

İngiltere Premier Ligi Maç Sonucu Tahmininde İki Aşamalı Bir Modelleme Yaklaşımı

Alinaz Aksu¹ , Hakan Yıldırım² , Hayri Sever² 

¹Çankaya Üniversitesi, Lisansüstü Eğitim Enstitüsü, Veri Analitiği Anabilim Dalı, Ankara, Türkiye

²Çankaya Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Ankara, Türkiye

Geliş Tarihi / Received Date: 29.04.2026

Kabul Tarihi / Accepted Date: 30.06.2026

Öz

Futbol maç sonucu tahmini, oyunun düşük skorlu yapısı, yüksek rastlantısallık içermesi ve sınıf dağılımlarının dengesiz olması nedeniyle spor analitiği alanındaki en zor problemlerden biri olarak kabul edilmektedir. Literatürde bu problem çoğunlukla ev sahibi galibiyeti, beraberlik ve deplasman galibiyeti olmak üzere üç sınıflı bir sınıflandırma problemi olarak ele alınmaktadır. Ancak bu yaklaşım, özellikle beraberlik sınıfının düşük ayırt edilebilirliği ve sınıf dengesizliği nedeniyle model performansını ve karar güvenilirliğini sınırlamaktadır. Bu çalışmada, futbol maç sonucu tahmin problemi İngiltere Premier Ligi (EPL) verileri üzerinde yeniden yapılandırılmakta ve iki aşamalı bir ikili sınıflandırma mimarisi önerilmektedir. Önerilen yaklaşımda ilk aşamada bir karşılaşmanın berabere sonuçlanıp sonuçlanmayacağı tahmin edilmekte, ikinci aşamada ise ev sahibi veya deplasman galibiyeti belirlenmektedir. Bu yapı, beraberliği bağımsız bir karar problemi olarak ele alarak sınıf dengesizliğini yapısal olarak azaltmaktadır. Çalışmada, 2012–2025 sezonları arasında oynanan İngiltere Premier Ligi maçlarına ait, yalnızca maç öncesinde erişilebilir veriler kullanılmıştır. Zaman temelli veri bölme stratejisi ile kayan pencere tabanlı ve göreceli (delta) özellikler kullanılmıştır. Logistic Regression, Support Vector Machine, Naive Bayes, Decision Tree ve LightGBM algoritmaları değerlendirilmiştir. Deneysel sonuçlar, önerilen yaklaşımın özellikle F1 skoru ve ROC–AUC metrikleri açısından daha kararlı ve yorumlanabilir sonuçlar ürettiğini göstermektedir. Bulgular, futbol maç sonucu tahmininde başarının algoritmadan ziyade problem tanımı ve modelleme stratejisinin uygunluğuna bağlı olduğunu ortaya koymaktadır.

Anahtar Kelimeler: futbol maç sonucu tahmini, ingiltere premier ligi, iki aşamalı sınıflandırma, hiyerarşik modelleme, sınıf dengesizliği

A Two-Stage Modeling Approach for Football Match Outcome Prediction in the English Premier League

Abstract

Football match outcome prediction is widely regarded as a challenging problem in sports analytics due to the low-scoring nature of the game, high inherent randomness, and imbalanced class distributions. In the existing literature, match outcomes are typically modeled as a three-class classification problem consisting of home win, draw, and away win. However, this formulation often suffers from poor discriminability of the draw class and reduced decision reliability caused by structural class imbalance. In this study, the football match outcome prediction problem is reformulated using data from the English Premier League (EPL), and a two-stage binary classification framework is proposed. In the first stage, matches are classified as draw or non-draw. In the second stage, matches predicted as non-draw are classified as home or away wins. This decomposition structurally mitigates class imbalance by treating draws as an independent decision problem. The experimental analysis is conducted using EPL match data from the 2012–2025 seasons, considering only information available prior to match kickoff. Time-aware data splitting and feature engineering based on rolling-window performance indicators and relative (delta-based) team features are applied. Logistic Regression, Support Vector Machine, Naive Bayes, Decision Tree, and LightGBM are evaluated. The results demonstrate that the proposed approach yields more stable and interpretable performance, particularly in terms of F1-score and ROC–AUC metrics. The findings highlight that, in football match outcome prediction, the definition and structuring of the problem play a more decisive role than the choice of algorithms.

Keywords: football match outcome prediction, english premier league, two-stage classification, hierarchical modeling, class imbalance

Giriş

Futbol maç sonuçlarının tahmini, ayrıntılı maç verilerinin giderek daha erişilebilir hâle gelmesi ve makine öğrenmesi yöntemlerindeki gelişmelerle birlikte spor analitiği alanında artan bir ilgi görmektedir. Bu alandaki çalışmalar yalnızca akademik araştırmalarla sınırlı kalmayıp, performans analizi, karar destek sistemleri ve bahis piyasaları gibi pratik uygulamalara da yön vermektedir. Buna karşın, futbolun düşük skorlu yapısı, yüksek rastlantısallık içermesi ve çok sayıda bağlamsal değişkenden etkilenmesi nedeniyle maç sonucu tahmini hâlen çözümü zor bir problem olarak değerlendirilmektedir (Baboota ve Kaur, 2019; Rico-González vd., 2023).

Futbol maç sonucu tahmininde karşılaşılan temel güçlüklerden biri, problemin nasıl tanımlandığıyla doğrudan ilişkilidir. Literatürdeki çalışmaların büyük bir bölümünde maç sonuçları; ev sahibi galibiyeti, beraberlik ve deplasman galibiyeti olmak üzere üç sınıflı bir sınıflandırma problemi olarak ele alınmaktadır. Ancak bu yaklaşım, özellikle beraberlik sınıfının düşük ayırt edilebilirliği ve sınıflar arasındaki dengesiz dağılım nedeniyle çeşitli yapısal sorunları beraberinde getirmektedir. Bu durum, karar sınırlarının sağlıklı biçimde öğrenilmesini güçleştirmekte ve model performansının kararsızlaşmasına yol açmaktadır (Alfredo ve Isa, 2019; Rana ve Vasudeva, 2019; Sathe vd., 2017).

Sınıf dengesizliği problemi, bu yapısal zorlukları daha da derinleştirmektedir. İngiltere Premier Ligi gibi rekabet seviyesi yüksek liglerde maç sonuçları sınıflar arasında eşit biçimde dağılmamaktadır. Bu tür veri setlerinde yalnızca genel doğruluk (accuracy) metriğine odaklanan modeller, yüzeysel olarak kabul edilebilir sonuçlar üretse dahi, özellikle beraberlik gibi belirsiz sınıflarda güvenilir tahminler sunamamaktadır. Bu durum, model çıktılarının yorumlanabilirliğini ve pratik kullanım değerini sınırlamaktadır (Baboota ve Kaur, 2019; Fischer ve Heuer, 2025; Krawczyk, 2016).

Son dönem çalışmalarda bu sorunların genellikle daha karmaşık algoritmalar, topluluk (ensemble) yöntemleri ve derin öğrenme mimarileri aracılığıyla aşılmaya çalışıldığı görülmektedir. Ancak model karmaşıklığının artırılması, her zaman yapısal problemlere çözüm üretmemekte; çoğu zaman hesaplama maliyetinin artmasına ve yorumlanabilirliğin azalmasına neden olmaktadır. Daha da önemlisi, bu yaklaşımlar futbol maç sonucu tahmin probleminin temelinde yer alan problem tanımına ilişkin sorgulamayı çoğunlukla göz ardı etmektedir (Wong vd., 2025).

Problem tanımı perspektifinden bakıldığında, futbol maç sonuçları hiyerarşik bir karar yapısı sergilemektedir. Bir karşılaşmanın berabere sonuçlanıp sonuçlanmayacağına ilişkin karar, maçın kazananının kim olacağını belirleme probleminden doğası gereği farklıdır. Bu iki kararın tek bir düz ve çok sınıflı yapı içerisinde ele alınması, veri içerisindeki bazı örüntülerin maskelenmesine ve modellerin öğrenme kapasitesinin sınırlandırılmasına yol açabilmektedir.

Bu bağlamda, bu çalışma İngiltere Premier Ligi'ni veri açısından zengin ve temsili bir örnek olarak ele almakta ve futbol maç sonucu tahmin problemini problem tanımı ekseninde yeniden değerlendirmektedir. Algoritma çeşitliliğinden ziyade modelleme stratejisine odaklanan çalışma, alternatif problem yapılandırmalarının tahmin performansı, model kararlılığı ve yorumlanabilirlik üzerindeki etkilerini incelemeyi amaçlamaktadır. Zaman temelli veri işleme yaklaşımı ve maç öncesi bilgilere dayalı özellik mühendisliği çerçevesinde yürütülen analizlerle, futbol maç sonucu tahmininde problem tanımının belirleyici rolüne dikkat çekilmektedir.

Literatürde futbol maç sonucu tahminine yönelik çalışmalar incelendiğinde, iki temel yaklaşımın öne çıktığı görülmektedir. İlk yaklaşım, maç sonuçlarını üç sınıflı bir problem olarak ele alarak doğrudan ev sahibi galibiyeti, beraberlik ve deplasman galibiyeti tahmini yapmayı amaçlayan modellerden oluşmaktadır.

