Premium e-Journal of Social Sciences

Premium Sosyal Bilimler E-Dergisi
Uluslararası Hakemli Dergi- International Refereed Journal
ISSN: 2687-5640

Received / Makale Geliş Tarihi 02.09.2025
Published / Yayınlanma Tarihi 30.11.2025
Volume (Issue) Cilt (Sayı) 9 (60)
pp / ss 1326-1344

Research Article /Araştırma Makalesi
10.5281/zenodo.17829182
Mail: editor@pejoss.com

Öğr.Gör.Dr. Mustafa Of
https://orcid.org/0000-0002-7924-9073
Kocaeli Üniversitesi, Kocaeli Meslek Yüksekokulu, Kocaeli / TÜRKİYE
ROR Id: https://ror.org/0411seq30

Öğr.Gör. İsmail Kılıçaslan
https://orcid.org/0000-0002-8443-9912
Kocaeli Üniversitesi, Ali Rıza Veziroğlu Meslek Yüksekokulu, Kocaeli / TÜRKİYE
ROR Id: https://ror.org/0411seq30

Sınıf İçi Takım Liderliği Algısının Makine Öğrenimi Yöntemleriyle Modellenmesi: Türkiye'de Önlisans ve Lisans Öğrencileri Üzerine Bir İnceleme

Modeling In-Class Team Leadership Perception with Machine Learning Methods: A Study on Associate and Undergraduate Students in Turkey

ÖZET

Bu çalışma, Türkiye'de öğrenim gören önlisans ve lisans öğrencilerinin öğretim elemanlarına yönelik sınıf içi takım liderliği algılarını makine öğrenimi yöntemleri kullanarak modellemeyi amaçlamaktadır. Araştırmada, öğretim elemanlarının iş birliği sağlama, öğrencileri güçlendirme ve etkili iletişim kurma davranışlarını ölçen çok boyutlu bir ölçek kullanılmış ve toplam 175 katılımcıdan elde edilen veriler analiz edilmiştir. Çalışmanın temel hedefi, öğrenci algılarına dayalı liderlik davranışlarının hangi değişkenlerden etkilendiğini belirlemek ve bu algıların makine öğrenimi modelleriyle tahmin edilebilirliğini incelemektir. Bu kapsamda, TensorFlow tabanlı yapay sinir ağı modelleri geliştirilmiş; ölçeğin alt boyutlarını ve genel liderlik algısını tahmin etmede modelin performansı değerlendirilmiştir. Elde edilen sonuçlar, öğrenci geri bildirimlerinde belirli davranış kümelerinin liderlik algısının güçlü göstergeleri olduğunu ortaya koymuştur. Ayrıca model, sınıf içi liderliğe ilişkin öğrenci algılarını yüksek doğrulukla tahmin ederek eğitim ortamlarında liderlik davranışlarının veri temelli biçimde analiz edilmesine imkân sağlamıştır. Bu yönüyle araştırma, eğitimde öğretim elemanı davranışlarının değerlendirilmesinde yapay zekâ ve makine öğrenimi yaklaşımlarının nasıl kullanılabileceğine dair yenilikçi bir çerçeve sunmakta ve gelecekte yapılacak araştırmalar için önemli bir metodolojik temel oluşturmaktadır.
Anahtar Sözcükler: Sınıf İçi Liderlik, Takım Liderliği Algısı, Makine Öğrenimi, TensorFlow, Yapay Sinir Ağları

ABSTRACT

This study aims to model the in-class team leadership perceptions of associate and undergraduate students studying in Turkey towards faculty members using machine learning methods. In the study, a multidimensional scale measuring the behaviors of faculty members to collaborate, empower students and communicate effectively was used and data obtained from a total of 175 participants were analyzed. The main goal of the study is to determine which variables affect leadership behaviors based on student perceptions and to examine the predictability of these perceptions with machine learning models. In this context, TensorFlow-based artificial neural network models have been developed; The performance of the model in estimating the sub-dimensions of the scale and the overall perception of leadership was evaluated. The results obtained revealed that certain behavioral clusters in student feedback are strong indicators of leadership perception. Additionally, the model predicted student perceptions of classroom leadership with high accuracy, enabling data-driven analysis of leadership behaviors in educational settings. In this respect, the research provides an innovative framework on how artificial intelligence and machine learning approaches can be used in the evaluation of instructor behavior in education and forms an important methodological basis for future research.
Keywords: Classroom Leadership, Team Leadership Perception, Machine Learning, TensorFlow, Artificial Neural Networks.

1. GİRİŞ

Eğitim ortamlarında öğretim elemanlarının sergilediği liderlik davranışları, öğrencilerin akademik performanslarını, sınıf içi etkileşimlerini ve öğrenme motivasyonlarını önemli ölçüde etkilemektedir (Katzenmeyer & Moller, 2009). Özellikle yükseköğretim düzeyinde öğretim elemanlarının sınıf içi iş birliğini teşvik etmesi, çatışmaları yönetmesi, öğrencileri güçlendirmesi ve etkili iletişim kurması; öğrenme ortamının niteliğini artıran temel liderlik bileşenleri olarak kabul edilmektedir (Beycioğlu & Aslan, 2010; Murphy vd., 2009). Bu nedenle öğrenci algılarına dayalı sınıf içi liderlik davranışlarının incelenmesi hem eğitim kalitesinin değerlendirilmesinde hem de öğretim elemanlarının mesleki gelişim süreçlerinin desteklenmesinde kritik bir öneme sahiptir.

Son yıllarda eğitim bilimlerinde veri temelli karar verme ve öğrenme analizleri giderek yaygınlaşmış; yapay zekâ ve makine öğrenimi yöntemleri, öğrenci davranışlarını, öğretimsel süreçleri ve eğitim çıktılarının tahmin edilmesini kolaylaştıran araçlar hâline gelmiştir (Zawacki-Richter vd., 2019). Bu yöntemler, klasik istatistiksel modellerin ötesine geçerek karmaşık ilişkileri keşfedebilmekte ve yüksek doğruluk oranlarıyla tahmin modelleri üretebilmektedir. Özellikle yapay sinir ağları, eğitim verilerindeki çok boyutlu ve doğrusal olmayan örüntüleri yakalamada etkili bir yaklaşım olarak değerlendirilmektedir (LeCun, Bengio & Hinton, 2015).

Sınıf içi liderlik davranışlarının makine öğrenimi teknikleriyle modellenmesi ise literatürde henüz sınırlı sayıda ele alınmış yenilikçi bir konudur. Liderlik davranışları genel olarak eğitim yönetimi literatüründe sıklıkla araştırılmış olsa da (Harris, 2013; Leithwood & Jantzi, 2006), bu davranışların makine öğrenimiyle tahmin edilmesi ve öğrenci algılarına ilişkin örüntülerin yapay zekâ yoluyla ortaya çıkarılması yeni bir metodolojik katkı sunmaktadır. Bu bağlamda, Türkiye'de önlisans ve lisans düzeyinde öğrenim gören öğrencilerden toplanan verilerle geliştirilecek makine öğrenimi modelleri, yükseköğretimde sınıf içi liderliğin veri temelli analizine önemli bir perspektif kazandıracaktır.

Bu çalışmanın amacı, öğretim elemanlarının sınıf içindeki takım liderliği davranışlarına ilişkin öğrenci algılarının TensorFlow tabanlı makine öğrenimi yöntemleri kullanılarak modellenmesi ve tahmin edilmesidir. Çalışma, üç temel katkı sunmaktadır. Yükseköğretim bağlamında sınıf içi liderliğin öğrenci algılarına dayalı ölçülmesi, bu algıların makine öğrenimi modelleriyle tahmin edilebilirliğinin incelenmesi, veri temelli liderlik değerlendirme yaklaşımının eğitim alanına kazandırılması.

Bu yönleriyle araştırma, sınıf içi liderliği yalnızca betimleyici yöntemlerle değil, aynı zamanda kestirimsel modellerle (Predictive models) değerlendiren bütüncül bir analitik çerçeve ortaya koymakta ve eğitimde yapay zekâ uygulamalarına yenilikçi bir katkı sunmaktadır. Kestirimsel modeller, tarihsel veri kümelerinden ve istatistiksel algoritmalardan faydalanarak gelecekteki olayları veya davranışları tahmin etmek amacıyla geliştirilen matematiksel yapılardır. Bu modellerin temel işlevi, veri madenciliği, makine öğrenmesi ve yapay zekâ tekniklerini kullanarak bir veri kümesi içindeki karmaşık desenleri ve ilişkileri öğrenmektir. Elde edilen bu bilgi, belirli bir sonucun (örneğin, bir olayın gerçekleşme ihtimali veya öngörülen bir değer) ne olacağını öngörmek için kullanılır (Hastie, Tibshirani & Friedman, 2009).

2. YÖNTEM

2.1. Araştırmanın Modeli

Bu araştırma, öğretim elemanlarının sınıf içi takım liderliği davranışlarına yönelik öğrenci algılarını kestirimsel (predictive) bir makine öğrenimi modeli aracılığıyla inceleyen nicel bir araştırma modeline dayanmaktadır. Çalışmada temel amaç, öğrencilerden toplanan liderlik algısı verilerini kullanarak öğretim elemanlarının sınıf içi liderlik davranışlarının makine öğrenimi yöntemleriyle tahmin edilmesidir. Bu nedenle araştırma tasarımı, klasik tanımlayıcı istatistiksel yaklaşımların ötesine geçerek sonuç değişkeninin yapay sinir ağlarıyla modellenmesine odaklanan ilişkisel tarama modeli ve deneysel olmayan kestirimsel modelleme yaklaşımının bir bileşimi olarak kurgulanmıştır.

Makine öğrenimi (Machine Learning-ML) ve özellikle yapay sinir ağları (Artificial Neural Networks – ANN), eğitim verilerindeki karmaşık örüntüleri tespit etmede etkili bir yöntem olarak görülmekte ve eğitim araştırmalarında giderek daha fazla kullanılmaktadır (Zawacki-Richter vd., 2019; LeCun, Bengio & Hinton, 2015). Bu çalışmada TensorFlow tabanlı derin öğrenme yaklaşımı kullanılarak liderlik davranışlarına ilişkin öğrenci yanıtları girdi (input) değişkenleri, ölçeğin alt boyutları ise çıktı (output) değişkenleri olarak modellenmiştir. Bu sayede, öğrencilerin liderlik algılarının hangi faktörlere dayanarak şekillendiği ve bu algıların nasıl bir örüntü oluşturduğu veri odaklı biçimde ortaya konulmuştur.

