



T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİ TEKNOLOJİLERİ ANA BİLİM DALI

YÜKSEK LİSANS TEZİ

YAPAY SİNİR AĞLARI İLE
ÖĞRENCİ BAŞARISINI DEĞERLENDİRME:
ANALİZ VE İLERLEME ÖNERİLERİ

Zeynep DEMİR

Mayıs-2024
BATMAN

T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİ TEKNOLOJİLERİ ANA BİLİM DALI

YÜKSEK LİSANS TEZİ

YAPAY SİNİR AĞLARI İLE
ÖĞRENCİ BAŞARISINI DEĞERLENDİRME:
ANALİZ VE İLERLEME ÖNERİLERİ

Zeynep DEMİR

Danışman
Prof. Dr. Ö. Faruk ERTUĞRUL

Mayıs-2024
BATMAN

TEZ KABUL VE ONAYI

Zeynep DEMİR tarafından hazırlanan ‘‘Yapay Sinir Ağları İle Öğrenci Başarısını Değerlendirme: Analiz Ve İlerleme Önerileri’’ adlı tez çalışması 17/05/2024 tarihinde aşağıdaki jüri tarafından oy birliği ile Batman Üniversitesi Bilgi Teknolojileri Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Prof. Dr. Necmettin SEZGİN

.....

Danışman

Prof. Dr. Ö. Faruk ERTUĞRUL

.....

Üye

Dr. Öğr. Üyesi Davut ÖZHAN

.....

Yukarıdaki sonucu onaylarım.

Dr. Öğr. Üyesi Ömer Murat ÖTER
Lisansüstü Eğitim Enstitüsü Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Zeynep DEMİR

17/05/2024

ÖZET

YÜKSEK LİSANS TEZİ

YAPAY SİNİR AĞLARI İLE ÖĞRENCİ BAŞARISINI DEĞERLENDİRME: ANALİZ VE İLERLEME ÖNERİLERİ

Zeynep DEMİR

Batman Üniversitesi Lisansüstü Eğitim Enstitüsü
Bilgi Teknolojileri Ana Bilim Dalı

Danışman: Prof. Dr. Ö. Faruk ERTUĞRUL

2024, 55 Sayfa

Jüri

Prof. Dr. Necmettin SEZGİN
Prof. Dr. Ö. Faruk ERTUĞRUL
Dr. Öğr. Üyesi Davut ÖZHAN

Bu çalışma, öğrenci başarısını tahmin etmek amacıyla eğitilen Yapay Sinir Ağı (YSA) modelinin performansını değerlendirmeyi hedeflemektedir. Geniş bir veri seti üzerinde gerçekleştirilen eğitim ve test süreçleri sonucunda elde edilen bulgular, çeşitli önemli kategorilerde detaylı bir şekilde incelenmiştir. Temel dersler arasında yer alan Türkçe ve Matematik gibi derslerde modelin düşük Root Mean Square Error (RMSE) değerleri elde ettiği gözlemlenmiştir. Bu durum, modelin bu derslerde güçlü tahminler yapabildiğini işaret etmektedir. Ancak, İnkılap Tarihi ve Fen Bilimleri gibi derslerde test RMSE değerlerinde bir artış gözlemlenmiştir; bu durum da modelin bu derslerde daha fazla iyileştirme potansiyeli taşıdığını göstermektedir. Deneme sınavı puanları ve toplam net sonuçları tahmininde de benzer bir analiz gerçekleştirilmiştir. Deneme sınavı puanları tahminlerinde eğitim ve test RMSE değerleri arasındaki fark dikkat çekicidir. Bu durum, modelin deneme sınavı puanları tahminlerinde daha fazla iyileştirme yapma potansiyeline ya da modelin daha fazla geliştirilmesi gerektiğine işaret etmektedir. Ayrıca, modelin eğitim süreleri incelenmiş ve farklı kategorilerde farklı eğitim süreleri tespit edilmiştir. Modelin daha karmaşık kategorilerde, özellikle de deneme sınavı puanları tahminlerinde, daha uzun sürelerle eğitilmesi gerektiği gözlemlenmiştir. Bu çalışmanın temel amacı, YSA modelinin öğrenci başarısını tahmin etme konusunda genel bir etkinlik sergilediğini vurgulamaktır. Ayrıca, çalışmanın kapsamında yer alan hedefler arasında; 1) Deneme sınavlarına bağlı olarak Liselere Geçiş Sınavı (LGS) sonucunu tahmin etme, 2) Deneme sınavlarının LGS sınavına olan benzerliğini ölçme ve 3) Yapay Zeka (AI) kullanarak öğrencilerin akademik başarısını belirlemede izleyeceği rolü belirleyen bir akademik danışmanlık/koçluk altyapısının kurulabileceğini gösterme hedefleri de bulunmaktadır. Bu hedefler, çalışmanın özünde yer alan önemli katkıları ifade etmektedir.

Anahtar Kelimeler: Eğitim, Öğrenci Başarı Tahmini, Yapay Sinir Ağları

ABSTRACT

MS THESIS

ASSESSING STUDENT ACHIEVEMENT WITH ARTIFICIAL NEURAL NETWORKS: ANALYSIS AND RECOMMENDATIONS

Zeynep DEMİR

**Batman University Graduate Education Institute
The Degree of Master of Science in Information Science**

Advisor: Prof. Dr. Ö. Faruk ERTUĞRUL

2024, 55 Pages

Jury

**Prof. Dr. Necmettin SEZGİN
Prof. Dr. Ö. Faruk ERTUĞRUL
Asst. Prof. Dr. Davut ÖZHAN**

This study aims to evaluate the performance of an Artificial Neural Network (ANN) model trained to predict student achievement. The findings obtained as a result of the training and testing processes on a large data set are analyzed in detail in various important categories. It was observed that the model obtained low Root Mean Square Error (RMSE) values in courses such as Turkish and Mathematics, which are among the basic courses. This indicates that the model is able to make strong predictions in these subjects. However, an increase in test RMSE values was observed in subjects such as History of Turkish Revolution and Science, indicating that the model needs to be further improved in these subjects. The difference between training and test RMSE values in the prediction of mock exam scores is striking. This indicates that the model needs to be further improved in the prediction of mock exam scores. Furthermore, training durations were analyzed and different training durations were found for different categories. It was observed that the model should be trained for longer periods for more complex categories, especially for predicting mock exam scores. The main objective of this study is to emphasize that the ANN model exhibits a general effectiveness in predicting student achievement. In addition, the objectives of the study include; 1) Predicting High School Transition Exam (LGS) scores based on mock exams, 2) Measuring the similarity of trial exams to the LGS exam and 3) There are also goals to show that an academic advising/coaching infrastructure that determines the role of Artificial Intelligence (AI) in determining the academic success of students. These goals represent important contributions at the core of the study.

Keywords: Artificial Neural Network (ANN), Education, Student Achievement Prediction

ÖNSÖZ

Tezimin tüm aşamalarında, sorularımı sabırla dinleyip cevaplayan, motivasyonumu her daim canlı tutan akademik danışmanım Prof. Dr. Ömer Faruk Ertuğrul Hocama en içten şükranlarımı sunuyorum.

Yüksek lisans yapmam konusunda beni daima cesaretlendiren ve destekleyen çocuklarım Aydın Eymen ile Mustafa'ya ve onlara örnek olmami sağlayan, hayatıma değer katan sevgili eşim İdris Demir'e sonsuz teşekkürler...

Zeynep DEMİR
BATMAN-2024



İÇİNDEKİLER

| | |
|--|-------------|
| ÖZET | iv |
| ABSTRACT | v |
| ÖNSÖZ | vi |
| İÇİNDEKİLER | vii |
| SİMGELER VE KISALTMALAR | viii |
| ŞEKİLLER DİZİNİ | v |
| TABLOLAR DİZİNİ | vi |
| 1. GİRİŞ | 1 |
| 2. LİTERATÜR ARAŞTIRMASI | 4 |
| 3. MATERYAL VE YÖNTEM | 7 |
| 3.1. Meteryal..... | 7 |
| 3.2. Yapay Sinir Ağları..... | 8 |
| 3.3. Çok Katmanlı Algılayıcı | 11 |
| 3.4. Hiperparametre Optimizasyonu ve Grid Search Yöntemi | 13 |
| 3.5. Hata Parametresi (Karekök Ortalama Kare Hatası) | 15 |
| 4. ARAŞTIRMA BULGULARI VE TARTIŞMA | 17 |
| 4.1. Araştırma Bulguları..... | 17 |
| 4.1.1. Türkçe dersi net sonuçları | 17 |
| 4.1.2. İnkılap tarihi ve atatürkçülük dersi net sonuçları..... | 18 |
| 4.1.3. Din kültürü ve ahlak bilgisi dersi net sonuçları | 20 |
| 4.1.4. Yabancı dil dersi net sonuçları..... | 21 |
| 4.1.5. Matematik dersi net sonuçları | 22 |
| 4.1.6. Fen bilimleri dersi net sonuçları..... | 23 |
| 4.1.7. Deneme (1-7) toplam net sonuçları..... | 25 |
| 4.1.8. Deneme (1-7) puanı sonuçları..... | 26 |
| 4.1.9. Tüm denemeler toplam net sonuçları..... | 27 |
| 4.1.10. Tüm denemeler toplam puan sonuçları | 29 |
| 4.2. Tartışma | 30 |
| 5. ÖNERİLER | 32 |
| KAYNAKLAR | 35 |
| ÖZGEÇMİŞ | 42 |

SİMGELER VE KISALTMALAR

Simgeler

| | |
|------------|-----------------------|
| y_i | : Gerçek Değer |
| $y \sim_i$ | : Tahmin Edilen Değer |
| e_i | : Hata Değeri |
| n | : Basıklık Katsayısı |



Kısaltmalar

| | |
|-----------|---|
| YZ | : Yapay Zeka |
| LGS | : Liselere Geçiş Sınavı |
| YSA | : Yapay Sinir Ağları |
| Din.K.A.B | : Din Kültürü ve Ahlak Bilgisi |
| PISA | : Uluslararası Öğrenci Değerlendirme Programı |
| MLP | : Çok Katmanlı Algılayıcı |
| ELM | : Aşırı Öğrenme Makinaları |
| RMSE | : Kök Ortalama Kare Hatası |
| Sig | : Sigmoidal Fonksiyonu |
| Sin | : Sinüs Fonksiyonu |
| Hardlim | : Hardlim Fonksiyonu |
| SVM | : Destek Vektör Makinesi |
| Tribas | : Üçgensel Taban Fonksiyonu |
| Radbas | : Radial Taban Fonksiyonu |
| ML | : Makine Öğrenmesi |

ŞEKİLLER DİZİNİ

| | |
|--|----|
| Şekil 3. 1. Yapay Sinir Hücresi..... | 8 |
| Şekil 3. 2. Yapay Sinir Ağı | 9 |
| Şekil 4. 1. Türkçe Tahmin Sonuçları | 18 |
| Şekil 4. 2. İnkılap Tarihi ve Atatürkçülük Tahmin Sonuçları..... | 19 |
| Şekil 4. 3. Din Kültürü ve Ahlak Bilgisi Tahmin Sonuçları..... | 20 |
| Şekil 4. 4. Yabancı Dil Tahmin Sonuçları | 21 |
| Şekil 4. 5. Matematik Tahmin Sonuçları | 23 |
| Şekil 4. 6. Fen Bilimleri Tahmin Sonuçları | 24 |
| Şekil 4. 7. Tüm Denemeler Tahmin Sonuçları..... | 28 |
| Şekil 4. 8. Tüm Denemeler Tahmin Sonuçları..... | 29 |



TABLÖLAR DİZİNİ

| | |
|---|----|
| Tablo 4. 1. Deneme (1-7) Toplam Net Sonuçları | 25 |
| Tablo 4. 2. Deneme (1-7) Puan Sonuçları..... | 26 |



1. GİRİŞ

Eğitim, toplumların evriminde temel bir itici güç olup bireylerin potansiyellerini maksimum seviyeye çıkarma ve kişisel gelişimlerini sağlama amacını taşır. Bu bağlamda, öğrencilerin akademik başarılarını değerlendirmek ve onlara uygun rehberlik sunmak, eğitim sistemlerinin temel amaçlarından biridir (Aybek, 2018, Umar, 2019, Uzel vd., 2018, Güven vd., 2023). Ancak, her öğrencinin farklı yeteneklere ve güçlü-zayıf yön kombinasyonlarına sahip olması, geleneksel değerlendirme yöntemlerinin sınırlarını ortaya çıkarmaktadır. Bu noktada, yapay zekâ (YZ) tabanlı tekniklerin eğitim alanındaki kullanımı, öğrenci başarısını değerlendirme ve rehberlik konularında yeni bir perspektif sunmaktadır (Buraimoh vd., 2021, Bucos vd., 2018, Yıldız vd., 2020, Zacharis, 2016, Lau vd., 2019, Baashar vd., 2022, Huang vd., 2023).

Liselere Geçiş Sınavı (LGS), Türkiye'deki ortaokul öğrencilerinin liselere yerleşme sürecinde kritik bir konumda bulunan bir sınavdır. Bu sınav, öğrencilerin akademik başarılarını değerlendirmenin yanı sıra potansiyellerini belirleyerek, liselere yerleşme sürecinde karar verici bir etken olarak ön plana çıkmaktadır (Poyraz vd., 2023, Güngör vd., 2023, Görgüt vd., 2023). LGS, öğrencilerin genel eğitim seviyelerini ölçmenin yanı sıra, bu öğrencilerin gelecekteki eğitim yolculuklarını şekillendiren ve belirleyen kapsamlı bir değerlendirme aracıdır. Öğrenciler için bu sınav, liselere geçiş aşamasında yaşadıkları önemli bir kilometre taşı olup, akademik ve kariyer hedeflerini belirleme sürecinde hayati bir role sahiptir (Dilekçi vd., 2023, Kayalı vd., 2022, Çakmak vd., 2023).

Yapay sinir ağları, yapay zeka alanındaki temel modelleme araçlarından birini oluşturan, biyolojik sinir ağlarının çalışma prensiplerinden esinlenen bir yapının temelini oluşturur. Bu ağlar, bilgisayar sistemlerine insan beyninin sinir ağlarına benzer bir yapı kullanma yeteneği kazandırarak, karmaşık bilgi işleme görevlerini gerçekleştirebilme kabiliyetine sahiptir (Zou vd., 2009, Zhang vd., 2018, Krenker vd., 2011). Yapay sinir ağları, geniş veri setleri üzerinde öğrenme ve desen tanıma yetenekleriyle öne çıkarak, özellikle eğitimde ve öğrenci başarısının analizinde yaygın olarak kullanılmaktadır (Khan vd., 2023, Triansyah vd., 2023, Pallathadka vd., 2023, Chen vd., 2023). Bu sinir ağları, biyolojik sinir hücrelerinin etkileşimini taklit ederek, bilgisayar sistemlerine öğrenme ve problem çözme yetenekleri kazandırmak amacıyla tasarlanmıştır. Her bir yapay sinir, girdi bilgilerini alır, ağırlıklarla çarpılır işlenir, bir aktivasyon fonksiyonuna tabi tutar ve ardından bir çıkış üretir. Bu işleyiş, birbirine bağlı sinir hücrelerinden oluşan katmanlar

arasında gerçekleşir. Bu katmanlar genellikle giriş katmanı, gizli katmanlar ve çıkış katmanı şeklinde düzenlenir (Hassoun, 1995, Shanmuganathan, 2016, Maind vd., 2014).

Eğitimde, yapay sinir ağları öğrenci başarısını tahmin etmek, öğrenci performansını analiz etmek ve öğrenme desenlerini tanımlamak için kullanılır. Bu ağlar, geniş ölçekli veri setlerini analiz edebilme ve karmaşık ilişkileri tespit edebilme yetenekleri sayesinde öğrencilerin güçlü ve zayıf yönlerini belirlemede etkili bir araç sunarlar. Ayrıca, öğrenciye özel eğitim stratejileri oluşturarak, öğrenme deneyimini daha kişiselleştirilmiş hale getirme potansiyeline sahiptirler (Ciolacu vd., 2018, Okewu vd., 2021, Ibragim vd., 2020, Valko vd., 2020).