Bu çalışmalar, çoğunlukla makine öğrenmesi veya Poisson tabanlı istatistiksel yöntemler kullanmakta (Baboota ve Kaur, 2019; Fischer ve Heuer, 2025; Loukas vd., 2024; Rana ve Vasudeva, 2019; Sathe vd., 2017) ancak beraberlik sınıfının düşük ayırt edilebilirliği ve sınıf dengesizliği gibi yapısal sorunları yeterince ele alamamaktadır.

Constantinou ve Fenton (2013), Avrupa futbol bahis piyasasında arbitraj fırsatları ve bahis oranlarına ilişkin sistematik yanlışlıklar bulunduğunu ortaya koymuştur.

İkinci yaklaşım ise, model karmaşıklığını artırarak bu sınırlılıkları aşmayı hedeflemekte; derin öğrenme veya hibrit mimariler aracılığıyla performans artışı sağlamaya çalışmaktadır (Chen, 2025; Wong vd., 2025).

Buna karşın, bu tür yöntemler genellikle yorumlanabilirlikten ödün vermekte ve problemin temel tanımına ilişkin sorgulamayı ikincil planda bırakmaktadır.

Bu çalışma, söz konusu iki yaklaşımın aksine, algoritma karmaşıklığına odaklanmak yerine futbol maç sonucu tahmin problemini karar yapısı açısından yeniden ele almakta ve iki aşamalı bir modelleme çerçevesi ile literatürdeki bu boşluğu hedeflemektedir.

Veri Seti ve Özellik Mühendisliği

Veri Setinin Tanıtımı

Bu çalışmada kullanılan veri seti, İngiltere Premier Ligi (English Premier League - EPL) kapsamında “<https://www.kaggle.com/datasets/panaaaaa/english-premier-league-and-championship-full-dataset/data>” seti içinden 1994-2025 sezonları arasında oynanan futbol müsabakalarına ait maç öncesi ve maç sonucu bilgilerini içermektedir.

Tablo 1. EPL Veri Değişken Türleri (1994–2025)

Değişken (Kolon)	Açıklama	Veri Tipi
Date	Maç tarihi	Date
HomeTeam	Ev sahibi takım adı	Categorical
AwayTeam	Deplasman takım adı	Categorical
FTHG	Maç sonunda ev sahibi takımın attığı goller	Integer
FTAG	Maç sonunda deplasman takımının attığı goller	Integer
FTR	Maç sonucu (H = Ev Sahibi, D = Beraberlik, A = Deplasman)	Categorical
HTHG	İlk yarı ev sahibi takımın golleri	Integer
HTAG	İlk yarı deplasman takımının golleri	Integer
HTR	İlk yarı sonucu	Categorical
Attendance	Maça gelen seyirci sayısı (varsa)	Integer/Optional
Referee	Hakem adı	Categorical
HS	Ev sahibi takımın şut sayısı	Integer
AS	Deplasman takımının şut sayısı	Integer
HST	Ev sahibinin kaleyi bulan şut sayısı	Integer
AST	Deplasmanın kaleyi bulan şut sayısı	Integer
HC	Ev sahibi takımın korner sayısı	Integer
AC	Deplasman takımının korner sayısı	Integer
HF	Ev sahibinin faul sayısı	Integer
AF	Deplasmanın faul sayısı	Integer
HY	Ev sahibinin sarı kart sayısı	Integer
AY	Deplasmanın sarı kart sayısı	Integer
HR	Ev sahibinin kırmızı kart sayısı	Integer
AR	Deplasmanın kırmızı kart sayısı	Integer

Veri seti 1994 yılından itibaren maç sonuçlarını içeriyor olsa da özellik mühendisliğinde olan değişkenlerin sağlıklı tutulmaması nedeniyle çalışma 2012-2025 verileri üzerinden yapılmıştır. Ayrıca COVID-19 pandemisi sürecinde oynanan ve olağan dışı koşullar nedeniyle futbol dinamiklerinde belirgin sapmaların gözlemlendiği sezonlar bilinçli olarak çalışma kapsamı dışında bırakılmıştır (Lee vd., 2022). Bu tercih, modelin daha tutarlı ve karşılaştırılabilir veriler üzerinde eğitilmesini amaçlamaktadır.

Tablo 2. EPL Veri İstatistikleri

	Date	FTH Goals	FTA Goals	HTH Goals	HTA Goals	H Shots	A Shots	H SOT	A SOT	H Fouls
count	11013	11.013	11.013	10.089	10.089	8.189	8.189	8.189	8.189	...
mean	NaN	1,53	1,14	0,69	0,50	13,6	10,68	6,21	4,79	...
min	NaN	0	0	0	0	0	0	0	0	...
25%	NaN	1	0	0	0	10	7	4	3	...
50%	NaN	1	1	0	0	13	10	6	4	...
75%	NaN	2	2	1	1	17	13	8	6	...
max	NaN	9	8	5	5	43	31	24	20	...
std	NaN	1,31	1,14	0,83	0,72	5,32	4,59	3,31	2,78	...

Tablo 2 incelendiğinde, veri setinin İngiltere Premier Ligi'nde gözlenen tipik maç dinamiklerini yansıttığı görülmektedir. Özellikle gol üretimi, şut sayıları ve kaleyi bulan şut istatistikleri bakımından ev sahibi takımlar lehine belirgin bir üstünlük bulunmaktadır. Bu durum, ev sahibi avantajının veri setinde de gözlemlendiğini göstermektedir.

Tablo 3. EPL Veri Seti Özeti (2012–2025)

Feature	Value
League	English Premier League
Season Range	2012–2025 (2019–2020 ve 2020–2021 hariç)
Total Matches	4180
Home Win (%)	45.7
Draw (%)	24.8
Away Win (%)	29.5
COVID-19 Seasons	Excluded
Data Type	Pre-match structured match statistics

Tablo 3 incelendiğinde, veri setinde ev sahibi galibiyetlerinin %45.7 ile en yüksek temsil oranına sahip olduğu, beraberliklerin ise %24.8 ile en düşük oranı oluşturduğu görülmektedir. Bu dağılım, klasik üç sınıflı sınıflandırma yaklaşımı açısından belirgin bir sınıf dengesizliği yapısına işaret etmektedir.

Özellikle beraberlik sınıfının hem düşük temsil oranına sahip olması hem de yapısal olarak daha yüksek belirsizlik içermesi, tek aşamalı modellerde karar sınırlarının çoğunluk sınıflara doğru kaymasına neden olabilmektedir. Bu durum, accuracy metriğinin görece kabul edilebilir görünmesine rağmen sınıf bazlı performansın dengesizleşmesine yol açmaktadır.

Bu gözlem, futbol maç sonucu tahmin probleminin iki aşamalı olarak yeniden yapılandırılmasının yalnızca metodolojik değil, aynı zamanda istatistiksel olarak da gerekçelendirilebilir olduğunu göstermektedir.

Her bir maç kaydı; karşılaşmanın oynandığı tarih, ev sahibi ve deplasman takımları ile temel maç istatistiklerini içerecek şekilde yapılandırılmıştır. Çalışmanın temel ilkelerinden biri, yalnızca maç başlamadan önce erişilebilir olan bilgilerin kullanılmasıdır. Bu doğrultuda, maç sonrası oluşan istatistikler veya dolaylı biçimde gelecek bilgisi içerebilecek değişkenler özellik setine dâhil edilmemiştir. Böylece geliştirilen modellerin teorik başarıdan ziyade, gerçek hayatta uygulanabilir tahmin üretme kapasitesine odaklanması hedeflenmiştir.

Tablo 4. EPL Veri Seti Ön İşleme ve Özellik Mühendisliği Sonrası (2012–2025)

	hometeam_last_5_matches_goals_sum	hometeam_last_5_matches_goals_avg	hometeam_last_5_matches_goals_conceded_sum	hometeam_last_5_matches_goals_conceded_avg	hometeam_last_5_matches_points_sum	hometeam_last_5_matches_points_avg	hometeam_last_5_matches_winrate	hometeam_last_5_matches_hots_sum	hometeam_last_5_matches_cold_sum	...
count	3629	3629	3629	3629	3629	3629	3629	3629	3629	...
mean	6,98	1,39	7,10	1,42	6,80	1,36	0,45	6,36	2,33	...
std	3,35	0,67	3,07	0,61	3,51	0,70	0,23	1,59	8,65	...
min	0	0	0	0	0	0	0	3	0	...
25%	4	1	5,00	1,00	4,00	0,80	0,26	53,00	17,00	...
50%	7	1	7,00	1,40	7,00	1,40	0,46	62,00	22,00	...
75%	9	2	9,00	1,80	9,00	1,80	0,60	73,00	28,00	...
max	24	5	20	4	15	3	1	128	72	...

Tablo 4 incelendiğinde, oluşturulan özelliklerin büyük bölümünün son 5 ve son 20 maçlık performans göstergelerine dayandığı görülmektedir. Özellik mühendisliği süreci sonucunda takımların hücum, savunma, form durumu ve istikrar düzeylerini temsil eden çok sayıda türetilmiş değişken elde edilmiştir. Bu yapı, modellerin yalnızca ham maç verilerini değil, takımların güncel performans eğilimlerini de öğrenebilmesine olanak sağlamaktadır.