Araştırma modeli, veri toplama aracıyla elde edilen çok boyutlu Likert verilerinin makine öğrenimi için uygun biçimde işlenmesini, eğitim–test kümelerine ayrılmasını, sinir ağı mimarisinin oluşturulmasını ve model performansının çeşitli ölçütlerle değerlendirilmesini kapsamaktadır. Bu yönüyle çalışma, eğitim liderliğinin değerlendirilmesinde yapay zekâ yaklaşımlarını kullanan yenilikçi ve uygulamalı bir araştırma modeli ortaya koymaktadır.

2.2. Katılımcılar ve Çalışma Grubu

Bu araştırmanın çalışma grubunu, Türkiye'de farklı üniversitelerde öğrenim görmekte olan önlisans ve lisans düzeyindeki öğrenciler oluşturmaktadır. Çevrim içi anket yoluyla elde edilen 183 yanıt içerisinden eksik veya tutarsız veriler temizlendikten sonra, 175 katılımcıdan elde edilen veri seti analiz için kullanılmıştır. Katılımcılar gönüllü olarak çalışmaya dahil olmuş ve tüm katılımcılara araştırmanın amacı, gizlilik ilkeleri ve veri kullanım koşulları hakkında ön bilgilendirme yapılmıştır.

Araştırmaya dahil olan öğrencilerin demografik özellikleri incelendiğinde; yaş aralığının 18–34 arasında değiştiği, çoğunluğunu 19–23 yaş grubunun oluşturduğu görülmektedir. Katılımcıların öğrenim düzeylerine bakıldığında hem önlisans hem de lisans öğrencilerinin temsil edildiği; çeşitli meslek yüksekokulları, fakülteler ve programlardan gelen geniş bir dağılımın mevcut olduğu anlaşılmaktadır. Bu durum, sınıf içi liderlik algısına ilişkin modellerin farklı öğrenci profilleri üzerinde genellenebilirliğini artırmaktadır.

Katılımcıların demografik özellikleri Tablo 1'de özetlenmiştir.

Tablo 1. Katılımcıların Demografik Özellikleri (N = 175)

Değişken	Kategori	n	%
Cinsiyet	Kadın	100	57,1%
	Erkek	75	42,9%
Yaş Grubu	18–20	28	16,0%
	21–23	47	26,9%
	24 ve üzeri	100	57,1%
Yerleşim Yeri	Büyükşehir	153	87,4%
	Şehir	21	12,0%
	Kırsal	1	0,6%
Sosyoekonomik Düzey	Orta	109	62,3%
	İyi	49	28,0%
	Kötü	17	9,7%
Öğrenim Türü	Önlisans	119	68%
	Lisans	56	32%
Öğrenim Düzeyi	Mezun	48	27,4%
	Aktif Öğrenci	127	72,6%

Çalışmanın demografik verileri incelendiğinde, toplam 175 katılımcının %57,1'inin kadın, %42,9'unun ise erkek olduğu görülmektedir. Yaş dağılımı incelendiğinde öğrencilerin önemli bir kısmının genç yetişkinlerden oluştuğu; %16'sının 18–20 yaş, %26,9'unun 21–23 yaş aralığında yer aldığı ve %57,1'inin 24 yaş ve üzerinde olduğu belirlenmiştir. Katılımcıların büyük çoğunluğu (%87,4) büyükşehirlerde ikamet ettiğini belirtmiş; şehir ve kırsal bölgelerde yaşayan öğrencilerin oranı sırasıyla %12 ve %0,6'da kalmıştır. Sosyoekonomik düzey açısından değerlendirildiğinde, öğrencilerin ağırlıklı olarak orta gelir grubunda (%62,3) yer aldığı, %28'inin iyi ve %9,7'sinin düşük gelir düzeyine sahip olduğu görülmektedir. Öğrenim türü açısından ise katılımcıların %68'inin önlisans, %32'sinin lisans programlarında öğrenim gördüğü belirlenmiştir. Ayrıca, öğrenim düzeyine ilişkin veriler öğrencilerin %27,4'ünün mezun durumda olduğunu, %72,6'sının ise aktif öğrenci olarak eğitimine devam ettiğini göstermektedir. Bu demografik yapı, araştırmanın çeşitli sosyoekonomik arka planlara, yaş gruplarına ve farklı yükseköğretim kademelerine mensup öğrencilerden oluşan geniş ve heterojen bir örneklem üzerinde gerçekleştirildiğini ortaya koymaktadır.

2.3. Veri Toplama Aracı

Bu araştırmada veri toplama aracı olarak, öğretim elemanlarının sınıf içi takım liderliği davranışlarına yönelik öğrenci algılarını ölçmek amacıyla hazırlanmış çok boyutlu bir ölçek kullanılmıştır. Ölçek, kuramsal temelini Katzenmeyer ve Moller (2009) tarafından geliştirilen Teacher Leadership Framework'ten almakta olup, Türkiye'de Beycioğlu ve Aslan (2010) tarafından Türkçeye uyarlanan Öğretmen Liderliği Ölçeği'nin yükseköğretim bağlamına uyarlanmış bir versiyonudur. Bu çalışmada ölçek maddeleri, "öğretmen" kavramı yerine "öğretim elemanı", "sınıf ortamı" kavramı yerine "sınıf içi takım liderliği" ifadesini temel alacak şekilde yeniden düzenlenmiştir.

Ölçme aracı toplam 20 maddeden oluşmakta ve üç boyut hâlinde yapılandırılmıştır. İlk boyut olan İşbirliği ve Takım Liderliği (ISBIRTKLD), öğretim elemanının sınıf içinde işbirliği ortamı oluşturma, çatışmaları yönetme, öğrencilerin görüşlerine değer verme ve katılımı destekleme davranışlarını ölçen 8 maddeden oluşmaktadır (ISBIRTKLD1–ISBIRTKLD8). İkinci boyut olan Güçlendirme ve Harekete Geçirme (GCLNDR_HGEC), öğretim elemanının öğrencileri motive etme, yönlendirme, yeteneklere göre sorumluluk verme, vizyon sunma ve kariyer gelişimini teşvik etme davranışlarına ilişkin 8 maddeden oluşmaktadır (GCLNDR_HGEC1–GCLNDR_HGEC8). Üçüncü boyut olan Etkili İletişim (ILTSM) ise öğretim elemanının iletişim becerisi, samimiyeti, dürüstlüğü ve öğrenci beklentilerine duyarlılığını değerlendiren 4 maddeden oluşmaktadır (ILTSM1–ILTSM4).

Tüm maddeler 5'li Likert tipi derecelendirme ile cevaplanmıştır. Katılımcılardan her bir maddeyi şu seçeneklere göre değerlendirmeleri istenmiştir: (1) Kesinlikle Katılmıyorum, (2) Katılmıyorum, (3) Kararsızım, (4) Katılıyorum, (5) Kesinlikle Katılıyorum.

Bu yapı, öğrenci algılarını sayısal olarak ifade etmeyi kolaylaştırmakta ve makine öğrenimi modellerinde kullanılmak üzere analiz edilebilir veri sağlamaktadır.

Ölçekte yer alan maddeler, özgün ölçeğin faktör yapısıyla uyumlu olacak şekilde düzenlenmiş; ancak yükseköğretim bağlamının gereklilikleri doğrultusunda terminolojik uyarlamalar yapılmıştır. Anket formunun ilk kısmında demografik bilgiler yer almakta, ikinci kısmında ise sınıf içi takım liderliği davranışlarını ölçen 20 madde bulunmaktadır.

2.4. Veri Toplama Süreci

Bu araştırmanın verileri, çevrim içi veri toplama araçlarından biri olan Google Formlar kullanılarak elde edilmiştir. Anket formu, katılımcılara üniversite birimlerinin e-posta grupları, öğrenci iletişim platformları ve ders duyuru kanalları aracılığıyla iletilmiş; çalışmaya katılım tamamen gönüllülük esasına dayalı olarak gerçekleştirilmiştir. Veri toplama süreci öncesinde katılımcılara araştırmanın amacı, kapsamı, gizlilik koşulları ve verilerin yalnızca bilimsel amaçlarla kullanılacağı açık bir biçimde bildirilmiştir. Formun giriş bölümünde bilgilendirilmiş onam açıklaması yer almış, katılımcıların anketi doldurmaya başlaması onam vermeleri şeklinde kabul edilmiştir.

Anket yaklaşık 3–5 dakika sürede tamamlanabilecek şekilde yapılandırılmış ve herhangi bir kişisel kimlik bilgisi talep edilmemiştir. Bu sayede katılımcıların yanıtlama sürecinde kendilerini daha rahat ifade etmeleri ve liderlik algılarına ilişkin maddelere içtenlikle yanıt verebilmeleri hedeflenmiştir. Veri toplama süreci yaklaşık iki haftalık bir dönem boyunca açık tutulmuş ve toplam 175 geçerli cevap analizlere dâhil edilmiştir. Eksik, hatalı veya tutarsız veri içeren kayıtlar çalışma kapsamı dışında bırakılmıştır.

Bu yöntem, hem geniş bir öğrenci kitlesine erişim sağlaması hem de veri giriş hatalarını minimize etmesi nedeniyle çevrim içi anketlerin eğitim araştırmalarındaki kullanımına uygun, pratik ve güvenilir bir veri toplama yaklaşımı sunmaktadır.

2.5. Veri Ön İşleme

Makine öğrenimi modellerinin başarısı, büyük ölçüde kullanılan verinin niteliğine ve analiz öncesinde gerçekleştirilen veri ön işleme adımlarına bağlıdır. Bu nedenle araştırmada Google Form aracılığıyla toplanan ham veriler, TensorFlow tabanlı yapay sinir ağı modeline uygun hâle getirilmeden önce kapsamlı bir ön işleme sürecinden geçirilmiştir. Eğitim verilerinin analiz için temizlenmesi, dönüştürülmesi ve yapılandırılması, özellikle insan temelli sosyal bilimler verilerinde model performansını önemli ölçüde artıran kritik bir aşamadır (García vd., 2016; Kuhn & Johnson, 2013).

