8	0-135
Alınan Vision Wardlar	Oyuncunun, haritadaki görüş alanını arttırmak için oyun içi oyun altınıyla item aldığını gösterir.	41,9	78,8	0-2.078
Toplanan Visionlar	Oyuncunun, haritada belirli bir bölgeye görüş sağlaması için topladığı görüş itemleri	697,15	1.066,8	0-38.733
Yerleştiren Ward Sayısı	Oyuncunun, haritadaki görüş alanını arttırmak için item kullandığını gösterir.	286,2	266,4	0-16.945
Kesilen Ward Sayısı	Oyuncunun karşı takım oyuncularının yerleştirdiği kaç wardı kestğini gösterir.	77,4	130,5	0-6.539
Toplam İyileşme	Oyuncunun kullandığı skiller ile ne kadar can yenilediğini gösterir.	230.098	399.316	0 - 10.974.140
Rakibi Kitleme	Rakibi hareketsiz bırakma süresi.	628	958	0-27.807
Alınan Fiziksel Hasar	Alınan fiziksel hasarı gösterir.	404.813	480.714	3.271-7.556.162
Şampiyonlara Verilen Hasar	Karşı takımın şampiyonlarına verilen toplam hasarı gösterir.	566.803	659.876	720-13.828.800
Şampiyonlara Verilen Toplam Fiziksel Hasar	Karşı takımın şampiyonlarına verilen toplam fiziksel hasarı gösterir.	286.561	484.977	210-6.246.233
Şampiyonlara Verilen Toplam Büyü Hasarı	Karşı takımın şampiyonlarına verilen toplam büyü hasarı gösterir.	242.489	416.260	0 -11.381.100
Baron, Vadinin Almeti ve Ejderlere Toplam Hasar	Oyundaki orman canavarlarına verilen toplam hasarı gösterir.	367.517	587.297	0 -7.900.710
Kulelere Verilen Toplam Hasar	Kulelere verilen toplam hasarı gösterir.	96.240	142.435	0-355.325
Toplam Hasar Engelleme	Oyuncunun pasif ya da aktif skilleri ile kendine gelen hasarların ne kadarını engellerdiğini gösterir.	542.173	726.253	1.031-11.756.200
En Fazla Çoklu Katletme	Oyuncunun bir maçta üst üste ne kadar iki ve ya daha fazla, üst üste öldürdüğünü gösterir.	2,73	1,01	0-7
En Yüksek Kritik Vuruş	Verilen en yüksek kritik hasarı gösterir.	405	587	0-4140
Ölmeden Üst Üste Alınan Maksimum Kill Sayısı	Oyuncunun bir maçta ölmeden üst üste ne kadar kill aldığını gösterir.	8,5	4,6	0-39
Oyundaki Seviye	Oyuncunun, oyunun oynadıkça kazandırdığı experience point'ler (XP) ile kaç levelle ulaştığını belirtir.	397	257	34-1548

Çalışmada kullanılan 41 özelliğin tanımı ve tanımsal istatistik değerleri Çizelge 4.1’de belirtilmiştir. Bu veriler, oyuncuların performansını ve genel olarak etkinliğini değerlendirmek kullanılmaktadır. Bu verilerin ne anlama geldiğini ve neden gerekli olduklarını anlamak, oyuncunun oyun içindeki rolünü ve katkısını daha kavramaya yardımcı olmaktadır.

Örneğin “toplam galibiyet” ve “toplam mağlubiyet” değişkenleri, oyuncunun sezon boyunca elde ettiği başarıları ve başarısızlıkları göstermektedir. Bu iki veri, galibiyet yüzdesinin hesaplanmasında temel alınır ve oyuncunun genel performansının bir yansımasıdır. Yüksek bir galibiyet yüzdesi, oyuncunun başarılı bir oyun stratejisi ve etkili bir performans sergilediğini göstermesi beklenirken, mağlubiyet sayısının yüksek olması, oyundaki zorluklarla başa çıkma konusunda bazı sorunlar yaşandığını işaret etmektedir.

Kullanılan “verilen toplam hasar” özelliği, oyuncunun karşı takıma, orman canlılarına ve kulelere ne kadar hasar verdiğini göstermektedir. Bu veri, oyuncunun atak oyunundaki etkisini ölçmek için bir göstergedir. Aynı şekilde, “alınan toplam hasar”, oyuncunun ne kadar hasar aldığını ifade etmektedir. Ayrıca oyuncunun defans oyunundaki etkisini ölçmek için kullanılan bir göstergedir.

Başka bir özellik olan “toplam vision skoru”, oyuncunun haritaya yerleştirdiği ward’lardan ve karşı takım ward’larını kesme eylemlerinden elde ettiği puanı temsil etmektedir. Vision skoru, oyuncunun harita üzerindeki görünürlüğü ve stratejik kontrolü sağlama konusundaki başarısını göstermektedir. Yüksek bir vision skorundan dolayı, muhtemel kendi çevresindeki harita görünürlüğünü, oyuncunun çevre kontrolünü ve karşı takımın hareketlerini etkili bir şekilde izlediğini, dolayısıyla oyun stratejilerinde önemli bir rol oynadığını ortaya koyması beklenmektedir.

Bu veriler, bir oyuncunun oyun içindeki çeşitli yönlerini kapsamlı bir şekilde analiz etmeye olanak tanımaktadır. Galibiyet ve mağlubiyetler genel performansı, verilen ve alınan hasar atak ve savunma yeteneklerini, “vision skoru” ise harita kontrolünü ve stratejik etkinliği değerlendirmektedir. Bu bilgilerin bir araya gelmesi, oyuncunun güçlü ve zayıf yönlerini belirlemek ve oyunun genel stratejisini optimize etmek için önem teşkil etmektedir.

Çalışmada kullanılan tüm özelliklerin tanımsal istatistikleri incelenmiştir. Örneğin “toplam galibiyet”, oyuncunun bir şampiyon özelinde değil, tüm şampiyonlardaki galibiyet sayısını göstermektedir. Toplam galibiyet tanımsal istatistikleri incelendiğinde ortalama galibiyet sayısı 75, galibiyet aralığının ise 8 ile 295 arasında olduğu gözlemlenmektedir. Standart sapmanın yüksek olması, oyuncular arasındaki galibiyet sayılarında değişkenliğin yüksek olduğunu göstermektedir. Bir diğer ortalama ölçütü olarak medyan incelendiğinde değerin 65 olduğu görülmektedir. Dolayısıyla veri setinin çoğunluğunun belirli bir aralıkta toplandığını, ancak bazı oyuncuların bu aralığın oldukça dışında galibiyetlere sahip olduğunu göstermektedir. Bu durum, özellikle yüksek yüzdelerdeki galibiyetlerin az sayıda oyuncu tarafından elde edildiğini göstermektedir. Anomaliler ve uç değerler incelendiğinde, maksimum değerin 295 olduğu ve veri setinde birkaç uç değer olduğu görülmektedir. Bu durum, bazı oyuncuların diğerlerinden belirgin şekilde galibiyet açısından üstün olduğunu göstermektedir. Benzer şekilde “toplam mağlubiyet” özelliği, oyuncunun bir şampiyon özelinde değil, tüm şampiyonlardaki mağlubiyet sayısını göstermektedir. Ortalama mağlubiyet sayısı 65’tir. Standart sapma değeri (43) ise bu özellik için oldukça yüksek bir değerdir. Bu durum bazı oyuncuların oyunda daha zorlandığını ve daha fazla mağlubiyet yaşadığını ifade etmektedir.

Tüm özelliklerde belirlenen genel eğilim, ortalamaların düşük değerlerde toplandığı ve standart sapma değerinin oldukça yüksek olduğu şeklindedir. Bu durum veri içerisindeki oyuncu seviyelerinin çeşitliliğinden ve seviyeler arasındaki özelliklerin birbirinden büyük oranda farklı olmasından kaynaklanmaktadır.

Veri setinde dört farklı oyuncu seviyesi bulunmaktadır. Bunlar; diamond, master, grandmaster ve challenger şeklindedir. Oyunun en yüksek seviyesi “challenger” dır. Diğer seviyeler sırasıyla “grandmaster”, “diamond” ve “master” dır. Oransal dağılım; %44 “diamond”, %34 “master”, %14 “grandmaster” ve %7 “challenger” şeklindedir.

Veri setinde sınıf etiketi (hedef değişken) profesyonel olma/olmama durumudur. Profesyonel olma durumu “0”, olmama durumu ise “1” ile ifade edilmiştir. Bu sınıf etiketi araştırmacılar tarafından belirlenmiştir. Ancak çalışmada, oyunun en yüksek seviyesi olan “challenger” profesyonel seviye olarak belirlenmiş ve diğer tüm seviyeler profesyonel olmama şeklinde tanımlanmıştır.

Sınıf etiketleri ve veri setinde kullanılacak özellikler belirlendikten sonra eksik veri kontrolü yapılmış ve eksik veriler temizlenmiştir. Ardından sınıf etiketine göre veri setinin dağılımı incelenmiştir. Sınıf dağılımı 588 profesyonel, 7704 profesyonel değil olarak belirlenmiştir. Veri seti sınıflandırma etiketi açısından değerlendirildiğinde dengesiz veri kategorisindedir.

Veri setindeki sınıf dengesizliği sorununu çözmek için SMOTE (Synthetic Minority Over-sampling Technique) yöntemi uygulanmıştır. SMOTE modelin çoğunluk sınıfına göre tahmin etme eğilimindedir. Azınlık sınıfı için sentetik veri üretir. Azınlık sınıfında daha iyi genelleme ve daha yüksek kesinlik ve duyarlılık metrikleri elde edebilir.

Dengesiz veri sorunu çözüldükten sonra veri seti 80:20 oranında eğitim ve test veri seti olarak bölünmüştür. Eğitim veri setindeki sınıf dağılımı (6163, 6163) olarak oluşturulmuştur. Veri setinin eğitim ve test veri seti olarak bölünmesinde k katlı çapraz doğrulama yöntemi seçilmiştir. Modelleri aşırı öğrenmeye karşı korumak için kullanılan bu doğrulama yönteminde k , “10” olarak belirlenmiştir.

Veri setinde, sayısal değişkenlerin standartlaştırılması amacıyla “Standart Scaler” kullanılmıştır. Bunun nedeni mesafeye dayalı sınıflandırma algoritmalarının (SVM, KNN vb.) da analizde kullanılmasıdır. Bu yöntem mesafeye dayalı modellerin performansını artırır ve dengesini sağlar.

Veri ön işleme adımı tamamlandıktan sonra karşılaştırılacak sınıflandırma modelleri belirlenmiştir. Sınıflandırma modelleri, literatürde Espor çalışmalarında en çok tercih edilen algoritmalar baz alınarak belirlenmiştir. Bu modeller sırasıyla RF, SVM, KNN, LR, XGBoost, NB, DT, ANN ve GBoost şeklindedir.