Yapay sinir ağlarının temel işleyişi, bu teknolojinin eğitimdeki potansiyelini değerlendirmek ve öğrenci başarısını daha etkili bir şekilde analiz etmek için kritik bir öneme sahiptir (Rodríguez-Hernández, vd., 2021, Naser vd., 2015). Bu bağlamda, yapay sinir ağlarının biyolojik sinir ağlarına benzer bir temel prensip üzerine kurulu olduğu, öğrenci başarısını değerlendirme ve tahmin etme süreçlerinde nasıl etkili bir rol oynadığı daha ayrıntılı bir şekilde incelenmelidir.

Bu araştırma, öğrenci başarısını değerlendirmede yeni perspektifler sunmanın yanı sıra, eğitimde bireyselleştirilmiş rehberlik hizmetlerinin geliştirilmesine de katkı sağlamayı amaçlamaktadır. Yapay sinir ağlarının, öğrencilerin güçlü ve zayıf yönlerini belirleme ve buna göre eğitim stratejileri oluşturma konusundaki potansiyeli, bu çalışmanın merkezinde yer almaktadır. Bu yaklaşım, öğrenci başarısını sadece nicel skorlarla değil, aynı zamanda öğrencinin bireysel güçlü ve zayıf yönleriyle birleştirerek daha kapsamlı bir şekilde değerlendirmeyi hedeflemektedir.

Yapay sinir ağları, geniş veri setleri üzerinde karmaşık desenleri analiz edebilme yetenekleri ile öne çıkar. Bu çalışma, öğrencilerin güçlü yönlerini belirleme ve zayıf noktalarını anlama konusunda yapay sinir ağlarının benzersiz yeteneklerini vurgular. Elde edilen verilerin derinlemesine analizi, öğrencilerin notlarını sadece genel bir başarı puanıyla değil, aynı zamanda spesifik derslerdeki performanslarıyla da değerlendirmeyi mümkün kılar. Bu, eğitimcilerin öğrencilere daha kişiselleştirilmiş rehberlik sağlamalarına olanak tanır. Yapay sinir ağlarının öğrenci başarısını tahmin etme ve analiz etme potansiyeli, eğitim stratejilerini oluşturmak adına büyük bir avantaj sunmaktadır. Bu potansiyeli değerlendirerek, öğrencilere özel olarak uyarlanmış eğitim planları oluşturmak, eğitimde bireyselleştirilmiş bir yaklaşımın temelini oluşturabilir. Bu, her öğrencinin eğitim sürecinde daha etkili ve kişisel bir rehberlik deneyimi yaşamasını sağlayabilir.

Bu çalışma, öğrenci başarısını tahmin etme konusunda yapay sinir ağları gibi yapay zeka modellerinin kullanılmasını ve bu tekniklerin eğitimdeki potansiyelini araştırmayı amaçlamaktadır. Geleneksel değerlendirme metodolojilerinin ötesine geçen yapay zeka modelleri, geniş veri setlerini analiz ederek karmaşık desenleri tespit edebilme yetenekleriyle öne çıkar. Bu durum, öğrenci performansını daha kapsamlı ve derinlemesine bir şekilde anlama fırsatı sunar. Çalışmamız, Türkçe, İnkılap Tarihi, Din Kültürü ve Ahlak Bilgisi (Din K.A.B.), Yabancı Dil, Matematik, Fen Bilimleri gibi temel derslerden oluşan denemelerden elde edilen net skorları kullanarak öğrencilerin LGS puanlarını önceden tahmin etmeyi hedeflemektedir.

Çalışmanın ilerleyen bölümlerinde, kullanılan metodoloji, elde edilen sonuçlar ve bu sonuçların eğitim pratiğine olan olası etkileri daha ayrıntılı bir şekilde incelenecektir. Bu araştırmanın, yapay zekâ destekli öğrenci değerlendirme alanındaki mevcut literatüre yeni bir bakış açısı getirmesi ve eğitimde daha etkili stratejiler geliştirmeye katkı sağlaması hedeflenmektedir.

2. LİTERATÜR ARAŞTIRMASI

Rahmani ve Aprilianto'nun (2014) yılındaki araştırmaları, Banjarmasin Üniversitesi'nden 2011-2012 yılları arasında mezun olan öğrencilerin akademik verilerini temel alarak bir yapay sinir ağları (YSA) modeli geliştirmelerini konu almaktadır. Bu çalışmada, öğrencilerin üç dönem boyunca elde ettikleri ders notlarının ortalamaları modelin girdi ağırlıkları olarak kullanılmıştır. Araştırmacılar, bu girdi verilerini analiz ederek öğrencilerin üniversiteden hangi not ortalamasıyla mezun olduklarını ve bu not ortalamasıyla mezuniyete ulaşmalarının ne kadar zaman aldığını tahmin etmeye çalışmışlardır. Bu model, öğrencilerin akademik performanslarını ölçmek ve eğitim süreçlerini iyileştirmek için değerli içgörüler sunmaktadır (Rahmani vd., 2014).

Tepehan'ın (2011) yılında yürüttüğü çalışma, Türkiye'deki öğrencilerin Uluslararası Öğrenci Değerlendirme Programı (PISA) sonuçları üzerinden elde edilen verileri kullanarak, Yapay Sinir Ağları (YSA) ve lojistik regresyon analizi yöntemlerinin tahmin performanslarını karşılaştırmıştır. Bu araştırma, matematik, fen bilimleri ve okuma olmak üzere üç farklı akademik branşta yapılan performans değerlendirmesine odaklanmıştır. Karşılaştırmalı analizde, her iki metodolojinin başarı tahminleri incelenmiştir. Matematik branşında YSA yöntemi %78,6 doğruluk oranı ile öğrenci başarısını tahmin ederken, lojistik regresyon yöntemi ise %76,8 doğruluk oranı ile sonuçlar üretmiştir. Fen bilimleri branşında ise YSA %78,5, lojistik regresyon %78,1 doğruluk oranı ile performans sergilemiştir. Okuma branşında YSA, %79,4'lük bir doğruluk oranı ile en yüksek performansı gösterirken, lojistik regresyon yöntemi %78,4 ile takip etmiştir. Bu sonuçlar, Yapay Sinir Ağlarının lojistik regresyona göre genel olarak daha yüksek doğruluk oranları sağladığını ortaya koymaktadır. YSA'nın daha yüksek performansı, özellikle büyük ve karmaşık veri kümelerinde gizli kalıpları ve ilişkileri algılama kapasitesinden kaynaklanabilir. Bu, YSA'nın özellikle değişkenler arası etkileşimlerin yoğun olduğu durumlarda daha iyi tahminler yapabilmesine imkan tanır. Tepehan'ın çalışması, eğitim alanında veri bilimi yöntemlerini kullanarak öğrenci başarısını daha doğru şekilde tahmin etme ve eğitim politikalarını şekillendirme potansiyeline işaret etmektedir. Ayrıca, bu tür analizler, eğitimde karar verme süreçlerine katkıda bulunarak öğrenci başarısını artırmaya yönelik stratejilerin geliştirilmesine yardımcı olabilir (Tepehan, 2011).

Musso, Kyndt, Coscaller ve Dochy'nin (2013) yılındaki çalışması, öğrencilerin akademik performanslarını değerlendirmek üzere çeşitli bilişsel özellikleri ve demografik

ile çevresel faktörleri ele almıştır. Bu özellikler arasında dikkat, hafıza ve öğrenme stratejileri gibi kritik bilişsel faktörler bulunmaktadır. Araştırmacılar, bu faktörlerden yola çıkarak öğrencileri akademik başarılarına göre üç farklı gruba ayırmışlar ve her bir grubu Yapay Sinir Ağları (YSA) kullanarak sınıflandırmışlardır. Bu sınıflandırma sürecinde, iki grup için %100 doğruluk oranı elde edilmişken, üçüncü grup için doğruluk oranı %87 olarak gerçekleşmiştir. Çalışmanın bir diğer önemli bulgusu, YSA modeli tarafından üretilen sürekli puan değerleri ile gerçek gözlem değerleri arasındaki korelasyonun yüksek olmasıdır; bu ilişki 0.86 gibi oldukça yüksek bir korelasyon değeri ile ifade edilmiştir. Bu yüksek korelasyon değeri, modelin öğrencilerin akademik performanslarını tahmin etme konusunda yüksek güvenilirlik ve geçerlilik gösterdiğini belirtir (Musso vd., 2013).

Naik ve Ragothaman'ın (2004) yılındaki çalışmaları, işletme yönetimi alanında ki lisansüstü programındaki öğrencilerin akademik başarılarını tahmin etmek üzerine odaklanmıştır. Araştırma, öğrencilerin başarı durumlarını "başarılı" veya "başarısız" olarak sınıflandırmayı amaçlamaktadır. Bu sınıflandırma, Yapay Sinir Ağları (YSA), logit regresyon analizi ve probit regresyon analizi olmak üzere üç farklı istatistiksel ve yapay zeka yöntemi kullanılarak gerçekleştirilmiştir. Çalışma kapsamında, YSA modeli on girdi değişkeni ve bir çıktı değişkeni ile oluşturulmuştur. Bu on girdi değişkeni, öğrencilerin demografik bilgileri, önceki akademik başarıları ve diğer ilgili faktörler gibi çeşitli önemli ölçütleri içerebilir. YSA modelinin öğrenci performansını doğru sınıflandırma oranı %89,13 olarak belirlenmiş ve bu, diğer iki yönteme kıyasla daha yüksek bir başarı göstermiştir. Buna karşılık, logit regresyon modeli %72,83 ve probit regresyon modeli ise %73,37 doğruluk oranı ile sınıflandırma yapabilmıştır (Naik vd., 2004).

Toprak (2017) makalesinde, Yapay Sinir Ağları (YSA), 2012 yılında karar ağaçları ve ayırma analizi yöntemleriyle analiz yaparak seçkin sınavlardan biri olan Türkiye'deki öğrencilerin Uluslararası Öğrenci Değerlendirme Programı (PISA) matematik olimpiyatına katılan tüm öğrencilerin matematik başarılarını incelemiştir. Çalışma sonucunda elde ettiği karşılaştırma analizlerine göre Yapay Sinir Ağlarının diğer sınıflandırma yöntemlerine göre daha yüksek sınıflandırma oranına ulaştığını göstermiştir. Bu çalışma öğrenci performansını tahmin etmek ve anlamak için kullanılacak çok boyutlu ve karmaşık veri setlerinin analizinde YSA'nın etkinliğini göstermektedir (Toprak, 2017).

Aybek (2016) yaptığı tez çalışmasında, YSA modelini kullanarak Anadolu Üniversitesi Açık Öğretim Sistemine kayıtlı olan öğrencilerin Temel Bilgi Teknolojisi dersinden aldıkları not ve geçme durumları ve aldıkları puanları tahmin etmeye çalışmıştır. Toplamda 195584 öğrenci verisi kullanarak yaptığı analizde tahmin edilen puanlar ile gerçek puanlar arasında ki korelasyonun düşük olduğunu saptamıştır (Aybek, 2016).

Aslantaş ve diğerleri tarafından (2012) yılında gerçekleştirilen bir araştırma, eğitim fakültesinde öğrenim gören öğrencilerin akademik başarısını etkileyen faktörler üzerine yoğunlaşmıştır. Bu çalışma, öğrencilerin dönem sonu başarılarını etkileyebilecek çeşitli sosyo-ekonomik ve eğitimle ilgili değişkenleri incelemiştir. Araştırma sonuçları, ailelerin gelir durumunun, babaların eğitim düzeyinin, öğrencilerin üniversiteyi kaçınıcı denemede kazandıklarının, dershaneye gitme durumlarının ve lise bitirme derecelerinin öğrencilerin akademik başarıları üzerinde önemli bir etkiye sahip olduğunu göstermiştir. Bu faktörlerin her biri, öğrencinin eğitim sürecinde karşılaştığı fırsatlar ve zorluklar açısından belirleyici olabilir (Aslantaş vd., 2012).

Diğer yandan, Çırak'ın (2012) yılındaki çalışması yüksek öğrenimdeki öğrencilerin başarılarını sınıflandırmayı amaçlamış ve bu süreçte Lojistik Regresyon ile Yapay Sinir Ağları (YSA) metodolojilerini karşılaştırmıştır. Çalışmada kullanılan YSA modeli, özellikle Çok Katmanlı Perceptron (MLP) ağı formunda uygulanmıştır. Bu modelin performansı, lojistik regresyon analizi ile karşılaştırıldığında daha yüksek bir başarı oranı (%70,16) göstermiş, buna karşın lojistik regresyon analizinin başarı oranı %66,10 olarak kaydedilmiştir. YSA'nın daha yüksek performansı, bu modelin karmaşık veri yapılarını ve öğrenci başarısını etkileyen çeşitli faktörler arasındaki ilişkileri modellemede daha etkili olabileceğini düşündürmektedir. Her iki çalışma da, öğrenci başarısını etkileyen faktörlerin belirlenmesi ve bu faktörlere dayalı olarak tahmin yapılabilmesi için farklı analitik yaklaşımların potansiyelini ortaya koymaktadır. Bu tür bilgiler, eğitim politikaları ve müdahale stratejilerinin geliştirilmesinde önemli bir rol oynayabilir, böylece eğitim kurumları öğrencilerin ihtiyaçlarına daha iyi yanıt verebilir ve akademik başarıları artırabilir (Çırak, 2012).

Tekin (2014), yaptığı çalışmada üniversiteyi bitiren öğrencilerinin genel not ortalamasını tahmin etmek amacıyla Yapay Sinir Ağları (YSA), Destek Vektör Makinesi (SVM) ve Aşırı Öğrenme Makinesi (ELM) yöntemlerini kullanmıştır. Çalışma sonunda elde ettiği başarı karşılaştırmasını SVM % 97,98, ELM % 94,92 ve YSA % 93,76 oranlarında saptamıştır (Tekin, 2014).

3. MATERYAL VE YÖNTEM

3.1. Meteryal

Bu arařtırmada, öğrenci başarısını Yapay Sinir Ağları (YSA) modeli kullanarak tahmin etme amacıyla kapsamlı bir veri seti toplanmıştır. Toplamda 628 öğrencinin akademik performansını değerlendirmek üzere Türkçe, İnkılap Tarihi, Din Kültürü ve Ahlak Bilgisi, Yabancı Dil, Matematik, Fen Bilimleri gibi çeşitli derslerden oluşan 7 adet deneme sınavı ve Liselere Geçiş Sınavı (LGS) sonuçları kullanılmıştır. Bu geniş veri seti, öğrencilerin akademik başarılarını çeşitli ölçütlerle değerlendirmek ve YSA modelinin performansını değerlendirmek için kullanılmıştır.

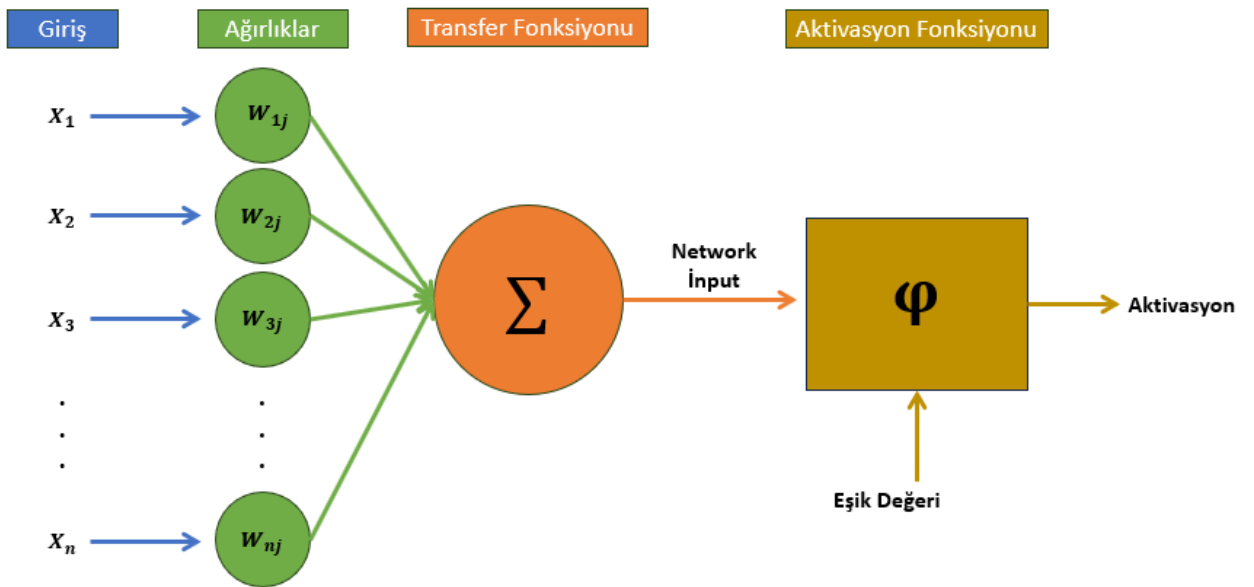
Çalışmada, farklı sınıf düzeylerinden ve LGS'den elde edilen deneme sonuçlarıyla YSA modeli eğitilmiş ve değerlendirilmiştir. Toplamda 8 farklı deneme sınavı seti incelenmiş, bunlardan, 3 tanesi 7. sınıfa, 4 tanesi 8. sınıfa ve 1 tanesi LGS'ye yöneliktir. Bu çeşitlilik, YSA modelinin farklı sınıflardaki performansını değerlendirmek ve genel tahmin yeteneklerini anlamak için önemlidir.