İlk aşamada, veri seti eksik (missing), uygunsuz (invalid) veya tutarsız (incoherent) değerler açısından incelenmiştir. Eksik değer içeren kayıt bulunmamakla birlikte, cevap bütünlüğünü bozabilecek hatalı girişler kontrol edilmiş ve bu tür kayıtlar çalışma dışında tutulmuştur. Ardından, anket maddelerine verilen nitel cevapların (örneğin "Katılıyorum", "Kesinlikle Katılmıyorum") makine öğrenimi modelleri için gerekli olan sayısal Likert karşılıklarına dönüştürülmesi sağlanmıştır. Bu çalışma kapsamında kullanılan tüm maddeler, beşli Likert tipinde olup şu şekilde yeniden kodlanmıştır:

1 = Kesinlikle Katılmıyorum, 2 = Katılmıyorum, 3 = Kararsızım, 4 = Katılıyorum, 5 = Kesinlikle Katılıyorum.

Bu dönüşüm, modelin giriş değişkenlerinin nicel forma getirilmesini sağlayarak yapay sinir ağlarının veriyi etkin biçimde işlemesine olanak tanımıştır. Literatürde de sosyal bilimlerde kullanılan ölçeklerin makine öğrenimi süreçlerinde bu şekilde sayısallaştırılması yaygın olarak önerilmektedir (LeCun, Bengio & Hinton, 2015).

Veri ön işleme sürecinin üçüncü aşamasında, tüm bağımsız değişkenler (ISBIRTKLD, GCLNDR_HGEC, ILTSM maddeleri) model eğitiminde dengesizliğe neden olabilecek aykırı değerler açısından incelenmiştir. Öğrenci cevap dağılımlarının doğal sınırlara sahip olması (1–5 Likert) nedeniyle aykırı değer bulunmamış, bu nedenle herhangi bir normalizasyon ya da standardizasyon zorunlu görülmemiştir. Bununla birlikte TensorFlow modelleri, 0–1 aralığında ölçeklenmiş verilere karşı daha kararlı davranabildiğinden (Goodfellow, Bengio & Courville, 2016), alternatif modeller için Min–Max normalizasyonun uygulanabilir olduğu not edilmiştir.

Son aşamada, veri seti eğitim (%70) ve test (%30) olmak üzere iki alt kümeye ayrılmıştır. Bu ayrım, modelin hem öğrenme aşamasında yeterli veriyle beslenmesini hem de bağımsız test verisi üzerinde nesnel performans değerlendirmesi yapılmasını sağlamıştır (Hastie, Tibshirani & Friedman, 2009). Böylece, TensorFlow tabanlı yapay sinir ağı modeli için temiz, tutarlı ve analiz edilmeye hazır bir veri yapısı elde edilmiştir.

2.6. Makine Öğrenimi Yaklaşımı

Bu araştırmada öğretim elemanlarının sınıf içi takım liderliği davranışlarına ilişkin öğrenci algılarını tahmin etmek amacıyla makine öğrenimi temelli bir yaklaşım benimsenmiş ve modelleme süreci TensorFlow kütüphanesi kullanılarak gerçekleştirilmiştir. Makine öğrenimi, veriden örüntü çıkarma ve geleceğe ilişkin tahminlerde bulunma kapasitesi sayesinde eğitim araştırmalarında giderek yaygınlaşan güçlü bir analitik yöntem hâline gelmiştir (Kuhn & Johnson, 2013). Özellikle sosyal bilimlerde yer alan çok değişkenli ve karmaşık ilişkilerin modellenmesinde yapay sinir ağları geleneksel istatistiksel yöntemlere kıyasla daha esnek ve yüksek doğruluk sağlayan bir alternatif sunmaktadır (Goodfellow, Bengio & Courville, 2016).

TensorFlow, Google Brain ekibi tarafından geliştirilen ve özellikle derin öğrenme modellerinin oluşturulması, eğitilmesi ve dağıtılmasına imkân sağlayan açık kaynaklı bir makine öğrenimi kütüphanesidir (Abadi vd., 2016). TensorFlow'un hesaplamaları yönlendirilmiş hesaplama grafikleri üzerinden gerçekleştirmesi, büyük veri setleriyle çalışmayı kolaylaştırmakta ve GPU/TPU hızlandırmalarıyla yüksek performans sağlamaktadır. Ayrıca Keras arayüzü sayesinde yapay sinir ağı modellerinin kolaylıkla inşa edilmesine imkân tanımaktadır.

Bu çalışmada öğrencilerin sınıf içi liderlik algıları, çok katmanlı yapay sinir ağı (Multilayer Perceptron – MLP) mimarisi kullanılarak modellenmiştir. Modellerde giriş katmanı, ölçeğin 20 maddesinden oluşan girdileri temsil etmektedir. Gizli katman sayısı ve her bir katmandaki nöron sayısı, model performansını optimize etmek amacıyla farklı kombinasyonlar denenerek belirlenmiştir. Gizli katmanlarda doğrusal olmayan öğrenme kapasitesini artırmak için ReLU (Rectified Linear Unit) aktivasyon fonksiyonu kullanılmıştır (Nair & Hinton, 2010). Çıktı katmanı ise tahmin edilen liderlik boyutlarına ilişkin sürekli değişkenleri modellemektedir.

Modelin eğitimi sırasında geri yayılım (Backpropagation) algoritması ve Adam optimizasyon yöntemi kullanılmıştır. Adam, momentuma dayalı adaptif öğrenme hızı yaklaşımıyla özellikle sosyal bilim verilerinin değişken yoğunlukta ürettiği kayıpları daha stabil şekilde optimize etmektedir (Kingma & Ba, 2014). Kayıp fonksiyonu olarak, tahmin performansını ölçmede yaygın kullanılan Ortalama Kare Hatası (Mean Squared Error-MSE) ve Ortalama Mutlak Hata (Mean Absolute Error-MAE) ölçütleri tercih edilmiştir. Modelin doğruluğu ve genellenebilirliği, eğitim (%70) ve test (%30) kümeleri üzerinden değerlendirilmiştir. Bu ayrım, makine öğrenimi literatüründe önerilen standart uygulamaya uygun olarak gerçekleştirilmiştir (Hastie, Tibshirani & Friedman, 2009).

Eğitim sürecinin her epoch (Dönem) sonunda doğruluk ve hata değerleri izlenmiş, aşırı öğrenmeyi (overfitting) engellemek için gerektiğinde erken durdurma (Early stopping) stratejileri değerlendirilmiştir. Sonuç olarak TensorFlow tabanlı yapay sinir ağı modeli, sınıf içi takım liderliği algısını etkileyen temel maddelerden yeni örneklem verileri için başarıyla tahmin üretebilen bir yapı hâline gelmiştir. Bu yönüyle çalışma, yükseköğretimde liderlik davranışlarının kestirimsel analizi için yenilikçi bir makine öğrenimi yaklaşımı sunmaktadır.

2.7. Modelleme Süreci ve Python/TensorFlow Kodları

Bu araştırmada öğretim elemanlarının sınıf içi takım liderliği davranışlarına ilişkin öğrenci algılarının tahmin edilmesi amacıyla TensorFlow tabanlı bir yapay sinir ağı modeli geliştirilmiştir. Uygulamada (sinificiliderlik_ml_modeli.py) TensorFlow 2.20 sürümü kullanılmıştır. Makine öğrenimi sürecinin tüm adımları Python programlama dili ve ilgili veri bilimi kütüphaneleri (Pandas, NumPy, Scikit-learn) kullanılarak gerçekleştirilmiştir. Bu nedenle modelin çalıştırılabilmesi için sistemde Python yorumlayıcısının (Python 3.10 ve üzeri) kurulu olması gerekmektedir. Python dağıtımı kurulduktan sonra gerekli kütüphaneler pip paket yöneticisi aracılığıyla yüklenebilmekte ve böylece araştırmanın tüm kodları herhangi bir platformda çalışabilir hâle gelmektedir. Bu bölümde modelleme yaklaşımının genel çerçevesi, kod yapısı ve algoritmik işleyiş özetlenmektedir. Kodların tamamı, tekrarlanabilirlik ilkelerine uygun olacak şekilde Ek A bölümünde sunulmuştur.

Modelleme süreci üç temel aşamadan oluşmaktadır:

- Veri setinin makine öğrenimi için hazırlanması,
- Yapay sinir ağı mimarisinin oluşturulması,
- Modelin eğitimi ve performansının değerlendirilmesi.

İlk aşamada, anket veri seti Pandas kütüphanesi ile içe aktarılmış; 20 maddeden oluşan Likert tipi ölçek değişkenleri sayısal biçime dönüştürülmüş ve tüm bağımlı değişkenler model için giriş katmanında kullanılmıştır. Eğitim ve test veri kümeleri, literatürde önerildiği şekilde %70–30 oranında ayrılmıştır (Hastie, Tibshirani & Friedman, 2009).

İkinci aşamada, TensorFlow/Keras kullanılarak çok katmanlı bir perceptron (MLP) mimarisi oluşturulmuştur. Model yapısında giriş katmanını takiben bir veya birden fazla gizli katman yer almakta; bu katmanlarda ReLU aktivasyon fonksiyonu kullanılarak doğrusal olmayan örüntülerin yakalanması sağlanmaktadır (Nair & Hinton, 2010). Çıkış katmanı ise liderlik boyutlarına ilişkin sürekli değişkenlere karşılık gelecek şekilde yapılandırılmıştır. Model, hatanın geri yayılımı (Backpropagation) yöntemi ve adaptif moment tahminine dayalı Adam optimizasyon algoritması kullanılarak eğitilmiştir (Kingma & Ba, 2015).

Üçüncü aşamada modelin eğitimi yürütülmüş; kayıp fonksiyonu olarak Ortalama Kare Hatası (MSE) ve ek değerlendirme ölçütü olarak Ortalama Mutlak Hata (MAE) tercih edilmiştir. Eğitim sürecinde epoch sayısı, öğrenme hızı ve batch size gibi hiperparametreler performans optimizasyonu için sistematik biçimde denenmiştir. Eğitim ve test kümelerindeki hata değerleri karşılaştırılarak modelin genellenebilirliği değerlendirilmiştir. Gerekli durumlarda aşırı öğrenmeyi (overfitting) önlemek için erken durdurma (Early stopping) stratejileri kullanılmıştır (Goodfellow, Bengio & Courville, 2016).