Belirlenen her sınıflandırma modeli için modelin öğrenme sürecini kontrol etmek ve model performanslarını arttırmak için hiperparametre optimizasyonu yapılmıştır. Sınıflandırma modelleri için yapılan hiperparametre ayarları şu şekildedir:

Çizelge 4.2. Araştırmada Kullanılan Hiperparametreler

Model	Hiperparametre	Tanımı	Değerler
Random Forest (RF)	n_estimators	Ormandaki ağaç sayısı	[100, 200, 300]
	max_depth	Her karar ağacını maksimum derinliği	[None, 10, 20, 30]
	min_samples_split	Bir içi düğümü bölmek için minimum örnek sayısı	[2, 5, 10]
	min_samples_leaf	Minimum dal sayısı	[1, 2, 4]

Çizelge 4.2. Devamı

Support Vector Machine (SVM)	C	Düzenleştirme parametresi	[0.1, 1, 10, 100]
	kernel	Çekirdek fonksiyon	['linear', 'rbf', 'poly']
	gamma		['scale', 'auto', 0.1, 0.01]
K-Nearest Neighbors (KNN)	n_neighbors	Komşu sayısı	[3, 5, 7, 9, 11]
Logistic Regression (LR)	C (Regularization)	Düzenleştirme parametresi	[0.001, 0.01, 0.1, 1, 10]
	solver	Optimizasyon algoritması	['liblinear', 'saga']
XGBoost	n_estimators	Boosting aşamalarının (ağaç) sayısı	[100, 200, 300]
	max_depth	Maksimum derinliği	[3, 6, 9, 12]
	learning_rate	Öğrenme oranı	[0.01, 0.05, 0.1]
Naive Bayes (NB)	var_smoothing	En küçük varyans dengesi	[1e-10, 1e-9, 1e-8, 1e-7]
Decision Tree (DT)	max_depth	Her karar ağacını maksimum	[None, 10, 20, 30]
	criterion	Düğümün bölüneceği fonksiyon	['gini', 'entropy']
	min_samples_split	Bir iç düğümü bölmek için minimum örnek	[2, 5, 10]
	min_samples_leaf	Minimum dal sayısı	[1, 2, 4]
Neural Network (NN)	hidden_layer_sizes	Gizli katman konfigürasyonu	[(50,), (100,), (50,50), (100,50)]
	alpha	Genişletilmiş alpha aralığı	[0.0001, 0.001, 0.01, 0.1]
	activation	Daha fazla aktivasyon fonksiyonu seçeneği	['relu', 'tanh']
	learning_rate_init	Öğrenme oranı	[0.001, 0.01, 0.1]
Gradient Boosting (GB)	n_estimators	Daha fazla Boosting (ağaç) sayısı seçeneği	[100, 200, 300]
	max_depth	Her karar ağacını maksimum derinliği	[3, 6, 9, 12]
	subsample	Her bir ağacın eğitimi için kullanılacak örneklerin oranı	[0.8, 0.9, 1.0]
	min_samples_split	[Bir iç düğümü bölmek için minimum örnek sayısı]	[2, 5, 10]
	learning_rate	Öğrenme oranı	[0.01, 0.05, 0.1]

Analizde gerçekleştirilen hiperparametre ayarları Çizelge 4.2’de verilmiştir. Hiperparametrelerin tanımlanmasının ardından makine öğrenmesi sınıflandırma algoritmaları analizine geçilmiştir. Çalışmada Jupyter Notebook IDE’si kullanılmıştır.

4.5. Araştırma Bulguları


Her bir sınıflandırma algoritması için elde edilen performans metrikleri ve karmaşıklık matrisleri hesaplanmıştır. Algoritmaların performans metriklerinin özet tablosu en iyiden en kötüye doğru sıralanarak Çizelge 4.3'te verilmiştir.

Çizelge 4.3. Sınıflandırma Algoritmalarının Performans Ölçümleri

Algorithm	Doğruluk	Kesinlik	Duyarlılık	F1-Score	AUC	En İyi CV Skoru
Gradient Boosting	0.95	0.94	0.95	0.94	0.95	0,98
XGBoost	0.95	0.94	0.95	0.94	0.95	0,98
Neural Network	0.93	0.92	0.93	0.93	0.90	0,97
SVM	0.92	0.91	0.92	0.92	0.84	0,97
Logistic Regression	0.88	0.94	0.88	0.90	0.93	0,89
Decision Tree	0.88	0.91	0.88	0.90	0.93	0,89
Random Forest	0.91	0.88	0.91	0.90	0.86	0,98
Naive Bayes	0.81	0.86	0.81	0.84	0.67	0,49
KNN	0.78	0.88	0.78	0.82	0.67	0,90

Çizelge 4.3'te göre kullanılan sınıflandırma algoritmalarının performans ölçüm sonuçları incelendiğinde en yüksek skoru Gradient Boosting ve XGBoost algoritmaları sağlamaktadır. Tüm metriklerde eşit performans sağlamışlardır. Dengesiz veri seti söz konusu olduğunda değerlendirilmesi gereken F1 skoruna göre ise GBoost (0,94) ve XGBoost (0,94) en iyi performansı gösterirken onu NN (0,93), SVM (0,92), LR (0,90), DT (0,90) ve RF (0,90) izlemiştir. NB (0,84) ve KNN (0,82) ile en kötü sınıflandırma performansına sahiptir.

Sınıflandırma algoritmalarının karşılaştırılmasında karar noktası olarak eşik değerleri kullanılmaktadır. Bu eşik değerlerinin farklı olasılıklardaki tahminlerini ifade etmek için ROC (Receiver Operating Characteristic Curve) kullanılmaktadır. ROC, doğru pozitif oranı (TP) ve yanlış pozitif (FP) arasındaki ilişkiyi gösterir. Böylece eşik değerinden bağımsız olarak performans metrikleri belirlenebilir.



Şekil 4.2. ROC Eğrisi Değerleri

Şekil 4.1’de ROC eğrisine göre en yüksek performans gösteren sınıflandırma algoritması Gradient Boosting (GB) olarak belirlenmiştir. GB, XGBoost, NN ve LR algoritmaları mükemmel; DT, SVM, RF ise iyi performans göstermiştir. En kötü performans ise NB ve KNN algoritmaları göstermiştir.


AUC, ROC grafiği üzerinden hesaplanan eğri altındaki alanı ifade eden bir performans ölçütüdür. Dengesiz veri setlerinde güvenilir bir performans ölçütüdür. Hesaplanan AUC değerleri sırasıyla; GB (0,95), XGBoost (0,95), LR (0,93), DT (0,93), NN (0,90), RF (0,86), SVM (0,84)’tür. En kötü performans ise NB (0,67) ve KKN (0,67) algoritmaları göstermiştir.

Çalışmada hiperparametre optimizasyonu ile elde edilen en iyi çapraz doğrulama sonuçları için kullanılan en iyi hiperparametre bilgileri Çizelge 2.4’de verilmiştir. En yüksek sonuçlar yine GBoost ve XGBoost algoritmaları ile elde edilmiştir.

Çizelge 4.4. En İyi Hiperparametre Değerleri

Model	Hiperparametre	Değerler
Random Forest (RF)	n_estimators	[300]
	max_depth	[30]
	min_samples_split	[2]
	min_samples_leaf	[1]
Support Vector Machine (SVM)	C	[100]
	kernel	['rbf']
	gamma	[0,1]
K-Nearest Neighbors (KNN)	n_neighbors	[3]
Logistic Regression (LR)	C (Regularization)	[1]
	solver	['liblinear']
XGBoost	n_estimators	[200]
	max_depth	[9]
	learning_rate	[0.1]
Naive Bayes (NB)	var_smoothing	[1e-10]
Decision Tree (DT)	max_depth	[None]
	criterion	['gini']
	min_samples_split	[2]
	min_samples_leaf	[1]
Neural Network (NN)	hidden_layer_sizes	[(100,50)]
	alpha	[0.0001]
	activation	['relu']
	learning_rate_init	[0.001]
Gradient Boosting (GB)	n_estimators	[300]
	max_depth	[12]
	subsample	[0.8]
	min_samples_split	[2]
	learning_rate	[0.1]

GBoosting ve XGBoost algoritmaları, hem test verisi üzerindeki doğruluk, kesinlik, duyarlılık, F1 skoru hem de çapraz doğrulama başarımı açısından en yüksek performans sergilemiştir (%95 doğruluk, %0.98 CV skoru). NN ve SVM algoritmaları da yüksek performans göstermiş olmakla birlikte, AUC gibi sınıf ayrımını ölçen metriklerde görece daha düşük sonuçlar elde edilmiştir. RF algoritması yüksek çapraz doğrulama başarısı elde etmesine rağmen test verisinde özellikle AUC değerinde düşüş göstermiştir. Temel algoritmalar olan LR ve DT modelleri, kabul edilebilir düzeyde başarı sağlarken; Naive Bayes ve K-En Yakın Komşu gibi algoritmalar, hem düşük doğruluk hem de sınıf ayrımı açısından yetersiz kalmıştır. Elde edilen bulgular, özellikle topluluk yöntemlerinin sınıflandırma problemlerinde daha yüksek ve dengeli performans sunduğunu ortaya koymakta, aynı zamanda model başarımının yalnızca doğruluk metriği üzerinden değil, çoklu ölçütlerle değerlendirilmesi gerektiğini vurgulamaktadır.



Şekil 4.1. Tüm Performans Ölçümlerine Göre Algoritmaların Karşılaştırması

Bu çalışmanın sonuçları, makine öğrenmesi modellerinin etkinliğini göstermektedir. Şekil 4.2’de kullanılan tüm sınıflandırma modellerinin performans metriklerinin karşılaştırması yer almaktadır. Espor oyunlarının oyuncu seviyesi tahmininde GB, XGBoost, NN, DT, SVM, RF ve LR iyi performans göstermiştir. GB algoritmasını performans değerleri %95 doğruluk, %94 kesinlik, %95 duyarlılık ve %94 F1 skoru şeklindedir. Elde edilen bulgular literatürde makine öğrenmesi algoritmalarının karşılaştırıldığı pek çok araştırma ile uyumludur. Çalışmada uygulanan hiperparametre optimizasyonu, literatürdeki çalışmalara göre modellerin performansında iyileştirme sağlamıştır.

BÖLÜM 5

SONUÇ ve ÖNERİLER

Bu çalışmada, LoL oyuncularının oyun içi davranış verileri makine öğrenmesi tekniklerini ile analiz edilmiştir. Çalışmada dokuz farklı sınıflandırma algoritması kullanılmıştır. Bu algoritmaların performans ölçümlerinin sonuçları birbiri ile karşılaştırılmış ve en iyi performansa sahip algoritmalar belirlenmiştir. Kullanılan algoritmaların amacı oyuncuların oyun içi verilerine göre oyunda profesyonel olma ve olmama durumunu doğru tahmin etmektir.

Çalışmada LoL oyununun belli bir tarihe ilişkin verileri, kamuya açık bir platformdan toplanmıştır. Öncelikle veri ön işleme adımları tanımlanmış, eksik veri problemi, özellik seçimi, sınıf etiketi belirleme, sınıf dağılımlarını belirleme, ölçeklendirme gibi tüm işlemler uygulanmıştır. Veri seti eğitim-test olarak ayrılmış ve bunun için k -katlı çapraz doğrulama kullanılmıştır. Ardından analizde kullanılacak sınıflandırma algoritmaları belirlenmiştir. Algoritmaların performans ölçümlerini iyileştirmek adına çeşitli seçeneklerde hiperparametre optimizasyonları gerçekleştirilmiş ve kullanılan algoritmalara dair performans ölçümleri elde edilmiştir.

LoL oyuncularının mevcut performanslarını objektif bir şekilde değerlendirme ve oyuncuların potansiyellerini tahmin etmede sınıflandırma yöntemleri oldukça başarılı sonuçlar vermiştir. Özellikle topluluk öğrenme algoritmaları içerisinde yer alan Boosting yöntemlerinden ikisi olan GBoost ve XGBoost en güçlü performans ölçümlerini sağlamıştır. NB ve KNN dışındaki tüm algoritmalar yüksek performans göstermektedir ve değerler birbirine oldukça yakındır.

Kullanılan veri setinde sınıf etiketine göre dağılım dengesiz olduğu için performans ölçümlerinde özellikle F1 skoru, ROC ve AUC değerleri dikkate alınmıştır. Bu üç değer üzerinden incelendiğinde NB ve KNN performans açısından zayıf etki

göstermektedir. Bu üç değer göre de en yüksek performansı GBoost (0,95) ve XGBoost (0,95) göstermektedir. Ancak diğer sınıflandırma algoritmaları da NN (0,93), SVM (0,92), LR (0,90), DT (0,90) ve RF (0,90) yüksek performans değerleri elde etmiştir.