Tablo 5. Veri Ön İşleme Sonuçları (Maç Sayısı, Özellik Sayısı)

İşlem	Önce	Sonra
Maç sayısı	12153	3629
Özellik sayısı	131	104
Eksik değer	35736	0

Tablo 5 incelendiğinde, veri ön işleme süreci sonucunda maç sayısının 12.153'ten 3.629'a düştüğü görülmektedir. Bu azalma, eksik gözlemlerin temizlenmesi ve özellik mühendisliği için gerekli geçmiş maç koşullarının sağlanamamasından kaynaklanmaktadır. Buna karşın eksik değerlerin tamamen giderilmiş olması ve özellik setinin 131 değişkenden 104 değişkene indirgenmesi, modelleme için daha tutarlı ve kaliteli bir veri yapısı oluşturulduğunu göstermektedir.

Zaman Temelli Veri Bölme Stratejisi

Futbol maç sonucu tahmini, doğası gereği zaman bağımlı bir problem olup, veri bölme stratejisinin bu yapıyı yansıtacak biçimde kurgulanması kritik öneme sahiptir. Rastgele veri bölme yöntemleri, özellikle geçmişten geleceğe doğru tahmin yapılması gereken senaryolarda veri sızıntısına yol açabilmektedir. Bu durum, model performansının gerçekte olduğundan daha yüksek görünmesine neden olmakta ve elde edilen sonuçların güvenilirliğini zayıflatmaktadır.

Bu çalışmada, veri seti kronolojik sıraya göre bölünmüş ve eğitim, doğrulama ve test kümeleri zaman eksenini gözetilerek oluşturulmuştur. Her bir tahmin senaryosunda model, yalnızca ilgili maçı önceki karşılaşmalardan elde edilen bilgilerle eğitilmiştir. Bu yaklaşım, model performansının gerçek kullanım senaryolarını daha doğru biçimde yansıtmayı sağlamak ve literatürde sıkça göz ardı edilen veri sızıntısı problemini önlemektedir.

Özellik Mühendisliği Yaklaşımı

Futbol maç sonucu tahmininde kullanılan özelliklerin niteliği, model başarımı üzerinde belirleyici bir rol oynamaktadır. Ham maç istatistiklerinin doğrudan modele sunulması, takımların güncel form durumunu ve göreceli güç dengelerini yeterince yansıtmayabilmektedir. Bu nedenle, çalışmada özellik mühendisliği süreci sistematik ve problem tanımıyla uyumlu bir çerçevede ele alınmıştır.

Özellikler, takımların kısa ve orta vadeli performanslarını yansıtacak şekilde kayan pencere (rolling window) yaklaşımı kullanılarak üretilmiştir. Kısa vadeli performans göstergeleri için son 5 maç, orta vadeli göstergeler için ise son 20 maçlık dönemler esas alınmıştır. Bu yapı sayesinde, takımların güncel

form durumları ile daha uzun vadeli istikrarları birlikte temsil edilebilmiştir (Eryarsoy ve Delen, 2019; Tang vd., 2014).

Görelî (Delta) Özelliklerin Oluşturulması

Maç sonucu, mutlak takım performanslarından ziyade, karşılaşan iki takım arasındaki görelî güç farklarıyla daha yakından ilişkilidir. Bu doğrultuda, çalışmada ev sahibi ve deplasman takımlarına ait performans göstergeleri ayrı ayrı kullanılmak yerine, bu değerler arasındaki farkları temsil eden görelî (delta) özellikler oluşturulmuştur.

Örneğin, ev sahibi ve deplasman takımlarının gol ortalamaları, galibiyet oranları veya puan ortalamaları arasındaki farklar doğrudan özellik setine dâhil edilmiştir. Bu yaklaşım, modelin mutlak değerlerden ziyade takımlar arasındaki dengeyi öğrenmesini kolaylaştırmakta ve karar sınırlarının daha net biçimde oluşmasına katkı sağlamaktadır.

Özellik Ölçekleme ve Standartlaştırma

Çalışmada kullanılan özellikler, farklı ölçeklerde ve farklı dağılımlarda değerler alabildiğinden, modelleme öncesinde özellik ölçekleme ve standartlaştırma işlemleri uygulanmıştır. Özellikle mesafe temelli veya gradyan tabanlı algoritmalar açısından bu adım, öğrenme sürecinin sağlıklı biçimde gerçekleşmesi için kritik öneme sahiptir (Wan, 2019).

Özellik ölçekleme süreci, modelleme mimarisinin farklı aşamaları için ayrı ayrı gerçekleştirilmiştir. Bunun temel gerekçesi, her bir aşamada kullanılan veri alt kümelerinin ve sınıf dağılımlarının farklılık göstermesidir. Bu sayede, her bir alt modelin kendi problem alanına özgü istatistiksel yapıyı daha doğru biçimde öğrenmesi amaçlanmıştır. Çalışmada kullanılan veri setinin kapsamı, zaman temelli veri bölme stratejisi ve özellik mühendisliği süreci ayrıntılı biçimde açıklanmıştır. Benimsenen yaklaşım, veri sızıntısını önleyen, problem tanımıyla uyumlu ve gerçek hayatta uygulanabilir tahmin üretmeyi hedefleyen bir çerçeve sunmaktadır.

Modelleme Yaklaşımı ve Deneysel Kurgu

Problem Tanımının Yeniden Yapılandırılması

Futbol maç sonucu tahmini literatüründe yaygın olarak benimsenen yaklaşım, maç sonuçlarını ev sahibi galibiyeti (H), beraberlik (D) ve deplasman galibiyeti (A) olmak üzere üç sınıflı bir sınıflandırma problemi olarak ele almaktadır. Ancak bu yapı, özellikle beraberlik sınıfının sınırlı ayırt edilebilirliği ve sınıf dağılımlarındaki dengesizlik nedeniyle çeşitli yapısal sorunlar doğurmaktadır. Bu sorunlar, model performansının kararsızlaşmasına ve karar sınırlarının belirsizleşmesine yol açabilmektedir (Baboota ve Kaur, 2019; Fischer ve Heuer, 2025).

Bu çalışmada, söz konusu sınırlılıkların problem tanımından kaynaklandığı varsayımından hareketle, futbol maç sonucu tahmin problemi yeniden yapılandırılmıştır. Üç sınıflı tek aşamalı bir yaklaşım yerine, karar sürecinin doğasına daha uygun olduğu düşünülen iki aşamalı bir ikili sınıflandırma çerçevesi benimsenmiştir. Bu çerçevede, maç sonucu tahmini tek bir karar problemi olarak değil, birbirinden yapısal olarak farklı iki alt problem olarak ele alınmaktadır.

Problem Tanımının Teorik Gerekçelendirilmesi

Futbol maç sonucu tahmin probleminin üç sınıflı (H–D–A) bir yapı altında ele alınması, literatürde yaygın olarak benimsenmiş olmakla birlikte, bu formülasyonun karar sınırları açısından önemli yapısal zorluklar içerdiği görülmektedir. Çok sınıflı sınıflandırma problemlerinde, özellikle sınıflar arasındaki dağılımın dengesiz olduğu ve bazı sınıfların istatistiksel olarak daha belirsiz örüntüler sergilediği durumlarda, tek aşamalı karar yapıları modelin öğrenme kapasitesini sınırlayabilmektedir.

Üç sınıflı yapı içerisinde beraberlik (D) sınıfı hem sayısal temsil oranı hem de yapısal karakteri bakımından diğer iki sınıftan ayrılmaktadır. Ev sahibi veya deplasman galibiyeti genellikle görelî güç

farkları ile daha net biçimde ilişkilendirilebilirken, beraberlik sonucu çoğu zaman iki takımın birbirine yakın performans düzeyine sahip olması, taktiksel dengeler veya rastlantısal oyun içi olaylar gibi çoklu faktörlerin birleşimiyle ortaya çıkmaktadır. Bu durum, beraberlik sınıfının karar uzayında daha geniş ve örtüşen bir dağılım sergilemesine neden olmaktadır.

Makine öğrenmesi perspektifinden bakıldığında, üç sınıflı bir karar fonksiyonu şu şekilde ifade edilebilir:

$$f(x) = \arg \max_{c \in \{H,D,A\}} P(Y = c | X = x) \quad (1)$$

$$P(D|X), P(H|X), P(A|X) \quad (2)$$

Bu yapı, tüm sınıflar için tek bir karar yüzeyi öğrenilmesini gerektirmektedir. Ancak beraberlik sınıfının dağılımı diğer sınıflarla önemli ölçüde örtüştüğünde, karar sınırları daha karmaşık ve istikrarsız hâle gelmektedir. Özellikle sınıf dengesizliği durumlarında, model parametreleri çoğunluk sınıflara doğru eğilim gösterebilmekte ve bu da az temsil edilen sınıfın hatalı biçimde baskılanmasına yol açmaktadır.