Bölüm içinde yalnızca örnek niteliğinde kısa kod bloklarına yer verilmiş olup, modelin çalıştırılabilir tam Python kodları Ek A bölümünde detaylı ve açıklamalı biçimde sunulmuştur:

```
# sinificiliderlik_ml_modeli.py 21.11.2025
# 1. Gerekli Kütüphaneler
import pandas as pd
import numpy as np
import tensorflow as tf
from tensorflow.keras import layers, models
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import MinMaxScaler

# 2. Veri Setinin Yüklenmesi
dosya_yolu = "anket_cevaplar.xlsx"
veri = pd.read_excel(dosya_yolu, sheet_name="Sayfa1")
```

Bu özet yapı, modelin genel mimarisini temsil etmekte olup çalışmada kullanılan tüm kod ayrıntıları Ek A'da sunulmuştur. Böylece araştırmanın tekrarlanabilirliği ve şeffaflığı tam olarak sağlanmıştır.

Ayrıca araştırmada kullanılan Python betiklerinin sorunsuz bir şekilde çalıştırılabilmesi için gerekli kütüphanelerin kurulması gerekmektedir. Bu çalışmada kullanılan temel kütüphaneler olan TensorFlow, Pandas, NumPy ve Scikit-learn, Python'un paket yönetim sistemi olan pip aracılığıyla kolaylıkla kurulabilmektedir. Kullanıcıların aşağıdaki komutları terminal veya komut satırı üzerinden çalıştırmaları yeterlidir:

pip install tensorflow

pip install pandas

pip install numpy

pip install scikit-learn

pip install matplotlib

pip install openpyxl

Kodların düzenlenmesi ve yürütülmesi için Visual Studio Code (VS Code-https://code.visualstudio.com) editörünün kullanılması önerilmektedir. VS Code, Python betiklerinin çalıştırılması, çıktıların incelenmesi, hata ayıklama (Debugging) ve eklentiler aracılığıyla gelişmiş bir çalışma ortamı sunması bakımından hem araştırmacılar hem de uygulayıcılar için oldukça elverişlidir. Kod dosyası (.py) VS Code ortamında kolaylıkla düzenlenebilir ve terminal üzerinden doğrudan çalıştırılabilir.

Araştırma kapsamında geliştirilen yapay sinir ağı modeli eğitim süreci tamamlandıktan sonra HDF5 (Hierarchical Data Format 5) dosya formatında dışa aktarılmıştır. "sinifici_liderlik_modeli.h5" adıyla kaydedilen dosya; modelin mimarisini, katman yapılarını, öğrenilmiş ağırlıkları (Weights), optimizasyon parametrelerini ve modelin çalışma sırasında ihtiyaç duyduğu tüm bilgileri içermektedir. Böylece model, başka bir ortamda tekrar eğitime gerek duyulmadan yeniden yüklenip kullanılabilmektedir. Bu özellik, makine öğrenimi araştırmalarında tekrarlanabilirlik ve model taşınabilirliği açısından önem taşımaktadır.

Örneğin;

```
from tensorflow.keras.models import load_model
model = load_model("sinifici_liderlik_modeli.h5")
```

Bu bütünsel yapı sayesinde, araştırma kapsamında geliştirilen modelin hem tekrar üretilebilirliği hem de farklı platformlarda uygulanabilirliği güvence altına alınmıştır.

3. BULGULAR

Bu bölümde araştırmaya katılan öğrencilerden elde edilen veriler doğrultusunda sınıf içi takım liderliği algısına ilişkin bulgular sunulmaktadır. Öncelikle veri setinin genel yapısına ve ölçekte yer alan maddelere ilişkin betimsel istatistikler değerlendirilmiş; ardından TensorFlow tabanlı makine öğrenimi modeli ile gerçekleştirilen tahminleme sürecine ait performans çıktıları detaylandırılmıştır.

Araştırmada kullanılan üç temel boyut, İşbirlikçi Liderlik, Güçlendirme Liderliği ve İletişim için öğrenciler tarafından verilen yanıtlar üzerinden elde edilen ortalama puanlar, modelin hedef değişkenleri olarak kullanılmıştır. Makine öğrenimi süreci kapsamında geliştirilen çok katmanlı yapay sinir ağı modeli, bu üç boyutun öğrenci yanıtlarından yüksek doğrulukla tahmin edilebildiğini göstermiştir.

Modelin eğitim sürecinde hata değerlerinin düzenli biçimde azalması, doğrulama performansının da istikrarlı seyretmesi, modelin hem öğrenme kapasitesinin yüksek olduğunu hem de aşırı uyum göstermediğini ortaya koymaktadır. Test verileri üzerinde elde edilen hata değerlerinin oldukça düşük olması (MAE $\approx$ 0.13), öğrencilerin sınıf içi liderlik algılarının makine öğrenimi yöntemleriyle güçlü biçimde modellenebildiğini göstermektedir.

Bu bulgular, sınıf içi takım liderliği algısının davranışsal ölçümler temelinde öngörülebilir olduğunu ve öğrenci yanıtlarına dayalı hesaplamalı modellerle etkili şekilde temsil edilebileceğini göstermektedir. Bulguların detayları alt başlıklarda sunulmaktadır.

3.1. Betimsel İstatistikler

Aşağıdaki tabloda, sınıf içi takım liderliği ölçeğinde yer alan toplam 20 maddenin ortalama ve standart sapma değerleri sunulmuştur. Değerler, katılımcıların ilgili maddelere 1–5 Likert ölçeğinde verdikleri cevapların dağılımını göstermektedir.

Tablo 2. Ölçek Maddelerine İlişkin Betimsel İstatistikler

Boyutlar	Ortalama	Standart Sapma
ISBIRTKLD1	3,91	0,95
ISBIRTKLD2	3,86	0,99
ISBIRTKLD3	3,82	1,03
ISBIRTKLD4	3,95	0,92
ISBIRTKLD5	4,02	0,84
ISBIRTKLD6	3,87	0,96
ISBIRTKLD7	3,34	1,16
ISBIRTKLD8	4,01	0,91
GCLNDR_HGEC1	3,95	0,95
GCLNDR_HGEC2	3,96	0,92
GCLNDR_HGEC3	4,22	0,84
GCLNDR_HGEC4	3,78	1,07
GCLNDR_HGEC5	4,03	0,96
GCLNDR_HGEC6	3,96	1,03
GCLNDR_HGEC7	4,11	0,98
GCLNDR_HGEC8	4,09	1
ILTSM1	3,94	1,03
ILTSM2	3,68	1,1
ILTSM3	4,18	0,88
ILTSM4	4,25	0,87

Betimsel analiz sonuçları incelendiğinde, öğrencilerin öğretim elemanlarının sınıf içi takım liderliği davranışlarını genel olarak olumlu değerlendirdikleri görülmektedir. İşbirlikçi Liderlik boyutuna ait maddeler çoğunlukla 3.8–4.0 aralığında ortalamalara sahiptir ve bu durum öğrencilerin öğretim elemanlarını işbirliğine açık, katılımı teşvik eden ve ekip çalışmasını kolaylaştıran kişiler olarak algıladıklarını göstermektedir.

Güçlendirme (Motivasyon) Liderliği boyutunda yer alan maddelerin ortalamaları 3.9 ile 4.2 arasında değişmektedir. Bu bulgu, öğretim elemanlarının öğrencileri motive etme, sorumluluk devretme ve öğrenme sürecine aktif katılım sağlama gibi davranışlarının öğrenciler tarafından yüksek düzeyde algılandığını ortaya koymaktadır.

İletişim boyutunda ise maddelerin ortalamaları 3.68 ile 4.25 arasında değişmektedir. Özellikle ILTSM3 ve ILTSM4 maddelerinde ortalamaların 4.2'nin üzerine çıkması dikkat çekicidir; bu bulgu öğretim elemanlarının sınıf içi iletişim becerilerinin (Açıklık, anlaşılabilirlik ve geri bildirim verme) öğrenciler tarafından oldukça olumlu değerlendirildiğini göstermektedir.

Genel olarak, tüm maddelerdeki standart sapma değerlerinin yaklaşık 0.84–1.16 aralığında seyretmesi, öğrenci algılarının farklılık gösterdiğini ancak büyük bir kısmının olumlu yönde kümelendiğini göstermektedir. Bu dağılım, makine öğrenimi modelinin öğrenci yanıtlarındaki örüntüleri başarıyla yakalamasına katkı sunan önemli bir veri yapısı sağlamaktadır.

3.2. Makine Öğrenimi Modeli Performansı

Araştırmada kullanılan TensorFlow tabanlı çok katmanlı yapay sinir ağı modeli, üç boyutlu sınıf içi takım liderliği algısını yüksek doğrulukla tahmin edebilecek şekilde başarılı biçimde eğitilmiştir. Modelin eğitim sürecine ilişkin kayıp (Loss) ve ortalama mutlak hata (MAE) değerleri Şekil 1 ve Şekil 2'de sunulmuştur. Grafikler, her iki performans ölçütünün de epoch ilerledikçe düzenli biçimde azaldığını ve yaklaşık 10. epoch sonrasında hem eğitim hem doğrulama hatasının kararlı bir seviyeye ulaştığını göstermektedir. Bu durum, modelin hızlı öğrendiğini ve aşırı uyum (Overfitting) sergilemediğini ortaya koymaktadır.

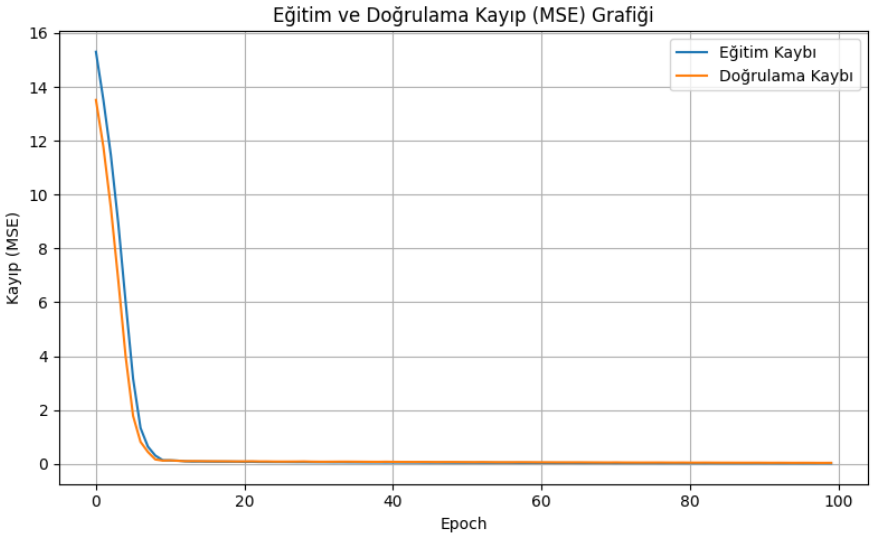

Şekil 1. Eğitim ve Doğrulama Kayıp Grafiği

Bu grafikte, modelin eğitim sürecinde epoch ilerledikçe eğitim kaybı (Training loss) ile doğrulama kaybının (Validation loss) nasıl değiştiği gösterilmektedir. Her iki eğri de ilk epoch'larda hızlı bir düşüş göstermekte ve yaklaşık 10. epoch sonrasında kararlı bir seviyeye ulaşmaktadır. Eğitim ve doğrulama kayıplarının birbirine yakın seyretmesi, modelin aşırı uyum (Overfitting) göstermediğini ve öğrenme sürecinin sağlıklı ilerlediğini göstermektedir.