Elde edilen bulgular literatürde makine öğrenmesi algoritmalarının karşılaştırıldığı pek çok araştırma ile uyumludur. Kamal vd. (2025: 780-781), Espor verileri ile sınıflandırma modellerini karşılaştıran çalışmaları incelemiş ve karar probleminin yapısına göre başarılı olarak öne çıkan modelin farklılık gösterdiğini belirlemiştir. LoL oyuncu performansına göre kazanma tahmini başarısının ölçüldüğü çalışmada GBoost (0, 92735) ve XGBoost (0,92732) en iyi performansı göstermiştir Bahrololloomi vd. (2022:73). Oyunu kaybetme tahmini performansını ölçen bir diğer çalışmada da yine XGBoost en güçlü sonuçları vermiştir (Stanlly vd., 2022).

Bu çalışmanın sonuçları, Espor'un hem kendi endüstrisi hem de veri analitiği ve büyük veri araştırmaları için odaklanması gereken bir alan olduğunu vurgulamaktadır. Özellikle, mobil cihazlar üzerinden oynanabilmesi, geniş ve çeşitli oyuncu tabanları, farklı oyun mekanikleri ve erişilebilirlik özellikleri nedeniyle Espor oyunları makine öğrenmesi çalışmaları için büyük bir potansiyel taşımaktadır. Espor platformları, özellikle verinin büyük değer taşıdığı makine öğrenmesi ve büyük veri araştırmalarında oldukça zengin bir kaynaktır ve araştırmalar için önemli fırsatlar sunabilir.

Sonuç olarak çalışmada, oyuncunun oyun esnasındaki davranışları dolayısıyla elde edilen veriler kullanılarak oyuncuların potansiyel seviyesi tahmin edilmiştir. Ancak gelecekteki çalışmalarda farklı oyuncu yetenek seviyelerinin analiz edilmesi, deneyimsiz oyuncuların öğrenme süreçlerinin geliştirilmesi ve oyuncu hatalarının belirlenmesi gibi konular da incelenebilir. Ayrıca, sayısal ve doğrudan etkili özelliklere; oyuncu iletişimi, takım çalışması ve liderlik gibi daha niteliksel faktörler de dahil edilebilir.

KAYNAKLAR

- Agha, B. (2015). League of Legends: Players and Esports (Doctoral dissertation).
- Al Samawi, M. S., Khan, F. Y., Eldeeb, Y., Almaslamani, M., Alkhal, A., Alsoub, H., Ghadban, W., Howady, F., & Hashim, S. (2016). Acinetobacter Infections among Adult Patients in Qatar: A 2-Year Hospital-Based Study. *The Canadian journal of infectious diseases & medical microbiology*, 2016(1), 6873689. doi: 10.1155/2016/6873689
- Ali, Z., Hayat, M. F., Shaukat, K., Alam, T. M., Hameed, I. A., Luo, S., Basheer, S., Ayadi, M., & Ksibi, A. (2022). A Proposed Framework for Early Prediction of Schistosomiasis. *Diagnostics* (Basel, Switzerland), 12(12), 3138. doi: 10.3390/diagnostics12123138
- Alshdaifat, E., Alshdaifat, D., Alsarhan, A., Hussein, F., & El-Salhi, S. M. F. S. (2021). The Effect of Preprocessing Techniques, Applied to Numeric Features, on Classification Algorithms' Performance. *Data*, 6(2), 11. doi: 10.3390/data6020011
- Anderson, C. G., Tsaasan, A. M., Reitman, J., Lee, J. S., Wu, M., Steel, H., ... & Steinkuehler, C. (2018, September). Understanding Esports as a stem career ready curriculum in the wild. In 2018 10th International conference on virtual worlds and games for serious applications (VS-games) (pp. 1-6). IEEE. doi: 10.1109/VS-Games.2018.8493445
- Baltezarević, R., & Baltezarević, B. (2018). The impact of video games on the formation of Esports. *Facta Universitatis: Series Physical Education & Sport*, 16(1). doi: 10.22190/FUPES170614012B
- Bányai, F., Griffiths, M. D., Király, O., & Demetrovics, Z. (2019). The psychology of Esports: A systematic literature review. *Journal of gambling studies*, 35, 351-365. doi: 10.1007/s10899-018-9763-1
- Baumann, F., Emmert, D., Baumgartl, H., & Buettner, R. (2018). Hardcore Gamer Profiling: Results from an unsupervised learning approach to playing behavior on the Steam platform. *Procedia Computer Science*, 126, 1289-1297. doi: <https://doi.org/10.1016/j.procs.2018.08.078>
- Bitkraft. (2017). Esports 101: A deep dive into the world of competitive video games. Retrieved December 1, 2019. Url: https://y4j7y8s9.ssl.hwcdn.net/wp-content/uploads/2017/01/Esports_101-whitepaper-BITKRAFT.pdf
- Bornemark, O. (2013). Success factors for e-sport games. USCCS 2013, 1. Url: <https://webapps.cs.umu.se/uminf/reports/2013/001/part1.pdf>

- Bouchiha, d., Bouziane, A., & Doumi, N. (2023). Ontology based Feature Selection and Weighting for Text classification using Machine Learning. *Journal of Information Technology and Computing*, 4(1), 1-14. doi: 10.48185/jitc.v4i1.612
- Brewer, G., Demediuk, S., Drachen, A., Block, F., & Jackson, T. (2022). Creating Well Calibrated and Refined Win Prediction Models. Available at SSRN 4054211. Url: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=4054211
- Buizza, G., Paganelli, C., D'Ippolito, E., Fontana, G., Molinelli, S., Preda, L., Riva, G., Iannalfi, A., Valvo, F., Orlandi, E., & Baroni, G. (2021). Radiomics and Dosimetrics for Predicting Local Control after Carbon-Ion Radiotherapy in Skull-Base Chordoma. *Cancers*, 13(2), 339. doi: 10.3390/cancers13020339
- Burroughs, B., & Rama, P. (2015). The Esports Trojan horse: Twitch and streaming futures. *Journal For Virtual Worlds Research*, 8(2). doi: 10.4101/jvwr.v8i2.7176
- Burton, L., & Peachey, J. W. (2014). Ethical leadership in intercollegiate sport: Challenges, opportunities, future directions. *Journal of Intercollegiate Sport*, 7(1), 1-10. doi: <https://doi.org/10.1123/jis.2014-0100>
- Cahyani, A. D., Mardiana, T., & Kurniawati, L. (2020). Sentiment Analysis of Digital Wallet Service Users Using Naïve Bayes Classifier and Particle Swarm Optimization. *Jurnal Riset Informatika*, 2(4), 241-250. doi: <https://doi.org/10.34288/jri.v2i4.114>
- Campbell, C., (1995). Ethos: character and ethics in technical writing. *IEEE Transactions on Professional Communication*, 38(3), pp.132-138. doi: 10.1109/47.406725
- Campbell, W., Goss, A., Trottier, K., & Claypool, M. (2021). Sports versus Esports—a comparison of industry size, viewer friendliness, and game competitiveness. *Global Esports: Transformation of Cultural Perceptions of Competitive Gaming*, Bloomsbury, London, 35-59. Url: <https://web.cs.wpi.edu/~claypool/papers/sports-Esports-21/chapter-excerpt.pdf>
- Cao, L. (2024, September). Research on Influencing Factors of Mobile Esports Player Behavior Based on Big Data Mining. In *2024 5th International Conference on Big Data & Artificial Intelligence & Software Engineering (ICBASE)* (pp. 129-134). IEEE. doi: 10.1109/ICBASE63199.2024.10762104
- Cava, C., Salvatore, C., & Castiglioni, I. (2023). Pan-cancer classification of gene expression data based on artificial neural network model. *Applied Sciences*, 13(13), 7355. doi: <https://doi.org/10.3390/app13137355>
- Cestino, J., Macey, J., & McCauley, B. (2023). Legitimizing the game: how gamers' personal experiences shape the emergence of grassroots collective action in Esports. *Internet Research*, 33(7), 111-132. doi: <https://doi.org/10.1108/INTR-05-2022-0347>
- Chahid, I., Elmiad, A. K., & Badaoui, M. (2023, November). Data preprocessing for machine learning applications in healthcare: a review. In *2023 14th International Conference on Intelligent Systems: Theories and Applications (SITA)* (pp. 1-6). IEEE. doi: 10.1109/SITA60746.2023.10373591
- Chamarro, A., & Lanzo, S. G. (2018). Basic psychological needs, passion and motivations in amateur and semi-professional Esports players. *Aloma: Journal of Psychology*,

- Educational Sciences and Sports, 36(2), pp. 59-68. doi: 10.51698/aloma.2018.36.2.59-68
- Chen, T., & Guestrin, C. (2016, August). Xgboost: A scalable tree boosting system. In Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining (pp. 785-794). doi: <https://doi.org/10.1145/2939672.293978>
- Chikish, Y., Carreras, M., & García, J. (2019). Esports: A new era for the sports industry and a new impulse for the research in sports (and) economics. Sports (and) economics, 477-508. Url: https://www.researchgate.net/publication/332781901_Esports_A_New_Era_for_the_Sports_Industry_and_a_New_Impulse_for_the_Research_in_Sports_and_Economics
- Christodoulou, E., Ma, J., Collins, G. S., Steyerberg, E. W., Verbakel, J. Y., & Van Calster, B. (2019). A systematic review shows no performance benefit of machine learning over logistic regression for clinical prediction models. Journal of clinical epidemiology, 110, 12–22. doi: 10.1016/j.jclinepi.2019.02.004
- Conley, K., & Perry, D. (2013). How does he saw me? a recommendation engine for picking heroes in dota 2. Retrieved Url: <https://cs229.stanford.edu/proj2013/PerryConley-HowDoesHeSawMeARecommendationEngineForPickingHeroesInDota2.pdf>.
- Constandt, B., Heres, L., Marlier, M., & Willem, A. (2020). A Stakeholder Perspective on Ethical Leadership in Sport: Bridging the Gap Between the Normative and Descriptive Lines of Inquiry. Psychologica Belgica, 60(1), 381–395. doi: 10.5334/pb.543
- Constantin, P. N., Stanescu, R., Pelin, F., Stoicescu, M., Stanescu, M., Barkoukis, V., ... & Vershuuren, P. (2021). How to Develop Moral Skills in Sport by Using the Corruption Heritage?. Sustainability, 14(1), 400. doi: <https://doi.org/10.3390/su14010400>
- Cranmer, E. E., Han, D. I. D., van Gisbergen, M., & Jung, T. (2021). Esports matrix: Structuring the Esports research agenda. Computers in Human Behavior, 117, 106671. doi: <https://doi.org/10.1016/j.chb.2020.106671>
- Curran, T., Hill, A., Appleton, P., Vallerand, R., & Standage, M. (2015). The psychology of passion: A meta-analytical review of a decade of research on intrapersonal outcomes. Motivation and Emotion, 39(5), pp. 631-655. Doi: 10.1007/s11031-015-9503-0
- Dananjaya, D., Werdiningsih, I., & Semiati, R. (2019). Decision support system for classification of early childhood diseases using principal component analysis and k-nearest neighbors classifier. J. Inf. Syst. Eng. Bus. Intell, 5(1), 13. doi: <https://doi.org/10.20473/jisebi.5.1.13-22>
- Dash, A. P., Sahu, S. K., Kar, S., Behera, B. K., & Panigrahi, P. K. (2020). Explicit demonstration of initial state construction in artificial neural networks using NetKet and IBM Q experience platform. Quantum Information Processing, 19, 1-15. doi: 10.13140/RG.2.2.30229.17129