Deneme sınavı setleri, öğrencilerin farklı akademik seviyelerini temsil etmek üzere özenle seçilmiştir. Örneğin, 7. sınıf deneme setleri, öğrencilerin ortaokul eğitimine devam etme sürecindeki akademik gelişimini yansıtırken, 8. sınıf deneme sınavı setleri, liseye geçiş öncesi kritik bir dönemi temsil etmektedir. LGS seti de öğrencilerin liseye geçiş sınavındaki performansını ölçmeyi amaçlamaktadır. Bu farklı sınıf düzeylerinden elde edilen deneme sonuçları, YSA modelinin her bir sınıf seviyesindeki başarı ve zorlukları değerlendirmesine olanak tanır. Bu değerlendirme, YSA modelinin öğrenci başarısını tahmin etme konusundaki genel etkinliğini daha iyi anlamamıza yardımcı olacaktır.

Bu zengin veri seti, öğrencilerin akademik performanslarını çeşitli yönlerden değerlendirmek ve YSA modelinin tahmin yeteneklerini test etmek için ideal bir ortam sağlar. Ayrıca, farklı sınıf düzeylerinden elde edilen verilerin analizi, eğitim sistemindeki öğrencilerin gelişimini anlamak ve eğitim stratejilerini iyileştirmek için önemli bir bilgi kaynağı oluşturur. Bu çalışma, YSA modelinin öğrenci başarısını tahmin etme yeteneğini değerlendirerek, eğitim alanında yapay zeka tekniklerinin kullanımının potansiyelini ortaya koymaktadır.

3.2. Yapay Sinir Ağları

Yapay sinir ağları, biyolojik sinir sisteminden esinlenerek tasarlanmış matematiksel modellerdir. Bu ağlar, yapay sinir hücrelerinden oluşur ve karmaşık bilgi işleme görevlerini gerçekleştirmek için kullanılırlar. Her bir yapay sinir hücresi, bir veya daha fazla girdi alır. Her girdiye bir ağırlık atanır ve bu ağırlıklar, girdi değerleri ile çarpılarak toplanır. Toplama işlemi sonucunda elde edilen ağırlıklı toplam, sinir hücresinin içsel aktivasyonunu belirler. Elde edilen toplam, bir aktivasyon fonksiyonundan geçirilir. Aktivasyon fonksiyonu genellikle bir eşik değeri üzerinden çalışarak, hücrenin çıkışı belirler. Eğer elde edilen toplam, belirlenen eşik değerini aşarsa, hücre aktive olur ve bir sinyal üretir; aksi halde, etkinleşmez (Dongare vd., 2012, Yegnanarayana, 2009, Wang vd., 2003). Bu süreç, sinir hücresinin temel işleyişini oluşturur. Şekil 1'de yapay sinir hücresi modeli gösterilmiştir.



Şekil 3. 1. Yapay Sinir Hücresi

Yapay sinir ağlarında, sinir hücreleri bir araya gelerek katmanlar oluştururlar. Bu katmanlar genellikle üç ana kısımdan oluşur: girdi katmanı, gizli katmanlar ve çıkış katmanı (Abraham, 2005, Uhrig, 1995, Abiodun vd., 2018).

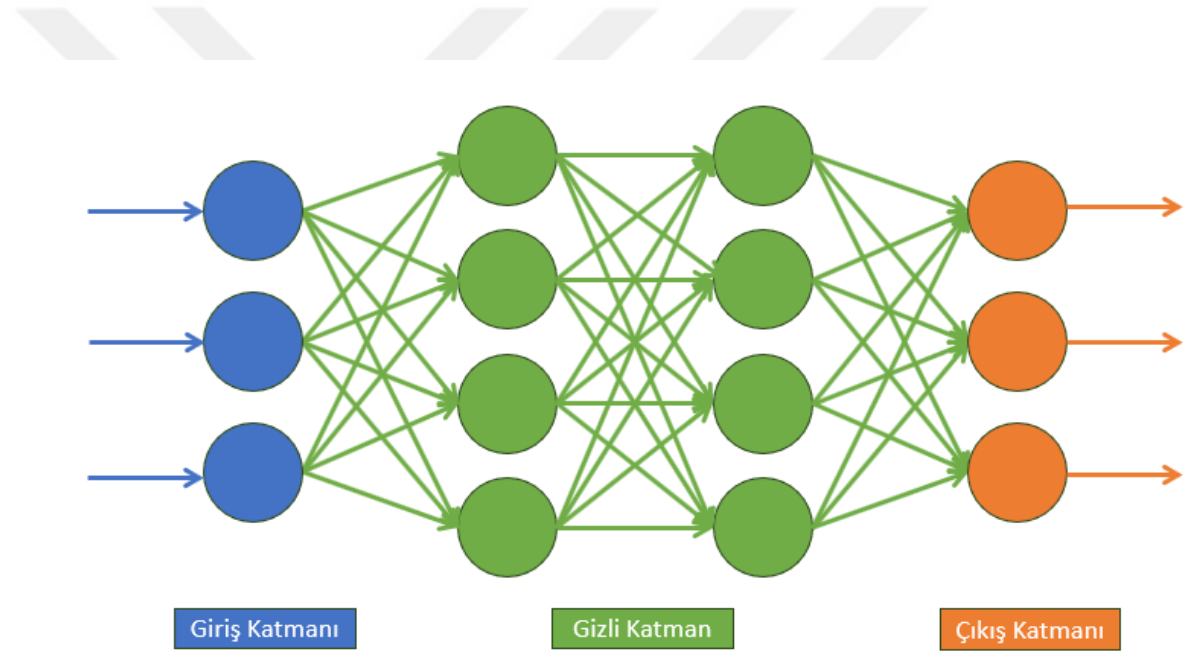
Girdi katmanı, ağa dış dünyadan gelen verileri sunar. Bu veriler genellikle sayısal değerlerdir ve ağın işlemesi gereken bilgileri içerir. Örneğin, bir görüntü tanıma uygulamasında, girdi katmanı piksel değerlerini alabilir (Abiodun vd., 2018).

Gizli katmanlar, girdi katmanından gelen verileri işlemek ve aralarındaki karmaşık ilişkileri öğrenmek için tasarlanmıştır. Bu katmanlar, girdiler arasındaki

desenleri algılamak ve öğrenmek için ağ tarafından otomatik olarak oluşturulan ağırlıkları kullanır. Bir yapay sinir ağı genellikle birden fazla gizli katmana sahip olabilir, bu da daha karmaşık ilişkilerin öğrenilmesine olanak tanır (Abiodun vd., 2018).

Çıkış katmanı, işlenmiş verilere dayanarak bir çıkış üretir. Bu çıkış, genellikle ağın amacına bağlı olarak değişir. Örneğin, bir sınıflandırma problemi için, çıkış katmanı farklı sınıflara ait olasılık değerlerini üretebilir (Abiodun vd., 2018).

Yapay sinir ağları, karmaşık bir bilgi işleme sürecini gerçekleştirmek için sinir hücreleri arasındaki bağlantıları kullanır. Her bir sinir hücresi, alınan girdileri işleyerek bir çıktı üretir. Bu işlem, ağın öğrenme yeteneğini sağlayan ve sonuçları optimize eden bir süreçtir. Şekil 2'de yapay sinir ağı modeli gösterilmiştir (Jain vd., 1996, Gershenson,2003).



Şekil 3.2. Yapay Sinir Ağı

Her bir sinir hücresi, girdilerinden gelen bilgileri alır. Bu girdiler, genellikle diğer sinir hücrelerinden veya dış kaynaklardan gelir ve sayısal değerler şeklinde temsil edilir. Sinir hücresi, her bir girdiye bir ağırlık atanır. Bu ağırlıklar, girdinin önem derecesini belirler ve sinir hücresinin çıktısını etkiler. Ağırlıklarla çarpılan ve toplanan girdi değerleri, sinir hücresinin içsel aktivasyonunu belirler. Bu işlem sonucunda elde edilen ağırlıklı toplam, sinir hücresinin ne kadar "uyandığını" veya "etkinleştiğini" gösterir (Basu vd., 2010). Aktivasyon fonksiyonu, genellikle bu ağırlıklı toplamı bir eşik değeri üzerinden değerlendirerek sinir hücresinin çıkışını belirler. Eğer elde edilen toplam,

belirlenen eşik değerini aşarsa, hücre aktive olur ve bir sinyal üretir; aksi halde, etkinleşmez. Bu işlem, her bir sinir hücresinin işlemlerini tanımlar ve bir yapay sinir ağının temel yapısını oluşturur. Bu hücreler bir araya gelerek katmanlar oluşturur ve bilgi işleme sürecini gerçekleştirir. Ağın genel olarak öğrenme süreci, ağırlıkların ve aktivasyon fonksiyonlarının uygun şekilde ayarlanması yoluyla gerçekleştirilir. Bu süreç, ağın istenen sonuçları üretecek şekilde optimize edilmesini sağlar ve öğrenme yeteneğini artırır (Agatonovic-Kustrin vd., 2000).

Yapay sinir ağlarının eğitimi, ağın içindeki ağırlıkların ve eşik değerlerin uygun şekilde ayarlanmasıyla gerçekleştirilir. Bu ayarlama genellikle geri yayılım algoritması gibi optimizasyon teknikleri kullanılarak yapılır. Geri yayılım algoritması, ağın hata fonksiyonunu minimize etmek için ağırlıkların ve eşik değerlerin gradyan iniş yöntemiyle güncellendiği bir süreçtir. Ağın eğitimi, genellikle eğitim veri seti üzerinde iteratif bir şekilde gerçekleştirilir. Bu süreçte, ağa verilen girdilerle beklenen çıktılar arasındaki fark, bir hata fonksiyonu kullanılarak hesaplanır. Ardından, bu hata geriye doğru yayılarak her bir ağırlık ve eşik değerinin bu hataya katkısı belirlenir. Geriye doğru yayılma süreci, zincir kuralı ve gradyan inişi gibi matematiksel teknikler kullanılarak gerçekleştirilir. Bu sürecin sonucunda, her bir ağırlık ve eşik değeri güncellenir, böylece ağın çıktılarının beklenen çıktılara daha yakın olması sağlanır. Bu güncelleme işlemi, ağın daha doğru ve etkili hale gelmesini sağlar. Eğitim süreci, genellikle belirli bir hata eşiği veya iterasyon sayısına ulaşıncaya kadar devam eder (Priddy vd., 2005, Krogh, 2008). Yapay sinir ağlarının eğitimi, bu şekilde veri setlerindeki desenleri tanımayı ve öğrenmeyi sağlar. Ağ, eğitim veri setindeki örneklerden öğrendiği bilgiyi genelleme yeteneğiyle yeni veri örneklerine uygulayabilir. Bu sayede, ağ genellikle daha önce görmediği verilerle de başarılı sonuçlar verebilir (Mehrotra vd., 1997).

Yapay sinir hücreleri ve ağları, geniş bir uygulama yelpazesine sahip güçlü yapay zekâ modelleridir. Özellikle, örüntü tanıma, sınıflandırma ve tahminleme gibi çeşitli görevlerde başarılı bir şekilde kullanılabilirler (Batoool vd., 2023). Örneğin, görüntü tanıma alanında, yapay sinir ağları, nesne tanıma, yüz tanıma, trafik işaretlerinin tanınması gibi birçok önemli görevde kullanılır (Azgomi vd., 2023). Aynı şekilde, dil işleme alanında yapay sinir ağları, metin sınıflandırma, duygu analizi, metin üretimi gibi birçok görevde kullanılır. Finansal analiz alanında yapay sinir ağları, hisse senedi fiyatlarının tahmin edilmesi, risk analizi, kredi derecelendirmesi gibi birçok finansal görevde kullanılır. Tıp alanında ise, yapay sinir ağları hastalık teşhisi, görüntü tabanlı tanı

yöntemleri, ilaç keşfi gibi birçok tıbbi uygulamada etkili bir şekilde kullanılabilir (Akıl vd., 2023, Oğuz vd., 2023, Oğuz vd., 2023, Li vd., 2010).

Bu geniş uygulama alanlarına ek olarak, yapay sinir ağları eğitim alanında da önemli bir rol oynar. Özellikle, öğrenci performansının değerlendirilmesi, öğrenme stratejilerinin optimize edilmesi ve bireyselleştirilmiş eğitim materyallerinin sunulması gibi görevlerde kullanılarak eğitim süreçlerine katkı sağlarlar. Yapay sinir ağları, öğrenci başarısını tahmin etmek için kullanılabilir (Deperlioglu vd., 2011). Sınav sonuçları, ödev notları, devamsızlık bilgileri gibi verilerle eğitimciler, her öğrencinin akademik başarısını daha ayrıntılı bir şekilde analiz edebilir. Ayrıca, yapay sinir ağlarının esnek yapısı, her öğrencinin güçlü ve zayıf yönlerini belirleyerek bireyselleştirilmiş öğrenme planları oluşturmayı mümkün kılar. Özel eğitim ihtiyaçları olan öğrencilere uygun materyaller sağlanabilir ve öğrenci performans verilerinin analiz edilmesiyle, eğitimciler öğrencilere daha etkili rehberlik ve danışmanlık yapabilirler (Mahapatra vd., 2007, Akgün vd., 2018, Oancea vd., 2013).

3.3. Çok Katmanlı Algılayıcı

Çok Katmanlı Algılayıcılar (MLP) ve Yapay Sinir Ağları (YSA), temelde aynı kavramı temsil eder: insan beyninin çalışma biçimini taklit etmek ve karmaşık veriler arasındaki ilişkileri modellemek için tasarlanmış yapay bir sinir ağı yapısı. Ancak, MLP ve YSA arasında bazı farklar bulunmaktadır (Kruse vd., 2022). MLP, en az bir gizli katmanı olan çok katmanlı bir yapıya sahiptir, bu da daha karmaşık ilişkileri modelleme yeteneği sunar. Diğer yandan, YSA genellikle daha basit bir yapıya sahiptir ve genellikle tek katmanlı veya en fazla bir gizli katmana sahiptir. MLP'ler daha geniş bir veri yelpazesini işleme ve daha karmaşık problemleri çözme yeteneğine sahipken, YSA'lar daha basit problemlerde veya küçük ölçekli uygulamalarda kullanılabilir. Bu farklar, her iki yapay sinir ağı türünün de farklı avantajlara sahip olduğunu ve hangisinin belirli bir görev için daha uygun olduğunu belirlemek için göz önünde bulundurulması gerektiğini gösterir (Rana vd., 2018, Ismail vd., 2015).

Çok Katmanlı Algılayıcı (MLP), yapay sinir ağlarının en yaygın ve etkili kullanılan türlerinden biridir. Bu ağlar, birçok farklı uygulama alanında başarıyla kullanılmaktadır. Örneğin, MLP'ler, öğrenci başarısını tahmin etmek, doğal dil işleme, finansal analiz, tıbbi teşhis ve otomatik sürüş teknolojileri gibi çeşitli alanlarda kullanılmaktadır (Lubis vd., 2023).