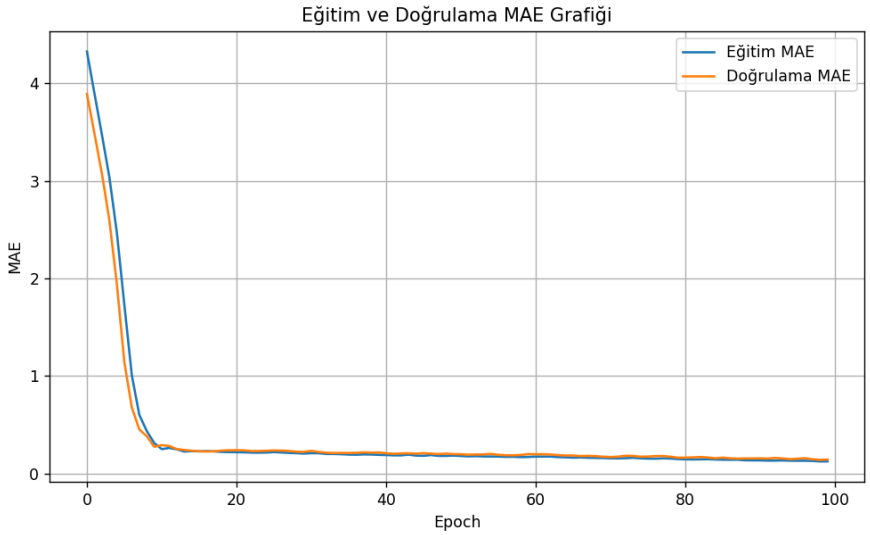

Şekil 2. Eğitim ve Doğrulama MAE Grafiği

Şekil 2'de modelin eğitim (Training MAE) ve doğrulama (Validation MAE) süreçlerindeki hata değerleri sunulmaktadır. MAE değerlerinin eğitim boyunca düzenli bir şekilde azaldığı ve iki eğrinin de birbirine yakın bir çizgide ilerlediği görülmektedir. Yaklaşık 10. epoch sonrası düşük ve kararlı bir hata seviyesine ulaşılması, modelin tahmin performansının güçlü olduğunu ve genelleme kapasitesinin yüksek olduğunu göstermektedir.

Modelin test verisi üzerindeki genel performansı da oldukça güçlüdür. Test setinde elde edilen ortalama karesel hata (MSE) 0.031, ortalama mutlak hata (MAE) 0.133 olarak hesaplanmıştır. Likert tipi 1–5 aralığındaki değişkenler düşünüldüğünde, 0.13 seviyesindeki MAE değeri oldukça düşük bir hata oranına karşılık gelmektedir. Bu sonuç, öğrencilerin sınıf içi liderlik algılarına ilişkin üç temel boyutun (İşbirlikçi Liderlik, Güçlendirme Liderliği ve İletişim) yüksek doğrulukla tahmin edilebildiğini göstermektedir.

Gerçek değerler ile model tarafından üretilen tahminlerin karşılaştırmasına ilişkin saçılım grafikleri (Şekil 3–5), modelin her üç boyutta da anlamlı bir doğrusal ilişki kurabildiğini göstermektedir. Noktaların büyük çoğunluğunun referans çizgisine yakın bir dağılım göstermesi, modelin gerçek değerlere yakın tahminler ürettiğini desteklemektedir. Özellikle İşbirlikçi Liderlik ve Güçlendirme Liderliği boyutlarında tahminlerin referans çizgisine son derece yakın kümelenmesi dikkat çekicidir. İletişim boyutunda ise birkaç uç gözleme rağmen genel doğruluk seviyesi oldukça yüksektir.

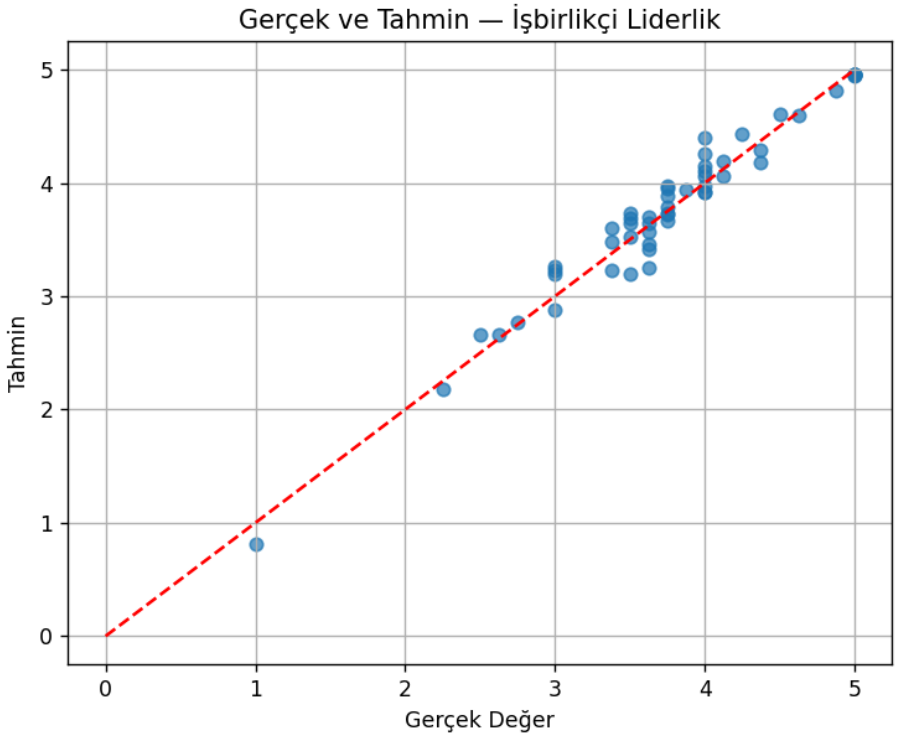

Şekil 3. Gerçek ve Tahmin Karşılaştırmaları (İşbirlikçi Liderlik)

Bu saçılım grafiği, İşbirlikçi Liderlik boyutunda modelin tahmin ettiği değerler ile öğrencilerin gerçek değerlendirmelerini karşılaştırmaktadır. Noktaların büyük bölümünün referans çizgisine (y = x) yakın bir dağılım sergilemesi, modelin bu boyutta yüksek doğrulukla tahmin ürettiğini göstermektedir. İşbirlikçi Liderlik, model tarafından en başarılı tahmin edilen boyutlardan biridir.

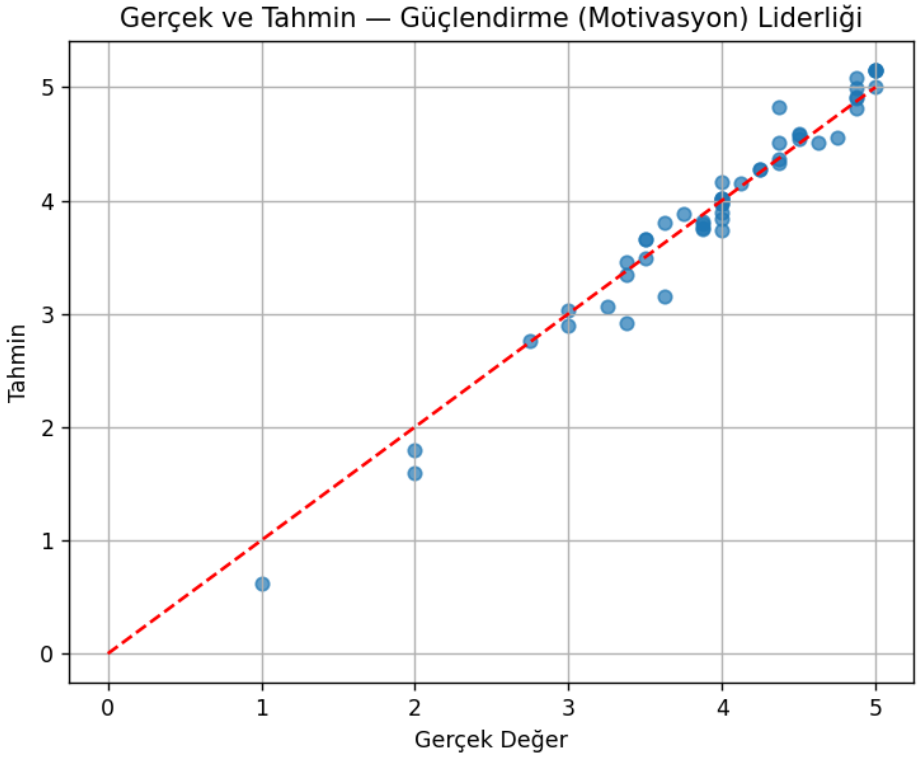

Şekil 4. Gerçek ve Tahmin Karşılaştırmaları (Güçlendirme-Motivasyon Liderliği)

Şekil 4'te, Güçlendirme (Motivasyon) Liderliği alt boyutuna ilişkin tahmin ve gerçek değerlerin karşılaştırması sunulmaktadır. Dağılım, referans çizgisine oldukça yakın bir doğrusal ilişki göstermektedir. Bu durum modelin öğrencilerin öğretim elemanlarının güçlendirme davranışlarını yüksek doğrulukla tahmin edebildiğini ortaya koymaktadır.