- De Zoeten, M., & Könecke, T. (2024). Esports, video gaming and their fuzziness: a conceptualization and categorization. *Sport, Business and Management: An International Journal*, 14(1), 99-116. Doi: 10.1108/SBM-10-2022-0097
- Delwiche, A. (2006). Massively multiplayer online games (MMOs) in the new media classroom. *Journal of Educational Technology & Society*, 9(3), 160-172. Url: https://www.samanthablackmon.net/courses/sites/digitalparlor.org.sp08.blackmon1/files/delwiche_MMO_New_Media_classroom.pdf
- Díaz-Uriarte, R., & Alvarez de Andrés, S. (2006). Gene selection and classification of microarray data using random forest. *BMC bioinformatics*, 7, 1-13. Url: <https://bmcbioinformatics.biomedcentral.com/articles/10.1186/1471-2105-7-3>
- Dickey, M. D. (2007). Game design and learning: A conjectural analysis of how massively multiple online role-playing games (MMORPGs) foster intrinsic motivation. *Educational Technology Research and Development*, 55, 253-273. doi: 10.1007/s11423-006-9004-7
- DiFrancisco-Donoghue, J., Balentine, J., Schmidt, G., & Zwibel, H. (2019). Managing the health of the Esport athlete: an integrated health management model. *BMJ open sport & exercise medicine*, 5(1), e000467. doi: 10.1136/bmjsem-2018-000467
- Ding, S., & Huang, H. (2014). Research on parameters optimisation of SVM based on swarm intelligence. *International Journal of Collaborative Intelligence*, 1(1), 4-17. doi: <https://doi.org/10.1504/IJCI.2014.064852>
- Drachen, A., Yancey, M., Maguire, J., Chu, D., Wang, I.Y., Mahlmann, T., Schubert, M., & Klabjan, D. (2014). Skill-based differences in spatio-temporal team behaviour in defence of the Ancients 2 (DotA 2). 2014 IEEE Games Media Entertainment, 1-8. Url: https://andersdrachen.com/wp-content/uploads/2014/07/ieee-gem2014_submission_72.pdf
- Du, Z. (2024). Review of Convolutional Neural Network. *Science and Technology of Engineering, Chemistry and Environmental Protection*, 1(9). doi: 10.61173/1xfrez14
- Ducheneaut, N., Yee, N., Nickell, E., & Moore, R. J. (2006, April). "Alone together?" Exploring the social dynamics of massively multiplayer online games. In *Proceedings of the SIGCHI conference on Human Factors in computing systems* (pp. 407-416). doi: 10.1145/1124772.1124834
- Dyer B. (2020). A Pragmatic Approach to Resolving Technological Unfairness: the Case of Nike's Vaporfly and Alphafly Running Footwear. *Sports medicine - open*, 6(1), 21. doi: 10.1186/s40798-020-00250-1
- Erol, G., Uzbaş, B., Yücelbaş, C., & Yücelbaş, Ş. (2022). Analyzing the effect of data preprocessing techniques using machine learning algorithms on the diagnosis of COVID-19. *Concurrency and computation : practice & experience*, 34(28), e7393. doi: 10.1002/cpe.7393
- Evans, R., McNamee, M., & Guy, O. (2017). Ethics, Nanobiosensors and Elite Sport: The Need for a New Governance Framework. *Science and engineering ethics*, 23(6), 1487–1505. doi: 10.1007/s11948-016-9855-1

- Fang, G., Xu, P., & Liu, W. (2020). Automated Ischemic Stroke Subtyping Based on Machine Learning Approach. *IEEE Access*, 8, 118426–118432. doi: 10.1109/ACCESS.2020.3004977
- Felczak, M. (2023). Systemic issues with narratives of identity: Toxicity and Esports media professionals. *Convergence*, 29(2), 400-416. Doi: <https://doi.org/10.1177/1354856522113876>
- Filchenko, M. (2018). A comparison between Esports and traditional sports. *ART 108: Introduction to Games Studies* (2018). Url: <https://scholarworks.sjsu.edu/art108/12/>
- Foxman, M., Cote, A. C., Can, O., Harris, B. C., Rahman, W., Hansen, J., & Fickle, T. (2021). Recasting collegiate Esports: independence and interdependence of university twitch streamers. Selected Papers of #AoIR2020: The 22nd Annual Conference of the Association of Internet Researchers Virtual Event. doi: 10.5210/SPIR.V2021I0.12166
- Friedman, J., Hastie, T., & Tibshirani, R. (2010). Regularization Paths for Generalized Linear Models via Coordinate Descent. *Journal of statistical software*, 33(1), 1–22. Doi: <https://doi.org/10.18637/jss.v033.i01>
- Funk, D. C., Pizzo, A. D., & Baker, B. J. (2018). Esport management: Embracing Esport education and research opportunities. *Sport Management Review*, 21(1), 7-13. doi: <https://doi.org/10.1016/j.smr.2017.07.008>
- Fuster, H., Chamarro, A., Carbonell, X., & Vallerand, R. J. (2014). Relationship between passion and motivation for gaming in players of massively multiplayer online role-playing games. *Cyberpsychology, Behavior and Social Networking*, 17(5), pp. 292-297. doi: 10.1089/cyber.2013.0349
- Gao, Q., Jin, X., Xia, E., Wu, X., Gu, L., Yan, H., ... & Li, S. (2020). Identification of orphan genes in unbalanced datasets based on ensemble learning. *Frontiers in genetics*, 11, 820. doi: <https://doi.org/10.3389/fgene.2020.00820>
- Gawrysiak, J., Burton, R., Jenny, S., & Williams, D. (2020). Using Esports efficiently to enhance and extend brand perceptions—A literature review. *Physical Culture and Sport. Studies and Research*, 86(1), 1-14. doi: 10.2478/pcssr-2020-0008
- Genkin, A., Lewis, D. D., & Madigan, D. (2007). Large-scale Bayesian logistic regression for text categorization. *Technometrics*, 49(3), 291-304. doi: 10.1198/0040170070000000245
- Ghojogh, B., & Ghodsi, A. (2024). Reinforcement Learning: Tutorial and Survey. doi: 10.31219/osf.io/s98ex
- Gitto, S., Cuocolo, R., Huisman, M., Messina, C., Albano, D., Omoumi, P., ... & Sconfienza, L. M. (2024). CT and MRI radiomics of bone and soft-tissue sarcomas: an updated systematic review of reproducibility and validation strategies. *Insights into Imaging*, 15(1), 54. Url: <https://insightsimaging.springeropen.com/articles/10.1186/s13244-024-01614-x>
- Gitto, S., Cuocolo, R., Annovazzi, A., Anelli, V., Acquasanta, M., Cincotta, A., Albano, D., Chianca, V., Ferraresi, V., Messina, C., Zoccali, C., Armiraglio, E., Parafioriti, A., Sciuto, R., Luzzati, A., Biagini, R., Imbriaco, M., & Sconfienza, L. M. (2021).

- CT radiomics-based machine learning classification of atypical cartilaginous tumours and appendicular chondrosarcomas. *EBioMedicine*, 68, 103407. doi: 10.1016/j.ebiom.2021.103407
- Gough, C. (2019, March 14). Global Esports market revenue by segment 2019. Url: <https://www.statista.com/statistics/490358/Esports-revenue-worldwide-by-segment/>
- Graham, B.A. (2017). Esports to be a medal event at 2022 Asian Games. *The Guardian*. Url: <https://www.theguardian.com/sport/2017/apr/18/Esports-to-be-medal-sport-at-2022-asian-games>
- Graham, L.T. and Gosling, S.D. (2013). Personality Profiles Associated with Different Motivations for Playing World of Warcraft. *Cyberpsychology, Behavior, and Social Networking*, 16(3), pp. 189–193. doi: 10.1089/cyber.2012.0090
- Granhölm, V., Noble, W. S., & Käll, L. (2012). A cross-validation scheme for machine learning algorithms in shotgun proteomics. *BMC bioinformatics*, 13 Suppl 16(Suppl 16), S3. doi: 10.1186/1471-2105-13-S16-S3
- Gu, F., Luo, X., Zhang, Y., Chen, Y., Luo, R., & Lytton, R. L. (2017). Prediction of geogrid-reinforced flexible pavement performance using artificial neural network approach. *Road Materials and Pavement Design*, 19(5), 1147–1163. doi: 10.1080/14680629.2017.1302357
- Guan, S., & Fu, N. (2022). Class imbalance learning with Bayesian optimization applied in drug discovery. *Scientific reports*, 12(1), 2069. doi: 10.1038/s41598-022-05717-7
- Gulsun, B., & Aydin, M. R. (2024). Optimizing the extreme gradient boosting algorithm through the use of metaheuristic algorithms in sales forecasting. doi: 10.21203/rs.3.rs-4515150/v1
- Hamari, J., & Sjöblom, M. (2017). What is Esports and why do people watch it?. *Internet research*, 27(2), 211-232. Url: <https://www.emerald.com/insight/content/doi/10.1108/intr-04-2016-0085/full/html>
- He, Y. (2022). Machine Learning Methods for Credit Card Fraud Detection. *Highlights in Science, Engineering and Technology*, 23, 106-110. doi: 10.54097/hset.v23i.3204
- Hemphill, D. (2005). Cybersport. *Journal of the Philosophy of Sport*, 32(2), 195-207. doi: <https://doi.org/10.1080/00948705.2005.9714682>
- Hilbe, J. M. (2016). Practical guide to logistic regression. Boca Raton, USA: CRC Press, Taylor & Francis Group. Doi: <https://doi.org/10.1201/b18678>
- Hilvert-Bruce, Z., Neill, J. T., Sjöblom, M., & Hamari, J. (2018). Social motivations of live-streaming viewer engagement on Twitch. *Computers in Human Behavior*, 84, 58-67. doi: <https://doi.org/10.1016/j.chb.2018.02.013>

- Himmelstein, D., Liu, Y., & Shapiro, J. L. (2020). An exploration of mental skills among competitive league of legend players. *Research Anthology on Rehabilitation Practices and Therapy*, 1607-1629. doi: 10.4018/978-1-7998-3432-8.ch081
- Hirano, Y., Kondo, Y., Sueyoshi, K., Okamoto, K., & Tanaka, H. (2021). Early outcome prediction for out-of-hospital cardiac arrest with initial shockable rhythm using machine learning models. *Resuscitation*, 158, 49-56. Doi: 10.1016/j.resuscitation.2020.11.020
- 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. Url: <https://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=8906016>
- Honda, S., Imura, Y., Sasaki, K., & Takeda, R. (2022). Adaptive Vibration Control of Smart Structure Using Deep Reinforcement Learning. *EPI International Journal of Engineering*, 5(2), 92-97. doi: <https://doi.org/10.25042/epi-ije.082022.03>
- Hong, S., Chen, Y., Lin, Y., Xie, X., Chen, G., Xie, H., & Lu, W. (2024). Personalized prediction of diabetic foot ulcer recurrence in elderly individuals using machine learning paradigms. *Technology and Health Care*, 32(1), 265-276. Doi: 10.3233/THC-248023
- Hua, Y.-T., Liu, K.-Y., Huang, H.-C., Rotherham, I. D., & Ma, S.-C. (2023). Testing Variation in Esports Spectators' Motivations in Relation to Consumption Behaviour. *Sustainability*, 15(3), 2028. doi: 10.3390/su15032028
- Irie, F., Matsumoto, K., Matsuo, R., Nohara, Y., Wakisaka, Y., Ago, T., Nakashima, N., Kitazono, T., & Kamouchi, M. (2024). Predictive Performance of Machine Learning-Based Models for Poststroke Clinical Outcomes in Comparison With Conventional Prognostic Scores: Multicenter, Hospital-Based Observational Study. *JMIR AI*, 3, e46840. doi: 10.2196/46840
- Jafari, N., Besharati, M. R., & Hourali, M. (2021). SELM: Software Engineering of Machine Learning Models. In *New Trends in Intelligent Software Methodologies, Tools and Techniques* (pp. 48-54). IOS Press. doi: 10.48550/arXiv.2103.11249
- Jang, W. W., Byon, K. K., Baker III, T. A., & Tsuji, Y. (2021). Mediating effect of Esports content live streaming in the relationship between Esports recreational gameplay and Esports event broadcast. *Sport, Business and Management: An International Journal*, 11(1), 89-108. doi: 10.1108/SBM-10-2019-0087
- Jang, W. W., Kim, K. A., & Byon, K. K. (2020). Social atmospherics, affective response, and behavioral intention associated with Esports events. *Frontiers in Psychology*, 11, 1671. doi: <https://doi.org/10.3389/fpsyg.2020.01671>
- Jang, W., Byon, K. K., & Song, H. (2021). Effect of prior gameplay experience on the relationships between Esports gameplay intention and live Esports streaming content. *Sustainability*, 13(14), 8019. doi: <https://doi.org/10.3390/su13148019>
- Jang, W., Choi, W., Kim, M. J., Song, H., & Byon, K. K. (2024). What makes Esports consumers watch streamers' Esports live-streaming contents? Extending the theory of planned behavior. *International Journal of Sports Marketing and Sponsorship*, 25(2), 288-309. doi: 10.1108/IJSMS-07-2023-0132