Öğrenci başarısını tahmin etmek amacıyla MLP'ler kullanıldığında, giriş katmanı genellikle öğrencinin ders notları, devamsızlık bilgisi, önceki sınav sonuçları gibi çeşitli akademik verileri içerir. Her bir gizli katman, belirli bir özelliği veya beceriyi temsil eder. Örneğin, birinci gizli katman matematik performansını, ikinci gizli katman ise dil becerilerini öğrenir. Son olarak, çıkış katmanı genel başarıyı yansıtan bir tahmin üretir. Bu şekilde, eğitimciler öğrencilerin akademik performansını daha iyi anlayabilir ve öğrenme stratejilerini optimize edebilir (Castellani, 2018, Ranjeeth vd., 2021, Almeida, 2020).

Doğal dil işleme alanında, MLP'ler metin sınıflandırma, duygu analizi, metin üretimi gibi birçok görevde etkili bir şekilde kullanılmaktadır. Metin sınıflandırma görevlerinde, giriş katmanı metin içindeki kelimeleri temsil eder. Her bir gizli katman, dilbilgisi özelliklerini öğrenir ve çıkış katmanı metni belirli bir kategoriye sınıflandırır. Bu sayede, metinlerin içeriğini analiz etmek, duygusal tonunu anlamak veya metin tabanlı tahminlerde bulunmak gibi birçok görevde MLP'ler önemli bir rol oynar (Goldberg,2022, Ma,2002).

Finansal analiz alanında da MLP'ler yaygın olarak kullanılmaktadır. Hisse senedi fiyatlarının tahmin edilmesi, risk analizi, kredi derecelendirmesi gibi birçok finansal görevde MLP'ler etkili bir şekilde kullanılabilir. Büyük miktarda finansal veri kullanılarak eğitilen MLP'ler, gelecekteki finansal trendleri belirlemek ve riskleri değerlendirmek için etkili bir araç olarak kullanılabilir (Namdari vd., 2018, Brenes vd., 2022).

Tıp alanında, MLP'ler hastalık teşhisi, görüntü tabanlı tanı yöntemleri, ilaç keşfi gibi birçok tıbbi uygulamada kullanılmaktadır. Tıbbi görüntülerdeki patolojik bulguları tanımlamak, hastalıkların erken teşhisini sağlamak ve tedavi planlarını optimize etmek için MLP'ler etkili bir şekilde kullanılabilir. Otomatik sürüş teknolojileri gibi gelişmiş uygulamalarda da MLP'ler önemli bir rol oynamaktadır. Örneğin, otonom araçlar, çevrelerindeki nesnelere algılamak ve doğru kararlar almak için MLP'leri kullanabilirler (Sonawane vd., 2014, Safar vd., 2023).

Bu çeşitli alanlarda MLP'lerin kullanımı, yapay zeka teknolojisinin geniş bir yelpazede etkili bir şekilde uygulanmasını sağlar ve birçok sektörde verimliliği artırır. Çok Katmanlı Algılayıcılar, eğitim alanında sunduğu bir dizi avantajla öne çıkan etkili yapay sinir ağlarından biridir. Bu model, öğrenci performansını değerlendirmek, öğrenme stratejilerini optimize etmek ve bireyselleştirilmiş eğitim materyalleri sunmak gibi önemli görevlerde kullanılarak eğitim süreçlerine katkı sağlamaktadır (Sinitsyn vd., 2020).

Çok Katmanlı Algılayıcılar, öğrenci başarısını tahmin etme konusunda etkili bir araçtır. Giriş katmanında öğrenci notları, devamsızlık bilgisi ve önceki sınav sonuçları gibi faktörler bulunabilir. Bu veriler, gizli katmanlar aracılığıyla işlenir ve çıkış katmanı genel başarıyı yansıtan bir tahmin üreterek eğitimcilerin öğrenci ihtiyaçlarını daha iyi anlamalarına yardımcı olur. MLP'nin esnek yapısı, öğrenciler arasındaki farklı öğrenme stillerini ve ihtiyaçlarını anlamak için kullanılabilir. Örneğin, birinci gizli katman matematik performansını, ikinci gizli katman ise dil becerilerini öğrenebilir. Bu, her öğrencinin güçlü ve zayıf yönlerini belirleyerek bireyselleştirilmiş öğrenme planları oluşturmayı mümkün kılar (Obsie vd., 2018).

MLP, eğitimde çeşitli kullanım alanlarına sahiptir. Öğrenci başarısının değerlendirilmesi, bireyselleştirilmiş öğrenme materyallerinin oluşturulması ve öğrenci rehberliği gibi görevlerde etkili bir şekilde kullanılabilir. MLP, öğrenci performans verilerini analiz ederek, eğitimcilerin öğrencilere daha etkili rehberlik ve danışmanlık yapmalarına yardımcı olabilir. Zayıf performans gösteren bir öğrenciye ek destek sağlama veya ileri düzey konularda yetenek gösteren bir öğrenciyi özel programlara yönlendirme gibi. Çok Katmanlı Algılayıcılar, bireyselleştirilmiş, veri odaklı ve etkili bir yaklaşım sunarak eğitimdeki çeşitli ihtiyaçlara cevap verir. Bu nedenle, MLP ve benzeri yapay sinir ağları, modern eğitim sistemlerinde önemli bir rol oynamaktadır. Yapay sinir ağları, eğitimde ve birçok diğer uygulamada geniş bir etki alanına sahiptir. Bu ağlar, karmaşık problemleri çözme, desenleri tanıma ve adaptasyon yetenekleri ile bilgisayar sistemlerine öğrenme yetisi kazandırmada önemli bir rol oynarlar.

3.4. Hiperparametre Optimizasyonu ve Grid Search Yöntemi

Makine öğrenimi modellerinin performansını etkileyen önemli bir faktör, modelin hiperparametrelerinin doğru şekilde ayarlanmasıdır. Hiperparametreler, modelin yapısal özelliklerini ve eğitim sırasında optimize edilmesi gereken parametreleri içerir (Feurer vd.,2019, Yang vd., 2020). Bu nedenle, doğru hiperparametrelerin belirlenmesi, modelin performansını önemli ölçüde etkiler. Hiperparametre optimizasyonu, bu hiperparametrelerin en uygun değerlerini bulmayı amaçlayan bir süreçtir (Andonie,2019, Wistuba vd., 2015). Grid Search yöntemi, hiperparametre optimizasyonunda yaygın olarak kullanılan bir tekniktir. Bu yöntem, aday hiperparametre kombinasyonlarını sistematik bir şekilde arayarak, en iyi performansı sağlayan kombinasyonu bulmayı hedefler. Grid Search, belirli bir parametre uzayında belirlenen hiperparametre değerlerini bir ızgara şeklinde arar ve her bir kombinasyonun performansını ölçer. Bu

performans metrikleri genellikle doğruluk oranı, ortalama karesel hata (RMSE), hassasiyet veya geri çağırma gibi ölçümlerdir (Liashchynskyi vd., 2019, LaValle vd., 2004).

Bu arařtırmada, öğrenme oranı, momentum terimi, gizli katman sayısı, düğüm sayıları ve aktivasyon fonksiyonları gibi hiperparametreler için belirli aralıklar veya değerler belirlendi. Örneğın, öğrenme oranı ve momentum terimi genellikle [0,1] aralığında değerler alabilir. Gizli katman sayısı ve düğüm sayıları için belirlenen aralık, 2 ile 150 arasında deęişen değerlerdir. Aktivasyon fonksiyonları için belirlenen set ise şunlardır: sigmoidal fonksiyon ('sig'), sinüs fonksiyonu ('sin'), hardlim fonksiyonu ('hardlim'), üçgensel taban fonksiyonu ('tribas') ve radial taban fonksiyonu ('radbas'). Çapraz doğrulama için 5 parça kullanılmıř olup, bu, veri setinin eşit parçalara bölünerek her bir parça için sırayla test ve eğitim seti oluşturulmasını ifade eder. Grid Search yöntemi, belirlenen hiperparametre kombinasyonlarını sistematik olarak deneyerek en iyi performansı saęlayan kombinasyonu bulmayı amaçlar. Bu süreç, her bir hiperparametre kombinasyonunun test edilmesini ve sonuçların deęerlendirilmesini içerir. En iyi performansı saęlayan hiperparametreler, test veri seti üzerinde elde edilen en düşük RMSE deęeri kullanılarak belirlenir.

Bu çalışmada, modelin hiperparametreleri Grid Search yöntemiyle optimize edildi. İlk olarak, arařtırılacak hiperparametreler belirlendi; genellikle öğrenme oranı, momentum terimi, gizli katman sayısı, gizli katman düğüm sayıları ve aktivasyon fonksiyonları gibi modelin performansını etkileyen faktörler üzerinde duruldu. Daha sonra, her bir hiperparametre için bir aralık veya deęer kümesi belirlendi. Grid Search sürecinde, belirlenen hiperparametre aralıklarındaki tüm kombinasyonlar sistematik bir şekilde deneyerek, her birinin modelin performansını nasıl etkilediđi gözlemlendi. Bu süreçte, genellikle çapraz doğrulama yöntemine başvurularak, elde edilen sonuçların güvenilirliđi artırıldı. Önerilen Grid Search yaklařımı, modelin en iyi performansını elde etmesini saęladı. Bu sayede, işlenen veri setindeki karmařıklık ve doğruluk dengesi için en uygun hiperparametreler belirlendi. Sonuç olarak, modelin genelleřtirilebilirliđi artırıldı ve tahmin doğruluđu optimize edildi. Bu da çalışmanın güvenilirliđini artırarak, sonuçların daha saęlam olmasını saęladı.

3.5. Hata Parametresi (Karekök Ortalama Kare Hatası)

Karekök Ortalama Kare Hatası (RMSE), regresyon analizinde yaygın olarak kullanılan bir performans ölçütüdür ve modelin gerçek verilere ne kadar yakın tahminler yaptığını değerlendirmeye yardımcı olur. RMSE, gerçek ve tahmin edilen değerler arasındaki farkın karelerinin ortalamasının karekökü olarak hesaplanır. Bu istatistiksel metrik, modelin tahmin yeteneğini değerlendirirken aynı zamanda tahminlerin ne kadar varyasyon gösterdiğini de gösterir (Willmott vd., 2005).

Karekök ortalama kare hatasının hesaplanması için her bir veri noktası için gerçek değer (y) ile tahmin edilen değer (\hat{y}) arasındaki farkın karesi alınır. Bu karelerin ortalaması alınarak bir ortalama kare hatası elde edilir. Daha sonra, bu ortalama kare hatasının karekökü alınarak RMSE değeri bulunur (Hastie vd., 2009).

RMSE'nin hesaplanması şu adımları içerir (Hastie vd., 2009):

- **Hata Hesaplama:** Her bir gözlem için gerçek değerler (y_i) ile modelin tahmin ettiği değerler (\hat{y}_i) arasındaki fark (hata) (e_i) hesaplanır: $e_i = (y_i - \hat{y}_i)^2$
- **Kare Hata Hesaplaması:** Her bir hata değeri karesi alınır: $(e_i)^2$
- **Ortalama Hata Hesaplaması:** Kare hatalarının ortalaması alınır: $\frac{1}{n} \sum_{i=1}^n e_i^2$, burada n gözlem sayısını temsil eder.
- **Karekök Alınması:** Ortalama kare hatalarının karekökü alınarak RMSE elde edilir:

Denklem 1' matematiksel olarak ifade edilirse;

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (1)$$

Karekök ortalama kare hatasının yorumlanması, modelin performansını anlamak için önemlidir. Düşük RMSE değerleri, modelin gerçek verilere daha yakın tahminler yaptığını ve verilere daha iyi uyum sağladığını gösterir (Chai vd., 2014). Bu durumda, modelin tahminlerinin gerçek değerlere çok yakın olduğu ve modelin genellikle iyi bir performans sergilediği söylenebilir. Öte yandan, yüksek RMSE değerleri, modelin tahminlerinin gerçek verilere daha uzak olduğunu ve modelin iyileştirilmesi gerektiğini işaret eder. Bu durumda, modelin gerçek verilere uyum sağlamakta zorlandığı ve tahminlerinin güvenilirliğinin düşük olduğu söylenebilir. Yüksek RMSE değerleri

genellikle modelde hatalı özelliklerin veya eksikliklerin olduğunu gösterebilir ve bu durumda modelin gözden geçirilmesi veya değiştirilmesi gerekebilir. Bu nedenle, RMSE değeri, modelin etkinliğini değerlendirmek için regresyon analizinde yaygın olarak kullanılan önemli bir ölçüttür (Hodson, 2022).

RMSE değerinin "iyi" veya "kötü" olduğunu belirlemek, belirli bir uygulamaya ve veri setine bağlıdır. Örneğin, finansal tahminler veya tıbbi teşhisler gibi alanlarda, tahminlerin yüksek doğrulukta olması kritiktir ve dolayısıyla daha düşük RMSE değerleri hedeflenir. Diğer yandan, sosyal bilimlerde veya pazarlama analizlerinde, daha yüksek RMSE değerleri kabul edilebilir olabilir.

Genellikle, RMSE değerleri şu kategoriler altında değerlendirilebilir:

0: Mükemmel eşleşme. Ancak, bu durum gerçek dünyada nadiren gerçekleşir.

0 ile 1 arası: Harika eşleşme.

1 ile 2 arası: Kabul edilebilir.

2 ile 5 arası: Orta seviye tahmin yeteneği.

5 ve üzeri: Zayıf tahmin yeteneği.

Bu aralıklar genel kılavuzlar olup, belirli bir uygulama bağlamında değişiklik gösterebilir. Önemli olan, elde edilen RMSE değerlerini mevcut endüstri standartlarıyla, kabul edilebilirlik kriterleriyle ve uygulama gereksinimleriyle uyumlu olacak şekilde yorumlamaktır.

Sonuç olarak, RMSE değeri, regresyon modellerinin performansını objektif bir şekilde değerlendirmeye yardımcı olan önemli bir metriktir ve modelin belirli bir uygulamadaki etkinliğini değerlendirmek için dikkate alınması gereken bir kriterdir.

4. ARAŞTIRMA BULGULARI VE TARTIŞMA

4.1. Araştırma Bulguları

Bu çalışmanın sonuçları, öğrenci başarısını tahmin etmek amacıyla eğitilen yapay sinir ağlarının performansını detaylı bir şekilde göstermektedir. Her bir kategori için elde edilen sonuçlar ayrı ayrı incelenmiş ve analiz edilmiştir. Bu sonuçlar, öğrencilerin farklı ders kategorilerindeki başarı düzeylerini anlamak ve öngörmek için önemli bir bakış açısı sunmaktadır.

Türkçe, T.C. İnkılap Tarihi ve Atatürkçülük, Din Kültürü ve Ahlak Bilgisi, İngilizce, Matematik, Fen Bilimleri gibi farklı ders kategorileri için yapılan analizlerin sonuçları ayrı ayrı incelenmiştir. Bu kategorilerde elde edilen sonuçlar, yapay sinir ağlarının öğrenci başarısını tahmin etme yeteneğini değerlendirmek için önemli bir ölçüdür.

Sonuçlar bölümünde her bir kategori için ayrı başlıklar altında bulunan sonuçlar, detaylı bir şekilde sunulacaktır. Ayrıca, Deneme Toplam Net, Deneme Puanları ve Tüm Deneme Puanları gibi toplam başarıyı yansıtan metriklerin sonuçları da ayrıca verilecektir. Bu sonuçlar, yapay sinir ağlarının öğrenci başarısını tahmin etme yeteneğini değerlendirmek için sağlam bir zemin oluşturacaktır.