Hiyerarşik veya iki aşamalı sınıflandırma yaklaşımları, bu tür problemlerde karar sürecini daha küçük ve yapısal olarak daha homojen alt problemlere ayırarak öğrenme sürecini basitleştirmektedir. Bu çalışmada önerilen iki aşamalı yapı, karar sürecini şu biçimde ayrıştırmaktadır:

$$f_1(x) = \arg \max_{c \in \{D, Non-D\}} P(Y = c | X = x) \quad (3)$$

$$f_2(x | Non-D) = \arg \max_{c \in \{H,A\}} P(Y = c | X = x, Y \neq D) \quad (4)$$

Bu ayrıştırma sayesinde, ilk aşamada beraberlik olasılığı bağımsız bir problem olarak ele alınmakta ve ikinci aşamada yalnızca galibiyet durumları arasında karar verilmektedir. Böylece ikinci aşamadaki sınıf dağılımı daha dengeli hâle gelmekte ve karar sınırları daha belirgin biçimde öğrenilebilmektedir. Teorik olarak bu yaklaşım, Bayes karar teorisi perspektifinden de desteklenmektedir.

Bu ayrıştırma, toplam olasılığın zincirleme kuralına dayanmaktadır. Böylece üç sınıflı yapı, önce Draw / Non-Draw ayrımı, ardından koşullu Home / Away ayrımı şeklinde iki daha sade alt probleme indirgenmektedir.

Eğer dağılımları farklı varyans ve örtüşme yapıları sergiliyorsa, tek aşamalı maksimum olasılık kararı yerine koşullu ayrıştırılmış karar yapıları daha düşük toplam hata riski üretebilir. Özellikle yüksek örtüşmeye sahip sınıfların ayrı bir karar problemi olarak modellenmesi, toplam sınıflandırma hatasını azaltma potansiyeline sahiptir.

Ayrıca, çok sınıflı problemlerde doğruluk metriğinin yanıltıcı olabileceği bilinmektedir. Sınıf dengesizliği durumunda model, çoğunluk sınıflar üzerinden yüksek doğruluk üretirken, karar sınırının karmaşıklığı azınlık sınıf performansını olumsuz etkileyebilir. İki aşamalı yapı, beraberlik sınıfını doğrudan optimize edilebilir bir hedef hâline getirerek bu sorunu yapısal düzeyde ele almaktadır.

Sonuç olarak, önerilen iki aşamalı model yalnızca algoritmik bir tercih değil, futbol maç sonucu tahmin probleminin karar geometrisini dikkate alan yapısal bir yeniden tanımlamadır. Bu yaklaşım, model karmaşıklığını artırmadan, karar sınırlarının daha net öğrenilmesini ve sınıf dengesizliğinin dolaylı biçimde azaltılmasını sağlamaktadır.

Bayes Karar Teorisi ve Hiyerarşik Risk Ayrıştırması

Futbol maç sonucu tahmin problemi, istatistiksel karar teorisi perspektifinden ele alındığında, gözlenen özellik vektörü X üzerinden hedef değişken $Y \in \{H,D,A\}$ için en düşük beklenen hata riskini üreten karar fonksiyonunun belirlenmesi problemi olarak tanımlanabilir. Bu çerçevede klasik üç sınıflı yaklaşımda amaç, aşağıdaki Bayes karar kuralını uygulayan bir fonksiyon öğrenmektir:

$$f(x) = \arg \max_{c \in \{H,D,A\}} P(Y = c | X = x) \quad (5)$$

Bu karar kuralı, 0–1 kayıp fonksiyonu altında toplam sınıflandırma hatasını minimize eden optimal çözümü temsil etmektedir. Genel formda beklenen risk şu şekilde ifade edilir:

$$R(f) = E_{X,Y}[L(Y, f(X))] \quad (6)$$

Çok sınıflı durumda bu risk aşağıdaki biçimde ayrıştırılabilir:

$$R_{multi}(f) = \sum_{c \in \{H,D,A\}} \int_{\mathcal{X}} L(c, f(x)) P(X = x, Y = c) dx \quad (7)$$

Bu yapı, tek bir karar yüzeyi altında tüm sınıfların aynı anda ayrıştırılmasını gerektirmektedir. Ancak futbol maç sonucu tahmin probleminde sınıfların dağılım özellikleri homojen değildir. Özellikle beraberlik (D) sınıfının karar uzayındaki konumu, ev sahibi (H) ve deplasman (A) galibiyetlerinden yapısal olarak farklıdır.

Beraberlik sonucu çoğu zaman iki takımın göreceli güçlerinin birbirine yakın olduğu durumlarda ortaya çıkmakta ve bu nedenle özellik uzayında H ve A sınıfları ile örtüşen bir dağılım sergilemektedir. Bu örtüşme, tek aşamalı karar yüzeyinin daha karmaşık hâle gelmesine ve model varyansının artmasına neden olabilmektedir. Sınıf dengesizliği ile birleştiğinde, bu durum beraberlik sınıfının karar sürecinde baskılanmasına yol açmaktadır.

Riskin Hiyerarşik Ayrıştırılması

Önerilen iki aşamalı yaklaşım, toplam riski tek birçok sınıflı karar fonksiyonu altında minimize etmek yerine, problemi iki ardışık alt risk minimizasyon problemine ayırmaktadır.

İlk aşamada hedef değişken:

$$Y_1 \in \{D, \text{Non-D}\} \quad (8)$$

olarak tanımlanır ve karar fonksiyonu şu şekilde ifade edilir:

$$f_1(x) = \arg \max_{c \in \{D, \text{NonD}\}} P(Y_1 = c | X = x) \quad (9)$$

Bu aşamanın beklenen riski:

$$R_1 = E[L(Y_1, f_1(X))] \quad (10)$$

şeklindedir.

İkinci aşamada ise yalnızca $Y \neq D$ koşulunu sağlayan örnekler ele alınır ve hedef değişken:

$$Y_2 \in \{H, A\} \quad (11)$$

olarak tanımlanır. Bu durumda karar fonksiyonu:

$$f_2(x) = \arg \max_{c \in \{H, A\}} P(Y = c | X = x, Y \neq D) \quad (12)$$

şeklindedir.

Toplam beklenen risk bu ayrıştırma altında yaklaşık olarak şu biçimde yazılabilir:

$$R_{total} = R_1 + P(Y \neq D) R_2 \quad (13)$$

$$R_2 = E[L(Y_2, f_2(X))] \quad (14)$$

Bu ifade, toplam hata riskinin iki daha basit alt problem üzerinden minimize edildiğini göstermektedir. Özellikle ikinci aşamada sınıf uzayının ikiye indirgenmesi, karar yüzeyinin karmaşıklığını azaltmakta ve varyans bileşeninin düşmesine katkı sağlamaktadır.

Bias–Variance Perspektifi

Çok sınıflı öğrenme problemlerinde model hatası genel olarak bias, varyans ve indirgenemez hata bileşenlerine ayrıştırılabilir:

$$E \left[\left(Y - \hat{f}(X) \right)^2 \right] = Bias^2 + Variance + \sigma^2 \quad (15)$$

Tek aşamalı üç sınıflı yapı, karar sınırlarının aynı anda üç sınıflı ayırmasını gerektirdiğinden, modelin öğrenmesi gereken fonksiyon daha karmaşık hâle gelmektedir. Bu durum özellikle sınıf örtüşmesinin yüksek olduğu bölgelerde varyansın artmasına neden olabilir.

İki aşamalı yapı ise:

- İlk aşamada “beraberlik var mı?” sorusunu,
- İkinci aşamada “kazanan kim?” sorusunu

ayrı ayrı ele alarak karar uzayını parçalamaktadır. Bu ayrıştırma, her bir alt modelin daha sade bir karar yüzeyi öğrenmesine olanak tanımakta ve toplam varyansın azalmasına katkı sağlayabilmektedir. Özellikle sınıf örtüşmesinin yüksek olduğu D sınıfı için ayrı bir karar problemi tanımlanması, bias–variance dengesinin daha kontrollü biçimde kurulmasına imkân vermektedir.

Karar Geometrisi ve Sınıf Örtüşmesi

Futbol maç sonucu tahmin probleminde göreceli (delta) özellikler kullanıldığında, özellik uzayında H ve A sınıflarının genellikle zıt uçlarda konumlandığı; D sınıfının ise merkezi ve örtüşen bir bölgede yoğunlaştığı gözlemlenmektedir. Bu yapı, doğrusal ya da yarı-doğrusal karar sınırlarının tek aşamada tüm sınıfları ayırmasını zorlaştırmaktadır.

İki aşamalı yapı, karar geometrisini şu şekilde sadeleştirmektedir:

1. Önce merkezi ve yüksek örtüşmeye sahip D sınıfı ayrıştırılır.
2. Daha sonra uç bölgelerde yer alan H ve A sınıfları arasında ayırım yapılır.

Bu yaklaşım, özellik uzayında örtüşmenin yüksek olduğu bölgelerin bağımsız olarak modellenmesini sağlayarak karar sınırlarının daha net oluşmasına katkı sunmaktadır.