- Jarrett, J. (2021). Gaming the gift: The affective economy of League of Legends ‘fair’ free-to-play model. *Journal of Consumer Culture*, 21(1), 102-119. doi: <https://doi.org/10.1177/1469540521993932>
- Jeng, S.-P. and Teng, C.-I. 2008. Personality and motivations for playing online games. *Social Behavior and Personality: an international journal*, 36(8), pp. 1053–1060. doi: <https://doi.org/10.2224/sbp.2008.36.8.1053>
- Jenny, S. E., Manning, R. D., Keiper, M. C., & Olrich, T. W. (2017). Virtual(ly) athletes: where Esports fit within the definition of “Sport”. *Quest*, 69(1), 1-18. Doi: <https://doi.org/10.1080/00336297.2016.1144517>
- Jin, D. (2010). Esports and television business in the digital economy. *Korea’s online gaming empire*, 59-79. Doi: <https://doi.org/10.7551/mitpress/9780262014762.003.0004>
- Jin, Q., Fan, X., Liu, J., Xue, Z., & Jian, H. (2020). Estimating Tropical Cyclone Intensity in the South China Sea Using the XGBoost Model and FengYun Satellite Images. *Atmosphere*, 11(4), 423. doi: 10.3390/atmos11040423
- Johansson, F. & Wikström, J. (2015). Result prediction by mining replays in dota 2. (Yayımlanmamış yüksek lisans tezi). Blekinge Institute of Technology, Sweden. Url: <https://www.diva-portal.org/smash/get/diva2:829556/fulltext01.pdf>
- Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science* (New York, N.Y.), 349(6245), 255–260. doi: 10.1126/science.aaa8415
- Jordan-Vallverdú, V., Plaza-Navas, M. A., Raya, J. M., & Torres-Pruñonosa, J. (2024). The Intellectual Structure of Esports Research. *Entertainment Computing*, 49, 100628. doi: <https://doi.org/10.1016/j.entcom.2023.100628>
- Jules Tygiel, (2000). *Past Time: Baseball as History* (New York, NY: Oxford University Press) doi: 10.2307/2700910
- Kahn, S., Shen, C., Lu, L., Ratan, R., Coary, S., Hou, J., Meng, J., Osborn, J & Williams, D. 2015. The Trojan Player Typology: A cross-genre, cross-cultural, behaviorally validated scale of video game play motivations. *Computers in Human Behavior*, 49, pp. 354-361. doi: <https://doi.org/10.1016/j.chb.2015.03.018>
- Kamal, A. A., Mansor, M. A., Truna, L., Shaipullah, N. M., & Sultan, N. H. H. (2025). Machine Learning Applications in Multiplayer Online Battle Arena Esports--A Systematic Review. *Pertanika Journal of Science & Technology*, 33(2). Url: [http://www.pertanika.upm.edu.my/resources/files/Pertanika%20PAPERS/JST%20Vol.%2033%20\(2\)%20Mar.%202025/11%20JST-5128-2024.pdf](http://www.pertanika.upm.edu.my/resources/files/Pertanika%20PAPERS/JST%20Vol.%2033%20(2)%20Mar.%202025/11%20JST-5128-2024.pdf)
- Kartal, M. (2023). Accessibility Technologies in Esports and Their Impact on Quality of Life in People with Physical Disabilities. *International Journal of Disabilities Sports and Health Sciences*, 6(Special Issue 1- Healthy Life, Sports for Disabled people), 464-474. doi: 10.33438/ijdsbs.1355037
- Keiper, M. C., Manning, R. D., Jenny, S., Olrich, T., & Croft, C. (2017). No reason to LoL at LoL: the addition of Esports to intercollegiate athletic departments. *Journal for the Study of Sports and Athletes in Education*, 11(2), 143–160. doi: 10.1080/19357397.2017.1316001

- Khiari, J., & Olaverri-Monreal, C. (2020). Boosting Algorithms for Delivery Time Prediction in Transportation Logistics. 2020 International Conference on Data Mining Workshops (ICDMW), 251-258. Doi: 10.1109/ICDMW51313.2020.00043
- Kho, L. C., Kasihmuddin, M. S. M., Mansor, M., & Sathasivam, S. (2020). Logic Mining in League of Legends. *Pertanika Journal of Science & Technology*, 28(1). Url: [http://www.pertanika.upm.edu.my/resources/files/Pertanika%20PAPERS/JST%20Vol.%2028%20\(1\)%20Jan.%202020/12%20JST-1649-2019.pdf](http://www.pertanika.upm.edu.my/resources/files/Pertanika%20PAPERS/JST%20Vol.%2028%20(1)%20Jan.%202020/12%20JST-1649-2019.pdf)
- Kim, D. H., Lee, C., & Chung, K. S. (2020, August). A confidence-calibrated moba game winner predictor. In 2020 IEEE Conference on Games (CoG), 622-625. IEEE. doi: 10.48550/arXiv.2006.15521
- Kim, M., & Kim, H. (2024). A Dynamic Analysis Data Preprocessing Technique for Malicious Code Detection with TF-IDF and Sliding Windows. *Electronics*, 13(5), 963. doi: 10.3390/electronics13050963
- Kim, S. G., Jung, J. Y., & Sim, M. K. (2019). A two-step approach to solar power generation prediction based on weather data using machine learning. *Sustainability (Switzerland)*, 11(5), Article 1501. doi: 10.3390/SU11051501
- Kim, S. H., & Thomas, M. K. (2015). A stage theory model of professional video game players in South Korea: The socio-cultural dimensions of the development of expertise. *Asian Journal of Information Technology*, 14(5), 176–186. Doi: 10.3923/ajit.2015.176-186
- Kim, Y. J., Engel, D., Woolley, A. W., Lin, J. Y. T., McArthur, N., & Malone, T. W. (2017). What makes a strong team? Using collective intelligence to predict team performance in League of Legends. In *Proceedings of the 2017 ACM conference on computer supported cooperative work and social computing*, 2316-2329. doi: <https://doi.org/10.1145/2998181.2998185>
- Kollongei, N., & Onyango, F. (2024). Motor Insurance Claim Frequency Prediction Using XGBoost. *Asian Journal of Probability and Statistics*, 26(10), 155–170. doi: 10.9734/ajpas/2024/v26i10665
- Kuittinen, J., Kultima, A., Niemelä, J. and Paavilainen, J. (2007). Casual Games Discussion. *Future Play '07: Proceedings of the 2007 conference on Future Play*. New York: Association for Computing Machinery, 105–112. doi: <https://doi.org/10.1145/1328202.132822>
- Kulkarni, V. Y., & Sinha, P. K. (2012). Pruning of random forest classifiers: A survey and future directions. In 2012 International Conference on Data Science & Engineering (ICDSE), 64-68. IEEE. doi: 10.1109/ICDSE.2012.6282329
- Kuzmenko, O. V., Hrytsenko, K. H., Yarovenko, H. M., Kushnerov, O. S., & Hrytsenko, A. K. (2021). Predictive modeling of the outcomes of cyber sport matches using Data Mining technologies. Url: <https://essuir.sumdu.edu.ua/handle/123456789/88617>

- Larriva-Novo, X., Vega-Barbas, M., Villagr , V. A., Rivera, D.,  lvarez-Campana, M., & Berrocal, J. (2020). Efficient Distributed Preprocessing Model for Machine Learning-Based Anomaly Detection over Large-Scale Cybersecurity Datasets. *Applied Sciences*, 10(10), 3430. doi: 10.3390/app10103430
- Larriva-Novo, X., Villagr , V. A., Vega-Barbas, M., Rivera, D., & Sanz Rodrigo, M. (2021). An IoT-Focused Intrusion Detection System Approach Based on Preprocessing Characterization for Cybersecurity Datasets. *Sensors (Basel, Switzerland)*, 21(2), 656. doi: 10.3390/s21020656
- Last, M., Maimon, O., & Minkov, E. (2002). Improving stability of decision trees. *International journal of pattern recognition and artificial intelligence*, 16(02), 145-159. Doi: <https://doi.org/10.1142/S0218001402001599>
- Lazzaro, N. (2004, March). Why we play games: Four keys to more emotion without story. In *Game Developers Conference*, 8(14). Url: https://gamemodworkshop.com/readings/xeodesign_whyweplaygames.pdf
- Leathart, T., & Polaczuk, M. (2020). Temporal probability calibration. *arXiv preprint arXiv:2002.02644*. doi: <https://doi.org/10.48550/arXiv.2002.02644>
- Lebedev, A. V., Westman, E., Van Westen, G. J. P., Kramberger, M. G., Lundervold, A., Aarsland, D., ... & AddNeuroMed consortium. (2014). Random Forest ensembles for detection and prediction of Alzheimer's disease with a good between-cohort robustness. *NeuroImage: Clinical*, 6, 115-125. doi: 10.1016/j.nicl.2014.08.023.
- Lee, D., & Schoenstedt, L. J. 2011. Comparison of Esports and traditional sports consumption motives. *The ICHPER-SD Journal of Research in Health, Physical Education, Recreation, Sport & Dance*, 6(2), 39-44. Url: <https://eric.ed.gov/?id=EJ954495>
- Lee, D., Cheon, W-K., Judge, L. W., Shin, H-B., & Kim, K-O. 2010. Motives and marketing stimuli affecting Esports consumption: A cross cultural comparison. Manuscript submitted for publication. Url: https://www.researchgate.net/publication/349252947_Motivation_for_playing_Esports-_Atela_Ghaura
- Li, Q., Xie, W., Li, L., Wang, L., You, Q., Chen, L., Li, J., Ke, Y., Fang, J., Liu, L., & Hong, H. (2021). Development and Validation of a Prediction Model for Elevated Arterial Stiffness in Chinese Patients With Diabetes Using Machine Learning. *Frontiers in physiology*, 12, 714195. doi: 10.3389/fphys.2021.714195
- Li, Y. (2024). Research on the Operation and Communication Strategies of League of Legends IP - A Case Study on the Launch of League of Legends: Wild Rift (China Server). *Transactions on Social Science, Education and Humanities Research*, 11, 399-405. doi: <https://doi.org/10.62051/vgvc3t90>
- Li, Y., & Chen, W. (2020). A Comparative Performance Assessment of Ensemble Learning for Credit Scoring. *Mathematics*, 8(10), 1756. doi: 10.3390/math8101756
- Liang, Y., Liu, C., Luan, X. Z., Leung, K. S., Chan, T. M., Xu, Z. B., & Zhang, H. (2013). Sparse logistic regression with a L 1/2 penalty for gene selection in cancer