4.1.1. Türkçe dersi net sonuçları

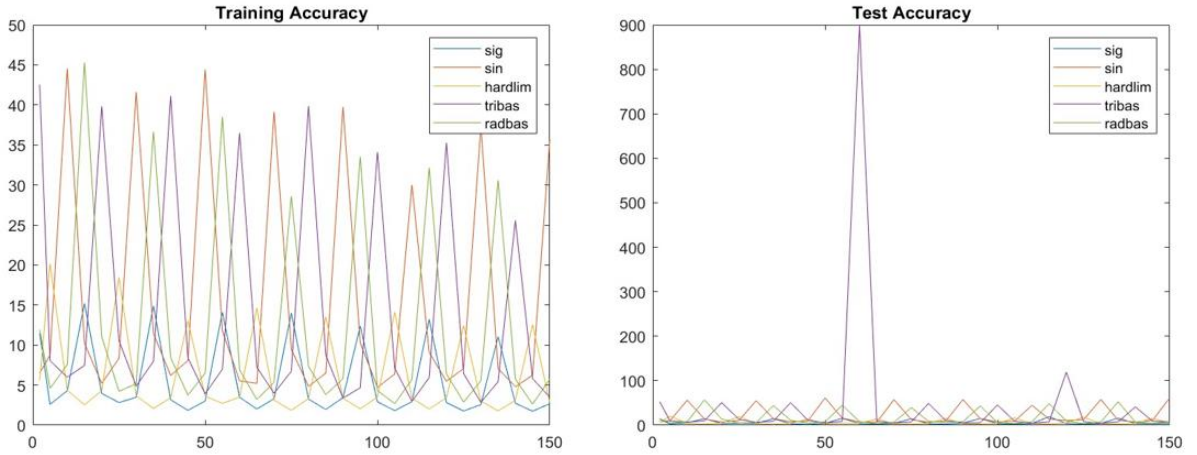
Türkçe dersi için yapılan analizlerin sonuçları aşağıdaki gibidir:

Eğitim RMSE: 1,7409

Test RMSE: 1,8464

Süre: 7,48

Türkçe net kategorisinde, eğitim sürecinde elde edilen RMSE değeri 1,7409 iken test sürecinde bu değer 1,8464 olarak belirlenmiştir. Modelin Türkçe net tahminlerindeki başarısı incelenmiş ve bu kategorideki eğitim sürecinin ortalama süresi 7,48 saniye olarak gözlemlenmiştir. Bu sonuçlar, Türkçe dersindeki performans tahmininin, modelin eğitim setine kıyasla test setinde de güçlü olduğunu göstermektedir. Elde edilen sonuçlar Şekil 3'te gösterilmiştir. Bu bulgular, Türkçe dersinde yapay sinir ağlarının etkin bir şekilde öğrenci başarısını tahmin etmede kullanılabileceğini ve eğitim sürecinin başarıya olan katkısını belirlemek için değerli bir araç olduğunu vurgular. Elde edilen sonuçlar Şekil 3'te gösterilmiştir.



Şekil 4.1. Türkçe Tahmin Sonuçları

Türkçe dersi için en iyi sonuçları veren hiperparametreler şu şekildedir:

Gizli Katman Nöron Sayısı: 85

Aktivasyon Fonksiyonu: sigmoid (sig)

Eğitim RMSE: 1,7409

Test RMSE: 1,8464

Bu hiperparametrelerin belirlenmesi, modelin Türkçe dersindeki başarısını en üst düzeye çıkarmak için önemli bir rol oynamaktadır.

4.1.2. İnkılap tarihi ve atatürkçülük dersi net sonuçları


İnkılap Tarihi ve Atatürkçülük dersi için yapılan analizlerin sonuçları aşağıdaki gibidir:

Eğitim RMSE: 1,7385

Test RMSE: 1,9796

Süre: 7,71

İnkılap Tarihi ve Atatürkçülük net kategorisinde, eğitim sürecinde elde edilen RMSE değeri 1,7385 iken test sürecinde bu değer 1,9796 olarak belirlenmiştir. Modelin İnkılap Tarihi ve Atatürkçülük net tahminlerindeki performansı detaylı bir şekilde değerlendirilmiş ve bu kategorideki eğitim sürecinin ortalama süresi 7,71 saniye olarak belirlenmiştir. İnkılap Tarihi ve Atatürkçülük dersinde yapılan tahminler, eğitim ve test setlerinde benzer bir başarı göstermektedir, bu da modelin genelleme yeteneğini gösterir. Elde edilen sonuçlar, Şekil 4'te ayrıntılı olarak gösterilmiştir.



Şekil 4.2. İnkılap Tarihi ve Atatürkçülük Tahmin Sonuçları

Bu bulgular, İnkılap Tarihi ve Atatürkçülük dersindeki öğrenci başarısını tahmin etmede kullanılan modelin güvenilirliğini ve etkinliğini vurgulamaktadır. Eğitim ve test setlerinde benzer RMSE değerlerinin elde edilmesi, modelin yeni verilere iyi uyum sağladığını ve genel olarak stabil bir performans sergilediğini gösterir. Bu sonuçlar, İnkılap Tarihi ve Atatürkçülük dersinde yapay sinir ağlarının etkin bir şekilde kullanılabileceğini ve öğrenci başarısını tahmin etmek için değerli bir araç olduğunu göstermektedir.

T.C. İnkılap Tarihi ve Atatürkçülük dersi için en iyi sonuçları veren hiperparametreler şu şekildedir:

Gizli Katman Nöron Sayısı: 135

Aktivasyon Fonksiyonu: hardlim

Eğitim RMSE: 1,7385

Test RMSE: 1,9796

Bu hiperparametrelerin belirlenmesi, modelin T.C. İnkılap Tarihi ve Atatürkçülük dersindeki başarısını maksimize etmek için önemlidir. Gizli katman nöron sayısının ve aktivasyon fonksiyonunun seçimi, modelin karmaşıklığı ve esnekliği üzerinde önemli bir etkiye sahiptir. Eğitim ve test RMSE değerlerinin karşılaştırılması, modelin test setindeki performansının eğitim setindeki performansına göre daha düşük olduğunu göstermektedir. Bu durum, modelin eğitim verilerine daha iyi uyum sağladığı ve genelleme yeteneğinin test verilerinde düşük olduğunu gösterebilir. Bu sonuçlar, modelin daha iyi genelleme yeteneği için hiperparametrelerin dikkatlice ayarlanması gerektiğini vurgular.

4.1.3. Din kültürü ve ahlak bilgisi dersi net sonuçları


Din Kültürü ve Ahlak Bilgisi dersi için yapılan analizlerin sonuçları aşağıdaki gibidir:

Eğitim RMSE: 1,6703

Test RMSE: 1,9903

Süre: 7,49

Din Kültürü ve Ahlak Bilgisi net kategorisinde, eğitim sürecinde elde edilen RMSE değeri 1,6703 iken test sürecinde bu değer 1,9903 olarak belirlenmiştir. Modelin Din Kültürü ve Ahlak Bilgisi net tahminlerindeki performansı detaylı bir şekilde değerlendirilmiş ve bu kategorideki eğitim sürecinin ortalama süresi 7,49 saniye olarak belirlenmiştir. Din Kültürü ve Ahlak Bilgisi dersinde yapılan tahminler, eğitim ve test setlerinde benzer bir başarı göstermektedir, bu da modelin genelleme yeteneğini gösterir. Elde edilen sonuçlar, Şekil 5'te ayrıntılı olarak gösterilmiştir.



Şekil 4.3. Din Kültürü ve Ahlak Bilgisi Tahmin Sonuçları

Bu bulgular, Din Kültürü ve Ahlak Bilgisi dersindeki öğrenci başarısını tahmin etmede kullanılan modelin güvenilirliğini ve etkinliğini vurgulamaktadır. Eğitim ve test setlerinde benzer RMSE değerlerinin elde edilmesi, modelin yeni verilere iyi uyum sağladığını ve genel olarak stabil bir performans sergilediğini gösterir. Bu sonuçlar, Din Kültürü ve Ahlak Bilgisi dersinde yapay sinir ağlarının etkin bir şekilde kullanılabileceğini ve öğrenci başarısını tahmin etmek için değerli bir araç olduğunu göstermektedir.

Din Kültürü ve Ahlak Bilgisi dersi için en iyi sonuçları veren hiperparametreler şu şekildedir:

Gizli Katman Nöron Sayısı: 60

Aktivasyon Fonksiyonu: sigmoid (sig)

Eđitim RMSE: 1,6703

Test RMSE: 1,9903

Bu hiperparametrelerin belirlenmesi, modelin Din Kùltürü ve Ahlak Bilgisi dersindeki başarısını maksimize etmek için önemlidir. Gizli katman nörön sayısının ve aktivasyon fonksiyonunun seçimi, modelin karmaşıklığı ve esnekliđi üzerinde önemli bir etkiye sahiptir. Eđitim ve test RMSE deđerlerinin karşılaştırılması, modelin test setindeki performansının eđitim setindeki performansına göre daha düşük olduğunu göstermektedir. Bu durum, modelin eđitim verilerine daha iyi uyum sağladığı ve genelleme yeteneđinin test verilerinde düşük olduğunu gösterebilir. Bu sonuçlar, modelin daha iyi genelleme yeteneđi için hiperparametrelerin dikkatlice ayarlanması gerektiđini vurgular.

4.1.4. Yabancı dil dersi net sonuçları

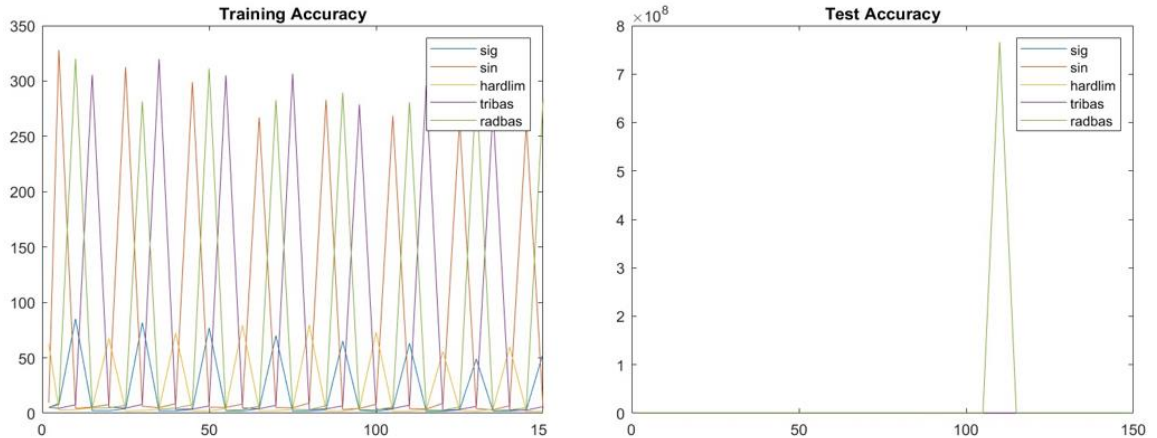
Yabancı Dil dersi için yapılan analizlerin sonuçları aşağıdaki gibidir:

Eđitim RMSE: 1,7327

Test RMSE: 1,9084

Süre: 7,44

Yabancı Dil net kategorisinde, eđitim sürecinde elde edilen RMSE deđeri 1,7327 iken test sürecinde bu deđer 1,9084 olarak belirlenmiştir. Modelin Yabancı Dil net tahminlerindeki başarısı detaylı bir şekilde incelenmiş ve bu kategorideki eđitim sürecinin ortalama süresi 7,44 saniye olarak gözlemlenmiştir. Yabancı Dil dersindeki tahminlerin, eđitim ve test setlerinde benzer bir başarı göstermesi, modelin genelleme yeteneđini vurgular. Elde edilen sonuçlar, Şekil 6'da detaylı bir şekilde gösterilmiştir.



Şekil 4.4. Yabancı Dil Tahmin Sonuçları

Bu sonuçlar, Yabancı Dil dersindeki öğrenci başarısını tahmin etmek için kullanılan modelin güvenilirliğini ve etkinliğini vurgular. Eğitim ve test setlerinde benzer RMSE değerlerinin elde edilmesi, modelin yeni verilere iyi uyum sağladığını ve genel olarak stabil bir performans sergilediğini gösterir. Bu bulgular, Yabancı Dil dersinde yapay sinir ağlarının etkin bir şekilde kullanılabileceğini ve öğrenci başarısını tahmin etmek için değerli bir araç olduğunu göstermektedir.

İngilizce dersi için en iyi sonuçları veren hiperparametreler şu şekildedir:

Gizli Katman Nöron Sayısı: 135

Aktivasyon Fonksiyonu: hardlim

Eğitim RMSE: 1,7327

Test RMSE: 1,9084

Bu hiperparametrelerin belirlenmesi, modelin İngilizce dersindeki başarısını en üst düzeye çıkarmak için önemlidir. Gizli katman nöron sayısının ve aktivasyon fonksiyonunun seçimi, modelin karmaşıklığı ve esnekliği üzerinde önemli bir etkiye sahiptir. Eğitim ve test RMSE değerlerinin karşılaştırılması, modelin test setindeki performansının eğitim setindeki performansına göre daha düşük olduğunu göstermektedir. Bu durum, modelin eğitim verilerine daha iyi uyum sağladığı ve genelleme yeteneğinin test verilerinde düşük olduğunu gösterebilir. Bu sonuçlar, modelin daha iyi genelleme yeteneği için hiperparametrelerin dikkatlice ayarlanması gerektiğini vurgular.

4.1.5. Matematik dersi net sonuçları

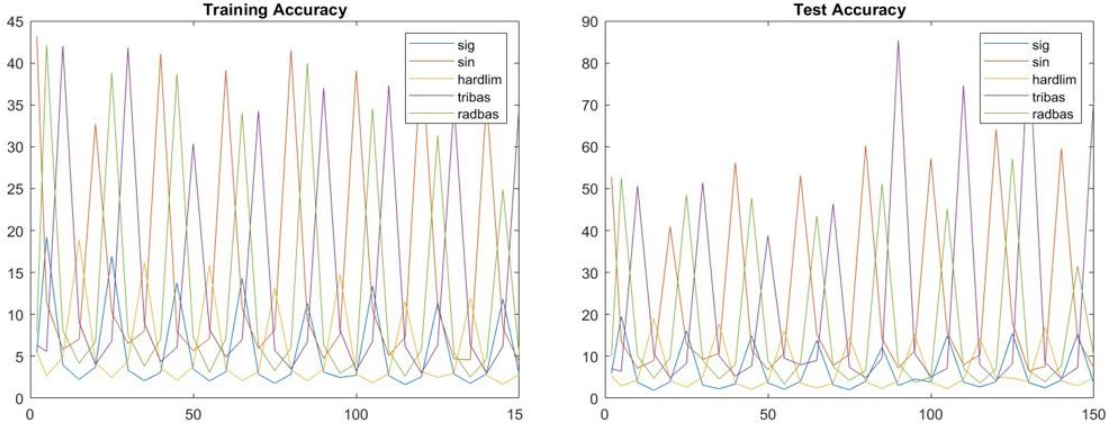
Matematik dersi için yapılan analizlerin sonuçları aşağıdaki gibidir:

Eğitim RMSE: 1,6318

Test RMSE: 1,8889

Süre: 7,54

Matematik net kategorisinde, eğitim sürecinde elde edilen RMSE değeri 1,6318 iken test sürecinde bu değer 1,8889 olarak belirlenmiştir. Modelin Matematik net tahminlerindeki başarısı detaylı bir şekilde incelenmiş ve bu kategorideki eğitim sürecinin ortalama süresi 7,54 saniye olarak gözlemlenmiştir. Bu sonuçlar, Matematik dersindeki performans tahmininin, modelin eğitim setine kıyasla test setinde de güçlü olduğunu göstermektedir. Elde edilen sonuçlar, Şekil 7’de detaylı bir şekilde gösterilmiştir.



Şekil 4.5. Matematik Tahmin Sonuçları

Bu bulgular, Matematik dersindeki öğrenci başarısını tahmin etmek için kullanılan modelin güvenilirliğini ve etkinliğini vurgulamaktadır. Eğitim ve test setlerinde benzer RMSE değerlerinin elde edilmesi, modelin yeni verilere iyi uyum sağladığını ve genel olarak stabil bir performans sergilediğini gösterir. Bu sonuçlar, Matematik dersinde yapay sinir ağlarının etkin bir şekilde kullanılabileceğini ve öğrenci başarısını tahmin etmek için değerli bir araç olduğunu göstermektedir.