Olasılıksal Ayrıştırma ve Kalibrasyon

İki aşamalı yapı aynı zamanda olasılıksal açıdan da daha esnek bir çerçeve sunmaktadır. Toplam olasılıklar aşağıdaki zincirleme yapı ile ifade edilebilir:

$$P(H | X) = P(\text{NonD} | X) \cdot P(H | X, \text{NonD}) \quad (16)$$

Bu ayrıştırma, özellikle olasılık kalibrasyonu açısından avantaj sağlamaktadır. Tek aşamalı modelde tüm sınıfların olasılıkları aynı karar fonksiyonu üzerinden normalize edilirken, iki aşamalı modelde koşullu olasılıklar daha homojen alt uzaylar üzerinde öğrenilmektedir. Bu durum, tahmin güvenilirliğini artırabilir ve pratik uygulamalarda daha anlamlı karar eşiklerinin belirlenmesine imkân tanıyabilir.

Sonuç olarak, önerilen iki aşamalı yaklaşım yalnızca algoritmik bir tercih değil, Bayes karar teorisi ve risk minimizasyonu perspektifinden temellendirilen yapısal bir yeniden formülasyondur. Toplam riskin iki daha sade alt probleme ayrılması; karar yüzeyinin karmaşıklığını azaltmakta, sınıf örtüşmesini daha kontrollü biçimde ele almakta ve özellikle dengesiz dağılımlara sahip futbol veri setlerinde daha istikrarlı öğrenme davranışı sergilenmesini mümkün kılmaktadır.

İki Aşamalı Yapının Olasılıksal ve Risk Temelli Formülasyonu

Önerilen iki aşamalı yapı, çok sınıflı karar problemini olasılıksal zincir kuralı (chain rule of probability) çerçevesinde ayrıştırmaktadır. Üç sınıflı durumda hedef değişken

$$Y \in \{H, D, A\} \quad (17)$$

olarak tanımlanmaktadır. İki aşamalı yaklaşımda ise önce ikili bir yardımcı değişken tanımlanır:

$$Z = \left[\{cases\} 1, \& Y = D \setminus 0, \& Y \in \{H, A\} \right] \{cases\} \quad (18)$$

Bu durumda toplam olasılık aşağıdaki biçimde yazılabilir:

$$P(Y = H | X) = P(Z = 0 | X) P(Y = H | X, Z = 0), \quad [6pt] \quad (19)$$

$$P(Y = A | X) = P(Z = 0 | X) P(Y = A | X, Z = 0), \quad [6pt] \quad (20)$$

$$P(Y = D | X) = P(Z = 1 | X). \quad (21)$$

Bu ayrıştırma, üç sınıflı tek aşamalı karar fonksiyonu yerine iki koşullu karar fonksiyonunun öğrenilmesine olanak tanımaktadır:

Aşama 1 (Beraberlik kararı):

$$f_1(x) = \arg \max_{z \in \{0,1\}} P(Z = z | X = x) \quad (22)$$

Aşama 2 (Kazanan taraf kararı):

$$f_2(x) = \arg \max_{c \in \{H,A\}} P(Y = c | X = x, Z = 0) \quad (23)$$

Toplam Riskin Ayrıştırılması

0–1 kayıp fonksiyonu altında toplam beklenen risk şu şekilde yazılabilir:

$$R(f) = P\big(f(X) \neq Y\big) \quad (24)$$

İki aşamalı yapı altında bu risk yaklaşık olarak şu biçimde ayrıştırılabilir:

$$R(f) = P\big(f_1(X) \neq Z\big) + P\big(f_1(X) = 0\big) P\big(f_2(X) \neq Y | Z = 0\big) \quad (25)$$

Bu ifade, toplam hata riskinin iki bileşenden oluştuğunu göstermektedir:

1. İlk aşamadaki beraberlik karar hatası
2. Beraberlik olmadığı durumlarda ikinci aşamadaki kazanan taraf hatası

Bu ayrıştırma, çok sınıflı tek bir karar yüzeyi altında öğrenilen karmaşık risk yerine, iki daha homojen alt risk minimizasyon probleminin çözülmesini sağlamaktadır.

Karar Yüzeyi Karmaşıklığı ve Varyans Etkisi

Tek aşamalı üç sınıflı yapı, özellik uzayında üç sınıflı aynı anda ayıran bir karar fonksiyonu öğrenmeyi gerektirir. Bu durumda öğrenilen karar sınırının karmaşıklığı şu faktörlere bağlıdır:

- Sınıf örtüşmesi
- Sınıf dengesizliği
- Koşullu dağılımların varyansı

İki aşamalı yapı ise karar yüzeyini iki alt problemde öğrenir:

1. Merkezi ve örtüşen bölge (D sınıfı)
2. Göreli uç bölgeler (H ve A ayrımı)

Bu ayrıştırma, özellikle ikinci aşamada sınıf uzayının küçülmesi nedeniyle karar yüzeyinin daha düşük varyanslı bir tahmin üretmesine olanak tanır. Bias–variance ayrıştırması perspektifinden bakıldığında:

$$E\big[\big(Y - \hat{f}(X)\big)^2\big] = \text{Bias}^2 + \text{Variance} + \text{Noise} \quad (26)$$


İki aşamalı yapı, karar geometrisini sadeleştirerek özellikle varyans bileşenini azaltma potansiyeline sahiptir. Bu durum, deneysel bulgulara gözlenen daha kararlı F1 ve ROC–AUC değerleriyle uyumludur.

İki Aşamalı Sınıflandırma Mimarisi

Önerilen modelleme yaklaşımı, hiyerarşik bir karar yapısı üzerine kuruludur. İlk aşamada, bir karşılaşmanın berabere sonuçlanıp sonuçlanmayacağı tahmin edilmektedir. Bu aşama, beraberlik sınıfını bağımsız bir karar problemi olarak ele alarak, üç sınıflı yapı içerisinde çoğu zaman baskılanan bu sınıfın daha net biçimde modellenmesini amaçlamaktadır. Önerilen iki aşamalı karar yapısının genel akışı Şekil 1’de görsel olarak sunulmaktadır.

İkinci aşamada ise, ilk aşamada berabere sonuçlanma olasılığı düşük olarak sınıflandırılan maçlar ele alınmakta ve bu karşılaşmalar için kazanan tarafın (ev sahibi veya deplasman) belirlenmesi hedeflenmektedir. Bu ayrıştırma sayesinde, ikinci aşamada kullanılan veri kümesi daha dengeli bir sınıf dağılımına sahip olmakta ve karar sınırlarının daha belirgin biçimde öğrenilmesi mümkün hâle gelmektedir.

Bu iki aşamalı yapı, sınıf dengesizliği problemini doğrudan örnekleme veya ağırlıklandırma teknikleriyle çözmek yerine, problemi yapısal olarak yeniden tanımlayarak ele almaktadır. Böylece model karmaşıklığını artırmadan, öğrenme sürecinin daha istikrarlı hâle getirilmesi amaçlanmaktadır (Chen, 2025; Groll vd., 2019).



Şekil 1. Önerilen İki Aşamalı Sınıflandırma Akışı

Kullanılan Makine Öğrenmesi Algoritmaları

İki aşamalı sınıflandırma mimarisi kapsamında, her iki aşama için de farklı makine öğrenmesi algoritmaları ayrı ayrı değerlendirilmiştir. Çalışmada kullanılan algoritmalar, literatürde yaygın olarak kullanılan ve farklı öğrenme varsayımlarına sahip yöntemlerden seçilmiştir. Bu kapsamda aşağıdaki algoritmalar incelenmiştir:

- Logistic Regression (LR)

- Support Vector Machine (SVM)
- Naive Bayes (NB)
- Decision Tree (DT)
- Light Gradient Boosting Machine (LightGBM)

Her bir algoritma, her iki aşamada da bağımsız olarak eğitilmiş ve değerlendirilmiştir. Bu yaklaşım, algoritmaların problem tanımına verdikleri tepkilerin daha net biçimde gözlemlenmesine olanak tanımaktadır (Cristianini ve Shawe-Taylor, 2000).

Eğitim ve Test Süreci

Model eğitimi sürecinde zaman temelli veri bölme stratejisi esas alınmıştır. Eğitim, doğrulama ve test kümeleri kronolojik sıraya göre oluşturulmuş; her bir model yalnızca ilgili maçtan önceki veriler kullanılarak eğitilmiştir. Bu yaklaşım, model performansının gerçek dünyadaki kullanım senaryolarını daha doğru biçimde yansıtmasını sağlamaktadır.

Pandemi etkilerinin sonuçları bozmasını önlemek amacıyla 2019/20 sezonu veri setinden çıkarılmıştır. 2012/13–2018/19 sezonları eğitim kümesi olarak, 2020/21–2024/25 sezonları ise test kümesi olarak kullanılmıştır.

Her bir aşama için özellik ölçekleme ve model eğitimi süreçleri ayrı ayrı gerçekleştirilmiştir. Bunun temel nedeni, iki aşamada ele alınan veri alt kümelerinin sınıf dağılımlarının ve istatistiksel özelliklerinin farklılık göstermesidir. Bu ayrım, her bir modelin kendi problem alanına özgü örüntüleri daha etkin biçimde öğrenmesini amaçlamaktadır.

Çalışmada özniteliklerin model üzerindeki göreceli etkilerini değerlendirmek amacıyla LightGBM algoritmasının dahili Feature Importance mekanizması kullanılmıştır. Öznitelik önem değerleri, model tarafından gerçekleştirilen bölünmelerin (split) sayısı ve bilgi kazancı temelinde hesaplanmış; elde edilen önem skorları sıralanarak en etkili değişkenler belirlenmiştir.