- classification. *BMC bioinformatics*, 14, 1-12. Url: <https://pmc.ncbi.nlm.nih.gov/articles/PMC3718705/>
- Limelight Networks. (2017). The state of online video 2017. Tempe, AZ: Author. Url: <https://www.limelight.com/resources/white-paper/state-of-online-video-2017>
- Liu, Q., Zhu, W., & Ma, Z. (2022). Multi-task support vector machine with generalized huber loss. doi: 10.21203/rs.3.rs-2286985/v1
- Liu, Y., Du, W., Guo, Y., Tian, Z., & Shen, W. (2023). Identification of high-risk factors for recurrence of colon cancer following complete mesocolic excision: An 8-year retrospective study. *PLoS One*, 18(8), e0289621. doi: 10.1371/journal.pone.0289621
- Liu, Z., Lv, X., Liu, K., & Shi, S. (2010, March). Study on SVM compared with the other text classification methods. In 2010 Second international workshop on education technology and computer science, 1, 219-222. IEEE. doi: 10.1109/ETCS.2010.248
- Liu, Z., Zhu, G., Jiang, X., Zhao, Y., Zeng, H., Jing, J., & Ma, X. (2020). Survival Prediction in Gallbladder Cancer Using CT Based Machine Learning. *Frontiers in oncology*, 10, 604288. doi: 10.3389/fonc.2020.604288
- Rosell Llorens, M. (2017). Esport gaming: the rise of a new sports practice. *Sport, ethics and philosophy*, 11(4), 464-476. doi: 10.1080/17511321.2017.1318947
- Lopez, C., Tucker, S., Salameh, T., & Tucker, C. (2018). An unsupervised machine learning method for discovering patient clusters based on genetic signatures. *Journal of biomedical informatics*, 85, 30-39. Doi: 10.1016/j.jbi.2018.07.004
- Lopez-Miguel, I. D. (2021). Survey on Preprocessing Techniques for Big Data Projects. *Engineering Proceedings*, 7(1), 14. doi: 10.3390/engproc2021007014
- Luo, G. (2017). Toward a progress indicator for machine learning model building and data mining algorithm execution: a position paper. *Acm Sigkdd Explorations Newsletter*, 19(2), 13-24. doi: 10.1145/3166054.3166057
- Luo, S., & Chen, T. (2020). Two derivative algorithms of gradient boosting decision tree for silicon content in blast furnace system prediction. *IEEE Access*, 8, 196112-196122. Doi: 10.1109/ACCESS.2020.3034566
- Ma, S. C., Byon, K. K., Jang, W., Ma, S. M., & Huang, T. N. (2021). Esports spectating motives and streaming consumption: Moderating effect of game genres and live-streaming types. *Sustainability*, 13(8), 4164. doi: <https://doi.org/10.3390/su13084164>
- Macey, J., & Hamari, J. (2018). Investigating relationships between video gaming, spectating Esports, and gambling. *Computers in Human Behavior*, 80, 344-353. doi: <https://doi.org/10.1016/j.chb.2017.11.027>
- Maillo, J., Luengo, J., García, S., Herrera, F., & Triguero, I. (2017). Exact fuzzy k-nearest neighbor classification for big datasets. In 2017 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE), 1-6. IEEE. doi: 10.1109/FUZZ-IEEE.2017.8015686

- Mancı, E., Güdücü, Ç., Günay, E., Güvendi, G., Campbell, M., & Bediz, C. Ş. (2024). The relationship between Esports game genres and cognitive performance: A comparison between first-person shooter vs. multiplayer online battle arena games in younger adults. *Entertainment Computing*, 50, 100640. Doi: 10.1016/j.entcom.2024.100640
- Manninen, T. (2003). Interaction forms and communicative actions in multiplayer games. *Game studies*, 3(1), 2003. Url: https://www.researchgate.net/publication/220200727_Interaction_Forms_and_Communicative_Actions_in_Multiplayer_Games
- Mao, W., Kostka, D., & Chikina, M. (2018). The perils of interaction prediction. *bioRxiv*, 435065. doi: <https://doi.org/10.1101/435065>
- Mariot, D. and Nufer, G. (2020), “Die Besonderheiten von PR in Esports [Specifics of PR in Esports]”, *NACHSPIELZEIT die Schriftenreihe des Deutschen Instituts für Sportmarketing* € , Vol. 2020, p.1 Url: <https://publikationen.uni-tuebingen.de/xmlui/bitstream/handle/10900/96384/NACHSPIELZEIT%20-%202020-1.pdf?sequence=1/1000>
- Markowska, M. (2017). Brief review of logit models applications in regional studies. *Prace Naukowe Uniwersytetu Ekonomicznego We Wrocławiu*, 476. Doi: 10.15611/pn.2017.476.01
- Marlisa, H., Satyahadewi, N., Imro'ah, N., & Debataraja, N. N. (2024). Application of ADASYN Oversampling Technique on K-Nearest Neighbor Algorithm. *BAREKENG: Jurnal Ilmu Matematika dan Terapan*, 18(3), 1829-1838. doi: <https://doi.org/10.30598/barekengvol18iss3pp1829-1838>
- Martončík, M. (2015). e-Sports: Playing just for fun or playing to satisfy life goals?. *Computers in human behavior*, 48, 208-211. Doi: 10.1016/j.chb.2015.01.056
- Matsubara, K., Takahashi, K., Matsuda, T., Ueki, Y., Seko, N., & Kakuchi, R. (2023). Building Machine Learning Models for Reactivity Prediction in Radiation-Induced Graft Polymerization Using Interpretable Parameters. doi: 10.26434/chemrxiv-2023-9g0fr
- Meeuwssen, S., & Kreft, L. (2023). Sport and politics in the twenty-first century. *Sport, Ethics and Philosophy*, 17(3), 342-355. Doi: <https://doi.org/10.1080/17511321.2022.2152480>
- Melentev, N., Somov, A., Burnaev, E., Strelnikova, I., Strelnikova, G., Melenteva, E., & Menshchikov, A. (2020). Esports players professional level and tiredness prediction using EEG and machine learning. In *2020 IEEE SENSORS*, 1-4. IEEE. doi: 10.1109/SENSORS47125.2020.9278704
- Mienye, I.D., & Sun, Y. (2022). A Survey of Ensemble Learning: Concepts, Algorithms, Applications, and Prospects. *IEEE Access*, 10, 99129-99149. Url: <https://ieeexplore.ieee.org/document/9893798>
- Minami, S., Koyama, H., Watanabe, K., Saijo, N., & Kashino, M. (2024). Prediction of Esports competition outcomes using EEG data from expert players. *Computers in Human Behavior*, 160, 108351. doi: <https://doi.org/10.1016/j.chb.2024.108351> Get rights and content

- Mishra, R. (2024, February). Support Vector Machines Application for Prediction Binding Elements. In 2024 IEEE International Conference on Big Data & Machine Learning (ICBDML), 265-269. IEEE. doi: 10.13052/rp-9788770040723.074
- Mnih, V., Kavukcuoglu, K., Silver, D., Rusu, A. A., Veness, J., Bellemare, M. G., ... & Hassabis, D. (2015). Human-level control through deep reinforcement learning. *Nature*, 518(7540), 529-533. Url: <https://www.nature.com/articles/nature14236>
- Monareng, K., Maphanga, R., & Ntoahae, P. (2023). Machine learning models for predicting density of sodium-ion battery materials. In MATEC Web of Conferences, 388(07009). EDP Sciences. doi: 10.1051/mateconf/202338807009
- Nascimento Jr, F. F. D., Melo, A. S. D. C., da Costa, I. B., & Marinho, L. B. (2017). Profiling Successful Team Behaviors in League of Legends. In Proceedings of the 23rd Brazilian Symposium on Multimedia and the Web, 261-268. Gramado, RS, Brazil. Doi: 10.1145/3126858.3126886
- Navarro, J. R. S., Pérez, Y. S., & Núñez, W. A. N. Meta-Analysis of the Evolution of Sports Management. (2024). *ESIC*, 8(1), 2088-2101. doi: <https://doi.org/10.70082/esiculture.vi.1618>
- Newzoo (2022). Global Esports and Live Streaming Market Report. Url: https://investgame.net/wp-content/uploads/2023/08/2022_Newzoo_Free_Global_Esports_Live_Streaming_Market_Report.pdf
- Nguyen, K. A., Chen, W., Lin, B.-S., & Seeboonruang, U. (2021). Comparison of Ensemble Machine Learning Methods for Soil Erosion Pin Measurements. *ISPRS International Journal of Geo-Information*, 10(1), 42. doi: 10.3390/ijgi10010042
- O'Connor, E. L., Longman, H., White, K. M., & Obst, P. L. (2015). Sense of community, social identity and social support among players of massively multiplayer online games (MMOGs): A qualitative analysis. *Journal of Community & Applied Social Psychology*, 25(6), 459-473. doi: <https://doi.org/10.1002/casp.2224>
- Oh, J. H., Tannenbaum, A., & Deasy, J. O. (2023). Improved prediction of drug-induced liver injury literature using natural language processing and machine learning methods. *Frontiers in genetics*, 14, 1161047. doi: 10.3389/fgene.2023.1161047
- Paramita, A. S., Maryati, I., & Tjahjono, L. M. (2022). Implementation of the K-Nearest Neighbor Algorithm for the classification of student thesis subjects. *Journal of Applied Data Sciences*, 3(3), 128-136. Url: <https://bright-journal.org/Journal/index.php/JADS/article/view/66>
- Park, J., Song, Y. and Teng, C.-I. 2011. Exploring the links between personality traits and motivations to play online games. *Cyberpsychology, Behavior, and Social Networking*, 14(12), 747–751. doi: <https://doi.org/10.1089/cyber.2010.0502>
- Pavlyshenko, B. M. (2019). Machine-learning models for sales time series forecasting. *Data*, 4(1), 15. doi: 10.3390/data4010015
- Peeken, J. C., Neumann, J., Asadpour, R., Leonhardt, Y., Moreira, J. R., Hippe, D. S., Klymenko, O., Foreman, S. C., von Schacky, C. E., Spraker, M. B., Schaub, S.

- K., Dapper, H., Knebel, C., Mayr, N. A., Woodruff, H. C., Lambin, P., Nyflot, M. J., Gersing, A. S., & Combs, S. E. (2021). Prognostic Assessment in High-Grade Soft-Tissue Sarcoma Patients: A Comparison of Semantic Image Analysis and Radiomics. *Cancers*, 13(8), 1929. doi: 10.3390/cancers13081929
- Piccialli, V., & Sciandrone, M. (2022). Nonlinear optimization and support vector machines. *Annals of Operations Research*, 314(1), 15-47. Url: <https://link.springer.com/article/10.1007/s10479-022-04655-x>
- Pizzo, A. D., Su, Y., Scholz, T., Baker, B. J., Hamari, J., & Ndanga, L. (2022). Esports scholarship review: Synthesis, contributions, and future research. *Journal of Sport Management*, 36(3), 228-239. Doi: 10.1123/jsm.2021-0228
- Pluss, M. A., Bennett, K. J. M., Novak, A. R., Panchuk, D., Coutts, A. J., & Fransen, J. (2019). Esports: The Chess of the 21st Century. *Frontiers in psychology*, 10, 156. doi: 10.3389/fpsyg.2019.00156
- Pradana, D., & Sugiharti, E. (2023). Implementation data mining with naive bayes classifier method and laplace smoothing to predict students learning results. *Recursive Journal of Informatics*, 1(1), 1-8. Url <https://pdfs.semanticscholar.org/7048/9615b1fe65986df6333637666c6ebd5cc75d.pdf>
- Prasanti, A. A., Fauzi, M. A., & Furqon, M. T. (2018). Neighbor Weighted K-Nearest Neighbor for sambat online classification. *Indonesian Journal of Electrical Engineering and Computer Science*, 12(1), 155-160. doi: <http://doi.org/10.11591/ijeecs.v12.i1.pp155-160>
- Rahman, M. S., & Yogarajah, P. (2022). Evaluating the Performance of Common Machine Learning Classifiers using various Validation Methods. In *Artificial Intelligence, Soft Computing and Applications*, 45-51. Doi: 10.5121/csit.2022.122304
- Rahman, N. F., Komaini, A., Wahyuri, A. S., Barlian, E., Muthia, R., & Zarya, F. (2023). Paradigms, Limitations, Opportunities, and Challenges of E-Sports in Indonesia. *Jurnal Pendidikan dan Pengajaran*, 56(3), 543-556. doi: <https://doi.org/10.23887/jpp.v56i3.67829>
- Raita, Y., Goto, T., Faridi, M. K., Brown, D. F. M., Camargo, C. A., Jr, & Hasegawa, K. (2019). Emergency department triage prediction of clinical outcomes using machine learning models. *Critical care (London, England)*, 23(1), 64. doi: 10.1186/s13054-019-2351-7
- Rambusch, J. (2011). *Mind Games Extended Understanding Gameplay as Situated Activity*. (Yayımlanmamış yüksek lisans tezi). Linköpings Universitet, Sweden. Url: <https://www.diva-portal.org/smash/record.jsf?pid=diva2%3A393991&dsid=4921>
- Rapaport, D. (2017). What to expect from the booming Esports industry in 2017. Url: <https://www.si.com/media/2017/02/09/Esports-industry-expectations-billion-dollar>