Matematik dersi için en iyi sonuçları veren hiperparametreler şu şekildedir:

Gizli Katman Nöron Sayısı: 130

Aktivasyon Fonksiyonu: sigmoid (sig)

Eğitim RMSE: 1,6318

Test RMSE: 1,8889

Bu hiperparametrelerin belirlenmesi, modelin Matematik dersindeki başarısını maksimize etmek için önemlidir. Gizli katman nöron sayısının ve aktivasyon fonksiyonunun seçimi, modelin karmaşıklığı ve esnekliği üzerinde önemli bir etkiye sahiptir. Eğitim ve test RMSE değerlerinin karşılaştırılması, modelin test setindeki performansının eğitim setindeki performansına göre daha düşük olduğunu göstermektedir. Bu durum, modelin eğitim verilerine daha iyi uyum sağladığı ve genelleme yeteneğinin test verilerinde düşük olduğunu gösterebilir. Bu sonuçlar, modelin daha iyi genelleme yeteneği için hiperparametrelerin dikkatlice ayarlanması gerektiğini vurgular.

4.1.6. Fen bilimleri dersi net sonuçları


Fen Bilimleri dersi için yapılan analizlerin sonuçları aşağıdaki gibidir:

Eğitim RMSE: 1,6003

Test RMSE: 2,0343

Süre: 7,39

Fen Bilimleri dersi net kategorisinde, eğitim sürecinde elde edilen RMSE değeri 1,6003 iken test sürecinde bu değer 2,0343 olarak belirlenmiştir. Modelin Fen Bilimleri net tahminlerindeki performansı detaylı bir şekilde değerlendirilmiş ve bu kategorideki eğitim sürecinin ortalama süresi 7,39 saniye olarak belirlenmiştir. Fen Bilimleri dersinde yapılan tahminler, eğitim ve test setlerinde benzer bir başarı göstermektedir, bu da modelin genelleme yeteneğini vurgular. Elde edilen sonuçlar, Şekil 8’de ayrıntılı olarak gösterilmiştir.



Şekil 4.6. Fen Bilimleri Tahmin Sonuçları

Bu bulgular, Fen Bilimleri dersindeki öğrenci başarısını tahmin etmek için kullanılan modelin güvenilirliğini ve etkinliğini vurgulamaktadır. Eğitim ve test setlerinde benzer RMSE değerlerinin elde edilmesi, modelin yeni verilere iyi uyum sağladığını ve genel olarak stabil bir performans sergilediğini gösterir. Bu sonuçlar, Fen Bilimleri dersinde yapay sinir ağlarının etkin bir şekilde kullanılabilirliğini ve öğrenci başarısını tahmin etmek için değerli bir araç olduğunu göstermektedir.

Fen Bilimleri dersi için en iyi sonuçları veren hiperparametreler şu şekildedir:

Gizli Katman Nöron Sayısı: 90

Aktivasyon Fonksiyonu: hardlim

Eğitim RMSE: 1,6003

Test RMSE: 2,0343

Bu hiperparametrelerin belirlenmesi, modelin Fen Bilimleri dersindeki başarısını maksimize etmek için önemlidir. Gizli katman nöron sayısının ve aktivasyon fonksiyonunun seçimi, modelin karmaşıklığı ve esnekliği üzerinde önemli bir etkiye sahiptir. Eğitim ve test RMSE değerlerinin karşılaştırılması, modelin test setindeki

performansının eğitim setindeki performansına göre daha düşük olduğunu göstermektedir. Bu durum, modelin eğitim verilerine daha iyi uyum sağladığı ve genelleme yeteneğinin test verilerinde düşük olduğunu gösterebilir. Bu sonuçlar, modelin daha iyi genelleme yeteneği için hiperparametrelerin dikkatlice ayarlanması gerektiğini vurgular.

4.1.7. Deneme (1-7) toplam net sonuçları

Deneme Toplam Net sayısı için yapılan analizlerin sonuçları Tablo da gösterilmiştir.

Tablo 4. 1. Deneme (1-7) Toplam Net Sonuçları

| Deneme (1-7) Net Sonuçları Tablosu | | | | | |
|------------------------------------|---------------------------|-----------------------|-------------|-----------|---------------|
| Deneme | Gizli Katman Nöron Sayısı | Aktivasyon Fonksiyonu | Eğitim RMSE | Test RMSE | Süre (saniye) |
| 1 | 130 | sig | 2,4361 | 3,7306 | 9,807121 |
| 2 | 130 | sig | 2,4264 | 4,6594 | 9,149259 |
| 3 | 65 | sin | 2,1919 | 4,5626 | 9,941906 |
| 4 | 130 | sig | 2,1386 | 5,1969 | 11,208684 |
| 5 | 10 | sig | 2,3127 | 5,893 | 8,870177 |
| 6 | 130 | sig | 2,4621 | 5,3607 | 11,805912 |
| 7 | 15 | sig | 3,3923 | 5,0974 | 10,148094 |

Bu analizde, farklı hiperparametreler kullanılarak gerçekleştirilen yedi farklı denemenin net sonuçları incelenmiştir. Her bir deneme için elde edilen hiperparametreler ve kök ortalama kare hatası (RMSE) değerleri değerlendirilmiştir.

Deneme 1: 130 gizli katman nöronu ve sigmoid aktivasyon fonksiyonu kullanılarak en düşük test RMSE değeri elde edilmiştir. Bu, modelin eğitim setine iyi uyum sağladığını ancak genel olarak modelin belirli bir veriye aşırı uyum riski taşıdığını gösterebilir.

Deneme 2: Benzer şekilde, 130 gizli katman nöronu ve sigmoid aktivasyon fonksiyonu kullanılarak yapılan bu denemede, Deneme 1'e benzer bir performans elde edilmiştir. Her iki denemede de hiperparametrelerin aynı olmasına rağmen, farklı rastgele başlangıç noktaları nedeniyle hafif farklılıklar gözlemlenebilir.

Deneme 3: 65 gizli katman nöronu ve sinüs aktivasyon fonksiyonu kullanılarak yapılan bu denemede, en düşük test RMSE değeri elde edilmiştir. Daha az karmaşık bir modelin daha iyi genelleme yeteneğine sahip olabileceğini gösterir.

Deneme 4: 130 gizli katman nöronu ve sigmoid aktivasyon fonksiyonu kullanılarak yapılan bu denemede, test RMSE değeri bir miktar daha yüksektir. Daha

büyük bir gizli katman nöron sayısına rağmen, modelin genelleme yeteneği Deneme 3'e kıyasla daha düşüktür.

Deneme 5: En düşük gizli katman nöron sayısına sahip olan bu denemede (10), test RMSE değeri diğer denemelere göre daha yüksektir. Bu, daha az karmaşık bir modelin genellikle daha kötü performans gösterebileceğini gösterir.

Deneme 6: 130 gizli katman nöronu ve sigmoid aktivasyon fonksiyonu kullanılarak yapılan bu denemede, test RMSE değeri bir miktar daha yüksektir. Bu da modelin belirli bir veriye aşırı uyum riski taşıdığını gösterebilir.

Deneme 7: 15 gizli katman nöronu ve sigmoid aktivasyon fonksiyonu kullanılarak yapılan bu denemede, test RMSE değeri diğer denemelere kıyasla daha yüksektir. Daha az gizli katman nöronu kullanmanın genel performansı düşürebileceğini gösterir.

Bu analiz, daha az karmaşık modellerin genellikle daha iyi genelleme yeteneğine sahip olduğunu, ancak her durumda garantili olmadığını göstermektedir. Hiperparametrelerin dikkatli bir şekilde seçilmesi ve modelin performansının sürekli olarak değerlendirilmesi önemlidir.

4.1.8. Deneme (1-7) puanı sonuçları

Deneme Puanı için yapılan analizlerin sonuçları Tablo da gösterilmiştir.

Tablo 4.2. Deneme (1-7) Puan Sonuçları

| Deneme (1-7) Puan Sonuçları Tablosu | | | | | |
|-------------------------------------|---------------------------|-----------------------|-------------|-----------|---------------|
| Deneme | Gizli Katman Nöron Sayısı | Aktivasyon Fonksiyonu | Eğitim RMSE | Test RMSE | Süre (saniye) |
| 1 | 150 | sig | 2,4058 | 7,9748 | 11,6784 |
| 2 | 85 | sig | 2,4574 | 8,1103 | 10,0920 |
| 3 | 85 | sig | 2,4316 | 8,74 | 8,9368 |
| 4 | 110 | sig | 2,3224 | 10,2868 | 8,6746 |
| 5 | 130 | sig | 2,4465 | 8,8615 | 12,0113 |
| 6 | 20 | sin | 2,5733 | 9,5734 | 9,3551 |
| 7 | 65 | sig | 2,0336 | 8,9312 | 11,4715 |

Bu analizde, farklı hiperparametreler kullanılarak gerçekleştirilen yedi farklı denemenin sonuçları incelenmiştir. Her bir deneme için elde edilen hiperparametreler ve kök ortalama kare hatası (RMSE) değerleri değerlendirilmiştir.

Deneme 1: 150 gizli katman nöronu ve sigmoid aktivasyon fonksiyonu kullanılarak yapılan bu denemede, eğitim RMSE değeri düşüktür ancak test RMSE değeri yüksektir, bu da modelin aşırı uyuma eğilimli olduğunu gösterebilir. Ayrıca, diğer denemelere kıyasla daha uzun süre alır.

Deneme 2: 85 gizli katman nöronu ve sigmoid aktivasyon fonksiyonu kullanılarak yapılan bu denemede, eğitim ve test RMSE değerleri yüksektir. Modelin aşırı uyuma eğilimli olduğunu ve daha iyi bir genelleme yeteneği olmadığını gösterebilir.

Deneme 3: 85 gizli katman nöronu ve sigmoid aktivasyon fonksiyonu kullanılarak yapılan bu denemede, test RMSE değeri diğer denemelere göre daha yüksektir. Bu da modelin daha az karmaşık olması gerektiğini ve belirli bir veriye aşırı uyum riski taşıdığını gösterebilir.

Deneme 4: 110 gizli katman nöronu ve sigmoid aktivasyon fonksiyonu kullanılarak yapılan bu denemede, eğitim RMSE değeri düşük ancak test RMSE değeri yüksektir. Bu da modelin aşırı uyuma eğilimli olduğunu ve daha az karmaşık olması gerektiğini gösterebilir.

Deneme 5: 130 gizli katman nöronu ve sigmoid aktivasyon fonksiyonu kullanılarak yapılan bu denemede, eğitim ve test RMSE değerleri yüksektir. Modelin aşırı uyuma eğilimli olduğunu ve daha iyi bir genelleme yeteneği olmadığını gösterebilir.

Deneme 6: 20 gizli katman nöronu ve sinüs aktivasyon fonksiyonu kullanılarak yapılan bu denemede, eğitim ve test RMSE değerleri yüksektir. Daha az karmaşık bir modelin daha iyi bir genelleme yeteneğine sahip olabileceğini gösterir.

Deneme 7: 65 gizli katman nöronu ve sigmoid aktivasyon fonksiyonu kullanılarak yapılan bu denemede, eğitim RMSE değeri düşük ancak test RMSE değeri yüksektir. Modelin aşırı uyuma eğilimli olduğunu gösterebilir.

Bu analiz, modelin hiperparametrelerinin dikkatlice ayarlanması gerektiğini ve aşırı uyuma karşı duyarlı olunması gerektiğini vurgular. Ayrıca, daha az karmaşık modellerin genellikle daha iyi bir genelleme yeteneğine sahip olduğunu gösterir.

4.1.9. Tüm denemeler toplam net sonuçları

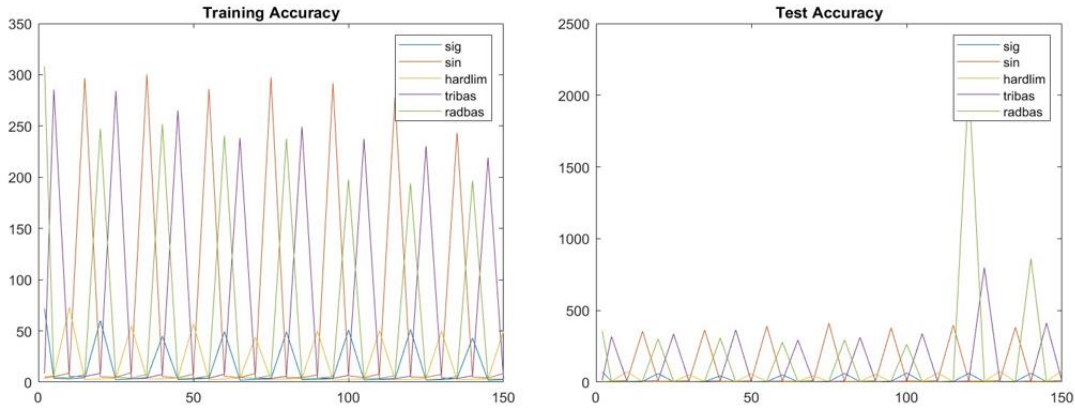
Tüm denemeler toplam net kategorisi için yapılan analizlerin sonuçları aşağıdaki gibidir:

Eğitim RMSE: 1,8679

Test RMSE: 2,1789

Süre: 7,6

Tüm denemeler toplam net kategorisinde, eğitim sürecinde elde edilen RMSE değeri 1,8679 iken test sürecinde bu değer 2,1789 olarak belirlenmiştir. Modelin tüm denemeler toplam net tahminlerindeki başarısı detaylı bir şekilde incelenmiş ve bu kategorideki eğitim sürecinin ortalama süresi 7,6 saniye olarak gözlemlenmiştir. Bu sonuçlar, tüm denemeler toplam net tahmininin, modelin eğitim setine kıyasla test setinde de güçlü olduğunu göstermektedir. Elde edilen sonuçlar Şekil 9’da gösterilmiştir.



Şekil 4.7. Tüm Denemeler Tahmin Sonuçları

Bu bulgular, tüm denemeler toplam net kategorisindeki öğrenci başarısını tahmin etmek için kullanılan modelin güvenilirliğini ve etkinliğini vurgulamaktadır. Eğitim ve test setlerinde benzer RMSE değerlerinin elde edilmesi, modelin yeni verilere iyi uyum sağladığını ve genel olarak stabil bir performans sergilediğini gösterir. Bu sonuçlar, tüm denemeler toplam net tahminlerinin, genel öğrenci başarısını değerlendirmede güçlü bir araç olabileceğini göstermektedir.

Tüm denemeler toplam net kategorisi için en iyi sonuçları veren hiperparametreler şu şekildedir:

Gizli Katman Nöron Sayısı: 65

Aktivasyon Fonksiyonu: sig (sigmoid)

Eğitim RMSE: 1,8679

Test RMSE: 2,1789

Bu hiperparametrelerin belirlenmesi, modelin Deneme Toplam kategorisindeki başarısını maksimize etmek için önemlidir. Gizli katman nöron sayısının ve aktivasyon fonksiyonunun seçimi, modelin karmaşıklığı ve esnekliği üzerinde önemli bir etkiye sahiptir. Eğitim ve test RMSE değerlerinin karşılaştırılması, modelin test setindeki performansının eğitim setindeki performansına göre daha düşük olduğunu göstermektedir. Bu durum, modelin eğitim verilerine daha iyi uyum sağladığı ve

genelleme yeteneğinin test verilerinde düşük olduğunu gösterebilir. Bu sonuçlar, modelin daha iyi genelleme yeteneği için hiperparametrelerin dikkatlice ayarlanması gerektiğini vurgular.

4.1.10. Tüm denemeler toplam puan sonuçları


Tüm deneme puanları kategorisi için yapılan analizlerin sonuçları aşağıdaki gibidir:

Eğitim RMSE: 1,7334

Test RMSE: 2,0276

Süre: 8,21

Tüm deneme puanları kategorisinde, eğitim sürecinde elde edilen RMSE değeri 1,7334 iken test sürecinde bu değer 2,0276 olarak belirlenmiştir. Modelin tüm deneme puanları tahminlerindeki performansı detaylı bir şekilde incelenmiş ve bu kategorideki eğitim sürecinin ortalama süresi 8,21 saniye olarak gözlemlenmiştir. Tüm deneme puanları tahminleri, eğitim ve test setlerinde benzer bir başarı göstermektedir. Elde edilen sonuçlar Şekil 10'da gösterilmiştir.