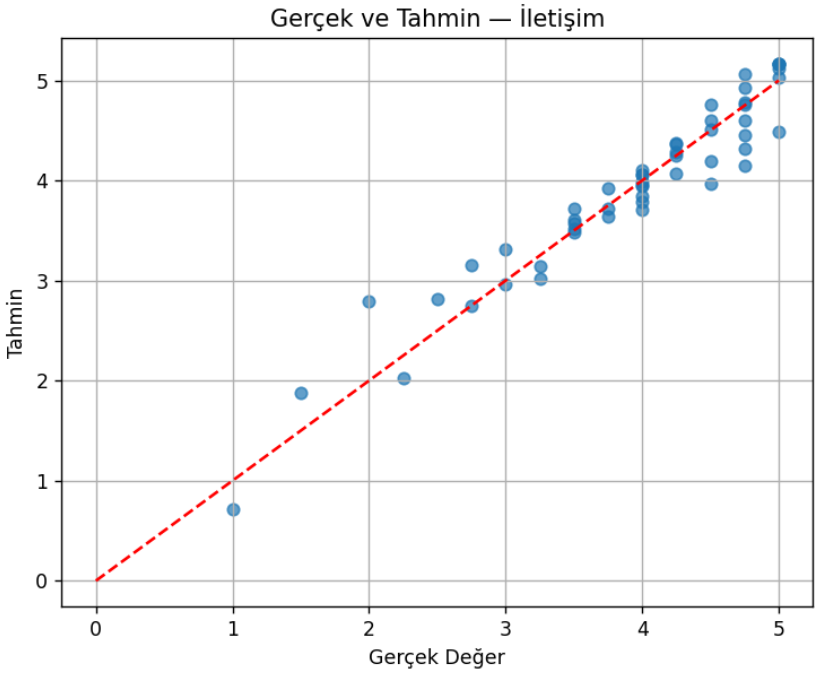

Şekil 5. Gerçek ve Tahmin Karşılaştırmaları (Etkili İletişim)

Bu grafikte İletişim boyutundaki gerçek ve tahmin edilen puanlar karşılaştırılmaktadır. Noktaların çoğunluğu referans çizgisine yakın olsa da birkaç uç gözlem tahminle gerçek değer arasında farklılık oluşturmaktadır. Buna rağmen genel eğilim modelin İletişim boyutunu da başarılı şekilde tahmin ettiğini göstermektedir.

Ayrıca uygulama sonucunda modelden elde edilen örnek bir çıktı aşağıda verilmiştir:

Tahmin edilen değerler:

- İşbirlikçi Liderlik: 3.84
- Güçlendirme Liderliği: 4.31
- İletişim: 4.61

Gerçek (Gözlenen) Boyut Ortalama Puanları:

- İşbirlikçi Liderlik: 3.75
  (ISBIRTKLD1–8 maddelerinin ortalaması)
- Güçlendirme (Motivasyon) Liderliği: 4.12
  (GCLNDR_HGEC1–8 maddelerinin ortalaması)
- İletişim: 5.00
  (ILTSM1–4 maddelerinin ortalaması)

Tahmin edilen değerlerle gerçek değerlendirmeler arasındaki farkın düşük olması, modelin öğrencilerin öğretim elemanlarına yönelik liderlik algılarını yüksek bir doğruluk düzeyiyle öngörebildiğini göstermektedir. Bu bulgular, sınıf içi liderlik davranışlarının makine öğrenimi yöntemleriyle modellenebilir ve tahmin edilebilir bir yapıda olduğunu ortaya koymaktadır.

3.3. Gerçek–Tahmin Karşılaştırmaları

Makine öğrenimi modeli tarafından üretilen tahmin değerleri ile öğrencilerin gerçek değerlendirmeleri arasındaki ilişki Şekil 3, Şekil 4 ve Şekil 5'te sunulmuştur. Bu saçılım grafiklerinde yatay eksen gerçek değerleri, dikey eksen ise modelin ürettiği tahminleri göstermektedir. Her grafikte aynı zamanda referans niteliğinde bir y = x doğrusu yer almakta olup, tahminlerin bu çizgiye yakınlığı modelin başarı düzeyini göstermektedir.

İşbirlikçi Liderlik boyutuna ilişkin karşılaştırmalar (Şekil 3) incelendiğinde, tahmin noktalarının büyük çoğunluğunun referans çizgisine oldukça yakın bir şekilde kümelendiği görülmektedir. Bu durum modelin öğrencilerin işbirlikçi liderlik algılarını yüksek doğrulukla tahmin edebildiğini göstermektedir. Hata payının düşük olması, bu boyutun davranış örüntülerinin model tarafından başarılı biçimde öğrenildiğini ortaya koymaktadır.

Güçlendirme Liderliği boyutunda (Şekil 4) tahmin ve gerçek değerler arasındaki ilişki yine güçlü bir doğrusal yapı sergilemektedir. Dağılım noktalarının büyük kısmı referans çizgisi çevresinde yoğunlaşmış olup modelin öğrencilerin öğretim elemanlarını motive etme, destekleme ve güçlendirme davranışlarına yönelik algılarını yüksek başarıyla öngörebildiği görülmektedir.

İletişim boyutuna ilişkin saçılım grafiği (Şekil 5) incelendiğinde, genel eğilimin yine yüksek doğruluk düzeyinde olduğu görülmekle birlikte, birkaç uç gözlemin referans çizgisinden sapma gösterdiği fark edilmektedir. Buna rağmen nokta kümelerinin büyük çoğunluğunun çizgiye yakın olması, öğretim elemanlarının sınıf içi iletişim becerilerinin model tarafından genel olarak başarılı biçimde tahmin edilebildiğini ortaya koymaktadır.

Tahmin edilen ve gerçek değerler arasındaki düşük farklar, modelin üç liderlik boyutunu oluşturan maddelerin ortalama puanlarını yüksek doğrulukla öngörebildiğini göstermektedir. Örnek bir test çıktısında model, İşbirlikçi Liderlik boyutunu oluşturan sekiz maddenin ortalamasını 3.84 olarak tahmin etmiş; gerçek ortalama ise 3.75 olarak hesaplanmıştır. Benzer şekilde model, Güçlendirme Liderliği boyutu için 4.31 (Gerçek ortalama: 4.12) ve İletişim boyutu için 4.61 (Gerçek ortalama: 5.00) değerlerini tahmin etmiştir. Bu sonuçlar, modelin her üç boyutu da madde düzeyindeki yanıtların ortalamaları üzerinden yüksek doğrulukla tahmin edebildiğini göstermektedir.

4. TARTIŞMA

Bu araştırmada, Türkiye'de öğrenim gören 175 önlisans ve lisans öğrencisinin öğretim elemanlarının sınıf içi takım liderliğine ilişkin algıları, makine öğrenimi teknikleri kullanılarak modellenmiş ve tahmin edilmeye çalışılmıştır. Elde edilen bulgular, yapay sinir ağı modelinin üç temel liderlik boyutunda (İşbirlikçi Liderlik, Güçlendirme (Motivasyon) Liderliği ve İletişim) oldukça başarılı tahminler ürettiğini göstermektedir. Özellikle test setinde elde edilen düşük hata değerleri (MAE ≈ 0.13; MSE ≈ 0.03), öğrencilerin liderlik algısı ölçeklerinde ortaya çıkan örüntülerin makine öğrenimi yaklaşımı ile anlamlı ve istikrarlı biçimde yakalanabildiğini ortaya koymuştur (Modelin test performansına ilişkin ölçütler Python/TensorFlow çıktılarından elde edilmiştir. Terminal çıktısında raporlanan hatalar (MSE = 0.0311; MAE = 0.1336), çalışmada kullanılan değerlere karşılık gelmektedir. Bu sonuçlar doğrudan modelin test setinde yürütülen değerlendirme sürecinden alınmıştır). Derin öğrenme modellerinde ağırlıkların rastgele başlatılması ve eğitim-test ayrımının rastlantısal doğası gereği, model her çalıştırıldığında MSE ve MAE değerlerinde küçük değişiklikler gözlenmiştir. Bu durum literatürde yapay sinir ağlarının karakteristik bir özelliği olarak tanımlanmaktadır (Goodfellow, Bengio & Courville, 2016).

Makine öğrenimi literatüründe regresyon modellerinin performansı genellikle Ortalama Mutlak Hata (MAE) ve Ortalama Kare Hatası (MSE) ile değerlendirilmektedir. Bu ölçütlerin mutlak sınır değerleri olmamakla birlikte, yorumlama kullanılan ölçeğin aralığına göre yapılmaktadır. Özellikle 1–5 arası Likert tipi ölçeklerle yapılan çalışmalarda MAE değerinin 0.20'nin altında olmasının yüksek doğruluk düzeyine işaret ettiği; 0.20–0.30 aralığının orta düzeyde, 0.30'un üzerindeki değerlerin ise düşük doğruluk olarak kabul edildiği belirtilmektedir (Goodfellow, Bengio & Courville, 2016). Benzer şekilde MSE'nin 0.02–0.05 aralığında olması modelin iyi ve kabul edilebilir uyum gösterdiğini, 0.05'in üzerindeki değerlerin ise uyum gücünün azaldığını göstermektedir (Chollet, 2021). Bu bağlamda çalışmada elde edilen MAE ≈ 0.13 ve MSE ≈ 0.03 değerleri, modelimizin yüksek doğruluk ve güçlü uyum özelliklerine sahip olduğunu ortaya koymaktadır.

Elde edilen sonuçlar, sınıf içi liderlik davranışlarının öğrenciler tarafından nasıl algılandığını modellemede yapay sinir ağı gibi derin öğrenme yöntemlerinin etkili bir alternatif sunduğunu göstermektedir. Bu bulgu, eğitim bilimleri alanında makine öğreniminin kullanımına yönelik literatürde belirtilen eğilimlerle uyumludur. Son yıllarda öğrenci başarısı, öğrenme motivasyonu, öğretim kalitesi ve sınıf içi etkileşim gibi karmaşık süreçlerin modellenmesinde makine öğrenimi yöntemlerinin güçlü bir tahmin performansı sunduğu sıkça raporlanmaktadır (Aldowah, Al-Samarraie & Fauzy, 2019; Conijn vd., 2017; Hussain vd., 2018). Bu çalışma da benzer biçimde, liderlik davranışlarının öğrenciler tarafından algılanma düzeylerinin doğrusal olmayan ilişkiler içerdiğini ve bu ilişkilerin geleneksel istatistiksel yöntemlere kıyasla makine öğrenimi modelleriyle daha iyi temsil edilebildiğini ortaya koymaktadır.