Performans Değerlendirme Ölçütleri

Model performansının değerlendirilmesinde, yalnızca genel doğruluk (accuracy) metriğine bağlı kalmamıştır. Özellikle sınıf dengesizliğinin belirgin olduğu problemler için doğruluk metriğinin tek başına yanıltıcı olabileceği bilinmektedir. Bu nedenle, çalışmada performans değerlendirmesi çok boyutlu bir bakış açısıyla ele alınmıştır.

Bu kapsamda, modeller aşağıdaki ölçütler üzerinden değerlendirilmiştir:

- Precision
- Recall
- F1 skoru
- ROC eğrisi ve ROC–AUC değeri

Değerlendirmeler hem aşama bazlı olarak hem de genel tahmin performansını yansıtacak biçimde raporlanmıştır. Bu sayede, iki aşamalı yapının farklı karar noktalarındaki etkileri ayrıntılı biçimde analiz edilebilmiştir.

DeneySEL Kurgu Özeti

Futbol maç sonucu tahmin problemi iki aşamalı bir sınıflandırma yapısı altında modellenmiş ve deneySEL süreç bu doğrultuda kurgulanmıştır. Benimsenen yaklaşım, algoritma karmaşıklığını artırmak yerine problem tanımını yeniden ele alarak daha dengeli, yorumlanabilir ve kararlı bir tahmin çerçevesi sunmayı amaçlamaktadır. Önerilen yaklaşımın etkinliği, deneySEL sonuçlar üzerinden değerlendirilmiş ve klasik üç sınıflı yöntemlerle karşılaştırmalı olarak analiz edilmiştir.

Bulgular ve Değerlendirme

Deneyisel Sonuçların Genel Görünümü

Tablo 6’da beraberlik tahminine yönelik birinci aşamada kullanılan algoritmaların performans sonuçları sunulmaktadır. Bu aşamada problem, maç sonucunun “beraberlik” olup olmamasını belirlemeye yönelik ikili bir sınıflandırma problemi olarak ele alınmıştır.

Sonuçlar incelendiğinde, modellerin doğruluk (accuracy) değerlerinin %30–41 aralığında değiştiği görülmektedir. En yüksek doğruluk oranı %41.08 ile SVM modelinde elde edilmiştir. Logistic Regression (%40.78) ve LightGBM (%40.58) modelleri benzer doğruluk düzeyleri sergilerken, Decision Tree modeli %39.54 doğruluk değeri ile bu modellere yakın bir performans göstermiştir. AdaBoost modelinin doğruluk değeri ise %30.70 ile diğer modellere kıyasla daha düşük kalmıştır.

Precision ve recall değerleri birlikte değerlendirildiğinde önemli farklılıklar gözlemlenmektedir. AdaBoost modeli %95.20 gibi oldukça yüksek bir recall değerine ulaşmıştır. Ancak precision değerinin %26.19 olması, modelin belirgin bir sınıf yanlılığı sergilediğine işaret etmektedir. Tercih olarak değerlendirilebilir. Buna karşılık SVM, Logistic Regression ve LightGBM modellerinde precision ve recall değerlerinin birbirine yakın olduğu görülmektedir (yaklaşık %25–30 aralığında). Bu bulgu, söz konusu modellerin daha dengeli bir sınıflandırma davranışı sergilediğini, ancak genel ayırt edicilik güçlerinin sınırlı kaldığını göstermektedir.

F1 skorları tüm modeller için düşük düzeydedir ve yaklaşık %25–26 bandında seyretmektedir. Bu durum, beraberlik sınıfının veri setinde azınlıkta yer alması ve sınıf dengesizliği probleminin performans üzerinde belirgin bir etkisi olduğunu düşündürmektedir.

AUC değerleri incelendiğinde modellerin 0.52–0.54 aralığında performans gösterdiği görülmektedir. En yüksek AUC değeri 0.5392 ile LightGBM modeline aittir. Bununla birlikte, bu değerlerin rastgele sınıflandırma seviyesine (0.50) oldukça yakın olması, modellerin beraberlik sınıfını ayırt etme kapasitesinin sınırlı olduğunu göstermektedir.

Genel olarak Tablo 6 sonuçları, beraberlik kararının bağımsız bir ikili problem olarak modellenmesinin teorik açıdan anlamlı olmakla birlikte, mevcut özellik seti ve veri dağılımı altında güçlü bir ayırt edicilik üretmediğini ortaya koymaktadır. Bu bulgu, beraberlik tahmini için daha gelişmiş özellik mühendisliği, sınıf ağırlıklandırma stratejileri veya yeniden örnekleme tekniklerinin değerlendirilmesi gerektiğine işaret etmektedir.

Tablo 6. Birinci Aşama (Beraberlik Tahmini: Draw / Non-Draw) Performans Sonuçları

Algoritma	Accuracy	Precision	Recall	F1 Score	AUC
AdaBoost	0.3070	0.2619	0.9520	0.4108	0.5284
SVM	0.3057	0.26421	0.8859	0.4078	0.5375
Logistic Regression	0.2642	0.2552	0.9900	0.4058	0.5392
LightGBM	0.2558	0.2543	0.9859	0.3954	0.5175
Decision Tree	0.2537	0.2537	0.9943	0.3848	0.4948

İkinci Aşama Sonuçları: Kazanan Tarafın Tahmini

İkinci aşamaya ilişkin performans sonuçları Tablo 7’de sunulmaktadır. Tablo 7’de yalnızca Non-Draw örnekleri üzerinde gerçekleştirilen Home/Away ayrımına ilişkin sonuçlar sunulmaktadır.

Bu aşamada Logistic Regression modeli 0.7476 F1 skoru ile en dengeli performansı üretmiştir. SVM modeli 0.8491 recall değeri ile yüksek duyarlılık göstermiştir; ancak 0.6611 precision değeri, modelin daha agresif pozitif tahmin eğilimi sergilediğini düşündürmektedir.

Decision Tree modelinin 0.5568 AUC değeri ile belirgin biçimde düşük performans göstermesi, tekil ağaç yapıların bu problemde yeterli genelleme kapasitesine sahip olmadığını göstermektedir.

Genel olarak F1 skorlarının 0.70–0.75 bandında yoğunlaşması, sınıf uzayının ikiye indirgenmesinin karar yüzeyini sadeleştirdiğini ve daha istikrarlı tahminler üretilmesini sağladığını göstermektedir.

Tablo 7’ye göre ise ikinci aşamada elde edilen F1 skorlarının 0.70–0.75 bandında yoğunlaşması, sınıf uzayının ikiye indirgenmesinin karar sınırlarını sadeleştirdiğini ve model performansını istikrarlı hâle getirdiğini göstermektedir.

Tablo 7. İkinci Aşama (Home / Away) Performans Sonuçları

Model	Precision	Recall	F1	ROC AUC
Logistic Regression	0.6846	0.8233	0.7476	0.6725
SVM	0.6611	0.8491	0.7434	0.6335
Naive Bayes	0.6840	0.7371	0.7095	0.6672
Decision Tree	0.6494	0.6466	0.6479	0.5568
AdaBoost	0.6541	0.8233	0.7290	0.6328

DeneySEL sonuçlar, ikinci aşamada elde edilen performans metriklerinin, üç sınıflı tek aşamalı yaklaşıma kıyasla daha yüksek ve istikrarlı olduğunu göstermektedir. Özellikle F1 skoru ve ROC–AUC değerlerindeki artış, iki aşamalı yapının karar sürecini sadeleştirerek model ayırt ediciliğini artırdığını ortaya koymaktadır.

Feature Importance (Özellik Önemi)

Tablo 8. Draw/Non-Draw Modelinde En Önemli 10 Özellik

	feature	importance
1	awayteam_last_5_matches_sot_against_sum	156
2	awayteam_last_20_matches_goals_std	128
3	hometeam_last_20_matches_sot_rate_std	104
4	match_last_20_goals_avg_diff	97
5	awayteam_last_5_matches_save_rate	90
6	hometeam_last_20_matches_rest_days_avg	89
7	match_last_20_winrate_diff	83
8	hometeam_last_20_matches_btts_count	77
9	awayteam_last_20_matches_yellow_cards_sum	74
10	hometeam_last_20_matches_goals_std	73

Tablo 8 incelendiğinde, beraberlik tahmininde performans istikrarı ve takımlar arası dengeyi temsil eden değişkenlerin öne çıktığı görülmektedir.

Tablo 9. Home/Away Modelinde En Önemli 10 Özellik

	Feature	Performance
1	awayteam_last_20_matches_shots_sum	55
2	hometeam_last_20_matches_shots_against_sum	40
3	awayteam_last_20_matches_sot	38
4	hometeam_last_5_matches_sot_rate_std	36
5	hometeam_last_20_matches_save_rate	35
6	awayteam_last_20_matches_rest_days_avg	34
7	awayteam_last_5_matches_sot_rate_std	34
8	match_last_20_save_rate_diff	33
9	match_last_20_sot_diff	31
10	hometeam_last_20_matches_sot_rate_std	30

Tablo 9 incelendiğinde ise galibiyet tahminlerinde hücum üretkenliği ve şut kalitesini temsil eden değişkenlerin daha belirleyici olduğu anlaşılmaktadır.