Şekil 4.8. Tüm Denemeler Tahmin Sonuçları

Bu sonuçlar, tüm deneme puanları kategorisindeki öğrenci başarısını tahmin etmek için kullanılan modelin güvenilirliğini ve etkinliğini vurgulamaktadır. Eğitim ve test setlerinde benzer RMSE değerlerinin elde edilmesi, modelin yeni verilere iyi uyum sağladığını ve genel olarak stabil bir performans sergilediğini gösterir. Bu sonuçlar, tüm deneme puanları tahminlerinin, öğrenci başarısını değerlendirmede güçlü bir araç olabileceğini göstermektedir.

Tüm deneme puanları kategorisinde en iyi sonuçları veren hiperparametreler şu şekildedir:

Gizli Katman Nöron Sayısı: 85

Aktivasyon Fonksiyonu: sig (sigmoid)

Eğitim RMSE: 1,7334

Test RMSE: 2,0276

Bu hiperparametrelerin belirlenmesi, modelin Tüm deneme puanları kategorisindeki başarısını maksimize etmek için önemlidir. Gizli katman nöron sayısının ve aktivasyon fonksiyonunun seçimi, modelin karmaşıklığı ve esnekliği üzerinde önemli bir etkiye sahiptir. Eğitim ve test RMSE değerlerinin karşılaştırılması, modelin test setindeki performansının eğitim setindeki performansına göre daha düşük olduğunu göstermektedir. Bu durum, modelin eğitim verilerine daha iyi uyum sağladığı ve genelleme yeteneğinin test verilerinde düşük olduğunu gösterebilir. Bu sonuçlar, modelin daha iyi genelleme yeteneği için hiperparametrelerin dikkatlice ayarlanması gerektiğini vurgular.

4.2. Tartışma

Bu tez çalışması, öğrenci başarısını tahmin etmek için eğitilen yapay sinir ağlarının performansını geniş bir perspektiften inceledi. Çeşitli ders kategorileri üzerinde gerçekleştirilen analizler, yapay sinir ağlarının öğrenci başarısını tahmin etme kabiliyetini değerlendirmek için önemli bir ışık tuttu. Türkçe, İnkılap Tarihi ve Atatürkçülük, Din Kültürü ve Ahlak Bilgisi, İngilizce, Matematik ve Fen Bilimleri gibi ders kategorileri için yapılan detaylı değerlendirmeler, modelin genel performansını, genelleme yeteneğini ve hiperparametrelerin belirlenmesinin model performansı üzerindeki etkisini ortaya koydu.

Türkçe dersi için yapılan analizler, eğitim ve test setlerinde benzer başarılar elde edildiğini gösterdi. Modelin Türkçe dersi için yüksek doğruluk oranları sergilemesi, genelleme yeteneğinin güçlü olduğunu göstermektedir. İnkılap Tarihi ve Atatürkçülük dersi için elde edilen sonuçlar da benzer bir başarıyı yansıttı ve modelin güvenilirliği vurgulandı. Din Kültürü ve Ahlak Bilgisi dersi için de benzer bir performans elde edildi ve modelin genel stabilitesi gösterildi.

Ancak, İngilizce dersi için yapılan analizlerde modelin genelleme yeteneğinin diğerlerine göre düşük olduğu gözlemlendi. Model, eğitim verilerine aşırı uyum sağladığı için test verilerinde beklenen performansı gösteremedi. İngilizce dersinde modelin başarısız olmasının birkaç nedeni olabilir. İlk olarak, dil becerilerini ölçmek karmaşıktır çünkü dilin doğası sürekli değişmektedir ve öğrencilerin dil becerileri kişisel deneyimlerine ve dilin kullanıldığı ortama bağlı olarak farklılık gösterebilir. Bu nedenle,

modelin eğitim verilerindeki dil örüntülerini öğrenmesi, gerçek dünya uygulamalarında karşılaşılan farklı dil kullanımlarını tam olarak kavramasını engelleyebilir. Ayrıca, İngilizce dilinin karmaşıklığı ve çeşitliliği nedeniyle, modelin tüm bu farklı yapıları ve dil özelliklerini kapsayacak kadar geniş bir veri kümesine erişimi olmayabilir. Bu durum, modelin belirli dil örüntülerini doğru bir şekilde öğrenememesine ve bu nedenle genelleme yeteneğinin diğer derslere göre düşük olmasına yol açabilir.

Benzer şekilde, matematik ve fen bilimleri derslerinde de modelin aşırı uyuma eğilimli olduğu ve genelleme yeteneğinin diğer derslere göre düşük olduğu tespit edildi. Matematik ve fen bilimleri, soyut düşünme ve problem çözme becerileri gerektiren disiplinlerdir. Modelin bu konuları anlaması ve genelleme yapabilmesi için kapsamlı bir öğrenme gereklidir. Ancak, modelin yalnızca belirli bir veri kümesine dayalı olarak eğitilmesi, gerçek hayatta karşılaşılan farklı matematiksel ve fen bilimleri problemlerini çözmek için gerekli olan geniş bir bilgi yelpazesini kapsayamayabilir. Bu da modelin, eğitim verilerinde gördüğü örüntülere sıkı sıkıya bağlı kalmasına ve yeni ve farklı sorunlara uyum sağlayamamasına neden olabilir. Dolayısıyla, matematik ve fen bilimleri derslerinde modelin istenilen oranda başarıyı sağlamamasının temel nedeni, genellikle bu konuların doğası gereği karmaşıklığı ve modelin bu karmaşıklığı tam olarak kavrayamamasıdır. Bu nedenle, modelin daha iyi genelleme yeteneği için, dil, matematik ve fen bilimleri gibi farklı derslerde daha çeşitli ve temsili veri kümeleriyle eğitilmesi ve hiperparametrelerin dikkatlice ayarlanması gerekebilir.

Deneme sonuçları incelendiğinde, farklı hiperparametrelerin ve aktivasyon fonksiyonlarının modelin performansını önemli ölçüde etkilediği görüldü. Daha az karmaşık modellerin genellikle daha iyi genelleme yeteneğine sahip olduğu belirlendi. Ancak, bu durumun her zaman garantili olmadığı ve modelin aşırı uyuma karşı duyarlı olması gerektiği vurgulandı.

Genel olarak, bu çalışma yapay sinir ağlarının öğrenci başarısını tahmin etmede değerli bir araç olduğunu göstermiştir. Ancak, modelin performansını iyileştirmek için hiperparametrelerin dikkatlice ayarlanması ve modelin sürekli olarak değerlendirilmesi gerekmektedir. Gelecekte, daha büyük veri setleri ve daha karmaşık modellerle yapılan çalışmaların yapay sinir ağlarının öğrenci başarısını tahmin etmedeki etkinliğini artırabileceği düşünülmektedir. Bu çalışmanın sonuçları, eğitimde yapay zeka teknolojilerinin potansiyelini anlamak ve öğrenci başarısını iyileştirmek için yeni yaklaşımlar geliştirmek isteyen araştırmacılar için önemli bir temel oluşturabilir.

5. ÖNERİLER

Bu çalışmadan elde edilen bulgulara dayanarak, yapay sinir ağlarını kullanarak öğrenci başarısını tahmin etmek isteyen araştırmacılar ve eğitim kurumları için çeşitli öneriler sunulabilir:

Veri Kalitesinin İyileştirilmesi: Veri kalitesi, her türlü tahmin modelinin temelidir ve yapay sinir ağları için de geçerlidir. Bu nedenle, öncelikle kullanılan veri setlerinin kalitesini artırmak önemlidir. Veri setlerinin toplanması sırasında, veri girişlerinin doğruluğunu ve tutarlılığını sağlamak için titizlikle çalışılmalıdır. Örneğin, öğrenci notları, devamsızlık kayıtları, öğretmen yorumları gibi çeşitli veri kaynaklarından bilgi toplanabilir ve analiz edilebilir. Ayrıca, veri setlerindeki eksik değerlerin ve aykırı verilerin ele alınması gerekmektedir.

Daha Büyük ve Çeşitli Veri Setlerinin Kullanılması: Yapay sinir ağlarının genelleme yeteneği, kullanılan veri setinin boyutu ve çeşitliliği ile yakından ilişkilidir. Bu nedenle, farklı coğrafi bölgelerden, farklı demografik özelliklere sahip öğrencilerden ve farklı eğitim kurumlarından elde edilen veri setlerinin kullanılması önerilir. Örneğin, bir yapay sinir ağı modeli, hem kentsel hem de kırsal bölgelerden gelen öğrencilerin başarısını tahmin etme yeteneğine sahip olmalıdır. Ayrıca, farklı yaş gruplarından ve eğitim seviyelerinden öğrencileri içeren veri setleri, modelin genellebilirliğini artırabilir.

Modelin Hiperparametrelerinin Ayarlanması: Yapay sinir ağları gibi karmaşık modellerin performansı, kullanılan hiperparametrelerin doğru bir şekilde ayarlanmasına bağlıdır. Bu nedenle, modelin performansını optimize etmek için hiperparametrelerin dikkatlice ayarlanması gerekmektedir. Örneğin, sinir ağı modelinin katman sayısı, her katmandaki nöron sayısı, öğrenme oranı ve toplu boyut gibi hiperparametreler, modelin performansını önemli ölçüde etkileyebilir. Grid arama veya rastgele arama gibi teknikler kullanılarak en iyi hiperparametre kombinasyonunun bulunması önerilir.

Modelin Sürekli İyileştirilmesi: Bir model geliştirildikten sonra, performansını sürekli olarak iyileştirmek önemlidir. Bu, geri bildirim döngüsü aracılığıyla gerçekleştirilebilir. Modelin tahminlerinin gerçek dünya performansıyla karşılaştırılması ve uygun düzeltici önlemlerin alınması gerekmektedir. Ayrıca, yeni veri setleriyle modelin periyodik olarak yeniden eğitilmesi ve güncellenmesi de önerilir. Örneğin, her

akademik dönem sonunda elde edilen yeni veriler, modelin güncellenmesi için kullanılabilir.

İşbirliği ve Bilgi Paylaşımı: Benzer çalışmaları yürüten araştırmacılar arasında işbirliği ve bilgi paylaşımı, algoritmaların ve yöntemlerin geliştirilmesine yardımcı olabilir. Deneyimlerin ve bulguların paylaşılması, alandaki ilerlemeyi hızlandırabilir ve yapay zeka tabanlı eğitim sistemlerinin etkinliğini artırabilir. Örneğin, bir araştırma grubunun elde ettiği başarılar ve başarısızlıklar, diğer araştırmacılar tarafından dikkate alınarak benzer çalışmalar için faydalı bir yol haritası oluşturabilir.

Etik ve Gizlilik Konularının Dikkate Alınması: Öğrenci başarısını tahmin etmek için kullanılan yapay zeka sistemlerinin etik ve gizlilik konuları göz önünde bulundurulmalıdır. Veri gizliliği, öğrencilerin kişisel bilgilerinin korunması ve güvenliği için son derece önemlidir. Ayrıca, algoritmaların adalet ve çeşitlilik ilkelerine uygunluğu da sağlanmalıdır. Örneğin, bir modelin sadece belirli demografik gruplara karşı önyargılı olmaması ve tüm öğrenciler için adil tahminler yapabilmesi önemlidir.

Bu öneriler, yapay sinir ağlarını kullanarak öğrenci başarısını tahmin etme amacıyla olan araştırmacılar ve eğitim kurumları için önemli bir rehberlik sunabilir. Yapay zeka tabanlı eğitim sistemlerinin geliştirilmesine katkıda bulunabilecekleri için bu önerilerin detaylı bir şekilde incelenmesi oldukça değerlidir. Öncelikle, yapay sinir ağlarının öğrenci başarısını tahmin etmede kullanılmasının sağladığı avantajlar üzerinde durulmalıdır. Bu teknoloji, büyük veri kümelerini işleyebilme yeteneği sayesinde öğrencilerin akademik performanslarını etkileyen faktörleri daha iyi anlamamıza olanak tanır. Örneğin, öğrencinin geçmiş ders performansı, katılım düzeyi, sınav sonuçları ve ödev teslimleri gibi çeşitli verilerin analizi, yapay sinir ağlarının öğrenci başarısını tahmin etmedeki etkinliğini artırır. Ayrıca, yapay sinir ağlarının kullanımıyla ilgili pratik rehberlik sağlar. Araştırmacılar ve eğitim kurumları, doğru veri toplama ve işleme yöntemlerini belirleyerek başarılı bir model oluşturabilirler. Modelin doğruluğunu artırmak için yapay sinir ağlarının mimarisini optimize etme ve eğitim sürecini iyileştirme konularında yönergeler sunar.

Öneriler aynı zamanda etik ve güvenilirlik konularına da odaklanmalıdır. Yapay zeka tabanlı sistemlerin kullanımıyla ilgili etik sorunlar göz önünde bulundurulmalı ve öğrenci verilerinin gizliliği ve güvenliği sağlanmalıdır. Bununla birlikte, modelin güvenilirliğini artırmak için yapılan tahminlerin doğrulanması ve sınanması için yöntemler geliştirilmelidir.

Sonuç olarak, yapay zeka tabanlı eğitim sistemlerinin geliştirilmesine yönelik gelecekteki çalışmalara öneriler sunulmalıdır. Bu öneriler, yapay sinir ağlarının daha karmaşık öğrenme modelleri üzerinde nasıl uygulanabileceğini, farklı öğrenme ortamlarında nasıl adapte edilebileceğini ve öğretmenlerin ve öğrencilerin eğitim sürecine nasıl entegre edilebileceğini araştırabilir. Tüm bu öneriler, yapay sinir ağlarını kullanarak öğrenci başarısını tahmin etmek isteyen araştırmacılar ve eğitim kurumları için kapsamlı bir rehberlik sunar. Bu rehberlik, yapay zeka tabanlı eğitim sistemlerinin daha etkili ve güvenilir bir şekilde geliştirilmesine katkıda bulunabilir.



KAYNAKLAR

- Abiodun, O. I., Jantan, A., Omolara, A. E., Dada, K. V., Mohamed, N. A., & Arshad, H. (2018). State-of-the-art in artificial neural network applications: A survey. *Heliyon*, 4(11).
- Abraham, A. (2005). Artificial neural networks. *Handbook of measuring system design*.
- Agatonovic-Kustrin, S., & Beresford, R. (2000). Basic concepts of artificial neural network (ANN) modeling and its application in pharmaceutical research. *Journal of pharmaceutical and biomedical analysis*, 22(5), 717-727.
- Akgün, E., & Demir, M. (2018). Modeling course achievements of elementary education teacher candidates with artificial neural networks. *International Journal of Assessment Tools in Education*, 5(3), 491-509.
- Akıl, M. F., & Ertuğrul, Ö. F. (2023). One-dimensional convolutional neural network-based identification of sleep disorders using electroencephalogram signals. In *Diagnostic Biomedical Signal and Image Processing Applications with Deep Learning Methods* (pp. 41-59). Academic Press.
- Almeida, L. B. (2020). Multilayer perceptrons. In *Handbook of Neural Computation* (pp. C1-2). CRC Press.
- Andonie, R. (2019). Hyperparameter optimization in learning systems. *Journal of Membrane Computing*, 1(4), 279-291.
- Aslantaş, H. İ., Özkan, M. ve Külekçi, E. (2012). Eğitim fakültesi öğrencilerinin akademik başarı düzeylerinin bazı demografik değişkenler açısından incelenmesi. *Elektronik Sosyal Bilimler Dergisi*. 11(39), 395-407.
- Aybek, H. S. Y. (2016). Öğrenci başarısının yapay sinir ağları ile kestirilmesi: Anadolu Üniversitesi Açıköğretim Sistemi örneği. Anadolu Üniversitesi. Yayınlanmamış yüksek lisans tezi.
- Aybek, H. S. Y. (2018). Öğrenci başarısının yapay sinir ağları ile kestirilmesi: Anadolu Üniversitesi Açıköğretim Sistemi örneği (Doctoral dissertation, Anadolu University (Turkey)).
- Azgomi, H., Haredasht, F. R., & Motlagh, M. R. S. (2023). Diagnosis of some apple fruit diseases by using image processing and artificial neural network. *Food Control*, 145, 109484.
- Baashar, Y., Alkawsı, G., Mustafa, A., Alkahtani, A. A., Alsariera, Y. A., Ali, A. Q., & Tiong, S. K. (2022). Toward predicting student's academic performance using artificial neural networks (ANNs). *Applied Sciences*, 12(3), 1289.