Araştırmada kullanılan ölçek maddelerine ait ortalama değerler incelendiğinde, öğrencilerin öğretim elemanlarının özellikle iletişim ve güçlendirme liderliği davranışlarına yönelik olumlu bir algıya sahip oldukları görülmüştür. Bu durum, sınıf içinde açık iletişim, destekleyici bir öğretim yaklaşımı ve öğrencinin karar süreçlerine katılımının, öğrenme ortamının kalitesini artırdığı yönündeki literatürle tutarlıdır (Northouse, 2022; Yukl, 2013). Çalışmadaki makine öğrenimi modelinin bu boyutlarda yüksek

doğrulukla tahminler üretebilmesi, ölçek maddelerinin tutarlı bir yapıya sahip olduğunu ve öğrencilerin bu liderlik davranışlarını benzer şekilde algıladığını göstermektedir.

Bulgular ayrıca, işbirlikçi liderlik boyutunda elde edilen tahmin performansının da yüksek olduğunu ortaya koymuştur. İşbirlikçi uygulamaların öğrenci katılımını, öğrenme motivasyonunu ve sınıf içi etkileşimi artırdığı yönündeki çalışmalar (Johnson & Johnson, 2019; Hadwin & Oshige, 2011) dikkate alındığında, modelin bu boyutta da öğrenci değerlendirmelerini başarıyla tahmin edebilmesi önemli bir sonuçtur. Bu durum, öğrencilerin sınıf içi takım liderliğini çok boyutlu ancak tutarlı bir yapı olarak algıladıklarını göstermekte; makine öğrenimi modelinin de bu çok boyutlu yapıyı etkili biçimde öğrenebildiğini ortaya koymaktadır.

Genel olarak değerlendirildiğinde, bu çalışma eğitim ortamlarında liderlik algılarının modellenmesi için makine öğrenimi temelli yaklaşımların güçlü bir metodolojik alternatif sunduğunu göstermektedir. Ayrıca araştırma, ölçeğe dayalı liderlik ölçümlerinin yalnızca tanımlayıcı istatistiklerle değil, aynı zamanda tahmine dayalı modellerle de desteklenebileceğini ortaya koyarak literatüre metodolojik bir katkı sağlamaktadır. Derin öğrenme tabanlı modeller ile öğrenci algılarının analiz edilmesi, gelecekte öğretim süreçlerinin kişiselleştirilmesi, öğretim elemanlarının liderlik profillerinin çıkarılması ve öğrenme ortamlarının iyileştirilmesi amacıyla kullanılabilecek önemli bir veri temeli sunmaktadır.

5. SONUÇ ve ÖNERİLER

Bu araştırmada, Türkiye'de öğrenim gören toplam 175 önlisans ve lisans öğrencisinin öğretim elemanlarının sınıf içi takım liderliği davranışlarına ilişkin algıları incelenmiş ve bu algıların makine öğrenimi yöntemleriyle tahmin edilebilirliği araştırılmıştır. Çalışmada kullanılan ölçek, üç temel liderlik boyutunu (İşbirlikçi Liderlik, Güçlendirme (Motivasyon) Liderliği ve İletişim) kapsayan 20 maddelik beşli Likert tipindedir. TensorFlow tabanlı çok katmanlı perceptron modeli ile gerçekleştirilen analizler, liderlik algılarının önemli ölçüde doğrulukla tahmin edilebildiğini göstermiştir.

Model performans sonuçları hem eğitim hem de test setlerinde oldukça düşük hata değerleri üretmiştir. Test setinde elde edilen MAE ≈ 0.13 ve MSE ≈ 0.03 değerleri, 1–5 arası bir Likert ölçeğinde oldukça güçlü bir tahmin performansına işaret etmektedir. Literatürde, MAE'nin 0.20'nin altında olmasının yüksek doğruluk göstergesi olduğu (Goodfellow, Bengio & Courville, 2016) ve MSE'nin 0.02–0.05 aralığında yer almasının model uyumunun iyi kabul edildiği (Chollet, 2021) dikkate alındığında, elde edilen değerler modelin liderlik algısına ilişkin örüntüleri başarılı biçimde yakaladığını doğrulamaktadır.

Araştırmanın bulguları, öğrencilerin sınıf içi liderlik algılarının önemli bileşenler içerdiğini ve bu algıların birlikte çalışabilirlik, güçlendirme ve etkili iletişim gibi pedagojik süreçlerle yakından ilişkili olduğunu göstermektedir. Ayrıca modelin tahmin gücü, öğrenci değerlendirmelerinde belirgin bir tutarlılık olduğunu ve bu değerlendirmelerin makine öğrenimi yöntemleri kullanılarak anlamlı biçimde modellenebileceğini göstermektedir. Bu durum, eğitim bilimleri alanında liderlik, öğrenme davranışları ve öğrenci etkileşimleri gibi karmaşık yapıları anlamada yapay zekâ temelli yaklaşımların önemli bir katkı sunabileceğini ortaya koymaktadır.

Bu bulgular doğrultusunda, öğretim elemanlarının sınıf içi takım liderliği davranışlarının öğrencilerin algıları üzerinde belirleyici bir rol oynadığı söylenebilir. Eğitim ortamlarında işbirlikçi yaklaşımın güçlendirilmesi, öğretim elemanlarının öğrencileri motive eden ve öğrenme sürecine aktif katılımı teşvik eden liderlik uygulamalarını artırmasıyla mümkün olabilir. Bu bağlamda üniversitelerde, öğretim süreçlerinin niteliğini yükseltmeye yönelik uygulamalara makine öğrenimi destekli değerlendirme sistemlerinin entegre edilmesi önerilmektedir. Böyle bir yaklaşım, öğrencilerin öğrenme deneyimlerindeki değişimleri daha erken tespit etmeyi ve ders içi etkileşimlerin geliştirilebileceği alanları görünür kılmayı sağlayacaktır. Ayrıca bu modelin sunduğu tahmin gücü, eğitim-öğretim yöneticilerinin öğretim kalitesine ilişkin daha nesnel ve sürekli ölçümler yapabilmesine katkı sunabilir.

Bununla birlikte gelecekte yapılacak araştırmalarda daha geniş örneklemler kullanılarak modelin genellenebilirliğinin sınanması önemlidir. Farklı üniversitelerden, disiplinlerden veya öğrenim seviyelerinden veri toplanması, liderlik algılarının kültürel ve bağlamsal farklılıklarını ortaya koyabilir. Ayrıca çalışmanın yalnızca nicel veriyle sınırlı olması, nitel görüşmeler veya odak grup çalışmalarıyla desteklenebilecek daha derinlemesine bulguların elde edilmesine imkân tanımaktadır. Ek olarak farklı makine öğrenimi algoritmalarının (örneğin Random Forest, XGBoost, Support Vector Machine–SVM) performans karşılaştırmalarının yapılması, liderlik algısının modellenmesine yönelik daha bütüncül bir metodolojik çerçeve sunabilir. Bunun yanında gelecekte yapılacak çalışmalarda açıklanabilir yapay zekâ (Explainable Artificial Intelligence–XAI) yöntemlerinin kullanılması, modelin hangi maddelere veya

boyutlara dayanarak tahmin ürettiğinin daha şeffaf biçimde anlaşılmasını sağlayabilir ve liderlik algısının hangi bileşenlerden daha fazla etkilendiğine ilişkin önemli içgörüler sunabilir.

KAYNAKÇA

Abadi, M., Agarwal, A., Barham, P., Brevdo, E., Chen, Z., Citro, C., … & Zheng, X. (2016). *TensorFlow: Large-scale machine learning on heterogeneous systems*. Google Research. https://www.tensorflow.org/

Aldowah, H., Al-Samarraie, H., & Fauzy, W. M. (2019). Educational data mining and learning analytics for 21st century higher education: A review and synthesis. *Telematics and Informatics, 37*, 13–49. https://doi.org/10.1016/j.tele.2019.01.007

Beycioğlu, K., & Aslan, M. (2010). Öğretmen liderliği ölçeğinin Türkçeye uyarlanması: Geçerlik ve güvenirlik çalışması. *Kuram ve Uygulamada Eğitim Yönetimi*, 16(1), 5–28.

Chollet, F. (2021). *Deep learning with Python*. Manning Publications.

Conijn, R., Snijders, C., Kleingeld, A., & Matzat, U. (2017). Predicting student performance from LMS data: A comparison of 17 blended courses using Moodle LMS. *IEEE Transactions on Learning Technologies, 10*(1), 17–29.

García, S., Luengo, J., & Herrera, F. (2016). *Data preprocessing in data mining*. Springer.

Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.

Hadwin, A., & Oshige, M. (2011). *Self-regulation, coregulation, and socially shared regulation: Exploring perspectives of social in self-regulated learning theory*. Teachers College Record, 113(2), 240–264.

Harris, A. (2013). Distributed leadership: Friend or foe? *Educational Management Administration & Leadership*, 41(5), 545–554.

Hastie, T., Tibshirani, R. ve Friedman, J. (2009). *The elements of statistical learning: Data mining, inference, and prediction*. Springer.

Hussain, M., Zhu, W., Zhang, W., & Abidi, S. M. R. (2018). Student engagement predictions in an e-learning system and their impact on student course assessment scores. *Computational Intelligence and Neuroscience*

Johnson, D. W., & Johnson, R. T. (2019). Joining together: Group theory and group skills (12th ed.). Pearson.

Katzenmeyer, M., & Moller, G. (2009). *Awakening the sleeping giant: Helping teachers develop as leaders*. Corwin Press.

Kingma, D. P., & Ba, J. (2014). Adam: A method for stochastic optimization. *International Conference on Learning Representations*.

Kuhn, M., & Johnson, K. (2013). *Applied predictive modeling*. Springer.

Leithwood, K., & Jantzi, D. (2006). Transformational school leadership for large-scale reform: Effects on students, teachers, and their classroom practices. *School Effectiveness and School Improvement*, 17(2), 201–227.

LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521, 436–444.

Murphy, J., Smylie, M., Mayrowetz, D., & Louis, K. S. (2009). The role of the principal in fostering the development of distributed leadership. *Journal of Educational Administration*, 58(3), 257–282.

Nair, V., & Hinton, G. E. (2010). Rectified linear units improve restricted Boltzmann machines. *Proceedings of the 27th International Conference on Machine Learning*, 807–814.

Northouse, P. G. (2022). *Leadership: Theory and practice* (9th ed.). Sage Publications.

Yukl, G. (2013). *Leadership in organizations* (8th ed.). Pearson.

Zawacki-Richter, O., Marín, V. I., Bond, M., & Gouverneur, F. (2019). Systematic review of research on artificial intelligence applications in higher education. *International Journal of Educational Technology in Higher Education*, 16(39), 1–27.