Özellik Önem Analizi

Draw (D / Non-D) modeli için özellik önem sıralaması, beraberlik tahmininin ağırlıklı olarak performans istikrarı ve takımlar arası denge göstergelerine dayandığını ortaya koymaktadır. Özellikle deplasman takımının son maçlarda yediği isabetli şut toplamı, gol üretimindeki standart sapma ve iki takım arasındaki gol ve kazanma oranı farkları en yüksek katkıyı sağlayan değişkenlerdir. Standart sapma (std) ve fark (diff) temelli değişkenlerin üst sıralarda yer alması, beraberlik sonucunun çoğunlukla performans istikrarı ve güç dengesi ile ilişkili olduğunu göstermektedir. Ayrıca kaleci performansı ve dinlenme süresi gibi değişkenlerin de önemli bulunması, beraberliğin yalnızca hücum üretkenliğiyle değil, savunma dengesi ve fiziksel hazırlıkla da bağlantılı olduğunu göstermektedir.

Home/Win modeli ise daha çok hücum üretkenliği ve şut kalitesi göstergelerine duyarlıdır. Deplasman takımının toplam şut sayısı, isabetli şut istatistikleri ve şut oranı değişkenleri en yüksek öneme sahip özellikler arasında yer almaktadır. Bunun yanında kaleci performans farkı ve savunma göstergeleri de belirleyici değişkenlerdir. Bu bulgu, ev sahibi galibiyetinin daha çok maç içi üstünlük göstergeleri ve hücum etkinliği farkları ile ilişkili olduğunu göstermektedir.

Genel olarak iki model karşılaştırıldığında, beraberlik tahmininin denge ve istikrar temelli değişkenlere, galibiyet tahmininin ise hücum ve performans farkı temelli değişkenlere dayandığı görülmektedir. Bu durum, iki aşamalı model yapısının kavramsal olarak tutarlı olduğunu desteklemektedir.

Algoritmalar Arası Karşılaştırma

Çalışma kapsamında değerlendirilen makine öğrenmesi algoritmaları arasında performans açısından belirli farklılıklar gözlemlenmiştir. Support Vector Machine algoritması, her iki aşamada da genel olarak en kararlı ve yüksek performanslı sonuçları üretmiştir. Bununla birlikte, Logistic Regression gibi daha basit modellerin de uygun problem tanımı ve özellik mühendisliği ile rekabetçi sonuçlar sunduğu görülmüştür.

Bu durum, futbol maç sonucu tahmininde başarının yalnızca kullanılan algoritmanın karmaşıklığına bağlı olmadığını; problem tanımı, veri temsili ve modelleme stratejisinin birlikte ele alınmasının belirleyici olduğunu göstermektedir. Daha karmaşık modellerin her zaman anlamlı bir performans üstünlüğü sağlamadığı, bazı durumlarda yorumlanabilirlikten ödün verilmesine neden olduğu gözlemlenmiştir.


Klasik Üç Sınıflı Yaklaşım ile Karşılaştırma

Tablo 10. Klasik Üç Sınıflı Yaklaşım ile Önerilen İki Aşamalı Yaklaşımın Karşılaştırılması

Approach	Accuracy	Macro F1
Three-class classification	0.4476	0.4303
Two-stage classification	0.4949	0.4365

Önerilen iki aşamalı modelleme yaklaşımı, klasik üç sınıflı sınıflandırma yöntemiyle doğrudan karşılaştırılmıştır. Karşılaştırma sonuçları, özellikle beraberlik sınıfının ayırt edilebilirliği açısından iki aşamalı yapının belirgin avantajlar sunduğunu ortaya koymaktadır. Klasik üç sınıflı yaklaşım ile önerilen iki aşamalı modelin karşılaştırmalı performans sonuçları Tablo 10'da sunulmaktadır. Tablo 10 incelendiğinde, önerilen iki aşamalı yaklaşımın hem Accuracy hem de Macro F1 metriklerinde klasik üç sınıflı modele kıyasla iyileşme sağladığı görülmektedir. Accuracy değeri 0.4476'dan 0.4949'a yükselirken, Macro F1 skoru 0.4303'ten 0.4365'e artmıştır. Her ne kadar artış oranı sınırlı olsa da, özellikle Macro F1 değerindeki iyileşme, performans kazanımının yalnızca çoğunluk sınıflardan kaynaklanmadığını göstermektedir. Bu bulgu, iki aşamalı yapının sınıf bazlı performans dağılımını daha dengeli hâle getirdiğini desteklemektedir.

Bu durum, genel doğruluğun tek başına model başarımını yansıtmadığını ve karar yapısının yeniden yapılandırılmasının anlamlı katkı sağladığını göstermektedir. Üç sınıflı modellerde, genel doğruluk metriği kabul edilebilir seviyelerde olsa dahi, beraberlik sınıfına ilişkin tahminlerin zayıf kaldığı ve model kararlarının güvenilirliğinin sınırlı olduğu gözlemlenmiştir. Buna karşılık, iki aşamalı yaklaşımda beraberlik kararı bağımsız olarak ele alındığından, bu sınıfa ilişkin performans daha dengeli ve anlamlı hâle gelmiştir (Fischer ve Heuer, 2025; Loukas vd., 2024).



Şekil 2. ROC Eğrileri Karşılaştırması

ROC eğrileri üzerinden yapılan karşılaştırma Şekil 2’de gösterilmektedir. Şekil 2 incelendiğinde, iki aşamalı yaklaşımın özellikle düşük yanlış pozitif oranlarında daha yüksek doğru pozitif oranı ürettiği ve dolayısıyla daha güçlü bir ayırt edicilik sağladığı görülmektedir.

Bulguların Tartışılması

Elde edilen bulgular, futbol maç sonucu tahmininde problem tanımının model başarımı üzerindeki belirleyici rolünü açık biçimde ortaya koymaktadır. Önerilen iki aşamalı yapı, sınıf dengesizliği problemini doğrudan veri düzeyinde çözmek yerine, karar sürecini daha doğal ve hiyerarşik bir biçimde ele alarak yapısal bir çözüm sunmaktadır.

Bu yaklaşım hem model performansını artırmakta hem de elde edilen sonuçların yorumlanabilirliğini güçlendirmektedir. Özellikle gerçek dünya uygulamalarında, karar süreçlerinin şeffaflığı ve güvenilirliği açısından bu tür yapılandırılmış modellerin önemli avantajlar sunduğu değerlendirilmektedir. Önerilen iki aşamalı sınıflandırma yaklaşımının deneysel sonuçları ayrıntılı biçimde sunulmuş ve klasik üç sınıflı yöntemlerle karşılaştırmalı olarak değerlendirilmiştir. Bulgular, önerilen yaklaşımın futbol maç sonucu tahmininde daha kararlı, yorumlanabilir ve dengeli sonuçlar ürettiğini göstermektedir.

Sonuç ve Gelecek Çalışmalar

Bu çalışmada, futbol maç sonucu tahmin problemi İngiltere Premier Ligi verileri üzerinden ele alınmış ve literatürde yaygın olarak kullanılan üç sınıflı sınıflandırma yaklaşımına alternatif olarak iki aşamalı bir modelleme çerçevesi önerilmiştir. Çalışmanın temel çıkış noktası, futbol maç sonuçlarının doğası gereği tek aşamalı ve düz bir sınıflandırma problemi olarak ele alınmasının, özellikle beraberlik sınıfı ve sınıf dengesizliği açısından yapısal sınırlılıklar içerdiği varsayımdır.

Önerilen iki aşamalı yaklaşımda, maçların berabere sonuçlanıp sonuçlanmayacağına ilişkin karar ile kazanan tarafın belirlenmesi birbirinden ayrıştırılmış ve bu iki karar süreci ayrı ikili sınıflandırma problemleri olarak modellenmiştir. Bu yapı sayesinde, beraberlik sınıfı bağımsız bir karar problemi olarak ele alınmış ve sınıf dengesizliği problemi veri düzeyinde müdahalelere başvurulmadan, problem tanımı düzeyinde yapısal olarak ele alınmıştır.

DeneySEL sonuçlar, önerilen yaklaşımın klasik üç sınıflı modellere kıyasla daha kararlı ve yorumlanabilir sonuçlar ürettiğini göstermektedir. Özellikle F1 skoru ve ROC-AUC metrikleri üzerinden yapılan değerlendirmeler, iki aşamalı yapının karar sınırlarını daha net biçimde öğrenebildiğini ve belirsiz sınıflarda daha güvenilir tahminler sunduğunu ortaya koymuştur. Elde edilen bulgular, futbol maç sonucu tahmininde başarının yalnızca kullanılan algoritmanın karmaşıklığına değil, problemin nasıl tanımlandığına ve yapılandırıldığına güçlü biçimde bağlı olduğunu ve önerilen iki aşamalı yaklaşımın yalnızca algoritmik bir alternatif sunmadığını, aynı zamanda çok sınıflı karar problemlerinde yapısal yeniden formülasyonun performans üzerindeki etkisini deneySEL olarak ortaya koyduğunu göstermektedir. Accuracy değerindeki artış (0.4476'dan 0.4949'a) ve Macro F1 skorundaki iyileşme, karar sürecinin hiyerarşik ayrıştırılmasının sınıf bazlı dengeyi güçlendirdiğini desteklemektedir. Bu sonuçlar, spor analitiği alanında model karmaşıklığını artırmaktan ziyade problem tanımının yeniden yapılandırılmasının daha verimli bir araştırma yönü olabileceğine işaret etmektedir.