- Basu, J. K., Bhattacharyya, D., & Kim, T. H. (2010). Use of artificial neural network in pattern recognition. *International journal of software engineering and its applications*, 4(2).
- Batool, S., Rashid, J., Nisar, M. W., Kim, J., Kwon, H. Y., & Hussain, A. (2023). Educational data mining to predict students' academic performance: A survey study. *Education and Information Technologies*, 28(1), 905-971.
- Brenes, R. F., Johannssen, A., & Chukhrova, N. (2022). An intelligent bankruptcy prediction model using a multilayer perceptron. *Intelligent Systems with Applications*, 16, 200136.
- Bucos, M., & Drăgulescu, B. (2018). Predicting student success using data generated in traditional educational environments. *TEM Journal*, 7(3), 617.
- Buraimoh, E., Ajoodha, R., & Padayachee, K. (2021, April). Application of machine learning techniques to the prediction of student success. In 2021 IEEE International IOT, Electronics and Mechatronics Conference (IEMTRONICS) (pp. 1-6). IEEE.
- Castellani, M. (2018). Competitive co-evolution of multi-layer perceptron classifiers. *Soft Computing*, 22(10), 3417-3432.
- Chai, T., & Draxler, R. R. (2014). Root mean square error (RMSE) or mean absolute error (MAE)?—Arguments against avoiding RMSE in the literature. *Geoscientific model development*, 7(3), 1247-1250.
- Chen, Y., & Zhai, L. (2023). A comparative study on student performance prediction using machine learning. *Education and Information Technologies*, 1-19.
- Ciolacu, M., Tehrani, A. F., Binder, L., & Svasta, P. M. (2018, October). Education 4.0-Artificial Intelligence assisted higher education: early recognition system with machine learning to support students' success. In 2018 IEEE 24th International Symposium for Design and Technology in Electronic Packaging (SIITME) (pp. 23-30). IEEE.
- Çakmak, Z., & Yiğen, V. (2023). Liselere Giriş Sınavına sosyal bilgiler öğretmenlerinin görüşleri doğrultusunda bakış: TC İnkılâp Tarihi ve Atatürkçülük Dersi örneği. *Journal of Innovative Research in Social Studies*, 6(1), 19-36.
- Çırak, G. (2012). Yüksek öğretimde öğrenci başarılarının sınıflandırılmasında yapay sinir ağları ve lojistik regresyon yöntemlerinin kullanılması. Ankara Üniversitesi. Yayınlanmış yüksek lisans tezi.
- Deperlioglu, O., & Kose, U. (2011). An educational tool for artificial neural networks. *Computers & Electrical Engineering*, 37(3), 392-402.
- Dilekçi, A., Karatay, H., & Koçyiğit, S. Türkçe Öğretmenlerinin Liselere Geçiş Sistemi'ne İlişkin Görüşleri. *Uludağ Üniversitesi Eğitim Fakültesi Dergisi*, 36(2), 1-16.

- Dongare, A. D., Kharde, R. R., & Kachare, A. D. (2012). Introduction to artificial neural network. *International Journal of Engineering and Innovative Technology (IJEIT)*, 2(1), 189-194.
- Feurer, M., & Hutter, F. (2019). Hyperparameter optimization. *Automated machine learning: Methods, systems, challenges*, 3-33.
- Gershenson, C. (2003). Artificial neural networks for beginners. arXiv preprint cs/0308031.
- Goldberg, Y. (2022). *Neural network methods for natural language processing*. Springer Nature.
- Görgüt, R. Ç., & Dönmez, S. M. K. Liselere Geçiş Sınavı Matematik Sorularının Matematiksel Anlamayı Değerlendirme Açısından İncelenmesi. *Educational Academic Research*, (50), 28-46
- Güngör, B. A., & Saraçoğlu, S. Liselere Geçiş Sistemi (LGS) Fen Bilimleri Sorularının Bağlam Temelli Öğrenme Yaklaşımı Açısından Değerlendirilmesi. *SDU International Journal of Educational Studies*, 10(2), 22-46.
- Güven, S., & Akdağ, H. (2023). Ortaokul Sosyal Bilgiler ve TC İnkılap Tarihi Ve Atatürkçülük Dersinin LGS (Liselere Geçiş Sistemi)'de Etkisinin Öğretmen Görüşlerine Göre İncelenmesi.
- Hassoun, M. H. (1995). *Fundamentals of artificial neural networks*. MIT press.
- Hastie, T., Tibshirani, R., Friedman, J. H., & Friedman, J. H. (2009). *The elements of statistical learning: data mining, inference, and prediction (Vol. 2, pp. 1-758)*. New York: springer.
- Hodson, T. O. (2022). Root mean square error (RMSE) or mean absolute error (MAE): When to use them or not. *Geoscientific Model Development Discussions*, 2022, 1-10.
- Huang, C., Zhou, J., Chen, J., Yang, J., Clawson, K., & Peng, Y. (2023). A feature weighted support vector machine and artificial neural network algorithm for academic course performance prediction. *Neural Computing and Applications*, 35(16), 11517-11529.
- Ibragim, S., Akhat, B., Dinara, M., Anastasiya, G., Mariya, K., & Grigoriy, M. (2020). Example of the use of artificial neural network in the educational process. In *Advances in Information and Communication: Proceedings of the 2020 Future of Information and Communication Conference (FICC)*, Volume 1 (pp. 420-430). Springer International Publishing.
- Ismail, M. R., Awang, M. K., Rahman, M. N. A., & Makhtar, M. (2015). A multi-layer perceptron approach for customer churn prediction. *International Journal of Multimedia and Ubiquitous Engineering*, 10(7), 213-222.

- Jain, A. K., Mao, J., & Mohiuddin, K. M. (1996). Artificial neural networks: A tutorial. *Computer*, 29(3), 31-44.
- Kayalı, S., & Savaş, S. Zaman Serisi Analizi Yoluyla Deneme Sınavları Üzerinden Ortaokul Öğrencilerinin LGS Başarısının Tahmini.
- Khan, J., Lee, E., & Kim, K. (2023). A higher prediction accuracy–based alpha–beta filter algorithm using the feedforward artificial neural network. *CAAI Transactions on Intelligence Technology*, 8(4), 1124-1139.
- Krenker, A., Bešter, J., & Kos, A. (2011). Introduction to the artificial neural networks. *Artificial Neural Networks: Methodological Advances and Biomedical Applications*. InTech, 1-18.
- Krogh, A. (2008). What are artificial neural networks?. *Nature biotechnology*, 26(2), 195-197.
- Kruse, R., Mostaghim, S., Borgelt, C., Braune, C., & Steinbrecher, M. (2022). Multi-layer perceptrons. In *Computational intelligence: a methodological introduction* (pp. 53-124). Cham: Springer International Publishing.
- Lau, E. T., Sun, L., & Yang, Q. (2019). Modelling, prediction and classification of student academic performance using artificial neural networks. *SN Applied Sciences*, 1, 1-10.
- LaValle, S. M., Branicky, M. S., & Lindemann, S. R. (2004). On the relationship between classical grid search and probabilistic roadmaps. *The International Journal of Robotics Research*, 23(7-8), 673-692.
- Liashchynskiy, P., & Liashchynskiy, P. (2019). Grid search, random search, genetic algorithm: a big comparison for NAS. arXiv preprint arXiv:1912.06059.
- Li, Y., & Ma, W. (2010, October). Applications of artificial neural networks in financial economics: a survey. In *2010 International symposium on computational intelligence and design* (Vol. 1, pp. 211-214). IEEE.
- Lubis, D. H., Sawaluddin, S., & Candra, A. (2023). Machine Learning Model for Language Classification: Bag-of-words and Multilayer Perceptron. *JOURNAL OF INFORMATICS AND TELECOMMUNICATION ENGINEERING*, 7(1), 356-365.
- Ma, Q. (2002, December). Natural language processing with neural networks. In *Language engineering conference, 2002. proceedings* (pp. 45-56). IEEE.
- Mahapatra, S. S., & Khan, M. S. (2007). A neural network approach for assessing quality in technical education: an empirical study. *International Journal of Productivity and Quality Management*, 2(3), 287-306.

- Maind, S. B., & Wankar, P. (2014). Research paper on basic of artificial neural network. *International Journal on Recent and Innovation Trends in Computing and Communication*, 2(1), 96-100.
- Mehrotra, K., Mohan, C. K., & Ranka, S. (1997). *Elements of artificial neural networks*. MIT press.
- Musso, M.F., Kyndt, E., Cascallar, E.C. & Dochy F. (2013). Predicting general academic performance and identifying the differential contribution of participating variables using artificial neural Networks. *Frontline Learning Research*. 1, 42-71.
- Naik, B. & Ragothaman, S. (2004). Using neural networks to predict MBA student success. *College Student Journal*. 38(1).
- Namdari, A., & Li, Z. S. (2018, June). Integrating fundamental and technical analysis of stock market through multi-layer perceptron. In 2018 IEEE technology and engineering management conference (TEMSCON) (pp. 1-6). IEEE.
- Naser, S. A., Zaqout, I., Ghosh, M. A., Atallah, R., & Alajrami, E. (2015). Predicting student performance using artificial neural network: In the faculty of engineering and information technology. *International journal of hybrid information technology*, 8(2), 221-228.
- Oancea, B., Dragoescu, R., & Ciucu, S. (2013). Predicting students' results in higher education using a neural network.
- Obsie, E. Y., & Adem, S. A. (2018). Prediction of student academic performance using neural network, linear regression and support vector regression: a case study. *International Journal of Computer Applications*, 180(40), 39-47.
- Oğuz, A., & Ertuğrul, Ö. F. (2023). Determining the fullness of garbage containers by deep learning. *Expert Systems with Applications*, 217, 119544.
- Oğuz, A., & Ertuğrul, Ö. F. (2023). Introduction to deep learning and diagnosis in medicine. In *Diagnostic Biomedical Signal and Image Processing Applications with Deep Learning Methods* (pp. 1-40). Academic Press
- Okewu, E., Adewole, P., Misra, S., Maskeliunas, R., & Damasevicius, R. (2021). Artificial neural networks for educational data mining in higher education: A systematic literature review. *Applied Artificial Intelligence*, 35(13), 983-1021.
- Pallathadka, H., Wenda, A., Ramirez-Asís, E., Asís-López, M., Flores-Albornoz, J., & Phasinam, K. (2023). Classification and prediction of student performance data using various machine learning algorithms. *Materials today: proceedings*, 80, 3782-3785.
- Poyraz, K., & Ergün, M. (2023). Lise Giriş Sistemi Sınavları (LGS) Üzerine Bir Araştırma. *International Journal of Eurasia Social Sciences/Uluslararası Avrasya Sosyal Bilimler Dergisi*, 14(54).

- Priddy, K. L., & Keller, P. E. (2005). *Artificial neural networks: an introduction* (Vol. 68). SPIE press.
- Rahmani, B. & Aprilianto, H. (2014). Early model of student's graduation prediction based on neural network. *Telkomnika (Telecommunication Computing Electronics and Controls)*. 12(2), 465-474.
- Rana, A., Rawat, A. S., Bijalwan, A., & Bahuguna, H. (2018, August). Application of multi layer (perceptron) artificial neural network in the diagnosis system: a systematic review. In *2018 International conference on research in intelligent and computing in engineering (RICE)* (pp. 1-6). IEEE.
- Ranjeeth, S., Latchoumi, T. P., & Paul, P. V. (2021). Optimal stochastic gradient descent with multilayer perceptron based student's academic performance prediction model. *Recent Advances in Computer Science and Communications (Formerly: Recent Patents on Computer Science)*, 14(6), 1728-1741.
- Rodríguez-Hernández, C. F., Musso, M., Kyndt, E., & Cascallar, E. (2021). Artificial neural networks in academic performance prediction: Systematic implementation and predictor evaluation. *Computers and Education: Artificial Intelligence*, 2, 100018
- Safar, A. A., Salih, D. M., & Murshid, A. M. (2023). Pattern recognition using the multi-layer perceptron (MLP) for medical disease: A survey. *International Journal of Nonlinear Analysis and Applications*, 14(1), 1989-1998.
- Shanmuganathan, S. (2016). *Artificial neural network modelling: An introduction* (pp. 1-14). Springer International Publishing.
- Sinitsyn, E., Tolmachev, A., Larionova, V., & Tolmachev, D. (2020). Success predicting for students of online courses using neural networks. In *INTED2020 Proceedings* (pp. 6547-6554). IATED.
- Sonawane, J. S., & Patil, D. R. (2014, February). Prediction of heart disease using multilayer perceptron neural network. In *International conference on information communication and embedded systems (ICICES2014)* (pp. 1-6). IEEE.
- Tekin, A. (2014). Early prediction of students' grade point averages at graduation: A data mining approach. *Eurasian Journal of Educational Research*. 54, 207-226.
- Tepehan, T. (2011). PISA başarılarının yordanmasında yapay sinir ağı ve lojistik regresyon modeli performanslarının karşılaştırılması. Hacettepe Üniversitesi. Yayınlanmış doktora tezi.
- Toprak, E. (2017). Yapay sinir ağı, karar ağaçları ve ayırma analizi ile PISA 2012 matematik başarılarının sınıflandırma performanslarının karşılaştırılması. Hacettepe Üniversitesi. Yayınlanmamış doktora tezi.

- Triansyah, F. A., Muhammad, I., Rabuandika, A., Pratiwi, K. D., Teapon, N., & Assabana, M. S. (2023). Bibliometric Analysis: Artificial Intelligence (AI) in High School Education. *Jurnal Imiah Pendidikan Dan Pembelajaran*, 7(1), 112-123.
- Uhrig, R. E. (1995, November). Introduction to artificial neural networks. In *Proceedings of IECON'95-21st Annual Conference on IEEE Industrial Electronics* (Vol. 1, pp. 33-37). IEEE.
- Umar, M. A. (2019). Student academic performance prediction using artificial neural networks: A case study. *International Journal of Computer Applications*, 975, 8887.
- Uzel, V. N., Turgut, S. S., & Özel, S. A. (2018, October). Prediction of students' academic success using data mining methods. In *2018 Innovations in Intelligent Systems and Applications Conference (ASYU)* (pp. 1-5). IEEE.
- Valko, N., & Osadchyi, V. (2020). Education individualization by means of artificial neural networks.
- Wang, S. C., & Wang, S. C. (2003). Artificial neural network. *Interdisciplinary computing in java programming*, 81-100.
- Willmott, C. J., & Matsuura, K. (2005). Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. *Climate research*, 30(1), 79-82.
- Wistuba, M., Schilling, N., & Schmidt-Thieme, L. (2015, October). Learning hyperparameter optimization initializations. In *2015 IEEE international conference on data science and advanced analytics (DSAA)* (pp. 1-10). IEEE.
- Yang, L., & Shami, A. (2020). On hyperparameter optimization of machine learning algorithms: Theory and practice. *Neurocomputing*, 415, 295-316.
- Yegnanarayana, B. (2009). *Artificial neural networks*. PHI Learning Pvt. Ltd
- Yıldız, M., & Börekci, C. (2020). Predicting academic achievement with machine learning algorithms. *Journal of educational technology and online learning*, 3(3), 372-392.
- Zacharis, N. Z. (2016). Predicting student academic performance in blended learning using artificial neural networks. *International Journal of Artificial Intelligence and Applications*, 7(5), 17-29.
- Zhang, Z., & Zhang, Z. (2018). Artificial neural network. *Multivariate time series analysis in climate and environmental research*, 1-35.
- Zou, J., Han, Y., & So, S. S. (2009). Overview of artificial neural networks. *Artificial neural networks: methods and applications*, 14-22.