- Rathnayake, N., Rathnayake, U., Dang, T. L., & Hoshino, Y. (2023). Water level prediction using soft computing techniques: A case study in the Malwathu Oya, Sri Lanka. *PloS one*, 18(4), e0282847. doi: 10.1371/journal.pone.0282847
- Reitman, J. G., Anderson-Coto, M. J., Wu, M., Lee, J. S., & Steinkuehler, C. (2020). Esports research: A literature review. *Games and Culture*, 15(1), 32-50. Doi: 10.1177/1555412019840892
- Rietz, J., & Hallmann, K. (2022). A systematic review on spectator behavior in Esports: why do people watch? *International journal of sports marketing and sponsorship*, 24(1), 38-55. doi: 10.1108/IJSMS-12-2021-0241
- Riout, F., Métivier, J. P., Helleu, B., Scelles, N., & Durand, C. (2014). Mining tracks of competitive video games. *AASRI procedia*, 8, 82-87. doi: 0.1016/j.aasri.2014.08.014
- Robertson, V. H. (2021). Esports and digital ecosystems: An antitrust perspective. *Journal of European Competition Law & Practice*, 12(8), 591-592. doi: 10.1093/jeclap/lpab040
- Rosell Llorens, M. (2017). Esport gaming: the rise of a new sports practice. *Sport, ethics and philosophy*, 11(4), 464-476. doi: 10.1080/17511321.2017.1318947
- Ruseti, S., Sirbu, M. D., Calin, M. A., Dascalu, M., Trausan-Matu, S., & Militaru, G. (2020). Comprehensive exploration of game reviews extraction and opinion mining using NLP techniques. In *Fourth International Congress on Information and Communication Technology: ICICT 2019, London, 1*, 323-331. Singapore: Springer. doi: 10.1007/978-981-15-0637-6_27
- Ryu, Y., Hwang, H., Jeong, J., Jang, W., Lee, G., & Pyun, H. (2023). Missed a live match? Determinants of League of Legends Champions Korea highlights viewership. *Frontiers in Psychology*, 14, 1213600. doi: <https://doi.org/10.3389/fpsyg.2023.1213600>
- Said, M., Azli, A. A., & Sabri, S. S. (2023). Investigating the factors influencing students' Acceptance of Esports as a career choice. *Inf Manage Business Rev*, 15(2), 109-15. doi: [https://doi.org/10.22610/imbr.v15i2\(I\)SI.3425](https://doi.org/10.22610/imbr.v15i2(I)SI.3425)
- Sajjadnia, Z., Khayami, R., & Moosavi, M. R. (2020). Preprocessing breast cancer data to improve the data quality, diagnosis procedure, and medical care services. *Cancer informatics*, 19, 1176935120917955. doi: 10.1177/1176935120917955
- Santos, T., Lemmerich, F., Strohmaier, M., & Helic, D. (2019). What's in a review: Discrepancies between expert and amateur reviews of video games on metacritic. *Proceedings of the ACM on human-computer interaction*, 3(CSCW), 1-22. doi: <https://doi.org/10.1145/3359242>
- Scholz, T. M., & Barlow. (2019). *Esports is Business*, 15. Springer International Publishing. doi:10.1007/978-3-030-11199-1
- Schubert, M., Drachen, A., & Mahlmann, T. (2016). Esports Analytics Through Encounter Detection. In *Proceedings of the 10th MIT Sloan Sports Analytics Conference*. Url: <https://lucris.lub.lu.se/ws/files/5549290/8773291.pdf>

- Seo, Y. (2013). Electronic sports: A new marketing landscape of the experience economy. *Journal of marketing management*, 29(13-14), 1542-1560. Doi: 10.1080/0267257X.2013.822906
- Seo, Y., & Jung, S. (2016). Beyond solitary play in computer games: The social practices of Esports. *Journal of Consumer Culture*, 16, 635 - 655. Doi: 10.1177/1469540514553711
- Serwa, A. (2022). Development of soft computational simulator for optimized deep artificial neural networks for geomatics applications: remote sensing classification as an application. *Geodesy and Cartography*, 48(4), 224-232. doi: 10.3846/gac.2022.15642
- Setiyorini, T., & Asmono, R. T. (2019). IMPLEMENTATION OF K-NEAREST NEIGHBOR AND GINI INDEX METHOD IN CLASSIFICATION OF STUDENT PERFORMANCE: Penerapan Metode K-Nearest Neighbor Dan Gini Index Pada Klasifikasi Kinerja Siswa. *Jurnal Techno Nusa Mandiri*, 16(2), 121-126. Url: <http://ejournal.nusamandiri.ac.id/index.php/techno/article/view/747/571>
- Setyanto, A., & Sunyoto, A. (2024, June). Comparative Study SVM and Random Forest Algorithms for the Classification of Terrestrial Visual Rock Types. In *IOP Conference Series: Earth and Environmental Science*, 1357(1), 01203. IOP Publishing. Doi: 10.1088/1755-1315/1357/1/012036
- Sharma, N., Chawla, V., & Ram, N. (2020). Comparison of machine learning algorithms for the automatic programming of computer numerical control machine. *International Journal of Data and Network Science*, 4(1), 1-14. doi: 10.5267/j.ijdns.2019.9.003
- Sherry, J. L., Lucas, K., Greenberg, B. S., & Lachlan, K. (2006). Video game uses and gratifications as predictors of use and game preference, In P. Vorderer & J. Bryant (Eds), *Playing Video Games: Motives, responses, and consequences*, Mahwah, NJ: Lawrence Erlbaum Associates, Inc. Url: <https://psycnet.apa.org/record/2006-05034-015>
- Sinap, V. (2023). Makine öğrenmesi teknikleri ile counter-strike: Global offensive raunt sonuçlarının tahminlenmesi. *Journal of Intelligent Systems: Theory and Applications*, 6(2), 119-129. doi: <https://doi.org/10.38016/jista.1235031>
- Sjöblom, M., Hamari, J., Jylhä, H., Macey, J., & Törhönen, M. (2019). Esports: Final Report. Tampere University. Url: <https://webpages.tuni.fi/gamification/2019/01/24/Esports-final-report/>
- Skubida, D. (2016). Can some computer games be a sport?: Issues with legitimization of Esport as a sporting activity. *International Journal of Gaming and Computer-Mediated Simulations (IJGCMS)*, 8(4), 38-52. doi: 10.4018/IJGCMS.2016100103
- Smed, J., Kaukoranta, T., & Hakonen, H. (2002). Aspects of networking in multiplayer computer games. *The Electronic Library*, 20(2), 87-97. Url: https://www.researchgate.net/publication/269251176_Aspects_of_Networking_in_Multiplayer_Computer_Games

- Smerdov, A., Burnaev, E.V., & Somov, A. (2019). Esports Pro-Players Behavior During the Game Events: Statistical Analysis of Data Obtained Using the Smart Chair. 2019 IEEE SmartWorld, Ubiquitous Intelligence & Computing, Advanced & Trusted Computing, Scalable Computing & Communications, Cloud & Big Data Computing, Internet of People and Smart City Innovation (SmartWorld/SCALCOM/UIC/ATC/CBDCom/IOP/SCI), 1768-1775. doi: 10.1109/SmartWorld-UIC-ATC-SCALCOM-IOP-SCI.2019.00314
- Solano, E. S., Dehghanian, P., & Affonso, C. M. (2022). Solar Radiation Forecasting Using Machine Learning and Ensemble Feature Selection. *Energies*, 15(19), 7049. doi: 10.3390/en15197049
- Subarkah, P., Damayanti, W. R., & Permana, R. A. (2022). Comparison of correlated algorithm accuracy Naive Bayes Classifier and Naive Bayes Classifier for heart failure classification, 14, 120-125. doi: 10.33096/ilkom.v14i2.1148.120-125
- SuperData. (2017). Esports courtside: Playmakers of 2017. Url: <https://www.superdataresearch.com/market-data/Esports-market-report/>
- Susaeta, H., Jimenez, F., Nussbaum, M., Gajardo, I., Andreu, J. J., & Villalta, M. (2010). From MMORPG to a classroom multiplayer presential role playing game. *Journal of Educational Technology & Society*, 13(3), 257-269. Url: <https://www.learntechlib.org/p/74910/>
- Toghani, T., & Allen, G.I. (2020). MP-Boost: Minipatch Boosting via Adaptive Feature and Observation Sampling. 2021 IEEE International Conference on Big Data and Smart Computing (BigComp), 75-78. doi: 10.1109/BigComp51126.2021.00023
- Tang, D., Sum, R. K., Li, M., Ma, R., Chung, P., & Ho, R. W. (2023). What is Esports? A systematic scoping review and concept analysis of Esports. *Heliyon*, 9(12), e23248. doi: 10.1016/j.heliyon.2023.e23248
- Taninaga, J., Nishiyama, Y., Fujibayashi, K., Gunji, T., Sasabe, N., Iijima, K., & Naito, T. (2019). Prediction of future gastric cancer risk using a machine learning algorithm and comprehensive medical check-up data: A case-control study. *Scientific reports*, 9(1), 12384. doi: 10.1038/s41598-019-48769-y
- Taşdemir, F. (2022). ROC analizi ve R yazılımı ile verilerin sınıflama doğruluklarının karşılaştırılması. *Ulusal Eğitim Akademisi Dergisi*, 6(2), 230-241. doi: <https://doi.org/10.32960/uead.1166987>
- Taylor, T. L. (2012). *Raising the stakes: E-sports and the professionalization of computer gaming*. Mit Press. Doi: 10.7551/mitpress/8624.001.0001
- Tembusai, Z. R., Mawengkang, H., & Zarlis, M. (2021). K-nearest neighbor with k-fold cross validation and analytic hierarchy process on data classification. *International Journal of Advances in Data and Information Systems*, 2(1), 1-8. doi: <https://doi.org/10.25008/ijadis.v2i1.1204>
- The OGA, (1999). What the hell is it? Url: <https://www.eurogamer.net/oga>
- Thu, T. N. T., & Xuan, V. D. (2018). Supervised support vector machine in predicting foreign exchange trading. *International Journal of Intelligent Systems and Applications*, 10(9), 48. doi: <https://doi.org/10.5815/ijisa.2018.09.06>