Bu çalışmanın önemli bir katkısı, algoritma merkezli performans artırma yaklaşımlarının ötesine geçerek, problem tanımının yeniden yapılandırılmasının model başarımı üzerindeki etkisini deneySEL olarak ortaya koymasındır. Görece basit makine öğrenmesi algoritmalarının dahi, uygun bir problem tanımı ve özellik mühendisliği ile rekabetçi ve istikrarlı sonuçlar üretebildiği gösterilmiştir. Bu yönüyle çalışma, futbol maç sonucu tahminine ilişkin literatüre yöntemsel ve mimari bir bakış açısı sunmaktadır.

Bununla birlikte, çalışmanın bazı sınırlılıkları bulunmaktadır. Kullanılan veri setinin yalnızca İngiltere Premier Ligi ve belirli sezonlarla sınırlı olması, elde edilen sonuçların diğer liglere veya farklı futbol ekosistemlerine doğrudan genellenebilirliğini kısıtlamaktadır. Ayrıca çalışmada yalnızca maç öncesi istatistikler kullanılmış; oyuncu kadroları, sakatlık bilgileri, hava koşulları veya bahis oranları gibi bağlamsal değişkenler kapsam dışı bırakılmıştır.

Gelecek çalışmalarda, önerilen iki aşamalı modelleme yaklaşımının farklı ligler ve turnuvalar üzerinde test edilmesi, genellenebilirlik açısından önemli bir araştırma alanı sunmaktadır. Ayrıca bağlamsal ve dinamik değişkenlerin modele dâhil edilmesi, karar sürecinin daha da zenginleştirilmesine katkı sağlayabilir. Bunun yanı sıra, iki aşamalı yapı içerisinde farklı maliyet duyarlı öğrenme stratejilerinin veya olasılıksal karar mekanizmalarının entegrasyonu, pratik uygulamalar açısından dikkate değer bir araştırma yönü olarak değerlendirilmektedir (Rico-González vd., 2023).

Sonuç olarak, bu çalışma futbol maç sonucu tahmininde algoritma seçiminden ziyade problem tanımının ve modelleme stratejisinin belirleyici rolüne dikkat çekmekte; daha dengeli, yorumlanabilir ve uygulanabilir tahmin sistemleri geliştirilmesi için alternatif bir çerçeve sunmaktadır.

Destek ve Teşekkür

Bu çalışma, Hayri Sever danışmanlığında Alınaz Aksu tarafından tamamlanan “İngiltere Premier Liginde Maç Sonuçlarının Tahmini için İki Aşamalı Makine Öğrenmesi Modeli: Özellik Mühendisliği ve Sınıflandırma Yaklaşımları” başlıklı yüksek lisans tezinden üretilmiştir (Aksu, 2026; Tez No. 1009185).

Yazar Katkısı

Alinaz Aksu, temel yazımı gerçekleştirmiş, literatür taramasını yapmış, deneysel çalışmaları tasarlamış, verilerin toplanması ve analiz süreçlerini yürütmüş, makalenin ilk taslağını yazmış ve revizyonlarını yapmıştır. *Hayri Sever*, danışman olarak çalışmanın bilimsel hipotezlerini belirlemiş, test edilmesi gereken modelleri tespit etmiş, model seçimlerinde ekleme ve çıkarma işlemlerini gerçekleştirmiş, çalışmanın metodolojisini gözden geçirmiş ve makalenin son halinin bilimsel bütünlüğünü onaylamıştır. *Hakan Yıldırım*, makale aşamasında elde edilen sonuçların doğruluğunu doğrulamış, istatistiksel analizlerin kontrolünü yapmış, sonuçların yorumlanmasına katkı sağlamış ve makalenin teknik geçerliliğini test etmiştir. Tüm yazarlar makaleyi birlikte yazmış, okumuş, tartışmış ve son halini onaylamıştır.

Etik

Bu makalenin yayınlanmasıyla ilgili herhangi bir etik sorun bulunmamaktadır.

Çıkar Çatışması

Yazarlar herhangi bir çıkar çatışması olmadığını belirtmektedir.

ORCID

Alinaz AKSU  <https://orcid.org/0009-0008-2921-4922>

Hakan YILDIRIM  <https://orcid.org/0000-0002-5959-2691>

Hayri SEVER  <https://orcid.org/0000-0002-8261-0675>

Kaynaklar

- Aksu, A. (2026). *A two-stage machine learning model for football match outcome prediction* (Tez No. 1009185) [Yüksek lisans tezi, Çankaya Üniversitesi]. YÖK Ulusal Tez Merkezi.
- Alfredo, Y. F. ve Isa, S. M. (2019). Football match prediction with tree-based model classification. *International Journal of Intelligent Systems and Applications*, 11(7), 20-28. <https://doi.org/10.5815/ijisa.2019.07.03>
- Baboota, R. ve Kaur, H. (2019). Predictive analysis and modelling football results using machine learning approach for English Premier League. *International Journal of Forecasting*, 35(2), 741-755. <https://doi.org/10.1016/j.ijforecast.2018.01.003>
- Chen, Z. A. (2025). A hybrid machine learning framework for soccer match outcome prediction: Incorporating bivariate Poisson distribution. *ITM Web of Conferences*, 70, 03020. <https://doi.org/10.1051/itmconf/20257003020>
- Constantinou, A. C., ve Fenton, N. E. (2013). Profiting from arbitrage and odds biases of the European football gambling market. *The Journal of Gambling Business and Economics*, 7(2), 41–70. <https://doi.org/10.5750/jgbe.v7i2.630>
- Cristianini, N. ve Shawe-Taylor, J. (2000). *An introduction to support vector machines and other kernel-based learning methods*. Cambridge University Press.
- Eryarsoy, E., ve Delen, D. (2019). Predicting the outcome of a football game: A comparative analysis of single and ensemble analytics methods. In *Proceedings of the 52nd Hawaii International Conference on System Sciences* (pp. 1107–1115). <https://doi.org/10.24251/HICSS.2019.136>
- Fischer, M., ve Heuer, A. (2025). Match predictions in soccer: Machine learning vs. Poisson approaches. In D. Memmert (Ed.), *Artificial intelligence and machine learning in sports science* (pp. 91–102). Springer. https://doi.org/10.1007/978-3-662-70155-3_7

- Groll, A., Ley, C., Schauburger, G., ve Van Eetvelde, H. (2019). A hybrid random forest to predict soccer matches in international tournaments. *Journal of Quantitative Analysis in Sports*, 15(4), 271–287. <https://doi.org/10.1515/jqas-2018-0060>
- Krawczyk, B. (2016). Learning from imbalanced data: Open challenges and future directions. *Progress in Artificial Intelligence*, 5(4), 221–232. <https://doi.org/10.1007/s13748-016-0094-0>
- Lee, J., Kim, J., Kim, H. ve Lee, J.-S. (2022). A Bayesian approach to predict football matches with changed home advantage in spectator-free matches after the COVID-19 break. *Entropy*, 24(3), 366. <https://doi.org/10.3390/e24030366>
- Loukas, K., Karapiperis, D., Feretzakis, G. ve Verykios, V. S. (2024). Predicting football match results using a Poisson regression model. *Applied Sciences*, 14(16), 7230. <https://doi.org/10.3390/app14167230>
- Rana, D., ve Vasudeva, A. (2019). Premier League match result prediction using machine learning [Project report]. Jaypee University of Information Technology.
- Rico-González, M., Pino-Ortega, J. P., Méndez, A., Clemente, F. M. ve Baca, A. (2023). Machine learning application in soccer: A systematic review. *Biology of Sport*, 40(1), 249–263. <https://doi.org/10.5114/biolsport.2023.112970>
- Sathe, S., Kasat, D., Kulkarni, N. ve Satao, R. (2017). Predictive analysis of Premier League using machine learning. *International Journal of Innovative Research in Computer and Communication Engineering*, 5(3), 4121–4124. <https://ijircce.com/admin/main/storage/app/pdf/losl28bHbQP5sQkmz47Ez0gPQqvCdr7wYYHfogh.pdf>
- Tang, J., Alelyani, S., ve Liu, H. (2014). Feature selection for classification: A review. In C. C. Aggarwal (Ed.), *Data classification: Algorithms and applications* (pp. 37–64). CRC Press. <https://doi.org/10.1201/b17320>
- Wan, X. (2019). Influence of feature scaling on convergence of gradient iterative algorithm. *Journal of Physics: Conference Series*, 1213(3), 032021. <http://doi.org/10.1088/1742-6596/1213/3/032021>
- Wong, A., Li, E., Le, H., Bhangu, G. ve Bhatia, S. (2025). A predictive analytics framework for forecasting soccer match outcomes using machine learning models. *Decision Analytics Journal*, 14, 100537. <https://doi.org/10.1016/j.dajour.2024.100537>