EK-A

sinificiliderlik_ml_modeli.py (Makine öğrenimi modeli)

```
# sinificiliderlik_ml_modeli.py 21.11.2025
# 1. Gerekli Kütüphaneler
import pandas as pd
import numpy as np
import tensorflow as tf
from tensorflow.keras import layers, models
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import MinMaxScaler

# 2. Veri Setinin Yüklenmesi
dosya_yolu = "anket_cevaplar.xlsx"
veri = pd.read_excel(dosya_yolu, sheet_name="Sayfa1")

# Veri setinin satır (gözlem) ve sütun (değişken) sayısını ekrana yazdırır.
# Bu adım, veri yapısının doğru yüklendiğini doğrulamak için kullanılır.
print("Veri seti boyutu:", veri.shape)

# 3. Modelde Kullanılacak Sütunların Belirlenmesi
isbirlik_sutunlar = [f"ISBIRTKLD{i}" for i in range(1, 9)]
guclendirme_sutunlar = [f"GCLNDR_HGEC{i}" for i in range(1, 9)]
iletisim_sutunlar = [f"ILTSM{i}" for i in range(1, 5)]

tum_maddeler = isbirlik_sutunlar + guclendirme_sutunlar + iletisim_sutunlar

# Girdi (X)
X = veri[tum_maddeler].copy()

# Üç boyutun ortalama puanlarını Y olarak hesaplıyoruz
veri["ISBIRLIK_PUAN"] = veri[isbirlik_sutunlar].mean(axis=1)
veri["GUCLENDIRME_PUAN"] = veri[guclendirme_sutunlar].mean(axis=1)
veri["ILETISIM_PUAN"] = veri[iletisim_sutunlar].mean(axis=1)

Y = veri[["ISBIRLIK_PUAN", "GUCLENDIRME_PUAN", "ILETISIM_PUAN"]]

print("Bağımsız değişken boyutu:", X.shape)
print("Bağımlı değişken boyutu:", Y.shape)

# 4. Eğitim / Test Ayrımı. Eğitim: %70, test: %30
X_egitim, X_test, Y_egitim, Y_test = train_test_split(
    X, Y, test_size=0.30, random_state=42
)
```

```
# 5. Normalizasyon
# Min-Max ölçeklendirme yöntemi kullanılarak tüm bağımsız değişkenler 0-1 aralığına çekilir.
# Bu yöntem özellikle yapay sinir ağlarında öğrenmeyi hızlandırır ve modelin kararlılığını artırır.
olceklendirici = MinMaxScaler()         # Min-Max ölçekleyici nesnesi oluşturulur
X_egitim = olceklendirici.fit_transform(X_egitim)   # Eğitim verisi 0-1 aralığına dönüştürülür
X_test = olceklendirici.transform(X_test)            # Test verisine aynı dönüşüm uygulanır

# 6. TensorFlow Modelinin Oluşturulması
# Bu model, 20 maddeden oluşan bağımsız değişkenleri kullanarak üç liderlik boyutunu tahmin eden
# çok katmanlı perceptron (MLP) mimarisi üzerine kurulmuştur.
# Gizli katmanlarda doğrusal olmayan ilişkilerin öğrenilebilmesi için ReLU aktivasyon fonksiyonu,
# çıkış katmanında ise regresyon çıktısı üretmek için linear aktivasyon fonksiyonu kullanılmıştır.
model = models.Sequential([
    layers.Dense(64, activation='relu', input_shape=(20,), name="GizliKatman1"),
    layers.Dense(32, activation='relu', name="GizliKatman2"),
    layers.Dense(3, activation='linear', name="CikisKatmani")
])

# Modelin derlenmesi
# Adam: Adaptif öğrenme hızına sahip güçlü bir optimizasyon algoritması
# MSE: Regresyon problemlerinde kullanılan temel kayıp fonksiyonu
# MAE: Tahminlerin ortalama mutlak hata miktarını ölçen değerlendirme metriği
model.compile(
    optimizer='adam',
    loss='mse',
    metrics=['mae']
)

# Model mimarisinin özet bilgilerini görüntüler.
# Her katmandaki nöron sayısı, parametre sayıları ve veri akışının şekli raporlanır.
model.summary()

# 7. Modelin Eğitilmesi
# Eğitim süreci 100 epoch boyunca yürütülür.
# Batch size = 16 → daha dengeli gradyan güncellemeleri sağlar.
# validation_split = 0.20 → eğitim verisinin %20'si doğrulama için kullanılır.
# verbose = 1 → eğitim sürecini detaylı olarak terminalde gösterir.
egitilmisveriler = model.fit(
    X_egitim,
    Y_egitim,
    epochs=100,
    batch_size=16,
```

```
    validation_split=0.20,
    verbose=1
)

# 8. Test Verisi Üzerinde Performans
# model.evaluate(): Test verisi üzerinde MSE (loss) ve MAE değerlerini hesaplar.
# Bu aşama modelin genellenebilirliğini ölçmek için etkin bir öneme sahiptir.
test_kayip, test_mae = model.evaluate(X_test, Y_test, verbose=1)

print("Test MSE:", test_kayip)
print("Test MAE:", test_mae)

# 9. Tahmin Örneği
# model.predict(): Test verisinden seçilen ilk örnek için liderlik boyutları tahmini yapılır.
# Ardından öğrencinin gerçek değerlendirme değerleri ile karşılaştırılır.
ornek_tahmin = model.predict(X_test[:1])   # İlk test örneği için tahmin
gercek_deger = Y_test.iloc[0]              # Aynı örneğe ait gerçek değerler
print("\nTahmin:", ornek_tahmin)
print("Gerçek Değer:", gercek_deger.values)

# 10. Modelin Kaydedilmesi
# Eğitim tamamlandıktan sonra model, HDF5 formatında dışa aktarılır.
# Bu sayede model yeniden eğitime gerek duyulmadan yüklenip kullanılabilir.
model.save("sinifici_liderlik_modeli.h5")
print("Model başarıyla kaydedildi.")

# 11. Grafikler
import matplotlib.pyplot as plt
# --- 11.1 Eğitim ve Doğrulama Kayıp Grafiği ---
plt.figure(figsize=(8,5))
plt.plot(egitilmisveriler.history['loss'], label='Eğitim Kaybı')
plt.plot(egitilmisveriler.history['val_loss'], label='Doğrulama Kaybı')
plt.title('Eğitim ve Doğrulama Kayıp (MSE) Grafiği')
plt.xlabel('Epoch')
plt.ylabel('Kayıp (MSE)')
plt.legend()
plt.grid(True)
plt.tight_layout()
plt.savefig("egitim_dogrulama_kayip_grafigi.png", dpi=300)
plt.show()

# --- 11.2 Eğitim ve Doğrulama MAE Grafiği ---
plt.figure(figsize=(8,5))
plt.plot(egitilmisveriler.history['mae'], label='Eğitim MAE')
```

```
plt.plot(egitilmisveriler.history['val_mae'], label='Doğrulama MAE')
plt.title('Eğitim ve Doğrulama MAE Grafiği')
plt.xlabel('Epoch')
plt.ylabel('MAE')
plt.legend()
plt.grid(True)
plt.tight_layout()
plt.savefig("egitim_dogrulama_mae_grafigi.png", dpi=300)
plt.show()

# --- 11.3 Gerçek Değer - Tahmin Karşılaştırma Grafiği ---
y_tahmin = model.predict(X_test)

boyut_isimleri = ["İşbirlikçi Liderlik", "Güçlendirme (Motivasyon) Liderliği", "İletişim"]

for i in range(3):
    plt.figure(figsize=(6,5))
    plt.scatter(Y_test.iloc[:, i], y_tahmin[:, i], alpha=0.7)
    plt.xlabel("Gerçek Değer")
    plt.ylabel("Tahmin")
    plt.title(f"Gerçek ve Tahmin – {boyut_isimleri[i]}")
    plt.grid(True)
    plt.tight_layout()
    plt.plot([0,5], [0,5], color='red', linestyle='--')  # referans çizgisi
    plt.savefig(f"gercek_vs_tahmin_{i+1}.png", dpi=300)
    plt.show()
```

EK-B

betimselistatistikler.py (Ölçek maddelerinin ortalamasını ve standart sapmasını bulan uygulama)

```
import pandas as pd
import re

df = pd.read_excel('anket_cevaplar.xlsx', sheet_name=0)
degerler = df.columns[8:]  # Madde kolonları

# Temizleme fonksiyonu
def temizle(x):
    if pd.isna(x):
        return None
    x = str(x).strip()
    x = re.sub(r'\s+', '', x)       # Unicode boşlukları sil
    x = re.sub(r'[^0-9]', '', x)    # Sayı olmayan karakterleri sil
    return x
```

```
temiz_degerler = df[degerler].applymap(temizle) # Temizlemeyi uygulama

temiz_degerler = temiz_degerler.apply(pd.to_numeric, errors='coerce') # Sayıya dönüştürme

sondegerler = temiz_degerler.agg(['mean', 'std']).T  # Betimsel istatistik tablosu

# Kolon adlarını adlandır
sondegerler = sondegerler.rename(columns={
    'mean': 'Ortalama',
    'std': 'Standart Sapma'
})

# İlk kolon başlığı olarak "Boyutlar" ekleyelim
sondegerler.index.name = 'Boyutlar'
print(sondegerler)
```

Programın çıktısı aşağıya çıkarılmıştır

Boyutlar	Ortalama	Standart Sapma
ISBIRTKLD1	3.914286	0.952052
ISBIRTKLD2	3.857143	0.992583
ISBIRTKLD3	3.822857	1.032541
ISBIRTKLD4	3.954286	0.921126
ISBIRTKLD5	4.022857	0.843871
ISBIRTKLD6	3.868571	0.964833
ISBIRTKLD7	3.342857	1.158250
ISBIRTKLD8	4.005714	0.912853
GCLNDR_HGEC1	3.948571	0.954533
GCLNDR_HGEC2	3.960000	0.918269
GCLNDR_HGEC3	4.217143	0.836483
GCLNDR_HGEC4	3.782857	1.071438
GCLNDR_HGEC5	4.028571	0.955496
GCLNDR_HGEC6	3.960000	1.030344
GCLNDR_HGEC7	4.108571	0.979494
GCLNDR_HGEC8	4.085714	0.999179
ILTSM1	3.942857	1.026736
ILTSM2	3.680000	1.098798
ILTSM3	4.182857	0.878048
ILTSM4	4.251429	0.874075