- Tian, X., Pavur, R., Han, H., & Zhang, L. (2023). A machine learning-based human resources recruitment system for business process management: using LSA, BERT and SVM. *Business Process Management Journal*, 29(1), 202-222. Url: <https://www.econbiz.de/Record/a-machine-learning-based-human-resources-recruitment-system-for-business-process-management-using-lsa-bert-and-svm-tian-xiaoguang/10014230550>
- Tomasev, N., Radovanović, M., Mladenović, D., & Ivanović, M. (2011, October). A probabilistic approach to nearest-neighbor classification: Naive hubness bayesian knn. In *Proceedings of the 20th ACM international conference on Information and knowledge management*, 2173-2176. doi: <https://doi.org/10.1145/2063576.206391>
- Torra, V., & Navarro-Arribas, G. (2018). Probabilistic metric spaces for privacy by design machine learning algorithms: Modeling database changes. In *International Workshop on Data Privacy Management*, 422-430, Springer International Publishing. Url: https://link.springer.com/chapter/10.1007/978-3-030-00305-0_30
- Towett, E. K., Drake, L. B., Acquah, G. E., Haefele, S. M., McGrath, S. P., & Shepherd, K. D. (2020). Comprehensive nutrient analysis in agricultural organic amendments through non-destructive assays using machine learning. *PloS one*, 15(12), e0242821. doi: 10.1371/journal.pone.0242821
- Uğuz, S. (2019). *Makine öğrenmesi teorik yönleri ve Python uygulamaları ile bir yapay zekâ ekolü*. Ankara: Nobel Yayıncılık.
- van Os, H. J. A., Ramos, L. A., Hilbert, A., van Leeuwen, M., van Walderveen, M. A. A., Kruijt, N. D., Dippel, D. W. J., Steyerberg, E. W., van der Schaaf, I. C., Lingsma, H. F., Schonewille, W. J., Majoie, C. B. L. M., Olabarriaga, S. D., Zwinderman, K. H., Venema, E., Marquering, H. A., Wermer, M. J. H., & MR CLEAN Registry Investigators (2018). Predicting outcome of endovascular treatment for acute ischemic stroke: potential value of machine learning algorithms. *Frontiers in neurology*, 9, 784. doi:10.3389/fneur.2018.00784
- Varshney, K. R., & Alemzadeh, H. (2017). On the safety of machine learning: Cyber-physical systems, decision sciences, and data products. *Big data*, 5(3), 246-255. doi: <https://doi.org/10.48550/arXiv.1610.01256>
- Vassallo, D., Vella, V., & Ellul, J. (2021). Application of gradient boosting algorithms for anti-money laundering in cryptocurrencies. *SN Computer Science*, 2(3), 143. doi: 10.1007/s42979-021-00558-z
- Vera, J. A. C., Terrón, J. M. A., & García, S. G. (2018). Following the Trail of Esports. *International Journal of Gaming and Computer-Mediated Simulations*, 10(4), 42–61. doi: 10.4018/ijgcms.2018100103
- Vorderer, P. (2000). Interactive entertainment and beyond. In D. Zillman & P. Vorderer (Eds.), *Media entertainment: The psychology of its appeal*, 21–36. Url: <https://psycnet.apa.org/record/2000-07809-002>
- Wagner, M. G. (2006). On the Scientific Relevance of Esports. In *International conference on internet computing*, 437-442. Url:

https://www.researchgate.net/publication/220968200_On_the_Scientific_Relevance_of_Esports

- Wang, L., Wang, X., Chen, A., Jin, X., & Che, H. (2020). Prediction of Type 2 Diabetes Risk and Its Effect Evaluation Based on the XGBoost Model. *Healthcare*, 8(3), 247. doi: 10.3390/healthcare8030247
- Wang, W. (2016). Predicting multiplayer online battle arena (MOBA) game outcome based on hero draft data. (Yayımlanmamış doktora tezi). National College of Ireland, Dublin. Url: <https://norma.ncirl.ie/2523/1/weiqiwang.pdf>
- Wang, Y., & Xu, Z. (2020). Monitoring of PM2. 5 concentrations by learning from multi-weather sensors. *Sensors*, 20(21), 6086. doi: <https://doi.org/10.3390/s20216086>
- Wattanaburanon, A., & Propoon, N. (2016, June). Method for classifying usability qualities and problems for action games from user reviews using text mining. In 2016 IEEE/ACIS 15th International Conference on Computer and Information Science (ICIS), 1-6. IEEE. doi: 10.1109/ICIS.2016.7550748
- Weiss, T., & Schiele, S. 2013. Virtual worlds in competitive contexts: Analyzing Esports consumer needs. *Electronic markets*, 23(4), 307-316. Doi: 10.1007/s12525-013-0127-5
- Wellner, B., Grand, J., Canzone, E., Coarr, M., Brady, P. W., Simmons, J., Kirkendall, E., Dean, N., Kleinman, M., & Sylvester, P. (2017). Predicting Unplanned Transfers to the Intensive Care Unit: A Machine Learning Approach Leveraging Diverse Clinical Elements. *JMIR medical informatics*, 5(4), e45. doi: 10.2196/medinform.8680
- Westreich, D., Lessler, J., & Funk, M. J. (2010). Propensity score estimation: neural networks, support vector machines, decision trees (CART), and meta-classifiers as alternatives to logistic regression. *Journal of clinical epidemiology*, 63(8), 826–833. doi: 10.1016/j.jclinepi.2009.11.020
- Whysall, P. (2014). Reflections on ethics, sport and the consequences of professionalisation. *Business Ethics: A European Review*, 23(4), 416-429. doi: <https://doi.org/10.1111/beer.12059>
- Wibawa, A. P., Kurniawan, A. C., Della Murbarani Prawidya Murti, Adiperkasa, R. P., Putra, S. M., Kurniawan, S. A., & Nugraha, Y. R. (2019). Naïve Bayes Classifier for Journal Quartile Classification. *Int. J. Recent Contributions Eng. Sci. IT*, 7(2), 91-99. doi: <https://doi.org/10.3991/ijes.v7i2.10659>
- Wickramasinghe, I., & Kalutarage, H. (2021). Naive Bayes: applications, variations and vulnerabilities: a review of literature with code snippets for implementation. *Soft Computing*, 25(3), 2277-2293. doi: <https://doi.org/10.1007/s00500-020-05297-6>
- Wohn, D. Y., & Freeman, G. (2020). Live streaming, playing, and money spending behaviors in Esports. *Games and Culture*, 15(1), 73-88. Url: <https://guof.people.clemson.edu/papers/gac20.pdf>
- Wolf, Mark J.P. (2012). *Encyclopedia of Video Games: The Culture, Technology, and Art of Gaming*. Santa Barbara, CA: Greenwood. doi: <https://doi.org/10.5860/RUSQ.52N4.353A>

- Wu, D., Jennings, C., Terpenney, J., Kumara, S., & Gao, R. X. (2018). Cloud-based parallel machine learning for tool wear prediction. *Journal of manufacturing science and engineering*, 140(4), 041005. Doi: <https://doi.org/10.1115/1.4038002>
- Wu, Q., Wu, B., Hu, C., & Yan, X. (2021). Evolutionary Multilabel Classification Algorithm Based on Cultural Algorithm. *Symmetry*, 13(2), 322. doi: 10.3390/sym13020322
- Wu, W., & Zhou, Z. (2021). A Comprehensive Way to Access Hospital Death Prediction Model for Acute Mesenteric Ischemia: A Combination of Traditional Statistics and Machine Learning. *International journal of general medicine*, 14, 591–602. doi: 10.2147/IJGM.S300492
- Xenopoulos, P. (2023). *Data Mining for Esports*. (Yayımlanmamış doktora tezi). New York University Tandon School of Engineering. Url: <https://www.proquest.com/openview/ef55ec79239a69d7bd94bdd82a8040c0/1?pq-origsite=gscholar&cbl=18750&diss=y>
- Xenopoulos, P., Doraiswamy, H., & Silva, C. (2020, December). Valuing player actions in counter-strike: Global offensive. In 2020 IEEE international conference on big data, 1283-1292. IEEE. doi: <https://doi.org/10.48550/arXiv.2011.01324>
- Xiaokang, D., Lei, Y., Jianping, Y., & Zhaozhong, Z. (2016). Optimization and analysis on Fuzzy SVM for targets classification in forest. *The Open Cybernetics & Systemics Journal*, 10(1), 155-162. doi: 10.2174/1874110X01610010155
- Xu, Y., Zhang, H., Xia, F., & Qian, H. (2024). Turning Viewers Into Consumers and Tourists: Uncovering the Multifaceted Engagement and Purchase Intentions of Esports Viewers Through Telepresence and Immersion. *International Journal of Tourism Research*, 26(6), e2803. Doi: <https://doi.org/10.1002/jtr.2803>
- Yan, D., Chi, G., & Lai, K. K. (2020). Financial Distress Prediction and Feature Selection in Multiple Periods by Lassoing Unconstrained Distributed Lag Non-linear Models. *Mathematics*, 8(8), 1275. doi: 10.3390/math8081275
- Yang, P., Harrison, B. E., & Roberts, D. L. (2014). Identifying patterns in combat that are predictive of success in MOBA games. In 9th International Conference on the Foundations of Digital Games, 1-8. Caribbean: Liberty of the Seas. Url: https://www.researchgate.net/publication/264934898_Identifying_Patterns_in_Combat_that_are_Predictive_of_Success_in_MOBA_Games
- Yang, Y., Qin, T., & Lei, Y. (2016). Real-time Esports Match Result Prediction. *ArXiv*, abs/1701.03162. doi: <https://doi.org/10.48550/arXiv.1701.03162>
- Yang, Z., Pan, Z., Wang, Y., Cai, D., Shi, S., Huang, S. L., ... & Liu, X. (2022). Interpretable real-time win prediction for honor of kings—a popular mobile MOBA Esport. *IEEE Transactions on Games*, 14(4), 589-597. Doi: <https://doi.org/10.48550/arXiv.2008.06313>
- Ye, Y., Xiong, Y., Zhou, Q., Wu, J., Li, X., & Xiao, X. (2020). Comparison of machine learning methods and conventional logistic regressions for predicting gestational diabetes using routine clinical data: a retrospective cohort study. *Journal of diabetes research*, 2020(1), 4168340. Doi: 10.1155/2020/4168340

- Yee, N. 2006. Motivations for Play in Online Games. *CyberPsychology & Behavior*, 9(6), 772–775. doi: 10.1089/cpb.2006.9.772
- Yuan, J., Li, H., Ding, S., & Cao, L. (2010, April). Intrusion detection model based on improved support vector machine. In 2010 Third International Symposium on Intelligent Information Technology and Security Informatics, 465-469. IEEE. doi: 10.1109/ICACTE.2008.132
- Yuzyk, M., & Seidner, P. (2022). E-sports competitions. In *Developments in Information & Knowledge Management for Business Applications*, 5, 671-716. Springer International Publishing. Url: <https://ojs.acad-pub.com/index.php/BMT/article/view/3019>
- Zhang, T., Zhu, L., Wang, X., Zhang, X., Wang, Z., Xu, S., & Jiao, W. (2024). Machine learning models to predict systemic inflammatory response syndrome after percutaneous nephrolithotomy. *BMC urology*, 24(1), 140. Url: <https://bmcurol.biomedcentral.com/articles/10.1186/s12894-024-01529-1>
- Zheng, T., Ye, W., Wang, X., Li, X., Zhang, J., Little, J., Zhou, L., & Zhang, L. (2019). A simple model to predict risk of gestational diabetes mellitus from 8 to 20 weeks of gestation in Chinese women. *BMC pregnancy and childbirth*, 19(1), 252. doi: 10.1186/s12884-019-2374-8
- Zhu, J. (2024). The Effect of Hyperparameters on the Model Convergence Rate of Cliff Walking Problem Based on Q-Learning. *Applied and Computational Engineering*, 110, 6-12. doi: <https://doi.org/10.54254/2755-2721/110/2024MELB0061>
- Zimmermann, A. (2008, October). Ensemble-trees: Leveraging ensemble power inside decision trees. In *International conference on discovery science*, 76-87. Berlin: Springer Berlin Heidelberg. Doi: 10.1007/978-3-540-88411-8_10

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı-Soyadı:

Tolga KOŞAR

EĞİTİM BİLGİLERİ

09. 2005 – 06.2009

Edirne Yıldırım Beyazıt Anadolu Lisesi

Fen Bilimleri

09. 2012 – 07.2018

Marmara Üniversitesi/Lisans

İngilizce İşletme

Muhasebe Finans

09. 2020 – 07.2022

Anadolu Üniversitesi/Açık Öğretim

Web Tasarım ve Kodlama

09. 2022 –

Trakya Üniversitesi/Yüksek Lisans

Veri Bilimi ve Analitiği